

**KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**JEODEZİ VE JEOİFORMASYON MÜHENDİSLİĞİ
ANABİLİM DALI**

DOKTORA TEZİ

**UZAKTAN ALGILAMA GÖRÜNTÜLERİNDE
GEOİSTATİSTİKSEL YÖNTEMLER İLE DOKU ANALİZİ**

ÖZER AKYÜREK

KOCAELİ 2019

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

JEODEZİ VE JEOİFORMASYON MÜHENDİSLİĞİ
ANABİLİM DALI

DOKTORA TEZİ

UZAKTAN ALGILAMA GÖRÜNTÜLERİNDE
GEOİSTATİSTİKSEL YÖNTEMLER İLE DOKU ANALİZİ

ÖZER AKYÜREK

Doç. Dr. Ozan ARSLAN
Danışman, Kocaeli Üniversitesi

Prof. Dr. Melih İNAL

Jüri Üyesi, Kocaeli Üniversitesi

Doç. Dr. Taner ÜSTÜNTAŞ


Jüri Üyesi, Kocaeli Üniversitesi


Prof. Dr. Nebiye MUSAOĞLU

Jüri Üyesi, İstanbul Teknik Üniversitesi

Prof. Dr. Şinasi KAYA

Jüri Üyesi, İstanbul Teknik Üniversitesi


.....

.....

.....

.....

.....

Tezin Savunulduğu Tarih: 12.07.2019

ÖNSÖZ VE TEŞEKKÜR

“Uzaktan Algılama Görüntülerinde Konumsal Doku Analizi” başlıklı bu çalışmada, uzaktan algılama görüntülerinde bulunan doku özelliklerini en elverişli biçimde belirleyebilecek bir kriterin kullanımıyla, standart bir uzaktan algılama uygulamasının (sınıflandırma, obje tanıma, bölütleme vb.) performansını hangi ölçüde etkileyeceğini nicel olarak ortaya koyabilecek bir çerçeve oluşturulması amaçlanmıştır.

Doktora eğitimimin başından sonuna kadar değerli birikimlerini benimle paylaşan, tezimin her aşamasında sorunlarımı dinleyerek çalışmalarına yön veren, yoğun akademik yaşamında değerli zamanını her türlü problemimi çözmeye ayıran ve tez çalışması boyunca göstermiş olduğu sabır, destek, emek ve imkân için doktora tez danışmanım saygıdeğer hocam Doç. Dr. Ozan ARSLAN’a teşekkür ederim.

Ayrıca tez çalışmamda kullanmış olduğum Uzaktan Algılama görüntüsünü bana sağlayan İTÜ öğretim üyesi sayın Prof. Dr. Nebiye MUSAOĞLU’na en içten teşekkürlerimi sunarım.

Tez çalışmamın başından sonuna kadar maddi ve manevi desteklerini benden esirgemeyen çalışma arkadaşlarım Arş. Gör. Dr. Pakize Küreç NEHBİT’e, Arş. Gör. Dr. Erman ŞENTÜRK’e, Arş. Gör. Burcu ASLAN’a ve Arş. Gör. Sevda OLGUN’a teşekkür ederim.

Çalışmam sürecinde manevi desteğini, sabrını ve sevgisini hiç eksik etmeyen, bugünlere gelmemi sağlayan annem Şükran AKYÜREK’e ve bizi bu kadar erken bırakıp gitmiş olsa da beni gittiği yerden sürekli izlediğini bildiğim babam Yusuf AKYÜREK’e ve ablam Özlem AKYÜREK’e saygı, sevgi ve sonsuz teşekkürlerimi sunarım.

Temmuz – 2019

Özer AKYÜREK

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iv
TABLOLAR DİZİNİ	vii
SİMGELER VE KISALTMALAR DİZİNİ	ix
ÖZET.....	xi
ABSTRACT.....	xii
GİRİŞ	1
1. DOKU KAVRAM VE TANIMI.....	10
2. DOKU ANALİZ YÖNTEMLERİ.....	11
2.1. Yapısal Yöntemler.....	12
2.2. İstatistiksel Yöntemler.....	13
2.2.1. Otokorelasyon fonksiyonu	13
2.2.2. Histogram	13
2.2.3. Gri seviye eş-oluşum matrisi (GLCM).....	15
2.3. Model Tabanlı Yöntemler	17
2.4. Dönüşüm Tabanlı Yöntemler	17
2.4.1. Fourier dönüşümü	18
2.4.2. Wavelet (Dalgacık) dönüşümü	19
3. KONUMSAL DOKU ANALİZİ.....	22
3.1. Mekansal İstatistik.....	22
3.1.1. Ortalama merkez	23
3.1.2. Ağırlıklandırılmış ortalama merkez	24
3.1.3. Medyan merkez	24
3.1.4. En kısa yol merkezi	25
3.1.5. Standart uzaklık.....	25
3.1.6. Standart sapma elipsi.....	25
3.1.7. Kuadrat analizi	26
3.1.8. En yakın komşuluk analizi	26
3.1.9. Ripley K fonksiyonu	27
3.2. Geoistatistik Analiz	28
3.3. Konumsal Örüntü Analizi	34
3.3.1. Konumsal otokorelasyon global ölçütleri	35
3.3.1.1 Genel Moran's I indeksi	35
3.3.2. Konumsal otokorelasyon yerel ölçütleri.....	36
3.3.2.1. Getis-Ord G* istatistiği	36
3.3.2.2. Anselin yerel Moran's I istatistiği	37
3.3.3. Mekansal regresyon modelleme.....	38
3.3.3.1. Genel en küçük kareler regresyonu (OLS).....	39
3.3.3.2. Konumsal Otokorelasyon modeli (SAR).....	40
3.3.3.3. Coğrafi ağırlıklandırılmış regresyon (GWR).....	40
3.4. Benzerlik Ölçütleri ve Doku İlişkisinin İrdelenmesi.....	42
3.4.1. Benzerlik ölçütü yöntemleri	43

3.4.1.1. Öklid mesafesi	44
3.4.1.2. Chebyshev mesafesi	44
3.4.1.3. City Block (Manhattan) mesafesi	44
3.4.1.4. Minkowski mesafesi	45
3.4.1.5. Chi-Kare (χ^2) mesafesi	45
3.4.1.6. Kullback-Leibler mesafesi	45
3.4.1.7. Jeffrey (Divergence) mesafesi	45
3.4.1.8. Kolmogorov-Smirnov mesafesi (Divergence)	45
3.4.1.9. Bray-Curtis (Sorensen) mesafesi	46
3.4.1.10. Kosinüs mesafesi	46
3.4.1.11. Korelasyon katsayısı mesafesi	46
3.4.1.12. Dice mesafesi	46
3.4.1.13. Bhattacharyya mesafesi	47
3.4.1.14. Fidelity mesafesi	47
3.4.1.15. Gower mesafesi	47
3.4.1.16. Soergel mesafesi	47
3.4.1.17. Jaccard mesafesi	47
3.4.1.18. Tanimoto mesafesi	48
3.4.1.19. Matusita mesafesi	48
3.4.1.20. Topsoe mesafesi	48
3.4.1.21. Jensen-Shannon mesafesi	48
4. UYGULAMA	49
4.1. Tarımsal Alan Uygulaması	53
4.1.1 Veri seti	53
4.1.2. Konumsal bağımlılık derecelerinin belirlenmesi	53
4.1.3. Sınıflandırma	55
4.2. Kentsel Alan Uygulaması	61
4.2.1. Veri seti	61
4.2.2. Benzerlik ölçütlerinin belirlenmesi	62
4.2.3. Standart doku ölçütleri	75
4.2.4. Konumsal örüntü analizi	80
4.2.5. Semivaryans parametrelerinin belirlenmesi	80
4.2.5.1. Konumsal bağımlılığın derecelendirilmesi	83
4.2.5.2. Spektral ve konumsal bilginin birleştirilmesi	86
4.2.6. Otoregresif model (AR)	87
4.2.7. Sınıflandırma işlemi	94
4.2.7.1. Maximum Likelihood yöntemi	100
4.2.7.2. Support Vector Machines (SVM) yöntemi	112
4.2.7.3. Neural Network (Yapay Sinir Ağı, YSA) yöntemi	126
5. SONUÇLAR VE ÖNERİLER	139
KAYNAKLAR	146
KİŞİSEL YAYIN VE ESERLER	171
ÖZGEÇMİŞ	172

ŞEKİLLER DİZİNİ

Şekil 2.1.	Doku analizi yöntemleri.....	12
Şekil 2.2.	Gri seviye eş-oluşum matrisinin oluşturulması	15
Şekil 2.3.	Eş oluşum matrisi oluşumunda yön bilgileri	16
Şekil 2.4.	İki ve üç seviyeli dalgacık dönüşümü örnekleri	19
Şekil 3.1.	Mekansal dağılımın gösterimi	28
Şekil 3.2.	Semivariogram parametreleri	31
Şekil 4.1.	İş akış şeması	52
Şekil 4.2.	Veri seti olarak tarım arazilerini içeren ortofoto görüntüsü	53
Şekil 4.3.	Veri seti üzerine uygulanan farklı semivariogram modelleri	54
Şekil 4.4.	Semivariogram parametrelerinden oluşturulan konumsal bağımlılık dereceleri görüntüsü	55
Şekil 4.5.	Sınıflandırma işleminde kullanılan eğitim verileri	56
Şekil 4.6.	Spektral değerler ile en kısa mesafe yöntemine göre sınıflandırılmış görüntü.....	57
Şekil 4.7.	Spektral değerler ile SVM yöntemine göre sınıflandırılmış görüntü	57
Şekil 4.8.	Spektral ve konumsal değerler ile en kısa mesafe yöntemine göre sınıflandırılmış görüntü	58
Şekil 4.9.	Spektral ve konumsal değerler ile SVM yöntemine göre sınıflandırılmış görüntü.....	59
Şekil 4.10.	Çalışmada veri seti olarak kullanılan uzaktan algılama görüntüsü	61
Şekil 4.11.	Öklid mesafesinin belirlenmesi için yazılan MATLAB kodu	62
Şekil 4.12.	Benzerlik ölçütleri için kullanılan doku örnekleri; (a) su, (b) yeşil alan ve (c) bina doku görüntüleri	64
Şekil 4.13.	Öklid mesafesi kırmızı band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina.....	65
Şekil 4.14.	City Block mesafesi mavi band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina	66
Şekil 4.15.	Chi Kare mesafesi kırmızı band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina	67
Şekil 4.16.	Jeffrey mesafesi kırmızı band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina	68
Şekil 4.17.	Sorensen mesafesi yeşil band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina.....	69
Şekil 4.18.	Dice mesafesi kırmızı band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina.....	70
Şekil 4.19.	Bhattacharyya mesafesi mavi band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina	71

Şekil 4.20.	Fidelity mesafesi kırmızı band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina	72
Şekil 4.21.	Soergel mesafesi yeşil band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina.....	73
Şekil 4.22.	Jaccard mesafesi kırmızı band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina	74
Şekil 4.23.	Standart doku ölçütlerinden 5x5 piksellik pencere yöntemiyle oluşturulan ortalama görüntüsü	77
Şekil 4.24.	Standart doku ölçütlerinden 5x5 piksellik pencere yöntemiyle oluşturulan entropi görüntüsü	77
Şekil 4.25.	Standart doku ölçütlerinden 5x5 piksellik pencere yöntemiyle oluşturulan kontrast görüntüsü.....	78
Şekil 4.26.	Standart doku ölçütlerinden 5x5 piksellik pencere yöntemiyle oluşturulan korelasyon görüntüsü	78
Şekil 4.27.	Standart doku ölçütlerinden 5x5 piksellik pencere yöntemiyle oluşturulan ikinci açısal moment görüntüsü	79
Şekil 4.28.	Standart doku ölçütlerinden 5x5 piksellik pencere yöntemiyle oluşturulan homojenlik görüntüsü	79
Şekil 4.29.	Semivaryans değerlerinin belirlenmesi için yazılan MATLAB kodu	81
Şekil 4.30.	Veri setinin semivariogram grafiği ve spherical model parametreleri	82
Şekil 4.31.	Veri setinin semivariogram grafiği ve exponential model parametreleri	82
Şekil 4.32.	Exponential modele göre oluşturulan konumsal bağımlılık dereceleri görüntüsü.....	85
Şekil 4.33.	Spherical modele göre oluşturulan konumsal bağımlılık dereceleri görüntüsü.....	86
Şekil 4.34.	Spektral bilgi ile analizler sonucunda elde edilen ek bilgilerin birleştirilmesi	87
Şekil 4.35.	f_s görüntü pikselinin yerel komşulukları	88
Şekil 4.36.	SAR modeli ile 5x5 boyutlu pencere ve 4 piksel komşuluk ile oluşturulan kontrast görüntüsü.....	91
Şekil 4.37.	SAR modeli ile 5x5 boyutlu pencere ve 4 piksel komşuluk ile oluşturulan açısal ikinci moment görüntüsü	93
Şekil 4.38.	Sınıflandırma işleminde kullanılan eğitim verileri	99
Şekil 4.39.	Sınıflandırma işleminin doğruluğu tespit etmek için belirlenen yer gerçeklik verileri	100
Şekil 4.40.	Maximum Likelihood yöntemiyle spektral değerlere göre sınıflandırılmış görüntü.....	102
Şekil 4.41.	Maximum Likelihood yöntemiyle spektral ve konumsal örüntü değerlerine göre sınıflandırılmış görüntü	104
Şekil 4.42.	Maximum Likelihood yöntemiyle spektral ve standart doku ölçütlerine göre sınıflandırılmış görüntü	106
Şekil 4.43.	Maximum Likelihood yöntemiyle spektral ve konumsal (exponential) değerlere göre sınıflandırılmış görüntü	108

Şekil 4.44.	Maximum Likelihood yöntemiyle spektral ve konumsal (spherical) değerlere göre sınıflandırılmış görüntü	110
Şekil 4.45.	Maximum Likelihood yöntemiyle veri setlerine ait elde edilen sınıflandırma doğruluk yüzdeleri.....	112
Şekil 4.46.	Doğrusal olarak ayrılabilen veri seti ve destek vektörleri	113
Şekil 4.47.	Doğrusal olarak ayrılamayan verilerin kernel(çekirdek) fonksiyonuyla üst boyutlu uzaya aktarılması.....	114
Şekil 4.48.	Yeşil alanlara ait belirli bir bölgenin topoğrafyasına ait genel görünüm	115
Şekil 4.49.	SVM yöntemiyle spektral değerlere göre sınıflandırılmış görüntü	116
Şekil 4.50.	SVM yöntemiyle spektral ve konumsal örüntü değerlerine göre sınıflandırılmış görüntü.....	118
Şekil 4.51.	SVM yöntemiyle spektral ve standart doku ölçütlerine göre sınıflandırılmış görüntü.....	120
Şekil 4.52.	SVM yöntemiyle spektral ve konumsal (exponential) değerlere göre sınıflandırılmış görüntü	122
Şekil 4.53.	SVM yöntemiyle spektral ve konumsal (spherical) değerlere göre sınıflandırılmış görüntü	124
Şekil 4.54.	SVM yöntemiyle veri setlerine ait elde edilen sınıflandırma doğruluk yüzdeleri	125
Şekil 4.55.	Neural Network yöntemiyle spektral değerlere göre sınıflandırılmış görüntü.....	128
Şekil 4.56.	Neural Network yöntemiyle spektral ve standart doku ölçütlerine göre sınıflandırılmış görüntü	130
Şekil 4.57.	Neural Network yöntemiyle spektral ve konumsal örüntü değerlerine göre sınıflandırılmış görüntü	132
Şekil 4.58.	Neural Network yöntemiyle spektral ve konumsal (exponential) değerlere göre sınıflandırılmış görüntü	134
Şekil 4.59.	Neural Network yöntemiyle spektral ve konumsal (spherical) değerlere göre sınıflandırılmış görüntü.....	136
Şekil 4.60.	Neural Network yöntemiyle veri setlerine ait elde edilen sınıflandırma doğruluk yüzdeleri.....	137
Şekil 4.61.	Sınıflandırma yöntemlerine veri setlerine ait elde edilen sınıflandırma doğruluk yüzdeleri karşılaştırılması	138

TABLolar DİZİNİ

Tablo 2.1.	Çeşitli doku analizi yöntemlerinin avantaj ve dezavantajları	20
Tablo 3.1.	Semivariogram terimleri, sembolleri ve açıklamaları.....	32
Tablo 4.1.	Spektral değerler ile gerçekleştirilen en kısa mesafe yöntemine ait hata matrisi.....	59
Tablo 4.2.	Spektral ve konumsal değerler ile gerçekleştirilen en kısa mesafe yöntemine ait hata matrisi	60
Tablo 4.3.	Spektral değerler ile gerçekleştirilen SVM yöntemine ait hata matrisi	60
Tablo 4.4.	Spektral ve konumsal değerler ile gerçekleştirilen SVM yöntemine ait hata matrisi.....	60
Tablo 4.5.	Sill / Range bağımlılık dereceleri için kullanılan eşik değerler.....	85
Tablo 4.6.	5x5 boyutlu pencere ve 4 piksel komşuluklu SAR modeli ile oluşturulan kontrast görüntüsüne ait model parametreleri	92
Tablo 4.7.	5x5 boyutlu pencere ve 4 piksel komşuluklu SAR modeli ile oluşturulan kontrast görüntüsüne ait özellikler.....	92
Tablo 4.8.	5x5 boyutlu pencere ve 4 piksel komşuluklu SAR modeli ile oluşturulan açısıl ikinci moment görüntüsüne ait model parametreleri	93
Tablo 4.9.	5x5 boyutlu pencere ve 4 piksel komşuluklu SAR modeli ile oluşturulan açısıl ikinci moment görüntüsüne ait özellikler	94
Tablo 4.10.	Spektral değerler ile gerçekleştirilen Maximum Likelihood sınıflandırmasına ait hata matrisi.....	103
Tablo 4.11.	Spektral ve konumsal örüntü değerleri ile gerçekleştirilen Maximum Likelihood sınıflandırmasına ait hata matrisi.....	105
Tablo 4.12.	Spektral ve standart doku ölçütleri ile gerçekleştirilen Maximum Likelihood sınıflandırmasına ait hata matrisi.....	107
Tablo 4.13.	Spektral ve Konumsal (Exponential) değerler ile gerçekleştirilen Maximum Likelihood sınıflandırmasına ait hata matrisi.....	109
Tablo 4.14.	Spektral ve Konumsal (Spherical) değerler ile gerçekleştirilen Maximum Likelihood sınıflandırmasına ait hata matrisi.....	111
Tablo 4.15.	Spektral değerler ile gerçekleştirilen SVM sınıflandırmasına ait hata matrisi.....	117
Tablo 4.16.	Spektral ve konumsal örüntü değerleri ile gerçekleştirilen SVM sınıflandırmasına ait hata matrisi	119
Tablo 4.17.	Spektral değerler ve standart doku ölçütleri ile gerçekleştirilen SVM sınıflandırmasına ait hata matrisi	121
Tablo 4.18.	Spektral ve Konumsal (Exponential) değerler ile gerçekleştirilen SVM sınıflandırmasına ait hata matrisi.....	123
Tablo 4.19.	Spektral ve Konumsal (Spherical) değerler ile gerçekleştirilen SVM sınıflandırmasına ait hata matrisi	125
Tablo 4.20.	Spektral değerler ile gerçekleştirilen Neural Network sınıflandırmasına ait hata matrisi.....	128

Tablo 4.21.	Spektral ve standart doku ölçüt değerleri ile gerçekleştirilen Neural Network sınıflandırmasına ait hata matrisi	130
Tablo 4.22.	Spektral ve konumsal örüntü değerleri ile gerçekleştirilen Neural Network sınıflandırmasına ait hata matrisi	133
Tablo 4.23.	Spektral ve Konumsal (Exponential) değerler ile gerçekleştirilen Neural Network sınıflandırmasına ait hata matrisi	135
Tablo 4.24.	Spektral ve Konumsal (Spherical) değerler ile gerçekleştirilen Neural Network sınıflandırmasına ait hata matrisi	137



SİMGELER VE KISALTMALAR DİZİNİ

A	: Toplam çalışma alanı boyutu
a	: Range mesafesi
C	: Partial Sill değeri
C_0	: Nugget değeri
Cov	: Varyans-kovaryans matrisi
d	: İki nokta arasındaki uzaklık
$D(x,y)$	: İki bağımsız değişken arasındaki mesafe değeri
$\bar{D}_0$	: Ortalama mesafe değeri
$\bar{D}_E$	: Beklenen ortalama mesafe değeri
G_i^*	: Getis-Ord G istatistik değeri
h	: lag mesafesi
K	: Kuadrat alanı
n	: Veri setinde bulunan nokta sayısı
nm	: Nanometre
$p(z_i)$	: Histogram değeri
$p(i,j)$	: Bileşik durum olasılık yoğunluk fonksiyonu değeri
S	: Sill değeri
w	: Ağırlık değeri
X	: Girdi veri seti
$\bar{x}$	: x verilerinin ortalama değeri
$\bar{y}$	: y değerlerinin ortalama değeri
$z(x_i)$	: Görüntüdeki piksel gri renk değeri
μ	: Ortalama
σ	: Standart sapma
γ	: Semivaryans değeri
β	: Regresyon katsayısı
ε	: Hata terimi
ρ	: Bağımlı değişken katsayısı
θ	: Model parametre vektörü

Kısaltmalar

ANN	: Average Nearest Neighbour (Ortalama En Yakın Komşuluk)
ARMA	: Auto Regressive Moving Average (Otoregresif Hareketli Ortalama)
DN	: Dijital Numara
ENVI	: Enviroment for Visualizing Images
GLCM	: Grey Level Co-occurrence Matrix (Gri Seviye Eş-Oluşum Matrisi)
GMI	: Genel Moran's I İndeksi
GWR	: Geographically Weighted Regression (Coğrafik Ağırlıklandırılmış Regresyon)
HOG	: Histogram of Oriented Gradients (Yönlü Gradyan Histogramı)

LBP	: Local Binary Pattern (Yerel İkili Örüntü)
LEP	: Local Edge Pattern (Yerel Kenar Örüntüsü)
LISA	: Local Indicator of Spatial Analyses (Yerel Konumsal Otokorelasyon)
LVQ	: Learning Vector Quantization (Öğrenmeli Vektör Nicemleme)
MATLAB	: Matrix Laboratory
MLP	: Multi Layer Perceptron (Çok Katmanlı Almaç)
MSE	: Mean Squared Error (Karesel Ortalama Hata)
MSS	: Multispectral Scanner System (Multispektral Tarama Sistemi)
NE	: Relative Nugget Effect (Bağıl Nugget Etkisi)
NN	: Neural Network (Sinir Ağları)
OLS	: Ordinary Least Square (Klasik En Küçük Kareler)
PSNR	: Peak Signal Noise Ratio (Sinyal Gürültü Oranı)
RBF	: Radial Basis Function (Radyal Tabanlı Fonksiyon)
SAR	: Spatial AutoRegressive Model (Konumsal Otoregresif Model)
SPD	: Spatial Dependence Degree (Konumsal Bağımlılık Derecesi)
SSIM	: Structural Similarity Metrics (Yapısal Benzerlik Ölçütleri)
STSIM	: Structural Texture Similarity Metrics (Yapısal Doku Benzerlik Ölçütleri)
SVM	: Support Vector Machines (Destek Vektör Makineleri)
YSA	: Yapay Sinir Ağı

UZAKTAN ALGILAMA GÖRÜNTÜLERİNDE GEOİSTATİSTİKSEL YÖNTEMLER İLE DOKU ANALİZİ

ÖZET

Uzaktan Algılama, yeryüzünde bulunan cisimlere herhangi bir temasta bulunulmaksızın cisimlerin yayılan veya yansıtılan elektromanyetik enerjileri yardımıyla cisimler hakkındaki bilgilerin elde edilmesi yöntemidir. Uzaktan algılanan uydu görüntüleri birçok uygulama alanında etkili olarak kullanılmaktadır. Görüntülerin çeşitli yöntemlerle analiz edilerek, faydalı bilgilerin çıkarılması görüntü analizi olarak adlandırılmaktadır. Görüntü analizi digital görüntülerin özellikleri ve piksel karakteristikleri hakkındaki bilgiyi kullanılır. Görüntüler içerisinde bulunan doku bu karakteristiklerden bir tanesidir. Doku bilgisinin çeşitli uzaktan algılama uygulamalarında sonuç elde etme doğruluğunu arttırmak amacıyla, görüntü içerisindeki bir pikselin diğer piksellerle olan konumsal ilişkisi hakkındaki bilgiyi sağlayabilecek bazı ek parametrelerin elde edilmesi gerekmektedir. Standart doku bilgisi çıkarım yaklaşımlarına ek olarak belli komşuluktaki piksellerin mekansal (örüntü) ilişkilerini dikkate alan yaklaşımlara ihtiyaç vardır. Bu yaklaşımlardan geoistatistik, son yıllarda uzaktan algılama alanında kendisine sıklıkla yer bulan ve piksellerin konumsal bağımlılık bilgilerini belirleyen yöntemlerden bir tanesidir. Literatürde bulunan çalışmalar geoistatistik yöntemlerle elde edilmiş konumsal bilginin klasik uzaktan algılama uygulamalarından birisi olan sınıflandırma işlemine katkı sağladığını göstermektedir. Piksellerin komşuluk ilişkisinin belirlenmesinde kullanılabilecek diğer bir yaklaşım mekansal istatistik ve ilgili ölçütleridir. Belirli komşulukta tanımlanmış doku bilgilerinin yerel ve global mekansal istatistik ölçütleri ile analiz edilmesi, görüntüler üzerinden bilgi çıkarımında katkı sağlayabilir.

Bu tez çalışmasında, uydu görüntülerinde geoistatistik yöntemler ile elde edilmiş olan konumsal bağımlılık bilgileri yardımıyla, görüntünün doku özelliklerini belirleyebilecek karakteristik bir bilginin kullanımının, uydu görüntülerinin sınıflandırılması başarımına hangi ölçüde etki sağlayacağını ortaya koyabilmek amaçlanmıştır. Bu amaç doğrultusunda veri seti olan uydu görüntüsü üzerinde benzerlik ölçütleri yöntemleri ile doku incelemesi yapılmıştır. Elde edilen bilgiler yardımıyla uydu görüntüsünün standart doku ölçütleri ve konumsal örüntüleri belirlenmiştir. Görüntü içerisinde doku bilgisinin varlığının tespit edilmesinden sonra geoistatistik yöntemler uygulanmış ve görüntünün konumsal bağımlılık bilgileri elde edilerek derecelendirilmiştir. Standart doku ölçütleri, konumsal örüntü bilgileri ve konumsal bağımlılık dereceleri spektral değerler ile bir araya getirilerek yeni veri setleri oluşturulmuştur. Elde edilen yeni veri setlerine konumsal otoregresif model (SAR) uygulanarak dokunun modellenmesi gerçekleştirilmiştir. Elde edilen beş adet yeni veri seti üzerinde sınıflandırma analizleri uygulanarak doğruluk değerleri incelemesi gerçekleştirilmiştir.

Anahtar Kelimeler: Benzerlik Ölçütleri, Doku, Konumsal/Uzamsal Analiz, SAR, Semivariogram.

TEXTURE ANALYSIS ON REMOTE SENSING IMAGES WITH GEOSTATISTICAL METHODS

ABSTRACT

Remote Sensing is a method of obtaining information about objects with the help of the radiated or reflected electromagnetic energies of the objects without making any contact with the objects on the earth. Remote sensing satellite images are used effectively in many fields of application. The analysis of the images by various methods and extracting useful information is called image analysis. Image analysis uses the information of the pixel and digital image characteristics. The texture is one of these characteristics in the images. In order to increase the accuracy of the texture information to obtain results in various remote sensing applications, it is necessary to obtain some additional parameters that can provide information about the spatial relationship of a pixel in the image to other pixels. In addition to the standard texture information extraction approaches, there is a need for approaches that take into account the spatial relationships of certain neighboring pixels. One of these approaches, geostatistics, is one of the methods that has been frequently used in the field of remote sensing in recent years and determines the spatial dependence information of pixels. In the literature studies show that spatial information obtained by geostatistics methods contribute to the classification process which is one of the classical remote sensing applications. Spatial statistics and related criteria are another approach that can be used to determine the neighborhood relationship of pixels. Analyzing the tissue information defined in a specific neighborhood with local and global spatial statistical criteria may contribute to information extraction through images.

In this thesis, it is aimed to reveal to what extent the use of characteristic information which can determine the texture properties of the image with the help of positional dependence information obtained by geostatistics methods on satellite images will effect the classification performance of satellite images. For this purpose, texture analysis was performed on the satellite image which is a data set with similarity measure methods. With the help of the obtained information, standard texture measures and spatial patterns of the satellite image were determined. After determining the presence of texture information in the image, geostatistics methods were applied and the spatial dependence information of the image was obtained and graded. New data sets were created by combining standard texture measures, spatial patterns information and spatial dependence degrees with spectral values. Texture modeling was performed by applying spatial autoregressive model (SAR) to new data sets. Accuracy values were determined and examined by applying classification analysis on five new data sets.

Keywords: Similarity Measures, Texture, Spatial Analysis, SAR, Semivariogram.

GİRİŞ

Uzaktan algılama gözlemlenen nesneye fiziksel bir temas olmaksızın algılayıcı platformlar yardımıyla bilgi toplama ve yorumlama bilimi olarak tanımlanmaktadır. Uzaktan Algılama'nın modern çağı; ilk olarak 1972 yılında Landsat Multispectral Scanner System (MSS) ile her biri 100nmlik dalgaboyunda ve 80m mekansal çözünürlüğe sahip olan 4 spektral banda sahip olan görüntüler ile başladı. Gelişen teknoloji ile birlikte artık günümüzde elektromanyetik spektrumu yaklaşık olarak 10 nm boyutunda spektral bandlara ayıran ve cm'den km'ye kadar değişen hassasiyete sahip piksel boyutlarıyla, her biri yüzlerce spektral bantlı sistemlerle örnekleme yapan hiperspektral uydu sistemleri bulunmaktadır (Showengerdt, 2007).

Bu sistemlerce oluşturulan dijital görüntü, yeryüzünde bulunan cisimlerden yansıyan veya yayılan elektromanyetik enerjinin konumsal (pikseller) ve radyometrik (piksel parlaklık değerleri) olarak değerlendirilmesi sonucu elde edilen ve matematiksel olarak satır-sütun koordinatlarındaki piksellerin parlaklık değerlerini üreten bir fonksiyon ile temsil edilmesi olarak tanımlanmaktadır (Sunar ve diğ., 2011). Bu dijital görüntülerin çeşitli ve oldukça karmaşık olabilen istatistik algoritmalarla (sınıflandırma, bölütleme v.b.) işlenerek, uygulamalara ve karar almaya yardımcı çeşitli sonuçların elde edilmesi işlemine ise görüntü analizi denir. Görüntü analizinde digital görüntülerin özellikleri ve piksel karakteristikleri hakkındaki bilgi kullanılır. Görüntüler üzerindeki doku bilgisi bunlardan bir tanesidir. Doku bilgisini faydalı bir özellik yapan, doğal ve yapay görüntüleri karakterize ederek, görüntü analizinde kullanılan önemli bir görsel özellik olmasıdır.

Doku analizi, görüntü içerisinde bulunan bir özelliği belirleyebilmek için görüntü işleme, örüntü tanıma v.b. standart uygulamalarda kullanılan ana özelliklerden biri olarak tanımlanabilir. Ayrıca görüntü içerisinde bulunan nesnelerin sınıflandırılmasında ve verilen görüntünün önemli bölgelerinin ana hatları ile çizilmesinde temel bir rol oynadığı yaygın olarak kabul edilen bir görüştür (Chaurasia ve Garg, 2013).

Analiz sürecinin ana gereksinimi, görüntüdeki piksellerin özelliklerinin bilgileridir. Eğer analiz işlemi uzaktan algılama görüntüleri gibi yüksek boyutlu ve çok bandlı görüntüler üzerinde gerçekleştirilecekse sonuç elde etme doğruluğunu arttırmak amacıyla görüntü içerisindeki bir pikselin diğer piksellerle konumsal ilişkisi hakkında bilgi sağlayabilecek bazı ek parametrelerin bilgisi de gerekecektir. Standart doku bilgisi çıkarım yaklaşımlarına ek olarak belli komşuluktaki piksellerin mekansal/uzamsal (örüntü) ilişkilerini dikkate alan yaklaşımlara ihtiyaç vardır. Bu yaklaşımlar standart mekansal/uzamsal istatistik ve otokorelasyon kavramı ile mekansal/uzamsal örüntü tanımlama ve analizleri yanında tamamlayıcı nitelikte geoistatistik yöntemleridir. Son yıllarda geoistatistik yöntemlerden sıklıkla yararlanılmaktadır. Geoistatistik; görüntülerin parlaklık değerlerinden elde edilen semivaryans değerlerini kullanarak pikseller arasındaki konumsal ilişkiyi belirleyebilen istatistik yöntemidir. Geoistatistik yöntemler ile elde edilen semivaryans değerlerine uydurulan çeşitli modellerin (spherical, exponential ve gaussian v.b) parametreleri yardımıyla (range, sill, nugget) piksellerin konumsal bağımlılık ilişkileri tespit edilir. Belirli komşulukta tanımlanmış doku bilgilerinin yerel ve global mekansal istatistik ölçütleri ile analiz edilmesi şeklindeki yaklaşımın, görüntüler üzerinden bilgi çıkarımında katkı sağladığı bilinmektedir. Doku tanımından hareketle; belli komşuluktaki piksellerin düzenini kantitatif anlamda tanımlamaya yardımcı olabilecek nitelikte, istatistik (histogram) ölçüt ve çeşitli metrik ölçülerin kullanımı amacıyla benzerlik ölçütlerinden yararlanarak görüntü analizleri gerçekleştirilebilir. Burada amaç, belirli görüntü bölgelerinde mekansal otokorelasyon ve varyogramlarla tanımlanacak mekansal değişkenlik veya ilişkilerin benzerlik ölçütleri ile görüntülerle karşılaştırılması/test edilmesi ve bu bölgelerde çıkarılacak doku bilgisine katkısının araştırılmasıdır. Başka bir deyişle görüntü üzerinden alınan doku örnek verilerinin semivariogram yardımıyla elde edilen konumsal/uzamsal ilişki/bağımlılık bilgileri tüm görüntü üzerinde benzerlik ölçütleri yardımıyla araştırılarak görüntüdeki benzer doku bölgeleri belirlenebilecektir. Bu kapsamda benzerlik ölçüt ve yöntemleri araştırılarak yukarıda belirtilen amaç için uygun olabilecek benzerlik ölçütlerinin belirlenmesine çalışılmıştır.

Bu tez çalışmasının ana amacı; mekansal/uzamsal otokorelasyon, geoistatistik yaklaşımlar ve metrik/istatistik benzerlik ölçütleri yardımıyla belirlenen konumsal

bağımlılık bilgileri ile çeşitli uydu görüntüleri için doku özelliklerini optimum biçimde belirleyebilecek ölçütlerin kullanımıyla standart bir uzaktan algılama uygulamasının (sınıflandırma, obje tanıma, bölütleme vb.) spektral bilgi çıkarımının performansını ne ölçüde etkileyeceğini, katkı düzeyi ve potansiyelini kantitatif olarak ortaya koyabilecek bir çerçeve oluşturmaktır. Literatürdeki çalışmaların genelinde; görüntüler üzerindeki konumsal/uzamsal bağımlılığı belirleyen semivariogram analizinin, yapılan spektral sınıflandırma işlemine dahil edilmesi ile sınıflandırma doğruluğunun arttığından bahsedilmektedir. Bu çalışmada görüntüler üzerinden yapılan mekansal otokorelasyon, örüntü analizleri ve semivariogram model parametrelerinin analizi ile görüntülerdeki dokuyu belirleyebilecek bir kriter elde edilerek, sınıflandırma işleminin doğruluk değerine yapacağı katkının etkin bir biçimde belirlenmesi amaçlanmıştır.

Oluşturulmak istenen çerçeve; literatür çalışmalarında sıklıkla rastlanılan semivaryans değerlerini kullanarak yapılan uzaktan algılama uygulamalarında elde edilen doğruluk başarımına yeni bir görüş veya yöntem önererek elde edilen doğruluk arttırımının nasıl gerçekleştirilebileceğinin araştırılmasıdır. Bu amacı gerçekleştirmek adına semivariogram parametrelerinden olan Sill ve Range değerlerinin birbirlerine oranlanmasıyla oluşturulacak ölçüt değerlerinin (konumsal bağımlılığın derecelendirilmesi) kullanımının, uzaktan algılama uygulamalarında elde edeceği sonucun araştırılmasına çalışılmıştır.

Literatürde, görüntüde bulunan farklı konumsal değişkenlik örüntüsüne sahip olan arazi sınıflarının farklı variogramlara sahip olduğunun gösterildiği çalışmalar bulunmaktadır (Miranda ve diğ., 1998). Ayrıca çeşitli doku ölçütlerinin yapılan sınıflandırma işlemlerinde sınıflandırma doğruluğunu arttırdığını belirten çalışmalar da mevcuttur (Fotsing ve diğ., 2013). (Carr, 1996), çalışmada tek ve çok bandlı görüntülerdeki her bir piksel etrafından elde edilen yerel variogramlar yardımıyla görüntü dokusunu sınıflandırabilen iki adet program geliştirilmiştir. Doku ile görüntü sınıflandırma doğruluğunun arttırıldığı, gerçekleştirilen uygulamalarla ortaya koyulmuştur. (Carr ve De Miranda, 1998), semivariogramlar ile eş-oluşum matrisleri karşılaştırılarak doku sınıflandırması ve doğruluğu test edilmiştir. Mikrodalga görüntülerde semivariogramların daha yüksek sınıflama doğruluğu sağladığı, optik görüntülerde ise eş-oluşum matrislerinin daha yüksek sınıflama doğruluğu elde

ettiğinden bahsedilmiştir. (Atkinson ve Lewis, 2000), derleme çalışmada uydu görüntülerinin sınıflandırılmasında konumsal bilgiyi kullanan çeşitli yöntemlerin incelemesi yapılmıştır. (Haack ve Bechdol, 2000), çalışmalarında Landsat ve RADAR görüntülerinden elde edilen ikinci derece doku özellikleri ile görüntüler sınıflandırmış ve sınıflandırma doğruluğunda artış elde edilmiştir. (Berberoglu ve diğ., 2000), Çukurova bölgesindeki arazi sınıflarının belirlenmesinde görüntüler üzerinden elde edilen doku bilgileri kullanmış ve yapay sinir ağları yöntemiyle yapılan sınıflandırma işleminde spektral bilginin yanında doku bilgisi de kullanılarak maximum likelihood yöntemine göre daha yüksek sınıflandırma doğruluğu elde edilmiştir. (Li ve diğ., 2001), çalışmalarında spektral veriye ek olarak farklı ölçeklerdeki (17x17 ve 61x61) yerel ve bölgesel konumsal istatistik verileri de eklenerek yapılan analizlerde genel sınıflandırma doğruluğunun arttığı tespit edilmiştir. (Sun ve Li, 2002), çalışmalarında semivariogram kullanarak SAR görüntüleri üzerinden tarımsal alanların konumsal örüntüleri belirlenmiştir. Özellikle pamuk gelişiminin izlenmesinde kullanılan bu yöntem ile elde edilen sonuçların doğruluğu artmıştır. (Kokare ve diğ., 2003), çalışmalarında 9 benzerlik ölçütü Brodatz doku görüntüleri üzerinde karşılaştırılmıştır. Canberra ve Bray-Curtis benzerlik ölçütlerinin geleneksel Öklid ve Mahalanobis yöntemlerine göre daha etkili oldukları vurgulanmıştır. (Zhang ve Lu, 2003), içerik bazlı yeniden görüntü elde etme yönteminde görüntü benzerlik ölçütlerinden yararlanılmıştır. Minkowski, kosinüs, histogram kesişimi, kuadratik mesafe, Mahalanobis mesafesi ve ki-kare istatistik mesafesi yöntemleri incelenmiş ve bu yöntemlerden Minkowski benzerlik grubu içerisinde bulunan City-Block (Manhattan) mesafesi ve Ki-Kare istatistik mesafesi yöntemlerinin diğerlerine göre daha iyi sonuçlar verdiklerinden bahsedilmiştir. (Durrieu ve diğ., 2005), uydu görüntülerindeki doku sınıflandırması için 23 adet yeni jeoistatistiksel parametre önerilmiştir. Bu parametrelerin hepsi uydu görüntüsünün pankromatik bandından elde edilen alt görüntülerin deneysel semivariogramları üzerinden hesaplanmıştır. Elde edilen parametrelerle doku sınıflaması yapılarak %80'in üzerinde bir sınıflama doğruluğu elde edilmiştir. (Cheng ve Li, 2005), çok bandlı görüntülerden tek seferde görüntü dokusunu çıkarabilen yeni bir yöntem geliştirilmiştir. Geliştirilen yöntem çok bandlı görüntülerin sınıflandırmasında, spektral yöntemlerle birlikte kullanılarak sınıflandırma doğruluğu arttırılmıştır. Ayrıca yöntemin hiperspektral ve farklı

zamanlı çok bandlı uydu görüntülerinde de kullanılabilir olduğundan bahsedilmiştir. (Chen ve Chu, 2005), Brodatz doku görüntülerinde öklid, Mahalanobis ve kosinüs benzerlik ölçütleri uygulanmış ve görüntüyü yeniden elde etme oranına göre değerlendirilmiştir. (Chiu ve Couloigner, 2006), çalışmada sulak alanların haritalandırılması ve sınıflandırılması işleminde fuzzy bölütleme yöntemi kullanılmıştır. Bu yöntemi kullanırken ek veri olarak semivariogram doku bilgisi de eklenmiş ve sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen sonuçlarda doku bilgisinden sağlanan yardımcı bilgi sayesinde sınıflandırma doğruluğunda artış meydana geldiğinden bahsedilmiştir. (Işık ve Çamurcu, 2008), çalışmada web belgeleri kümelemede benzerlik ve uzaklık ölçütlerinin başarıları karşılaştırılmıştır. Benzerlik ölçütleri olarak Öklid, Kosinüs, Pearson Korelasyon ve Genişletilmiş Jaccard yöntemleri incelenmiştir. Yapılan analizler sonucunda en iyi performansın Kosinüs ve Genişletilmiş Jaccard benzerlik ölçütlerine ait olduğu vurgulanmıştır. (Cha, 2008), yapılan kapsamlı çalışmada görüntü histogramları üzerinde kullanılan benzerlik ölçütleri gruplanarak kategorilere ayrılmıştır. Bu çalışmada her bir gri seviyenin diğer gri seviyelerden bağımsız olduğu nominal türde histogramlar kullanılmıştır. (Amoruso ve diğ., 2009), uydu görüntüleri üzerinden elde edilen semivariogramlar spektral olarak birbirlerine benzeyen arazi sınıflarının (yoğun zeytin ağaçlıkları ve orman gibi) ayırt edilmesinde kullanılmıştır. (Zujovic ve diğ., 2009), çalışmada doku analizinde önerilen yapısal benzerlik yönteminin; Peak Signal Noise Ratio (PSNR), Structural Similarity Metrics (SSIM) ve Structural Texture Similarity Metric (STSIM) yöntemleri ile seçilen doku görüntüleri üzerinde ki başarısı karşılaştırılmıştır. (Balaguer ve diğ., 2010), yüksek çözünürlüklü uydu görüntülerinin arazi kullanım sınıflandırmasında kullanılmak amacıyla deneysel variogramlardan elde edilen 14 adet doku parametresi önerilmiştir. Önerilen doku parametrelerinin Gri seviye Eş-oluşum Matrisi (GLCM) ve ham semivaryans değerlerine göre sınıflandırma doğruluğuna daha çok katkısı olduğu, yapılan deneysel çalışmalarla ortaya koyulmuştur. (Mitchell, 2010), görüntü benzerlik ölçütlerinin görüntü karma (fusion) algoritmalarında ve uygulamalarında (geri elde etme, sınıflandırma, değişim belirleme ve kalite belirleme v.b) önemli rol oynadığından bahsedilmiştir. Genel ve yerel benzerlik ölçütleri hakkında kapsamlı açıklamalarla birlikte örneklemeler yapılmıştır. (Tonye ve diğ., 2011), çalışmada görüntü üzerindeki doku örüntülerinden çıkarılan konumsal kovaryans bilgisinin

sınıflandırma doğruluğuna etkisi araştırılmıştır. Deneysel variogramlara uygulanan modellerle elde edilen parametreler kullanılarak oluşturulan özellik vektörü uydu görüntülerinin sınıflandırılmasında kullanılarak %94 gibi bir sınıflandırma doğruluğuna ulaşılmıştır. (Solana-Gutiérrez ve Merino-De-Miguel, 2011), orman alanlarının değişiminin belirlenmesi çalışmasında konumsal istatistikten yararlanılmıştır. Görüntülerden elde edilen deneysel semivariogramlara hangi modelin en uygun olduğu belirlenmeye çalışılmış, daha sonra görüntünün konumsal çözünürlüğüne göre semivariogram modellerinin nasıl çalıştığı araştırılmış ve son olarak deneysel variograma uyan modeller arasındaki ilişki incelenmiştir. Tüm bu incelemeler sonucunda konumsal çözünürlüğü düşük görüntülerde küresel (spherical) modelin daha iyi, konumsal çözünürlüğü yüksek olan görüntülerde ise üstel (exponential) modelin daha iyi sonuçlar verdiği belirlenmiştir. (Asha ve diğ., 2011), gri seviye eş-oluşum matrisinin histogramı üzerine ki-kare benzerlik ölçütü uygulanarak tekstil doku görüntüleri üzerindeki hataların otomatik algılanması amacıyla yeni bir algoritma önerilmiştir. (Zujovic, 2011), hazırlanan Algısal Doku Benzerlik Ölçütleri isimli doktora tezinde görüntü benzerlik ölçütlerine dair incelemelerde bulunulmuştur. Ayrıca doku benzerlik problemini çözmek amacıyla geliştirilen spesifik çeşitli algoritmalarından da (MSE (Mean Squared Error), PSNR, Eş-Oluşum Matrisleri, birinci ve ikinci derece istatistikler, rastgele alan modelleri ve local binary pattern v.b) bahsedilmiştir. (Collins ve Okada, 2012), geliştirilen medikal görüntü inceleme uygulamasında faydalanan çeşitli benzerlik ölçütleri hakkında bilgiler sunulmuştur. Minkowski ve Standart ölçütler, istatistiksel ölçütler, diverjans ölçütleri ve çeşitli diğer ölçütler hakkında bilgilendirmede bulunulmuştur. (Fotsing ve diğ., 2013), yapılan çalışmada jeostatistik teorisini kullanan doku modelleme ile ilgili bir yöntem geliştirilmiştir. Bu yöntem görüntüden elde edilen semivariogram modelleri yardımıyla oluşturulan semivariogram parametrelerini bir özellik vektörü olarak kullanarak görüntü sınıflandırmayı amaçlamaktadır. Geliştirilen yöntem ilk olarak doku işleme uygulamalarında genel bir geçerliliğe sahip olan Brodatz doku görüntüleri üzerinde uygulanarak çalışabilirliği test edilmiştir. Daha sonrasında SAR uydu görüntüsü geliştirilen yöntem yardımıyla sınıflandırılarak yöntemin sınıflandırmaya olan katkısı ortaya koyulmuştur. (Yue ve diğ., 2013), çalışmada Quickbird görüntülerinin obje tabanlı sınıflandırma doğruluğunu arttırmak için semivariogram doku özelliklerinden faydalanılmıştır.

Ayrıca semivariogram özelliklerinin yanında GLCM'den elde edilen standart doku ölçütleri olan ortalama, homojenlik, kontrast, açısız ikinci moment ve entropi görüntüleri de kullanılarak sınıflandırma doğruluğunda artış elde edilmiştir. (Kamal ve diğ., 2014), görüntüler üzerinden mangrove ağaçlarını daha doğru bir biçimde belirleyebilmek amacıyla optimum piksel boyutunun belirlenmesi için bir yöntem geliştirilmiştir. Geliştirilen bu yöntem görüntüler üzerindeki konumsal yapıyı karakterize etmek için semivariogramlardan yararlanmıştır. Semivariogramlardan elde edilen konumsal bağımlılık verisiyle, arazi çalışmalarından elde edilen veriler bir arada kullanılarak mangrove bitki örtüsü görüntüler üzerinden daha yüksek doğrulukla ortaya çıkarılmıştır. (Suruliandi ve Jenicka, 2015), uzaktan algılanmış görüntüler, çeşitli yöntemlerle elde edilen doku özellikleri ile birleştirilerek sınıflandırma işlemi gerçekleştirilmiş ve sonuçları hata matrisleri, doğruluk ve kapa istatistikleri ile sunulmuştur. Doku özelliklerinin sınıflandırma işlemine katılmasıyla doğruluk değerlerinin arttığı gösterilmiştir. (Wu ve diğ., 2015), semivariogram özellikleri kullanılarak nesne tabanlı görüntü sınıflandırma yöntemi geliştirilmiş ve sınıflandırma doğruluğunda artış elde edilmiştir. (Durrieu ve diğ., 2016), uzaktan algılanmış görüntülerdeki doku sınıflandırması için yeni bir yöntem önerilmiştir. Deneysel semivariogram üzerinden elde edilen parametreler, uzaktan algılanmış görüntülerde bulunan kentsel alanlar, tarım alanları ve ormanlık alanların sınıflandırılmasında kullanılarak, parametrelerin sınıflama doğruluğuna yaptıkları katkı ortaya koyulmuştur. (Suhardiman ve diğ., 2016), Mahakam deltasındaki mangrove ormanlarında bulunan ağaçların ortalama çaplarının hesaplanmasında ortofoto görüntülerinden elde edilen semivariogramlar kullanılarak başarı sağlanmıştır. Semivariogram model parametrelerinden olan Range kullanılarak 0.5 metrelik bir hata payıyla ortalama ağaç çapı belirlenmiştir. (Seidel ve de Oliveira, 2016), çalışmada konumsal bağımlılık indeksi geliştirilerek görüntü üzerindeki konumsal değişkenlik, zayıf, orta ve güçlü olarak sınıflandırılmıştır. Üç farklı variogram modeli için zayıf, orta ve güçlü konumsal bağımlılık indeksi oranları belirlenmiş ve görüntülerden elde edilen semivariogramlarda bu indeks kullanılarak görüntüler sınıflandırılmıştır. (Gao ve diğ., 2016), çalışmada obje tabanlı sınıflandırma için spektral bilgi ile doku bilgisi birleştirilerek kullanıp Support Vector Machines (SVM) yöntemi ile sınıflandırma işlemi gerçekleştirilmiştir. Doku bilgisinin eklenmesiyle elde edilen sınıflandırma doğruluğu, spektral bilgilerle elde

edilen doğruluk değerinden daha yüksek olduğu tespit edilmiştir. (Qiu ve Ming, 2018), çalışmada uydu görüntüleri üzerinde yapılan litosferik sınıflandırmada en uygun pencere boyutu kullanılarak elde edilen semivariogram doku bilgisi ile sınıflandırma doğruluğunda artış sağlanmıştır. Ayrıca GLCM' den elde edilen açısallık ikinci moment doku bilgisi kullanılarak uygulanan SVM sınıflandırmasında genel doğruluk ve kappa katsayısında belirli miktarda gelişme sağlanmıştır.

Bu tez çalışmasının birinci bölümünde görüntüler içerisinde bulunan dokunun kavram ve tanımı yapılmıştır.

İkinci bölümde görüntüler üzerinde bulunan doku bilgisinin analizinin yapılabilmesi için bugüne kadar geliştirilen yapısal, istatistiksel, dönüşüm tabanlı ve model tabanlı olarak gruplandırılmış olan analiz yöntemleri hakkında bilgiler verilmiştir.

Üçüncü bölümde, konumsal doku analiz başlığı altında mekansal istatistik, geoistatistiksel yöntemler ve konumsal örüntü analizi hakkında bilgiler verilmiş ve kullanılan yöntemlerin açıklaması yapılmıştır. Ayrıca görüntüdeki belirli alanlardan alınan örneklerin histogram değerlerini kullanarak elde edilen benzerlik ölçütleri ile doku ilişkisinin incelenmesi işlemi gerçekleştirilmiştir. Tez çalışması içerisinde kullanılmış olan 21 adet benzerlik ölçütü yönteminin matematik modelleri verilerek çalışma prensipleri açıklanmıştır.

Dördüncü bölümde, tez çalışmasında uygulanan sayısal işlem adımları 7 başlık altında açıklanmıştır. Bu başlıklardan birincisinde uygulamada veri seti olarak kullanılan uydu görüntüsüne ait bilgiler açıklanmıştır. İkinci başlık altında görüntü üzerindeki doku bölgelerinin belirlenmesine çalışılmıştır. Bunun için görüntünün belirli bölgelerinden alınan örneklerin istatistik/histogram değerleri ile oluşturulan benzerlik ölçütleri yardımıyla doku incelemesi yapılmıştır. Benzerlik ölçütlerinin oluşturulması için literatürde tanımlanan birçok method içersinden seçilen 21 adet yöntem kullanılmış ve belirlenen her bir örnek doku örüntüsü için benzerlik ölçüsü görüntüleri oluşturulmuştur. Üçüncü başlık altında uydu görüntüsünden oluşturulan Gri Seviye Eş-Oluşum Matrisi (GLCM) verisinden faydalanarak altı adet standart doku ölçütü oluşturulmuş ve analizi gerçekleştirilmiştir. Dördüncü başlık altında konumsal örüntü analizi yöntemlerinden olan Getis-Ord G istatistiği ve Moran's I indeksi yöntemleri kullanılarak uydu görüntüsünün her bir bandına ait konumsal

örüntü görüntüleri oluşturulmuştur. Beşinci başlık altında geoistatistik yöntemler yardımıyla görüntüden semivaryans değerlerinin nasıl elde edildiği ve bu semivaryans değerlerine uygulanan modellerin ve model parametrelerinin neler olduğu açıklanmıştır. Ayrıca semivariogram model parametrelerinde görüntü piksellerine ait konumsal bağımlılık bilgisinin nasıl elde edildiği ve spektral bilgi ile konumsal bilginin bir araya getirilmesi hakkında bilgiler verilmiştir. Altıncı başlık altında konumsal otoregresif model (SAR) yöntemi kullanılarak benzerlik ölçütü görüntülerini belirlemek için kullanılan homojen doku örnekleri yardımıyla görüntü içerisindeki dokunun mekansal modellenmesine çalışılmış ve elde edilen sonuç görüntüleri standart doku ölçütleri ile karşılaştırılmıştır. Yedinci başlık altında ise standart doku ölçütlerinin, konumsal örüntü görüntülerinin ve konumsal bilginin spektral bilgi ile bir araya getirilmesi ile oluşturulan yeni veri setleri ile sadece spektral değerlere sahip olan ham görüntünün sınıflandırılması işlemi gerçekleştirilmiştir. Üç adet farklı kontrollü sınıflandırma yöntemiyle gerçekleştirilen sınıflandırma işlemine ait sonuç görüntüleri ve sınıflandırma işlemine ait doğruluk değerlerinin belirlendiği hata (confusion) matrisleri bu bölümde analiz edilerek tez çalışmasında önerilen yöntemin nasıl sonuç verdiği araştırılmıştır.

Tezin son bölümü olan beşinci bölümde ise elde edilen sonuçlar irdelenmiş, doktora tez çalışması olarak önerilen yöntemin oluşturduğu sonuçların hangi ölçüde başarıya ulaştığı açıklanmış ve bu sonuçlara göre görüşler sunulmuştur.

1. DOKU KAVRAM VE TANIMI

Doku için literatürde çok sayıda tanım yapılmışsa da evrensel anlamda üzerinde fikir birliğine varılmış genel ve tek bir tanım yoktur. En yalın tanımla doku, görüntünün belli bir bölgesinin gri değer yoğunluğundaki karakteristik değişimdir. Görüntü yoğunluğundaki yerel değişimlerin tekrarlayan örüntüleri olarak da tanımlanabilir. Görüntülerde bulunan dokular için yapılmış farklı tanımlar mevcuttur. Haşiloğlu dokuyu; görüntü içerisindeki çeşitli farklılıkların belirlenmesinde önemli bir yardımcı veri ve görüntünün renk değerlerinin (gri seviyelerinin) yerel komşuluk özelliklerinin toplamı olarak tanımlamıştır (Haşiloğlu, 2001). Chaurasia ve Garg'a göre doku; görüntü üzerinde aynı gözüken fakat yeryüzünde birbirinden farklı olan nesneleri belirlemeye yardımcı olan önemli bir özellik olarak tanımlanmaktadır (Chaurasia ve Garg, 2013). Tuceryan ve Jain; görüntü içerisinde her yerde benzer özelliği göstermemesine rağmen belli bir örüntü ve desen oluşturan yüzeyleri görsel dokusu olan yüzeyler olarak betimlemişlerdir (Tuceryan ve Jain, 1998). Sklansky; görüntüdeki belirli bir bölgenin lokal istatistiksel ve diğer özellik fonksiyonları sabitse veya yavaş yavaş değişiyorsa ya da periyodikse bu bölgede sabit bir doku bulunduğu bahsedilebilir şeklinde tanımlamıştır (Sklansky, 1978). Materka ve Strzelecki; parlaklık, renk, eğim ve boyut gibi benzer karakteristik özelliklere sahip girdilerden veya alt örüntülerden oluşan karmaşık görsel örüntülerin birleşimidir. Buna göre doku görüntüdeki bir benzerlik gruplaması olarak kabul edilebilir şeklinde tanımlamışlardır (Materka ve Strzelecki, 1998). Russ dokuyu; görüntü içerisinde yakın (küçük) komşuluklarda bulunan pikseller arasındaki parlaklık değişiminin tanımlayıcıdır şeklinde ifade etmektedir (Russ, 1999). Gonzalez ve Woods; görüntü hakkında sezgisel olarak düzgünlük (yumuşaklık), kabalık ve düzenlilik gibi özellikler hakkında genel bir bilgi sağlayıcı olarak tanımlamışlardır (Gonzales ve Woods, 2014). Haralick, bir görüntünün dokusu o görüntüyü oluşturan nesnelerin uzaysal dağılımı, türü ve sayısı ile tanımlanabilir. Uzaysal dağılım rastgele olabilir, komşu nesneler arasında ikili veya n adet nesneye bağlı bir bağ bulunabilir. Bu bağımlılık olasılıksal, istatistiksel veya fonksiyonel olabilir şeklinde tanımlamıştır (Haralick, 1979).


2. DOKU ANALİZ YÖNTEMLERİ

Dokunun yapısal özelliği incelenecek olursa, tekrarlanan en temel doku özelliklerine teksel (texel) denir. Teksellerin görüntü içerisindeki dağılımı rastgele, periyodik veya yarı-periyodik olabilir. Doğal dokular genellikle rastgele, uzaktan algılama görüntüleri bu gruba girmektedir, yapay dokular ise genellikle periyodik veya yarı-periyodiktirler. (Materka ve Strzelecki, 1998).

Doku analizi, görüntü içerisinde bulunan bir özelliği belirleyebilmek için görüntü işleme, örüntü tanıma vb. standart uygulamalarda kullanılan ana özelliklerden biri olarak tanımlanabilir. Ayrıca görüntü içerisinde bulunan nesnelerin sınıflandırılmasında ve verilen görüntünün önemli bölgelerinin ana hatları ile belirlenmesinde temel bir rol oynadığı yaygın olarak kabul edilen bir görüştür (Chaurasia ve Garg, 2013). Doku analizi genellikle otomatik kalite kontrol, medikal görüntü işleme, metin ve belge işleme, endüstriyel ürünlerin incelenmesi, yeryüzü sınıflandırma, yerleşim yeri çıkarımı, bitki örtüsü haritalama, ağaç türlerinin sınıflandırılması gibi uzaktan algılanmış görüntülerin de kullanıldığı geniş bir kullanım alanına sahiptir (Bharati ve diğ., 2004; Savran, 2009).

Görüntülerden dokusal bilgi çıkarımına yönelik çok sayıda ve birbirinden farklı analiz yöntemleri mevcut olup, bu yöntemler 4 sınıfta gruplandırılmaktadır (Şekil 2.1). Bunlar;

- Yapısal (Structural)
- İstatistiksel (Statistical)
- Model Tabanlı (Model Based)
- Dönüşüm Tabanlı (Transformation Based) yöntemlerdir (Chaurasia ve Garg, 2013).



Şekil 2.1. Doku analizi yöntemleri

2.1. Yapısal Yöntemler

Yapısal yöntemler, düzenli olarak yerleşmiş paralel çizgilere dayalı bir yapının tanımı gibi görüntü ana özelliklerinin düzeni ile ilgilidir (Gonzales ve Woods, 2014). Haralick'e göre yapısal yöntemlerin temeli; doku, düzenliye yakın olarak tekrarlanan konumsal bağımlılıklardaki öncüllerden oluşur. Dokuyu tanımlamak için piksellerin öncül özellikleri (mikro dokular) ve bunların konumsal ilişkileri mutlaka tanımlanmalıdır (Haralick, 1979). Doku analizindeki yapısal yaklaşımlar iyi tanımlanmış özelliklerle ve bu özelliklerin konumsal düzenlemelerinin hiyerarşisi yardımıyla dokuyu tanımlamaya dayalıdır. Bu özellikler birbirleriyle ilişkili piksellerle tanımlanır. Bir pikselin en basit özelliği onun gri değer bilgisidir. Yapısal yöntemler tek başına görüntü üzerindeki dokuyu belirlemede yeterli değildir. Bu nedenle İstatistiksel yöntemlerle birlikte kullanılırlar (Chaurasia ve Garg, 2013). Yapısal yöntemlerin avantajı, görüntünün sembolik tanımlamasını iyi yapabilmesidir.

Bununla birlikte, bu özellik görüntü analizinden çok görüntü sentezinde daha kullanışlıdır (Materka ve Strzelecki, 1998).

2.2. İstatistiksel Yöntemler

İstatistiksel yöntemler deterministik olmayan özelliklere göre bir görüntünün gri seviyeleri arasındaki ilişkiyi ve dağılımı düzenleyerek görüntüdeki dokuyu tanımlarlar. Düzgünlük, kabalık, tanecik gibi görüntü yapılarının karakteristiklerini verirler (Gonzales ve Woods, 2014). İstatistiksel aşamada doku, çok sayıdaki yerel görüntü özelliklerinden çıkarılan istatistik parametreler olarak tanımlanır. Birinci dereceden gri seviye istatistikleri gibi en basit istatistikler bile dokuları sınıflandırmak için dönüşüm yöntemi olarak kullanılabilirler. En çok kullanılan istatistik yöntemleri; Otokorelasyon fonksiyonu, Histogram ve Gri seviye eş-oluşum matrisidir.

2.2.1. Otokorelasyon fonksiyonu

Görüntülerdeki doku gri seviye öncüllerinin konumsal boyutuna bağlıdır. Büyük boyutlu gri seviye öncülleri kötü, küçük boyutlu gri seviye öncülleri ise iyi dokuyu göstermektedirler. Otokorelasyon fonksiyonu gri seviye öncüllerinin tanımını en iyi şekilde yapmaktadır. Otokorelasyon fonksiyonu yerel ton değişimlerini ve doku tekrarlanabilirliğini gösterir.

$$\rho(i,j) = \frac{\sum_{u=0}^M \sum_{v=0}^M \frac{X(u,v)X(u+i,v+j)}{\sum_{u=0}^N \sum_{v=0}^N X^2(i,j)}}{\sum_{u=0}^N \sum_{v=0}^N X^2(i,j)} \quad (2.1)$$

(2.1) denklemi otokorelasyon fonksiyonunu tanımlamaktadır. Burada i,j konumsal farklılığı, u ve v ise yönü göstermektedir.

2.2.2. Histogram

Doku tanımlama için en basit yaklaşımlardan birisi de bir görüntü veya bölgenin histogramının istatistiksel momentlerini kullanmaktır. Histogramdan elde edilen 1.derece istatistikler;

Ortalama; görüntünün bir parçası içerisinde bulunan tüm piksellerin renk değerlerinin ortalamasını belirten özelliktir. Görüntünün genel ortalama piksel renk değeri hakkında bilgi verir.

$$\mu = \sum_{i=0}^{L-1} z_i p(z_i) \quad (2.2)$$

L gri seviye sayısını, z_i gri seviye değerini, $p(z_i)$ ise histogram değerini göstermektedir.

Varyans; bağıl düzgünlüğün tanımlayıcılarını oluşturmak için kullanılan gri seviye farklılığının bir ölçüsünü verir. Standart sapma ($\sigma(z)$) dokunun gri değer seviyeleri bakımından ne kadar değişkenliğe sahip olduğunu göstermektedir. Görüntüde bulunan piksel renk değerlerinin (gri seviye değerlerinin) o görüntünün hesaplanmış olan ortalama gri seviye değerinden ne kadar saptığı (değişim gösterdiği) hakkında bilgi verir. Doku karşılaştırmada sıklıkla kullanılan bir ölçüttür.

$$\sigma^2 = \sum_{i=0}^{L-1} (z_i - \mu)^2 p(z_i) \quad (2.3)$$

denklemleriyle ifade edilir.

Çarpıklık (Skewness, Üçüncü Moment); Sola (negatif değer) veya sağa (pozitif değer) yaslanmış olabilen histogramların simetri derecesini belirlemede kullanılır. Bu, gri değer seviyesinin ortalamadan karanlık veya parlak tarafına doğru yönelmiş olması durumu hakkında kaba bir fikir verir. Doku anlamında üçüncü momentten elde edilen bilgi, ölçümler arasındaki sapmalar büyük olduğunda daha kullanışlıdır. Normal dağılıma sahip bir veri setinin çarpıklık değeri sıfırdır.

$$\mu_3 = \sum_{i=0}^{L-1} (z_i - \mu)^3 p(z_i) \quad (2.4)$$

denklemleri çarpıklığın hesaplanmasında kullanılır.


Basıklık(Kurtosis); görüntülerdeki piksel gri seviyelerinin grafiksel dağılımı hakkında bilgi verir. Grafik gösteriminin basık veya sivri olması ile ilgilidir. Normal dağılıma sahip değerlerin istatistiksel olarak basıklık değerleri sıfıra yakın bir değer almaktadır. Değerlerin basıklık değeri pozitif ise, grafik dağılımının şekli sivri, negatif ise grafik dağılımı düz/basık bir görünümde olur.

$$\mu_4 = \sum_{i=0}^{L-1} (z_i - \mu)^4 p(z_i) - 3 \quad (2.5)$$

denklemini ile ifade edilir.


2.2.3. Gri seviye eş-oluşum matrisi (GLCM)

Sadece histogramlar kullanarak belirlenen dokunun ölçümleri, piksellerin her birinin bir diğeri ile ilişkili konumuna ait bilgiyi taşımaz. Bu durum dokuyu tanımlamada önemlidir. Doku analizinde yalnızca gri seviye dağılımı değil, aynı zamanda görüntüdeki ilgili piksel konumlarını da dikkate almak gereklidir. Gri seviye eş-oluşum matrisi piksellerin belirlenen konum operatörüne ve yönüne göre konumsal bağımlılığını gösteren matristir (Şekil 2.2).



Şekil 2.2. Gri seviye eş-oluşum matrisinin oluşturulması (URL-1)

Şekil 2.2’de 8 adet gri seviyeye sahip bir görüntü parçasından (solda) oluşturulan eş-oluşum matrisi (sağda) gösterilmektedir. Konum operatörü olarak Şekil 2.3’de gösterilen yönlerden 0 derece (yatay) ve bir piksel komşuluğu ölçüt olarak seçilmiştir. Eş oluşum matrisinin boyutunu görüntünün gri seviye değerleri belirler. 256 farklı gri seviyeye sahip bir görüntüden oluşturulan eş-oluşum matrisi 256 x 256 boyutunda olacaktır. Ancak belirli durumlarda artan hesapsal yükün azaltılması için 256 farklı gri seviye değeri normlandırılarak eş-oluşum matrisinin boyutu küçültülebilmektedir.



Şekil 2.3. Eş oluşum matrisi oluşumunda yön bilgileri (URL-1)

Doku analizi için gri seviye eş-oluşum matrisinden elde edilen ikinci derece istatistikler kullanılır. Bunlar;

Maksimum Olasılık; Gri seviye eş-oluşum matrisinin en güçlü cevabını ölçer.

Korelasyon; Bütün bir görüntü boyunca bir pikselin kendi komşusuyla nasıl ilişkili olduğunun bir ölçüsüdür. Tam pozitif veya tam negatif korelasyona bağlı olarak değer aralığı 1 ve -1 arasındadır.

$$\text{Korelasyon} = \sum_{i,j=1}^n \frac{(1 - \bar{x}_i)(1 - \bar{x}_j)p(i,j)}{\sigma_i \sigma_j} \quad (2.6)$$

Denklemde i,j görüntüdeki piksel konumlarını, $p(i,j)$ ise bileşik durum olasılık yoğunluk fonksiyon değerini, $\bar{x}_i, \bar{x}_j$ piksel değerlerinin ortalamasını ve σ ise standart sapma değerlerini göstermektedir.

Kontrast; Görüntüdeki bir piksel ve komşusu arasındaki gri değer zıtlığının bir ölçüsüdür.

$$\text{Kontrast} = \sum_{i,j=1}^n |i-j|^2 p(i,j) \quad (2.7)$$

Enerji; $[0,1]$ aralığında benzerliğin bir ölçüsüdür. GLCM elemanlarının karesel toplamları ile elde edilir. Benzerlik sabit bir görüntü için 1'dir.

$$\text{Enerji} = \sum_{i,j=1}^n p(i,j)^2 \quad (2.8)$$

Homojenlik; Gri seviye eş-oluşum matrisindeki elemanların dağılımının köşegene olan konumsal yakınlığı ölçer.

$$\text{Homojenlik} = \sum_{i,j=1}^n \frac{p(i,j)}{1 + |i-j|} \quad (2.9)$$

Entropi; Değişkenliğin (belirsizliğin) bir ölçüsüdür. Sabit bir görüntü için sıfırdır. Eş-oluşum matrisinin bütün elemanları sıfır olduğunda entropi sıfır ve bütün elemanlar eşit olduğunda da entropi maksimum değerini alır.

$$\text{Entropi} = \sum_{i,j=1}^n -\ln(p(i,j)) p(i,j) \quad (2.10)$$

şeklinde hesaplanmaktadır.

2.3. Model Tabanlı Yöntemler

Model tabanlı yöntemler görüntülerde bulunan dokuyu tanımlamak için matematik modeller ve dokuyu çıkarmak amacıyla uygulanacak analizin model parametrelerini kullanırlar. En çok kullanılan model tabanlı yaklaşımlar; Otoregresyon modeli, Markov Rastgele Alan modeli, Gibbs Rastgele Alan modeli ve Fraktallardır.

2.4. Dönüşüm Tabanlı Yöntemler

Dönüşüm tabanlı teknikler, Fourier ve Dalgacık (Wavelet) dönüşümü, frekans uzayındaki yüksek enerjili, dar tepeleri tanımlayarak görüntüdeki global periyodiklikleri algılamak için kullanılır (Gonzales ve Woods, 2014). Doku analizindeki dönüşüm tabanlı yaklaşımlar görüntüyü dokunun karakteristikleriyle yakından ilişkili olan uzay koordinat sistemine (boyut ve frekans gibi) dönüştürerek yorumlarlar. Dönüşüm tabanlı yaklaşımların ana avantajı konumsal bilgiye ek olarak frekans bilgisinin de kullanılabilir olmasıdır (Chaurasia ve Garg, 2013). Sayısal görüntülerde bulunan gürültü değerleri görüntünün içerisinde bulunduğu konumsal uzayda belirgin değişikliklere sebebiyet vermektedir, frekans uzayında ise bu etkiler hemen hemen benzer dağılımlı bir davranış göstermektedir. Frekans uzayı, konumsal uzaya göre gürültü değerinin göstermiş olduğu bozucu etkilerden daha az etkilenmektedir. Fourier dönüşümü, Gabor dönüşümü ve Dalgacık dönüşümü gibi teknikler frekans uzayının oluşturulmasında genellikle kullanılan yöntemlerdir. Görüntüler içerisinde bulunan doku özelliklerinin tespit edilebilmesi için çoklu çözünürlüklü bir ayrıştırma tekniği olan dalgacık dönüşümü kullanılmaktadır. Bu teknik bir görüntüyü farklı bir konumsal frekanstaki alt görüntülere hiyerarşik bir

şekilde dönüştürmektedir. Bu dönüşüm görüntünün iki boyutlu frekans uzayını, alçak ve yüksek geçiren filtreleme tekniği kullanarak alçak ve yüksek geçiren alt görüntülerine dönüştürür. Görüntü içerisinde bulunan doku öznelikleri değişik frekans kanalları ve çözünürlük seviyelerine dönüştürülen bu görüntülerden tespit edilir (Baştürk ve diğ., 2006).

Dalgacık dönüşümünün avantajları;


- Dokunun en iyi şekilde belirlenebileceği ölçeğin seçilebilme imkanı,
- Çeşitli doku analizi uygulamaları için kullanılabilecek olan en uygun dalgacık dönüşümü fonksiyonunun çokluğu (Materka ve Strzelecki, 1998).

2.4.1. Fourier dönüşümü

Fourier dönüşüm yöntemi doku analizi için sıklıkla başvurulanan yöntemlerden birisidir. Çünkü bu yöntem genellikle yarı tekrarlı örüntü içeren görüntü özelliklerini tanımlamaya en uygun periyodik fonksiyondur. Fouier dönüşümü ideal olarak bir görüntüdeki periyodik veya yarı periyodik iki boyutlu örüntünün yönselliğini tanımlamak için uygundur. Fouier dönüşümü sonrası elde edilen spektrumdaki değerler görüntüdeki örüntünün baskın yönünü belirler ve bunların frekans domainindeki dağılımları doku ile yakından ilişkilidir. Genel doku örüntüleri spektrumdaki yüksek enerji patlamaları yoğunlukları gibi kolaylıkla ayrıştırılabilirler. Bu özellikler sebebiyle Fouier dönüşümü doku analizinde önemli bir rol oynar. Burada, doku tanımlama için kullanılabilecek üç Fourier spektrumu özelliği düşünülebilir: (1) Spektrumdaki belirgin tepeler doku örüntülerinin ana yönünü verir. (2) Frekans düzlemindeki tepelerin konumu örüntülerin ana konumsal periyodunu tanımlar. (3) Süzgeçleme yoluyla herhangi bir periyodik bileşeni yok etme, daha sonra istatistiksel tekniklerle tanımlanabilecek periyodik olmayan görüntü bileşenlerinin kalmasına yol açar. Fouier dönüşümünün; baskın konumsal dağılımın gösterilmesi, gürültüden daha az etkilenmesi gibi önemli özellikleri vardır. Fouirer dönüşüm yönteminin olumsuz tarafı, düşük konumsal çözünürlük sağlamasıdır. Bu özellik pencereleme yöntemiyle aşılmış ancak bu durumda işlem yükünü arttırmıştır (Chaurasia ve Garg, 2013; Gonzales ve Woods, 2014).

2.4.2. Wavelet (Dalgacık) dönüşümü

Dalgacık dönüşümü görüntüyü çeşitli alt ölçeklere ayırıştırarak doku analizinde kullanışlı ve popüler bir yöntemdir. Dalgacık dönüşümü, veriyi farklı frekans bileşenlerine ayıran ve daha sonra her bir bileşeni kendi ölçeği içerisinde işleyen matematiksel fonksiyonlardır. Dalgacık dönüşümü görüntüyü ayırıştırmak için alçak ve yüksek geçişli filtreleri kullanır. Dalgacık dönüşümü veriyi 4 alt bileşene ayırır; LL, LH, HL ve HH'dir. HH, HL ve LH yüksek frekans bilgileri içerir. LL ise düşük frekans bilgileri içerir. Oluşan 4 alt bileşende; HH köşegen detayları (her iki yöndeki yüksek frekansı, köşeleri), HL yatay yüksek frekansları (düşey kenarlar), LH düşey yüksek frekansları (yatay kenarlar) ve LL düşük frekansları temsil eder. İkinci seviye dalgacık dönüşümü LL bileşenine uygulanarak tekrar 4 alt bileşen elde edilir (Şekil 2.4).



Şekil 2.4. İki ve üç seviyeli dalgacık dönüşümü örnekleri (Materka ve Strzelecki, 1998)

Doku analizinde kullanılan yöntemlerin sağladığı avantajlar ve dezavantajları Tablo 2.1’de gösterilmektedir.

Tablo 2.1. Çeşitli doku analizi yöntemlerinin avantaj ve dezavantajları (Chaurasia ve Garg, 2013)

	Yöntem Türü	Doku Analizi Yöntemi	Avantajları	Dezavantajları
1	İstatistiksel	Otokorelasyon Fonksiyonu	Yerel renk değişimlerini ve dokunun tekrarlanabilirliğini bir arada gösterir	Doğal dokular için çok iyi bir ayırıcı değildir
		Histogram	Birinci derece istatistikleri değerlendirir, kolay uygulanabilir	Konumsal ilişkiyi belirleyemez
		Gri seviye Eş Oluşum Matrisi	İkinci derece istatistikleri değerlendirir	Düşük kontrastlı ve rastgele dokuların belirlenmesinde çok etkili bir yöntem değildir
2	Dönüşüm Tabanlı	Fourier	Yüksek periyodik dokular için uygundur	Kenarlar ve görüntü sınırları doku analizinin doğruluğunu etkileyebilir
		Wavelet	Yüksek periyodik dokular için uygundur. Çok ölçekli analiz yapmak mümkündür, gürültü etkisinden daha az etkilenme, düşük işlem yüküne sahiptir	Doğru dalgacığın seçim sorunu, kenarlaşmadan etkilenme
3	Model Tabanlı	Markov Rastgele Alan Modeli	Köşegenlik, gri seviye dağılımı ve keskinlik seçilen parametrelerle kontrol edilebilir	Düzenli dokular iyi modellenemez, geometrik olmayan doku öncülleri gerçek yüzeylerin doku görüntüleri için doğru modeller oluşturamaz
		Fraktallar	Ölçeklemeden etkilenmez, yüksek derecede düzensizlik içeren objeleri en iyi biçimde tanımlar	Bütün doku türlerinin segmentasyonu için uygun değildir
		Otoregresyon modeli	Düşey yönlü dokular için çok iyi çalışır	Yatay yönlü dokular için performansı kötüdür

Uydu görüntülerinin günümüzde konumsal çözünürlüğünün artmış olması, detay çıkarımında görüntü doku (texture) bilgisinin önemini arttırmıştır. Doku işleme için çok sayıda yöntem/yaklaşım geliştirilmiştir ve kantitatif anlamda konumsal (spatial) bilgi işlemenin spektral bilgi işlemeye nazaran daha güç/karmaşık olduğu bilinmektedir. Doku belirleme ile ilgili çalışmaların başlangıç yıllarında doku özellikleri daha çok istatistik anlamda incelenmiştir (eş-oluşum matrisleri, filtreleme tabanlı yaklaşımlar vb.). Bu yaklaşımlar benzer test ve örnekleme verilerine sahip veri setleri için başarılı sonuçlar üretmiş olsa da karmaşık yapı ve örüntüler için farklı sonuçlar alınmıştır. Bu nedenle veri yapısını (ölçek, dağılım, dönüklük, vb.) dikkate alan Local Binary Pattern (LBP), Local Edge Pattern (LEP), Histogram of Oriented Gradients (HOG) ve kenar yön çıkarımı gibi yeni bazı yöntemler de önerilmiştir.

Bütün bu yeni geliştirilen yöntemlerin yanı sıra uzaktan algılama uygulamalarında bir süredir kullanılan geoistatistiksel yöntemler görüntü piksellerinin içerdiği renk bilgilerinin (spektral bilgi) yanısıra konum bilgilerini de kullanarak elde edilmek istenen bilgiye göre kullanılan çeşitli analiz yöntemlerinde etkili sonuçlar vermeyi başarmıştır. Geoistatistik, genel istatistik yöntemlerin örnekler arasındaki ilişkiyi belirleme yöntemlerinden farklı olarak, veri setindeki örneklerin konum bilgilerini de değerlendirerek hesaplama işlemini gerçekleştirir. Bu yüzden klasik istatistik yöntemlerden ayrılır. Yöntemin temelleri; fonksiyonlar teorisindeki durağan rastlantı hipotezine (stationary hypothesis) dayanan istatistiksel hesaplama yöntemidir. Ortaya çıkan hata miktarını belirli bir güven seviyesinde belirleyebilmesi bu yöntemlerin en büyük avantajıdır. Geoistatistik yöntemler, ilk olarak gözlem verilerinin deneysel varyans yapısının belirlenmesi, daha sonra bu yapıya teorik bir modelin uydurulması ve model parametrelerinin elde edilmesi şeklinde çalışmaktadır.

Geoistatistik analiz teknikleri, görüntülerde bulunan doku bilgisinin nicel anlamda belirlenmesinde, hesap yükü göz ardı edilirse, önemli ve etkin bir araç olarak ortaya çıkmıştır. Görüntülerin doku özelliklerinin tanımlanması için piksellerin konumsal dağılımının/örüntülerinin analiz edilmesi ve doğrusal konumsal ilişkilerin tanımlanmasında geoistatistikten yararlanılmaktadır.

3. KONUMSAL DOKU ANALİZİ

3.1. Mekansal İstatistik

Mekansal kelimesinin anlamı, veri setindeki her bir datanın, ilgili koordinat sistemi içerisinde nerede bulunduğunu bilinmesini sağlayan coğrafi bir referansa sahip olması demektir. Farklı mekansal alanlarda tanımlı olan değişkenler birbirleri ile ilişkili olduğundan her zaman bağımsız olmamaktadırlar. Bu sebepten ötürü bu tür verilerin analizinde, bağımlı değişkenlerin analizini yapmayı sağlayan yöntemlere ihtiyaç duyulmaktadır. Mekansal verinin içerisinde bulunan mekansal bağımlılık varsayımı nedeniyle mekansal istatistik, klasik istatistik yöntem ve tekniklerini kullanmaz. Klasik istatistikte olduğu gibi, mekansal veri için tanımlayıcı ve çıkarımlı yaklaşımlara sahip olmakla birlikte kendine özgü yöntem ve tekniklere sahiptir.

1980 ve 1990’larda mekansal istatistik, istatistik bilim dalının bir alt dalı olarak kabul görmeye başlamıştır. 1990’lar öncesinde çoğu mekansal modelleme, doğrusal regresyon modelinde yapılan bazı değişikliklere dayalı iken, 1990’lardan itibaren mekansal verinin modellenmesi alanında Bayes yaklaşımı da kullanılmaya başlanılarak, mekansal bağımlılığın etkilerini modelleme de farklı yollar ortaya çıkmıştır.

Mekansal istatistik; olasılık teorisini dayanak alarak geliştirilmiş bir analiz yöntemidir. Mesafe, uzunluk, alan gibi verinin konumuna bağlı özelliklerin dağılımını ve ilişkilerini inceler. Mekansal verileri belirlemek ve modelleyebilmek için çeşitli tekniklerden oluşan yöntemler bütünüdür. Veri setinin mekansal modellerini, dağılımlarını, eğilimlerini ve ilişkilerini çeşitli yönlerden analiz etmeyi sağlar. Mekansal istatistiksel teknikler, uzay-alan, uzunluk, yakınlık, dağılım, yönelim veya mekansal ilişkileri belirleyebildikleri için çeşitli uygulamalarda yoğun olarak tercih edilerek kullanılırlar.

Mekansal istatistiğin amacı, veri seti içerisindeki nitelik değerlerinde bulunan mekansal farklılığı belirlemek ve diğer nitelikler bakımından değişkenliğin mekansal

örüntüsünü ortaya çıkarmaktır. Mekansal değişim, veri setindeki yüksek veya düşük değerlerin kümelerini ve yığılmalarını belirlemede kullanılan özellikleri belirlemek olarak tanımlanır. Mekansal değişim belirlendikten sonra analizdeki bir sonraki adım, üzerinde çalışılan veri setinin belirli alanlarının neden yüksek veya düşük değerlerin bir kümelenmeye veya yığılmaya sahip olduklarını anlamaya çalışmaktır. Geoistatistik gibi bazı mekansal analiz alanlarında ise amaç, henüz örneklendirilmemiş konumlardaki özellik değerlerinin tahminlerini de elde etmektir.

Veri setlerinin kendi içindeki dağılımları değişik şekillerde olabilir. Rastgele dağılım gösteren noktalardan oluşan veri setleri, tesadüfe dayalı bir dağılım gösterir ve birbirinden tamamen bağımsızdır. Düzenli noktalardan oluşan veri setleri, rastgele olanlara göre neredeyse birbirlerine eşit uzaklıktaki mesafelerde bulunurlar. Kümelenmiş noktalardan oluşan veri setleri ise kendi aralarında benzer özellik gösteren gruplardan oluşur ve rastgele olanlara oranla birbirlerine daha yakındırlar.

Mekansal istatistiğin çok geniş uygulama alanları vardır ve bir çok farklı alanla ilgilidir. Çeşitli konularda çalışılan uygulamalarda, mekansal bir yapıya sahip ya da mekansal veri içeren problemlerle sık sık karşılaşmaktadırlar. Mekansal analiz için; ortalama merkez, ağırlıklandırılmış ortalama merkez, medyan merkez, standart uzaklık, standart sapma elipsi gibi çeşitli analiz yöntemleri geliştirilmiştir.

3.1.1. Ortalama merkez

Ortalama merkez, mekansal dağılımın çekim merkezi olarak kabul edilebilir ve veri seti için coğrafi merkezi tanımlar. Veri setinin dağılımının zamana göre hangi yönde hareket ettiğini belirleyebilmektedir. Veri setinin dağılımının merkezi eğiliminin belirlenmesinde kullanılır.

Ortalama merkez, veri setinde bulunan her bir verinin x ve y koordinatlarının aritmetik ortalaması alınarak hesaplanır. Bu iki ortalama koordinat değeri, ortalama merkezin konumunu belirtmektedir. Ortalama merkez;

$$\bar{x} = \frac{\sum x}{n}, \quad \bar{y} = \frac{\sum y}{n} \quad (3.1)$$

formülleri ile hesaplanmaktadır. Burada x ve y veri setine ait noktaların koordinatlarını, $\bar{x}$ ve $\bar{y}$ sırasıyla x ve y nokta koordinatlarının ortalama değerlerini ve n ise veri setinde bulunan nokta sayısını göstermektedir.

3.1.2. Ağırlıklandırılmış ortalama merkez

Ortalama merkezin hesaplanmasında veri setine ait her bir noktanın ağırlık değeri eşit kabul edilmektedir. Ancak bazı durumlarda, dağılımın merkezinin hesaplanmasında her bir noktanın eşit ağırlığa sahip olamayacağı açıkça görülmektedir.

Dağılıma ait ağırlıklandırılmış ortalama merkezi, her bir veri seti noktası için x ve y koordinatlarının, bu noktalara atanmış olan ağırlıkları ile çarpılmasıyla hesaplanabilir. Ağırlıklandırılmış olan x ve y koordinatlarının ortalaması, ağırlıklandırılmış ortalama merkezin konumunu belirtmektedir. Ağırlıklandırılmış ortalama merkez;

$$\bar{x}_w = \frac{\sum wx}{\sum w}, \quad \bar{y}_w = \frac{\sum wy}{\sum w} \quad (3.2)$$

denklemleri ile hesaplanmaktadır. Burada x ve y noktaların koordinatları iken, $\bar{x}_w$ ve $\bar{y}_w$ bu koordinatların ağırlıklandırılmış ortalamalarını ve w ise her bir noktaya atanmış ağırlık değerlerini göstermektedir. Ortalama merkez sadece noktaların dağılımının ağırlık merkezini verebilirken, ağırlıklandırılmış ortalama merkez ağırlıkların sunmuş olduğu karakteristiklerin dağılımının da ağırlık merkezini vermektedir.

3.1.3. Medyan merkez

Medyan merkez, her iki tarafta da aynı sayıda nokta bulunacak şekilde iki dik eksen birbirinden ayıran ara kesitin noktalara olan Öklid mesafesini en aza indirgeyen konumunu belirtir. Medyan merkezinin avantajı, veri setinde bulunan noktaları saymaktan başka herhangi bir matematiksel işleme gereksinim duymadan konumu hızlıca belirlenebilmektedir. Dezavantajı ise konumu nokta dağılımını bölmek için kullanılan iki eksen çizgisinin yönlendirmesine bağlıdır.

3.1.4. En kısa yol merkezi

En kısa yol merkezi, bir dağılım içindeki tüm noktalara olan uzaklıkların toplamının minimum olduğu noktadır. Bu merkezin konumu, deneme yanılma yoluyla elle açık bir şekilde bulunabilir. Birkaç alternatif deneme konumlarının seçilmesi ve her bir deneme merkezinin tüm noktalara olan uzaklıklarının toplamının hesaplanması ile doğru en kısa yol merkezi bulunabilir. Çoğu durumda ortalama merkez, medyan merkez ve en kısa yol merkezi birbirlerine oldukça yakındır. Bu nedenle ortalama merkez ve medyan merkez, en kısa yol merkezinin bulunmasında bir başlangıç noktası olarak kullanılmaktadırlar.

3.1.5. Standart uzaklık

Standart uzaklık, veri seti içerisinde bulunan noktaların geometrik ortalama merkezi çevresinde yoğunlaşma veya dağılma derecesini ölçer ve standart sapmanın mekansal karşılığıdır. Standart uzaklık için en basit denklem;

$$\text{Standart Uzaklık} = \sqrt{\frac{\sum d^2}{n}} \quad (3.3)$$

şeklindedir. Burada d her bir noktanın ortalama merkezden olan uzaklığını ve n ise noktaların sayısını göstermektedir.

Standart uzaklığın hesaplanmasında dikkat edilmesi gereken hususlardan bir tanesi, bir dağılım içindeki ortalama merkezden çok uzak olan uç noktalardan aşırı derece etkilenmesidir. Standart uzaklık, veri setinde bulunan noktaların dağılımını tek bir değer ile belirttiğinden dolayı nokta örüntülerde saçılımın kullanışlı bir ölçütüdür, ancak farklı yönlerde farklı olacak ortalama merkez ile ilgili dağılımın etkisini hesaba katmamaktadır.

3.1.6. Standart sapma elipsi

Standart sapma elipsi, veri setini oluşturan noktaların coğrafi özelliklerinin merkezi eğilim, dağılım ve yön eğilimleri gibi mekansal özelliklerini ortaya çıkarmak için oluşturulur. Verilerin merkezi ve yönsel eğilimlerini, dağılımlarını ifade etmeyi sağlayan mekansal istatistik göstergesidir. Standart sapma elipsinin şekli ve boyutu dağılımın derecesini belirtirken, eksen durumları da verilerin üzerindeki yönelim

özelliklerini göstermektedir. Mekansal veriler için standart sapma elipsinin belirlenmesinde dört değerden faydalanılır. Bunlar; (1) Ortalama merkez, (2) Birincil eksen uzunluğu, (3) İkincil eksen uzunluğu ve (4) Birincil eksen açısıdır. Maksimum saçılım yönündeki birincil eksen ve minimum saçılım yönündeki ikincil eksen ve ortalama merkez elipsin merkezi olacak şekilde yerleştirilir (Tosunoğlu, 2007; Tat, 2008; Eryılmaz, 2010; Bozoğlu, 2014; Duran, 2018).

3.1.7. Kuadrat analizi

Kuadrat analizi veri setinin oluşturan noktaların mekansal dağılımının analiz edilmesi amacıyla geliştirilmiş bir yöntemdir. Bu analiz yöntemi, veri setini oluşturan çalışma alanını birbirine eşit büyüklükte alanlara –bu alanlar kuadrat olarak adlandırılır- bölerek her kuadrat içinde bulunan nokta sayısının dağılımının, teorik ya da kurgusal dağılımlar ile karşılaştırılmasına dayanmaktadır. Kuadrat analizinin çalışma prensibinde ilk aşama çalışma alanının eşit büyüklükte alanlara ayrılmasıdır. Bu alanlar genellikle kare ya da dikdörtgen biçimlidir. Ancak daire, beşgen veya altıgen gibi geometrik şekillerde de olabilmektedirler. Yapılması planlanan kuadrat analizinde çalışma alanının eşit parçalara bölünerek elde edilmiş olan tek bir kuadratin alanı;

$$K = \frac{2A}{n} \quad (3.4)$$

formülü ile belirlenir. Burada K, kuadratin alanını; A, toplam çalışma alanı boyutunu; n ise nokta gözlem sayısını göstermektedir. Kuadrat analizinin amacı; çalışma alanının eşit büyüklüklerde bölgelere ayrılarak oluşturulan kuadrların içerisinde bulunan nokta sayılarına göre noktasal örüntünün kümelenmiş, rastlantısal veya dağınık olup olmadığının araştırılmasıdır.

3.1.8. En yakın komşuluk analizi

En Yakın Komşuluk analizi, bir nokta veri setinin mekansal dağılımını incelemek için geliştirilmiş bir analiz yöntemidir. Yöntemin çalışma prensibinde ilk olarak, veri setindeki her bir noktanın en yakın komşuları belirlenir ve bu noktalara olan mesafeler belirlenir. Daha sonra bu mesafelerin ortalaması alınarak gözlemlenen ortalama mesafe değeri $\bar{D}_0$ belirlenir;

$$\bar{D}_O = \frac{\sum_{i=1}^n d_i}{n} \quad (3.5)$$

d_i , bir i noktasının en yakın komşusuna olan mesafe değerini, n ise veri setindeki toplam nokta sayısını ifade etmektedir. Gözlemlenen mesafe değeri belirlendikten sonra olması beklenen ortalama mesafe değeri $\bar{D}_E$ hesaplanır. Bu hesaplama;

$$\bar{D}_E = \frac{1}{2\sqrt{n/A}} \quad (3.6)$$


formülü ile gerçekleştirilir. Burada n yine veri setindeki toplam nokta sayısını, A ise noktaların bulunduğu toplam alanı belirtir. Hesaplanan bu iki mesafe değerinin bir birine oranlanmasıyla ortalama en yakın komşuluk oranı ANN belirlenir;

$$ANN = \frac{\bar{D}_O}{\bar{D}_E} \quad (3.7)$$

ANN değerinin 1'den büyük çıkması, veri setine ait olan mekansal dağılımın dağınık olduğunu belirtmektedir. Bu değer 1'den küçük çıkması, mekansal dağılımın kümeleşme eğiliminde olduğunu göstermektedir. 1'e yakın olduğu durumda ise veri setinin mekansal dağılımının rastlantısal olduğu sonucuna varılır (Şekil 3.1). En yakın komşu analizinde, sıfır hipotezinin kontrol aşamasında Z istatistiği kullanılabilir.

3.1.9. Ripley K fonksiyonu

Ripley'in K fonksiyonu, veri setindeki noktalara olan farklı mesafe değerleri dikkate alındığında, gözlemlenen nokta veri dağılımının hangi türde olduğunun belirlenmesinde kullanılan bir analiz yöntemidir. Veri setini oluşturan noktalar kümeleşmiş, rastlantısal ve dağınık türde dağılıma sahip olabilirler. Ripley'in K fonksiyonunda, her noktadan belirli bir mesafedeki diğer noktaların konumları dikkate alınır (Gayır ve Arslan, 2018).



Şekil 3.1. Mekansal dağılımın gösterimi (URL-2)

3.2. Geoistatistik Analiz

Doku, genel anlamda uydu görüntüleri de olmak üzere dijital görüntü işleme alanında büyük ilgi gören görüntünün görsel bir özelliğidir. Konumsal etki alanı içerisindeki renk tonu varyasyonlarını temsil eder ve görüntünün genel görsel özelliklerini belirtir. Doku, görüntüdeki nesnelerin düzenlenmesi ve görüntü içindeki

konumsal ilişkileriyle ilgili önemli bilgiler sağlar; bu da, görüntü yorumlama ve arazi örtüsü sınıflandırması gibi uygulamalar için büyük bir bilgi kaynağıdır (Chica-Olmo ve Abarca-Hernandez, 2004).

Uzaktan Algılanmış görüntülerdeki doku gri değerlerin konumsal değişkenliği ile yakından ilişkilidir. Bu nedenle uzaktan algılanmış görüntülerdeki doku bilgisini belirlemek için bir piksel ile onun komşusu arasındaki spektral bağımlılığı göz önüne alan ve bu piksellerin konumsal bilgilerini kullanan geoistatistiksel analizler (variogram) potansiyel bir tanımlayıcı olarak kullanılabilir. Bu özelliğinden dolayı variogramlar, uzaktan algılama uygulamalarında sıklıkla kendisine yer bulmaktadır. Doku ölçütleri yardımıyla yapılan görüntülerdeki konumsal değişkenliğin karakterizasyonu, görüntüde bulunan objeler (arazi sınıfları, arazi örtüleri v.b) ve bunların konumsal ilişkileri hakkında önemli bilgiler sağlamaktadır (Chica-Olmo ve Abarca-Hernandez, 2000; Rodríguez-Galiano ve diğ., 2011; Fotsing ve diğ., 2013). Uzaktan Algılama verilerine uygulanan geleneksel piksel tabanlı spektral sınıflandırma yöntemleri pikseller arasındaki yararlı konumsal bilgiyi yok sayarak çalışmaktadır. Konumsal bilgi çıkarımı büyük oranda araştırılıp, bu konuda yöntemler geliştirilmesine rağmen, görüntü sınıflandırmayı geliştirmek için spektral ve konumsal bilginin bir arada kullanıldığı yöntemlerin uygulaması sınırlı olarak kalmıştır. Bu durumda görüntüde bulunan bir pikselin komşularından bağımsız olmayacağı ve ayrıca bu bağımlılığın belirlenerek sınıflandırma işlemine yardımcı olacak bir tanımlayıcı olarak katılabileceği göz ardı edilmemelidir (Wijaya ve diğ., 2008).

Klasik istatistik yöntemlerin en basit anlamdaki problemi, verilerin birbirlerinden bağımsız olduğunu varsaymasıdır. Düzenli bir grid yapısında dağılmış olan piksel değerleri için tam istatistiksel bağımsızlığın elde edilmesi olası değildir. Özellikle birbirlerine komşu olan piksellerdeki yansıma değerlerinin benzer olması muhtemeldir. Eğer bir pikseldeki yansıma değeri büyükse komşusundaki yansıma değerinin de büyük olması beklenir. Birbirlerine yakın olan gözlemlerin, birbirlerine uzak olan gözlemlerden daha benzer olması olarak tanımlanan konumsal bağımlılık, klasik istatistiklerin bağımsızlık varsayımını geçersiz kılmaktadır (Atkinson, 2002).

Semivariogram, semivaryans değerleri ile örnekleme mesafesini birbirleriyle ilişkilendiren bir fonksiyondur. Bu fonksiyon kullanılan veri setindeki her bir bileşenin komşusu ile olan konumsal bağımlılığını bir grafik şeklinde gösterilebilmesini sağlar (Curran, 1988). Semivariogram konumsal değişimin değeri ve yapısı hakkında detaylı bilgiler verir. Durağan hipotezinin (stationary hypothesis) geçerli olduğu durumlarda çalışma bölgesine ait olan veri setinin konumsal değişiminin ve otokorelasyonunun büyüklüğünü araştırmak için kullanılır. Semivariogramlar lokal değişkenlerin konumsal değişimini gösterirler. Uydu görüntülerinde her piksele ait gri seviye değeri (renk değeri) o piksele ait olan yer koordinatı ile ilişkilendirilebildiği için yerel değişimlerden bahsetmek mümkün olmaktadır. Bu nedenle uzaktan algılanmış görüntülerdeki konumsal değişimi belirleyebilmek için semivariogramlar etkin bir yöntem olarak kullanılabilir (Kaya ve Sertel, 2006). Bir uydu görüntüsünün herhangi bir bandındaki spektral değerler gibi sürekliliğe sahip bir veri setinde farklı pikseller arasındaki konumsal bağımlılığın derecesini belirleyebilmekte oldukça kullanışlıdır (Durrieu ve diğ., 2005; Ruiz ve diğ., 2007).

Deneysel semivariogramın hesaplanmasında;

$$\gamma(h) = \frac{1}{2N} \sum_{i=1}^N [Z(x_i) - Z(x_i+h)]^2 \quad (3.8)$$

formülü kullanılır. Bu formül uzaktan algılanmış görüntülerde kullanıldığında N görüntü üzerindeki toplam nokta çifti sayısını, $Z(x_i)$ görüntünün belirli bir x_i noktasındaki gri renk değerini (DN), $Z(x_i+h)$ ise belirlenen h mesafesindeki (lag distance) gri renk değerinin temsil etmektedir. γ değeri konumsal olarak birbirlerinden ayrı olan piksellerin arasında bulunan farklılıkları gösterebilmek için kullanılan önemli bir özelliktir. Bu değer yüksek olması piksellerin birbirlerine daha az benzediği anlamına gelmektedir (Kaya ve Sertel, 2006).

Görüntülerdeki gri değerlerin konumsal dağılımı çeşitli yönlerde bağımlılık (isotropy) oluşturabilirler. Bu gibi durumlarda dikkat edilmesi gereken konulardan bir tanesi de variogramların belirli yönlerde hesaplanabilir olmasıdır (Chica-Olmo ve Abarca-Hernandez, 2004). Karşılaştırılabilinecek bu gibi durumlarda 4 ana yönde

hesaplanan variogramlar kullanılır. Bunlar; Yatay (0^0), Düşey (90^0), ve iki köşegen (45^0 ve 135^0) yönleridir.

Yatay (0^0) yöndeki semivariogram;

$$\gamma(h) = \frac{1}{2(N \times (M-h))} \sum_{i=1}^N \sum_{j=1}^{M-h} [Z(i,j) - Z(i,j+h)]^2 \quad (3.9)$$

Düşey (90^0) yöndeki semivariogram;

$$\gamma(h) = \frac{1}{2((N-h) \times M)} \sum_{i=1}^{N-h} \sum_{j=1}^M [Z(i,j) - Z(i+h,j)]^2 \quad (3.10)$$


Köşegen 45^0 yönündeki semivariogram;

$$\gamma(h) = \frac{1}{2((N-h)(M-h))} \sum_{i=1}^{N-h} \sum_{j=1}^{M-h} [Z(i,j) - Z(i+h,j+h)]^2 \quad (3.11)$$

Köşegen 135^0 yönündeki semivariogram;

$$\gamma(h) = \frac{1}{2((N-h)(M-h))} \sum_{i=1}^{N-h} \sum_{j=1}^{M-h} [Z(i,j+h) - Z(i+h,j)]^2 \quad (3.12)$$

formülleriyle dört farklı yöndeki semivariogram değerleri elde edilebilir. Formüllerde kullanılan N ve M görüntünün piksel boyutları, h piksel mesafesi (lag distance), $Z(i,j)$ ise i ve j piksellerindeki gri renk değerini göstermektedir (Fotsing ve diğ., 2013).



Şekil 3.2. Semivariogram parametreleri

Şekil 3.2’de görülen semivariogram parametrelerinden; Nugget teorik eğrinin $h = 0$ noktasında düşey eksenini kestiği noktadır. Partial Sill (yapısal varyans) variogramın yapısal bileşenleri için düşey ölçek değeridir.

Tablo 3.1. Semivariogram terimleri, sembolleri ve açıklamaları (Curran, 1988)

Terim	Sembol	Açıklama
Lag Mesafesi	h	Örnek piksel çiftleri arasındaki mesafe
Sill	s	Maksimum semivaryans seviyesi
Range	a	Semivaryans seviyesinin maksimum seviyeye ulaştığı mesafe
Nugget	C_0	Model eğrisinin semivaryans eksenini kestiği nokta. Konumsal olarak bağımsız varyansı temsil eder.
Partial Sill	C	Sill değerinden nugget değerinin farkıdır

Range (etki uzaklığı) variogramın yatay uzaklığıdır. Bu uzunluktan sonra veriler artık birbirleri ile korelasyonsuzdur. Variogram ya da kovaryans değerleri bu uzunluktan sonra sabit kalır. Range’deki değişim interpolasyon değerinin de değişimine sebep olur. Mesafe (Lag distance) örnekleme noktaları arası ya da interpolasyon noktası ile örneklem noktaları arası yatay uzunluktur. Sill (eşik değer) variogram fonksiyonunun toplam düşey ölçek değeridir. Yaklaşık örneklem varyansına eşittir (Akyürek ve diğ., 2013). Sill değişkenliğin değerini gösterirken, Range değeri konumsal bağımlılığın veya homojenliğin bir ölçütü olarak kullanılabilir (Cohen ve diğ., 1990).

Semivaryans değerleri elde edildikten sonra semivariogramı en iyi temsil eden model ve parametrelerini belirleme işlemi gerçekleştirilir. Birçok model mevcuttur ancak sadece birkaçı sürekli verilerde kullanmak için daha uygundur. En çok kabul gören model çeşitleri Spherical (Küresel), Exponential (Üstel), Gaussian (Gauss), Lineer, Çembersel ve Pentaspherical modelleridir.

En basit, en yaygın olarak kullanılan ve $h \geq 0$ için tanımlanan variogram modeli küresel modeldir;

$$\gamma(h) = \begin{cases} C \cdot \left(\frac{3}{2} \left(\frac{h}{a} \right) - \frac{1}{2} \left(\frac{h}{a} \right)^3 \right), & 0 \leq h < a \\ C, & a \leq h \end{cases} \quad (3.13)$$

şeklinde gösterilir. Küresel model büyük mesafelerde korelasyonun sıfır olduğunu varsaymaktadır. Fakat bazı durumlarda, büyük mesafelerdeki korelasyonlar tamamen sıfır olmak yerine küçük değerler alabilmektedirler. Bu durumlara en uygun olan model ise $h \geq 0$ için kullanılan üstsel modeldir;

$$\gamma(h) = C \cdot \left(1 - \exp\left(\frac{-3h}{a}\right) \right) \quad (3.14)$$

formülüyle gösterilir.

Gaussian modeli; Gauss fonksiyonu normal bir olasılık dağılım eğrisi kullanarak veri setindeki değerlerin kısa mesafelerde birbirlerine benzer olduğu durumlarda daha etkili sonuçlar sunmaktadır. Model;

$$\gamma(h) = C \cdot \left(1 - \exp\left(-3 \left(\frac{h}{a}\right)^2\right) \right) \quad (3.15)$$

formülü ile gösterilir.

Lineer model;

$$\gamma(h) = \begin{cases} C \cdot \left(\frac{h}{a}\right), & 0 \leq h < a \\ C, & a \leq h \end{cases} \quad (3.16)$$

denklemlerle temsil edilir.

Çembersel model;

$$\gamma(h) = \begin{cases} C \cdot \left(1 - \frac{2}{\pi} \cos^{-1}\left(\frac{h}{a}\right) + \frac{2h}{\pi a} \sqrt{1 - \frac{h^2}{a^2}} \right), & 0 \leq h < a \\ C, & a \leq h \end{cases} \quad (3.17)$$

şeklinde ifade edilir.

Pentaspheical model;

$$\gamma(h) = \begin{cases} C \cdot \left(\frac{15}{8} \left(\frac{h}{a}\right) - \frac{5}{4} \left(\frac{h}{a}\right)^3 + \frac{3}{8} \left(\frac{h}{a}\right)^5 \right), & 0 \leq h < a \\ C, & a \leq h \end{cases} \quad (3.18)$$

formülü ile gösterilir (Bohling, 2005; Smith, 2016).

Yukarıda belirtilen matematik modellerde kullanılan semboller Tablo 3.1’de açıklanmıştır.

3.3. Konumsal Örüntü Analizi

Çalışma alanı içerisindeki veri setini oluşturan her konumsal gözlemin ya da veri noktasının bir değişken değeri ile temsil edildiği durumlarda, gözlemler/noktalar arasında bulunan ilişkiyi gösterir (Gayır ve Arslan, 2018). Konumsal korelasyon kavramı ilk olarak 1950 yılında ortaya atılmıştır. Konumsal gözlemlerin/nesnelerin özelliklerinin uzaklık ile ilişkili pozitif veya negatif olarak değerlendirmesi işlemi olarak da tanımlanabilir.

Konumsal otokorelasyon ölçüm ve analizleri, yapılacak olan analizin kapsamına veya ölçeğine göre değişiklik göstermektedir. Genellikle global ve yerel ölçek olarak ikiye ayrılmaktadır. Global ölçekte veri seti üzerinden oluşturulan konumsal bağımlılığa ait ağırlık matrisinin tüm elemanları konumsal otokorelasyonun değerlendirilmesine katılırken; yerel ölçekte ağırlık matrisindeki tüm değerler dikkate alınmaz, bir ya da birkaç ilişkili alansal birimler için konumsal otokorelasyon değerlendirmesi yapılır.

Konumsal otokorelasyon teknikleri ile verilerin benzer özellikleri taşıyıp taşımadığının belirlenmesi mümkündür. Konumsal otokorelasyon üç değişik şekilde ifade edilir;

- Pozitif Otokorelasyon: Birbirlerine yakın noktaların çalışma bölgesi içerisinde belirli yerlerde kümelenmeleri ve benzer özellikleri göstermesidir.
- Negatif Otokorelasyon: Veri setinde bulunan noktaların birbirlerine yakın mesafede bulunması fakat benzer özellik göstermemeleri.
- Sıfır Otokorelasyon: Noktalar arasında konumsal etkilere bağlı olarak bir bağlantının olması durumudur.

3.3.1. Konumsal otokorelasyon global ölçütleri

Konumsal otokorelasyonun global ölçütlerinde çalışma alanını oluştural veri setinin konumsal dağılımına ilişkin olarak tek bir indeks değeri ve tek bir Z-istatistiği hesaplanır. Veri setinin tümü için hesaplanan bu indeks değeri ve istatistiğe bağlı olarak örneklemin konumsal dağılımına ilişkin değerlendirme yapılır. En yaygın olarak kullanılan global ölçüt yöntemi Moran's I analiz yöntemidir.

3.3.1.1 Genel Moran's I indeksi

Çalışma alanı ve veri seti noktaları ile ilişkili sıralı veya belirli mesafelere sahip değerler arasındaki konumsal otokorelasyonu ölçen birkaç test bulunmaktadır. Bu testlerden bir tanesi 1950 yılında Moran tarafından geliştirilen Moran'ın mekansal otokorelasyon katsayısı (Moran indeksi) tekniğidir. Genel Moran's I indeksi (GMI) istatistiği, olayların konumları ve bu olaylarla ilişkili değerler temelinde konumsal otokorelasyon derecesinin ölçülmesi işlemidir. Moran's I istatistiği bir veri seti içerisindeki konumsal otokorelasyon veya dağılım derecesini tanımlar (Akyürek ve Arslan, 2018).

Moran's I istatistik değeri;

$$I = \frac{n}{S_0} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij}(x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.19)$$

denklemini ile hesaplanır. Burada x_i , i noktasına ait değişken değerini; x_j , j noktasına ait değişken değerini; $\bar{x}$, değişkene ait ortalama değerini; w_{ij} , i ve j değişkenleri arasındaki yakınlık ilişkisini veren konumsal ağırlığı, n toplam özellik sayısını ve S_0 tüm ağırlık değerlerinin toplamını temsil etmektedir.

Eşitlik (3.19) ile belirlenen Moran I indeks değeri,

$$E(I) = \frac{-1}{n-1} \quad (3.20)$$

denkleminle hesaplanan, beklenen indeks değeri ile karşılaştırılarak yorumlanır. $I > E(I)$ olması durumunda, gözlemlenen konumsal nokta veri setinde bulunan noktalarda kümelenme eğiliminin bulunduğu, başka bir ifadeyle benzer değişken

değerlerine sahip noktaların birbirlerine konumsal olarak yakın oldukları sonucuna varılır. $I < E(I)$ olması durumunda ise kümelenme eğiliminin oluşmadığı ve gözlemlenen konumsal nokta veri setinin dağınık bir dağılıma sahip olduğu sonucuna ulaşılır. $I \approx E(I)$ olması durumunda da veri setine ait noktaların rastlantısal olarak dağıldığı ve özniteliğe bağlı bir kümelenme eğiliminin gözlenmediği değerlendirilir (Gayır ve Arslan, 2018).

Global Moran's I istatistiği -1 ile +1 arasında değişebilmektedir. 1 değeri, tamamiyle pozitif bir konumsal otokorelasyonu, -1 değeri, tamamiyle negatif yönlü bir konumsal otokorelasyonun olduğunu göstermektedir. Elde edilecek olan 0 değeri ise konumsal raslantısallığı temsil eder.

3.3.2. Konumsal otokorelasyon yerel ölçütleri

Konumsal otokorelasyon global ölçütleri ile veri setinin konumsal dağılımı için tek bir değer hesaplanır. Ancak çeşitli durumlarda veri seti içerisinde bir birine benzeyen değişken değerlerine sahip noktaların oluşturdukları kümelerin konumlarının tespiti önemlidir. Böyle bir durumda veri setinin konumsal dağılımının genel bir incelemeye tutulması yerine ayrı ayrı değerlendirilmesi daha uygundur. Veri setini oluşturan her nokta bir için tek tek inceleme yapılarak her bir nokta için indeks değeri ve Z istatistiği hesaplanır (Gayır ve Arslan, 2018).

Yerel konumsal otokorelasyon (Local indicator of spatial analyses-LISA) özel bir alan ile birlikte tanımlanan komşuluk sınırları içerisindeki bir değişkene ait nokta etrafındaki benzer değerlerin konumsal kümelenmelerini belirlemektedir. Yüksek veya düşük değerlerin yerel kümelenmeleri ile sıcak ve soğuk noktaların varlığını göstermektedir. En çok tercih edilen konumsal otokorelasyon yerel ölçütleri Getis-Ord G^* ve Anselin Yerel Moran's I istatistiği yöntemleridir.

3.3.2.1. Getis-Ord G^* istatistiği

Getis-Ord G^* istatistiği, veri seti noktalarının benzer kümelenme eğilimlerinin bulunup bulunmadığının ve bu konumsal kümelerin yerlerinin tespitinde kullanılır. Getis-Ord G^* yöntemi veri setinde bulunan sıcak (hot spots) ve soğuk nokta (cold spots) değerlerin konumsal olarak hangi alanlarda kümelendiğini tespit eder.

İstatistiksel olarak hesaplanan Z skoru değerinin büyüklüğüne göre veri setinde bulunan yüksek/sıcak değerlerin kümelenmesi de o oranda yüksek olmaktadır. Diğer yandan Z skoru ne kadar küçükse düşük değerlerin kümelenmesi de o oranda fazla olmaktadır. Hesaplanan G^* değeri sıfıra yakınsa ilgili özelliğin komşuluğunda yüksek veya düşük değerlerin bulunmadığından bahsedilebilir (Akyürek ve Arslan, 2018; Gayır ve Arslan, 2018).

Getis- Ord G^* istatistiği;

$$G_i^* = \frac{\sum_{j=1}^n w_{ij}x_j - \bar{x} \sum_{j=1}^n w_{ij}}{S \sqrt{\left[\left(n \sum_{j=1}^n w_{ij}^2 \right) - \left(\sum_{j=1}^n w_{ij} \right)^2 \right] / (n-1)}} \quad (3.21)$$

formülü ile hesaplanır. Burada; n, veri setindeki nokta sayısını; x_j , j noktasına ait değişken değerini; w_{ij} , i noktası ve j noktası arasındaki yakınlık ilişkisini veren konumsal ağırlık değerini; $\bar{x}$, ilgili değişkene ait ortalama değeri göstermektedir. G^* istatistiğinin hesaplanmasında kullanılan S değeri;

$$S = \sqrt{\frac{\sum_{j=1}^n x_j^2}{n} - (\bar{x})^2} \quad (3.22)$$

denklemleri ile hesaplanır.

3.3.2.2. Anselin yerel Moran's I istatistiği

Moran's I indeksi, global ölçekte olup veri setinin dağılımının genel konumsal bağımlılık düzeyini belirlemektedir. Ancak çalışma alanı içerisinde veri seti noktalarının nerelerde kümelenmeler oluşturduğunu yerel olarak tespit edememektedir. Anselin Yerel Moran's I birbirine benzeyen ve benzemeyen değişkenlerin oluşturduğu kümelenmelerin tespit edilmesinde kullanılan yerel bir analiz yöntemidir. İstatistiksel olarak analiz sonucunda elde edilen değer yüksek ise; ilgili bölgenin komşuluğundaki konumlarda da yüksek veya düşük değerlerin kümelenmediği sonucuna ulaşılabilmektedir. Eğer sonuç değeri düşük çıkmış ise birbirine benzemeyen değerlerin bir araya gelerek kümelenmeler oluşturduğu anlamı taşımaktadır. Z skoru değeri de çıkan sonuç değerinin istatistiksel anlamlılığı hakkında bilgi vermektedir. Anselin Yerel Moran's I istatistiği;

$$I_i = z_i \sum_{j=1}^n w_{ij} z_j \quad (3.23)$$

şeklinde tanımlanır. Burada; n , veri seti içerisindeki nokta sayısını; w_{ij} , i ve j noktası arasındaki yakınlık ilişkisine göre konumsal ağırlık değerini temsil etmektedir. Farklı komşuluk ölçütlerine bağlı olarak tanımlanabilen (kesikli, sürekli v.b.) ve bütün noktalar arasındaki rölatif konum ölçüsünü veren bir konumsal ağırlık matrisi olarak düşünülebilir. z_i ve z_j ise i ve j noktalarına ait değişken değerinin ortalamadan sapmalarını verir. i noktası için değişken değerinin ortalamadan sapması, z_i değeri;

$$z_i = \frac{(x_i - \bar{x})}{\sigma} \quad (3.24)$$

denklemleri ile hesaplanır. Bu denklemlerde; x_i , i noktasına ait değişken değerini; $\bar{x}$, değişkene ait ortalama değerini; σ , değişken değerinin standart sapmasını belirtmektedir. Standart sapma değeri olan σ ise;

$$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} \quad (3.25)$$

şeklinde hesaplanır (Akyürek ve Arslan, 2018; Gayır ve Arslan, 2018).

3.3.3. Mekansal regresyon modelleme

Çoklu doğrusal regresyon modeli $y = X\beta + \varepsilon$ olarak gösterilmektedir. Bu modelde bulunan y , bağımlı değişken vektörünü; X , veri setine ait girdi değişkenler vektörünü; β , regresyon katsayısını ve ε , hata terimini belirtmektedir. Doğrusal regresyon modelinde gösterilen hata terimlerinin birbirinden bağımsız, sıfır ortalama ve sabit varyansla normal dağıldığı varsayılır ($\varepsilon \sim N(0, \sigma^2 I_n)$). Ancak bu hatalar içerisinde konumsal otokorelasyon barındırıyorsa bu varsayım geçerliliğini kaybeder. Elde edilmiş olan gözlemlerin bağımsız olması modeli büyük oranda kolaylaştırmaktadır. Ancak bu sadeleştirme, konumsal verilerde gözlenen hata terimlerindeki bağımlılık nedeniyle pek uygun değildir.

Konumsal bağımlılık, uzayda belirli bir noktada gerçekleşen olaylarla farklı bölgelerde meydana gelen olaylar arasındaki fonksiyonel ilişkinin varlığı olarak tanımlanabilir. Başka bir deyişle, bir değişkenin belirli bir konumda aldığı değer içsel şartlar tarafından açıklanmakla birlikte, komşu konumlarda aldığı değer tarafından da

açıklanabilmektedir. Konumsal bağımlılığın (otokorelasyonun) dikkate alınmaması durumunda verilerin gerçek varyansının tahmininde eksiklikler meydana gelir. Bu durum sonuçların tahmininde ve yorumlarında sorunlara sebep olmaktadır.

3.3.3.1. Genel en küçük kareler regresyonu (OLS)

Genel En Küçük Kareler regresyon yöntemi hata kareleri toplamını en küçük değerde tutmayı amaçlayan istatistiksel bir analiz yöntemidir. Bu analiz yöntemi, belirlenen verilerin normallik, sabit varyanslılık, sapan değer içermeme gibi çeşitli varsayımların sağlandığı durumlarda güvenilir tahminler oluşturmasını sağlamaktadır. Yaygın olarak kullanılan ve işlem kolaylığı sağlayan bir tahmin yöntemidir.

$$y = X\beta + \varepsilon \quad (3.26)$$

denklemleri ile ifade edilir. y bağımlı değişken vektörünü, X girdi veri seti değerlerini, β parametre vektörünü ve ε ise hata vektörünü göstermektedir.

β vektörü;

$$\hat{\beta} = (X^T X)^{-1} X^T y \quad (3.27)$$

şeklinde tahmin edilir. Bu vektörün her bir elemanına regresyon modelinin katsayıları da denir.

$\hat{\beta}$ vektörü ile $\hat{y} = X\hat{\beta}$ bağımlı değişken tahminleri yapılarak y ve $\hat{y}$ vektörleri arasındaki farklardan ε değerleri elde edilir.

$$\varepsilon = y - \hat{y} \quad (3.28)$$

En küçük kareler regresyon yönteminin tüm amacı 3.29 eşitliği ile elde edilen fark değerlerinin karelerinin minimum değerde olduğu doğruyu bulmaktır.

$$\min_{\beta} \sum_{i=1}^n \varepsilon_i^2 \quad (3.29)$$

En küçük kareler regresyon yöntemi veri setindeki tüm gözlemlere eşit ağırlık vererek kareler toplamını indirgeyen bir analiz yöntemidir. Aykırı bir gözlemin

vereceği büyük fark değeri, farkların kareleri toplamını ve dolayısıyla parametre tahminlerini de olumsuz bir biçimde etkileyecektir (Yorulmaz, 2009; Aksakal ve Çılan, 2015).

3.3.3.2. Konumsal Otoregresyon modeli (SAR)

Konumsal otoregresyon modeli (Spatial Autoregressive Model (SAR)) klasik regresyon modelinin bir uzantısıdır. SAR bir konumdaki veriye ait bağımlı değişken üzerinde, bu verinin komşu konumlardaki değişkenlerin de etkisi olduğunu varsaymaktadır. Konumsal otoregresyon modeli;

$$y = \rho Wy + X\beta + \varepsilon \quad (3.30)$$

şeklinde gösterilir. Bu modelde yer alan; W, konumlar arasındaki bulunan komşuluk ilişkisini ifade eden ağırlık matrisini; y, bağımlı değişken vektörünü; X, veri setindeki değişkenler matrisini; ε , hata terimini ($\varepsilon \sim N(0, \sigma^2 I_n)$) belirtmektedir. Yine bu eşitlikte gösterilen bağımlı değişken katsayısı ρ , komşu konumlardaki y'lerin ilgili konumda bulunan y üzerindeki etkisini ölçmektedir ve genellikle $|\rho| < 1$ olduğu kabul edilir. Konumsal otoregresif parametre olan ρ 'nun anlamlı olması konumsal bağımlılığın varlığı anlamına gelmektedir. Bu parametre anlamlı olduğunda en küçük kareler tahminleri yanı olacağından klasik regresyon modelinin kullanılması uygun değildir. Bu durumda konumsal otoregresyon modeli kullanılması daha uygun olacaktır (Srinivasan, 2008; Aral ve Aytaç, 2018).

3.3.3.3. Coğrafi ağırlıklandırılmış regresyon (GWR)

Coğrafi ağırlıklandırılmış regresyon (GWR) ile ilgili yapılan çalışmalar incelendiğinde, yöntemin ilk olarak Fotheringham, Brunsdon ve Charlton tarafından geliştirildiğinden bahsedilmektedir. 1996 yılında Brunsdon, Fotheringham ve Charlton tarafından yapılan çalışmada GWR modelinin ilk defa öne sürüldüğü, 2002 ve 2007 yıllarında yapılan çalışmalarla modelin daha da geliştirildiği görülmektedir. Regresyon analizi sonucunda elde edilen sonuç değerinin konum bilgisi ile ilişkisini kuran GWR modeli çeşitli alanlarda kendisine kullanım imkanı bulmuştur. Regresyon analizi, iki veya daha fazla değişken arasında ilişki bulunup bulunmadığını ve bu değerler arasında ilişki varsa bu ilişkinin derecesini belirlemeye

ve kestirimler yapmaya olanak sağlayan bir istatistik analiz yöntemidir. Regresyon analizi ile elde edilen katsayı tek bir (global) değer olup, ölçüme veya kestirime dahil edilen nesnelerin tamamı için sabittir. Bu sabit olma durumu üzerine yapılan analizler sonucunda regresyon analizine konum faktörü dahil edilerek, global yerine yerel regresyon değerlerini hesaplayan GWR modeli geliştirilmiştir.

GWR analizi; En Küçük Kareler (OLS) yönteminin geliştirilmiş bir versiyonudur. Bir bölge ile diğer bölgelerin regresyon katsayıları tahminleri arasındaki mesafenin bir fonksiyonu şeklindeki gözlem değerlerinin ağırlıklandırılmasıyla oluşan genişletilmiş bir modeldir. GWR;

$$Y_i = \alpha_{i0} + \sum_{k=1}^p \beta X_{ik} + \varepsilon_i \quad (3.31)$$

şeklinde ifade edilmektedir. Burada; Y bağımlı değişkeni, $k = 1, \dots, p$ 'ye kadar değer alan X_k bağımsız değişkenleri, ε_i sıfır ortalama ve sabit varyansa sahip normal dağılımlı hata terimini, β regresyon katsayısını ve α_{i0} ise modele ait sabit değişken değerini tanımlamaktadır.

(3.27) eşitliğinde belirtilen regresyon denklemi ile elde edilen yerel tahmin değerleri belirli bir konumda diğer konumlara olan mesafenin bir fonksiyonu olan gözlemlerin ağırlıklandırılmasıyla oluşturulan ağırlıklı regresyon model çözümü ile belirlenmektedir. Bu vektörler;

$$\hat{\alpha}_i = (X^T W_i X)^{-1} X^T W_i Y \quad (3.32)$$

denklemleriyle elde edilir. Bu denklemede yer alan W_i her bir nokta için yerel konumsal ağırlık matrisini temsil etmektedir. GWR yönteminde parametre tahminindeki ana etmen konumlar arasındaki her bir veri noktasının önemini gösteren ağırlık matrisinin oluşturulmasıdır. Konumsal analizde; Toblerin birinci yasasına göre bir konumda belirlenmiş olan bir gözlemin kendisine yakın olmayan bir konuma oranla kendisine daha yakında bulunan gözlemleri daha fazla etkileyeceği genel olarak kabul görmüştür. Bu sebeple ağırlık matrisleri oluşturulurken ters mesafe kriteri olarak bilinen $1/d_{ij}$ denkleminde faydalanılır. Bu denkleme göre i ve j konumlarında bulunan gözlem değerleri aralarında bulunan uzaklık değerine göre ağırlıklandırılırlar. İlgili konumdaki gözleme ait ağırlık matrisi

belirlendikten sonra deęerlerin tahmini iřlemi gerekleřtirilir. Bu tahmin iřlemlerinden bir kaı;

1. Kernel yoęunluk tahmini veya yerel regresyon yaklařımı olarak bilinen apraz geerlilik (CV) yntemi,
2. Akaike Information Criterion (AIC) minimize edilmesi, bylece uyum iyilięi ve serbestlik derecesi arasındaki dengenin saęlanması
3. Schwartz Information Criterion (SIC) yntemleridir (Keme ve Dzgn, 2006; Zeren ve Yurtkur, 2012; Atalay ve dię., 2013; Ceyhan, 2013; Sakarya ve İbiřoęlu, 2015; Akıncı ve dię., 2017; Arslan, 2019).

3.4. Benzerlik ltleri ve Doku İliřkisinin İrdelenmesi

Uzaklık, matematiksel olarak iki veri arasındaki mesafe anlamına gelmektedir. Bilimsel ve matematiksel pencereden incelendięinden uzaklık, iki veri setinin birbirlerinden ne kadar farklı olduęunun niceliksel derecesi olarak tanımlanmaktadır. Uzaklık, baęımsız veri setleri arasındaki farklılıkları gsterir. Farklılıklarda eřitli karakteristik zelliklere dayalı olarak iki veri seti arasındaki benzemezlik veya uyumsuzlukların bir lmdr. Analizlerde kullanılan girdi veri setleri birbirine ne kadar benzemezse uzaklık deęeri o derecede byk, birbirlerine ne kadar benzerse uzaklık lsnn deęeri o derecede kk olacaktır. Dięer bir deyiřle arařtırılan veri setleri birbirlerine mesafe uzayında o kadar yakın olacaklardır.

Gzlemlenen herhangi iki deęiřken, farklı deęiřken iftlerine nazaran ierdikleri karakteristik zellikleri bakımından birbirlerine daha fazla benziyorlarsa, bu iki deęiřken birbirine benzer, bu duruma da benzerlik denir. Benzerlik kavramı; iki deęiřkenin birbirine mesafe uzayındaki yakınlıęı olarak ifade edilmektedir. Deęiřkenler arasındaki matematiksel mesafenin kk deęere sahip olması benzerlięin (similarity) yksek, byk deęere sahip olması ise deęiřkenlerin birbirlerine gre farklı olduęunun bir gstergesidir.

İstatistikte veri kmelemede benzerlik veya benzemezlik ls olan sayısal deęere uzaklık ls adı verilmektedir. Uzaklık, iki gzlemin birbirinden ne kadar ayrı, farklı olduęunu anlamına gelirken, benzerlik iki gzlemimin birbirine olan yakınlıęını ifade etmektedir. Uzaklık deęerinin byk olması iki gzlemin

birbirinden çok farklı olduğunu, benzerlik değerinin büyük olması ise bu iki nesnenin birbirine yakın olduğunu göstermektedir (Ergüt, 2011).

Görüntü işlemede; benzerlik ölçütleri, görüntülerin histogramları karşılaştırılarak uygulanabilir. Histogram karşılaştırmada iki tür yaklaşım bulunmaktadır; vektörel ve olasılıksal. Renk seviyelerinden her biri birbirinden bağımsız olarak kabul edildiği için, bir histogram vektör olarak kartezyen veya öklid uzayında bir nokta gibi kabul edilebilir. Bu sebeple birçok benzerlik ölçütü bu histogramların karşılaştırılmasında kullanılabilir (Emekdaş, 2010).

Bir ölçütün, benzerlik ölçütü olarak adlandırılabilmesi için aşağıda belirtilen şartları taşıması gereklidir;

- $D(x,y) \geq 0$
- $D(x,x) = 0$
- $D(x,y) = D(y,x)$
- $D(x,y) \leq D(x,h) + D(h,y)$ (Mitchell, 2010)

Bir ölçütün benzerlik ölçütü olarak kabul edilebilmesi için gereken koşullardan olan birinci koşul iki gözlem arasındaki matematiksel mesafenin negatif olamayacağını göstermektedir. İkinci koşul elde edilmiş olan bir gözlemin kendisine olan mesafenin her zaman sifıra eşit olması gerektiğini ifade eder. Üçüncü koşul simetri özelliği olarak isimlendirilir. Bu koşulda farklı iki gözlemin birbirleri arasındaki mesafenin farklı değerde olmaması gerektiğini belirtmektedir. Dördüncü koşul üçgen eşitsizliği olarak adlandırılır. Üçgenin herhangi bir kenarının uzunluğunun, diğer iki kenarının uzunlukları toplamından daha büyük olamayacağını ifade etmektedir. Bu dört koşulu bir arada gerçekleşmesini sağlayan ölçütler “Benzerlik Ölçütleri” olarak adlandırılırlar (Ergüt, 2011).

3.4.1. Benzerlik ölçütü yöntemleri

Uzaklık veya benzerlik ölçütleri, iki görüntü veya görüntü içerisinden alınan parçalar arasındaki uyum derecesinin kantitatif bir ölçümünü sağlar. Örüntü sınıflandırma, gruplandırma ve bilgi çıkarım problemlerinde temel öneme sahiptir (Cha, 2008). Görüntüler arasındaki mesafeyi (uzaklığı) ölçen yöntemlerdir. Görüntülerin

birbirlerine ne oranda benzedikleri veya benzemedikleri bu yöntemler yardımıyla belirlenebilmektedir. Bu ölçütler, görüntü birleştirme/karma (fusion) algoritmalarında, sınıflandırma işleminde, değişiklik tespitinde, kalite değerlendirme ve tescili dahil birçok çeşitli görüntü işleme uygulamalarında önemli bir rol oynamaktadır (Mitchell, 2010; Emekdaş, 2010).

(Cha, 2008)'in çalışmasında yer alan benzerlik ölçütlerinden yararlanılarak görüntünün histogramlarının karşılaştırılması ilkesine dayalı olarak birçok benzerlik ölçütü yöntemi geliştirilmiştir. Bu tez çalışmasında kullanılmış olan 21 adet yöntem aşağıda açıklanmıştır.

3.4.1.1. Öklid mesafesi

İki noktayı birleştiren doğrusal hat olarak tanımlanmaktadır. Çok boyutlu bir uzayda bulunan nesnelerin birbirlerine olan geometrik uzaklığıdır.

$$D(x,y)=\sqrt{\sum_{i=1}^n (x_i-y_i)^2} \quad (3.33)$$

3.4.1.2. Chebyshev mesafesi

İki vektör arasındaki mesafenin herhangi bir koordinat uzayında, farklarının en büyük olduğunu tanımlayan bir metriktir.

$$D(x,y)=\max_{i=1}^n |x_i-y_i| \quad (3.34)$$

3.4.1.3. City Block (Manhattan) mesafesi

City Block mesafesi; iki nokta arasındaki mesafeyi x ve y düzlemlerindeki mesafelerin toplanmasıyla hesaplar. Bir şehirde (Manhattan şehrine) hareket ederken binalardan düz geçilemeyip etrafından dolaşmak zorunda olunmasına benzediği için bu ismi almıştır.

$$D(x,y)=\sum_{i=1}^n |x_i-y_i| \quad (3.35)$$

3.4.1.4. Minkowski mesafesi

Bu ölçüt n boyutlu iki nokta arasındaki farkı ölçer. Öklid, City Block (Manhattan) ve Chebyshev mesafelerinin genelleştirilmiş halidir.

$$D(x,y)=\left[\sum_{i=1}^n |x_i-y_i|^p\right]^{1/p} \quad (3.36)$$

3.4.1.5. Chi-Kare (χ^2) mesafesi

Bir dağılımın diğer bir dağılıma olan uygunluğunun ölçütüdür. Ki-kare mesafesi, iki histogram arasındaki farklılığın bir ölçüsü olarak, doku, nesne ve şekil sınıflandırma gibi çeşitli uygulamalarda yaygın olarak kullanılan uzaklık ölçülerinden biridir.

$$D(x,y)=\sum_{i=1}^n \frac{(x_i-y_i)^2}{(x_i+y_i)} \quad (3.37)$$

3.4.1.6. Kullback-Leibler mesafesi

İki olasılık dağılımı (P ve Q) arasındaki farkın bir ölçütüdür. P ve Q'da simetrik değildir. Uygulamalarda, P genelde verilerin "gerçek" dağılımı, gözlemleri veya tam olarak hesaplanmış bir teorik dağılımı temsil eder. Q ise tipik olarak P'nin teorisini, modelini, açıklamasını veya yaklaşımını temsil etmektedir.

$$D(x,y)=\sum_{i=1}^n x_i \log \frac{x_i}{y_i} \quad (3.38)$$

3.4.1.7. Jeffrey (Divergence) mesafesi

Kullback-Leibler mesafesinin simetrik versiyonudur.

$$D(x,y)=\sum_{i=1}^n x_i \log \frac{x_i}{\mu_i} + y_i \log \frac{y_i}{\mu_i} \quad (3.39)$$

μ ; x ve y değerlerinin ortalaması

3.4.1.8. Kolmogorov-Smirnov mesafesi (Divergence)

Kolmogorov-Smirnov bir örneğin belirli bir dağılıma sahip bir popülasyondan gelip gelmediğine karar vermek için kullanılır. İki veri kümesinin önemli ölçüde farklı olup olmadığını belirlemeye çalışır.

$$D(x,y)=\max_{i=1}^n |X_i-Y_i| \quad (3.40)$$

X ve Y görüntünün histogram değerlerinin toplanmasıyla elde edilen tek bir değerdir.

3.4.1.9. Bray-Curtis (Sorensen) mesafesi

Bray-Curtis (Sorensen), her bir bölgedeki sayımlara dayalı olarak, iki farklı vektör arasında uyum farklılığını ölçmek için kullanılan bir istatistiktir.

$$D(x,y)=\frac{\sum_{i=1}^n |x_i-y_i|}{\sum_{i=1}^n (x_i+y_i)} \quad (3.41)$$

3.4.1.10. Kosinüs mesafesi

Kosinüs benzerliği, iki vektörün iç çarpımları uzayının arasındaki kosinüs açısını ölçen benzerlik ölçütüdür. Girdi verisi olarak kullanılan vektörün boyutundan etkilenmemesi bu yöntemin en güçlü özelliğidir.

$$D(x,y)=1 - \frac{x_i \cdot y_i}{\sqrt{(x_i x_i')(y_i y_i')}} \quad (3.42)$$

3.4.1.11. Korelasyon katsayısı mesafesi

İki veya daha fazla değişken arasındaki istatistiksel ilişkiyi göstermektedir.

$$D(x,y)=\frac{\sum_{i=1}^n (x_i-\bar{x}_i)(y_i-\bar{y}_i)}{\sqrt{\sum_{i=1}^n (x_i-\bar{x}_i)^2 (y_i-\bar{y}_i)^2}} \quad (3.43)$$

3.4.1.12. Dice mesafesi

Sorensen mesafesinden türetilmiş ve iki veri seti arasındaki benzerliği ölçen istatistik parametredir. Aynı zamanda F_1 değeri olarakta bilinmektedir.

$$D(x,y)=\frac{\sum_{i=1}^n (x_i-y_i)^2}{\sum_{i=1}^n x_i^2 + \sum_{i=1}^n y_i^2} \quad (3.44)$$

3.4.1.13. Bhattacharyya mesafesi

Bhattacharyya mesafesi, iki olasılık dağılımının birbirleriye olan benzerliğini ölçer. Bu ölçüt iki veri seti arasındaki örtüşme/benzeme miktarının bir ölçütü olan Bhattacharyya katsayısı ile yakından ilişkilidir.

$$D(x,y) = -\ln \sum_{i=1}^n \sqrt{x_i y_i} \quad (3.45)$$

3.4.1.14. Fidelity mesafesi

Aşağıdaki denklemde görüldüğü gibi geometrik ortalamaların toplamı Fidelity mesafesini temsil etmektedir. Bhattacharyya mesafesi ile benzerlikler göstermektedir.

$$D(x,y) = \sum_{i=1}^n \sqrt{x_i y_i} \quad (3.46)$$

3.4.1.15. Gower mesafesi

Gower mesafesi veri setlerinin bulunduğu vektör uzayını normalize ederek ölçekledikten sonra L1 normu kullanarak veri setleri arasındaki mesafeyi hesaplayarak benzerliklerini bulmayı amaçlamaktadır.

$$D(x,y) = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad (3.47)$$

3.4.1.16. Soergel mesafesi

Aynı zamanda Jaccard indeks olarak bilinen bu mesafe ölçütü iki veri seti arasındaki benzerliği ölçen bir yöntemdir.

$$D(x,y) = \frac{\sum_{i=1}^n |x_i - y_i|}{\sum_{i=1}^n \max(x_i, y_i)} \quad (3.48)$$

3.4.1.17. Jaccard mesafesi

Örnek veri setleri arasındaki farklılığı/çeşitliliği ölçen Jaccard mesafesi, Jaccard katsayısının tamamlayıcısıdır ve Jaccard katsayısının 1'den çıkarılmasıyla elde edilir. Normalize edilmiş nokta(dot) çarpımının bir başka versiyonudur.

$$D(x,y)=\frac{\sum_{i=1}^n (x_i-y_i)^2}{\sum_{i=1}^n x_i^2 + \sum_{i=1}^n y_i^2 - \sum_{i=1}^n x_i y_i} \quad (3.49)$$

3.4.1.18. Tanimoto mesafesi

Tanimoto benzerlik ölçüsü, biyolojik sınıflandırma ve bilgi çıkarımı gibi alanlarda sıklıkla kullanılan bir ölçüttür. Normalleştirilmiş iç çarpımın farklı bir çeşitidir. Jaccard ölçüsünün genelleştirilmiş bir durumudur.

$$D(x,y)=\frac{\sum_{i=1}^n x_i + \sum_{i=1}^n y_i - 2 \sum_{i=1}^n \min(x_i, y_i)}{\sum_{i=1}^n x_i + \sum_{i=1}^n y_i - \sum_{i=1}^n \min(x_i, y_i)} \quad (3.50)$$

3.4.1.19. Matusita mesafesi

Bhattacharyya mesafesi matematik modelinden türetilmiş bir benzerlik ölçütüdür.

$$D(x,y)=\sqrt{\sum_{i=1}^n (\sqrt{x_i} - \sqrt{y_i})^2} \quad (3.51)$$

3.4.1.20. Topsoe mesafesi

K Diverjans benzerlik ölçütünün simetrik formudur.

$$D(x,y)=\sum_{i=1}^n \left(x_i \ln \left(\frac{2x_i}{x_i+y_i} \right) + y_i \ln \left(\frac{2y_i}{x_i+y_i} \right) \right) \quad (3.52)$$

3.4.1.21. Jensen-Shannon mesafesi

Jensen-Shannon mesafesi Topsoe mesafesinden türetilmiş ve sayısal olarak bu benzerlik ölçütünün yarısına eşittir.

$$D(x,y)=\frac{1}{2} \left[\sum_{i=1}^n x_i \ln \left(\frac{2x_i}{x_i+y_i} \right) + \sum_{i=1}^n y_i \ln \left(\frac{2y_i}{x_i+y_i} \right) \right] \quad (3.53)$$

4. UYGULAMA

Bu tez çalışmasında mekansal/geoistatistik yaklaşımların sağladığı fayda ile uzaktan algılanmış yüksek spektral ve konumsal bilgiye sahip olan görüntüler üzerinden belirlenen konumsal bağımlılık bilgileri yardımıyla çeşitli doku özelliklerini en uygun seviyede belirleyebilecek olan ölçütlerin kullanımıyla genel bir uzaktan algılama uygulaması olan sınıflandırma başarımını ne ölçüde etkileyebileceğini ortaya koyabilecek bir çerçeve oluşturmak amaçlanmıştır.

Belirlenmiş olan bu amacı gerçekleştirmek adına yapılması planlanarak gerçekleştirilen genel işlem adımları -iş akış şeması- Şekil 4.1’de gösterilmiştir. Buna göre iki farklı görüntü veri seti olarak kullanılmıştır. Bu veri setlerinden ilki tarımsal bir alana ait olan bir ortofoto görüntüsünün kırmızı bandı, ikincisi ise Pleiades uzaktan algılama platformu tarafından algılanmış olan İstanbul şehrine ait kentsel bir alanın görüntüsüdür. Burada iki farklı veri setinin seçilmesinin sebebi önerilecek algoritmanın, problemin yapısına uygun seçilmiş test verisi niteliğinde bir görüntü veriseti ile rastlantısal olarak seçilmiş başka bir veriseti üzerindeki potansiyelinin araştırılması ve sonuçlarının karşılaştırılmasıdır. Tarımsal alan görüntüsü, doku tanımına uygun olması ve görüntünün yapısıyla ilgili olarak doku özelliklerini belirlemeye uygun homojen bir yapıda olmasından dolayı tercih edilmiştir. Kentsel alan görüntüsü ise önerilen yaklaşımın homojen yapıdan çok içerisinde çeşitli spektral/istatistik heterojenlikler bulunduran bir görüntü verisi için standart bir uygulamada denendiğinde hangi sonuçların elde edileceğinin belirlenmesi ve karşılaştırma yapılması için tercih edilmiştir. Veri setlerinin oluşturan görüntülerin radyometrik ve geometrik olarak düzeltme işlemleri gerçekleştirilmiştir. Tarımsal alan görüntüsüne ilk olarak konumsal bağımlılık derecelerinin belirlenebilmesi için semivariogram analizi uygulanmış ve belirlenen semivaryans değerlerine Exponential model uygulanarak model parametreleri olan Sill ve Range değerleri elde edilmiştir. Elde edilen Sill ve Range değerleri birbirlerine oranlandıktan sonra çeşitli eşik değerleri yardımıyla konumsal bağımlılık dereceleri belirlenerek 5 gruba ayrılarak derecelendirilmiştir. Oluşturulan konumsal


bağımlılık derece görüntüsü ham spektral değerlerle birleştirilerek iki bandlı yeni bir veri seti oluşturulmuştur. Ham spektral değerlere sahip görüntü ile konumsal bağımlılık derece görüntüsü eklenmiş olan yeni veri seti iki adet kontrollü sınıflandırma yöntemi ile sınıflandırılmış ve oluşturulan yeni ek bilginin sınıflandırma ve bilgi çıkarımına yaptığı etki/katkının belirlenmesine çalışılmıştır. Sınıflandırma işlemi sonrasında oluşturulan hata (confusion) matrisleri ile doğruluk değerlendirilmesi yapılmıştır.

Kentsel alan görüntüsü üzerinde ilk işlem adımı olarak doku bilgisinin belirlenmesi hedeflenmiş ve standart doku ölçütleriyle birlikte benzerlik ölçütlerinden de yararlanılmıştır. Doku bilgisinin tanımlanmasında benzerlik ölçütlerinden ne ölçüde yararlanılabileceği ve hangi ölçütlerin doku tanımında daha etkili olduğu araştırılmıştır. Bir diğer yaklaşım benzerlik ölçütlerinin farklı yaklaşım ve algoritmalarla hesaplanmış doku ve örüntü parçalarının karşılaştırılmasında kullanılabilecek olmasıdır. Kentsel alan görüntüsü üzerinde üç adet homojen özelliğe sahip doku alanı belirlenerek veri seti olan uzaktan algılama görüntüsünün 21 adet benzerlik ölçütü yöntemi ile analizinin gerçekleştirilmesi için matematik modelleri bilinen yöntemlerin ham kodlamalarının MATrix LABoratory (MATLAB) programlama diline uyarlanması sağlanarak benzerlik ölçüt görüntülerinin oluşturulması gerçekleştirilmiştir. Seçilen alanlardan üretilen benzerlik ölçütleri incelenerek görüntü üzerindeki doku bilgisinin varlığı tespit edildikten sonra standart doku ölçütlerine ait altı adet ölçüt görüntüsü ve görüntüler içerisindeki konumsal örüntüleri belirleyebilen Getis-Ord G istatistiği ve Moran's I indeksi yöntemleri kullanılarak konumsal örüntü görüntüleri oluşturulmuştur. Bir sonraki adım tezin ana amacını oluşturan konumsal bilginin elde edilmesi için semivariogram değerlerinin belirlenmesi işlemi gerçekleştirilmiştir. Bunun için literatürde bulunan yatay yöndeki semivaryans değerlerini belirlenmesini sağlayan matematik model MATLAB programlama diline adapte edilerek çalıştırılması sağlanmış ve görüntüye ait semivaryans değerleri hesaplanmıştır. Elde edilen semivaryans değerlerine model uydurma işlemiyle parametrelerinin belirlenmesi için 2010 yılında MATLAB programlama dilinde Wolfgang Schwanghart tarafından yazılmış olan kod parçacığı kullanılmıştır. Böylece konumsal bilginin temsil edilebildiği bir ölçütün çıkarılabilmesi için Sill ve Range değerlerinin birbirlerine oranlanması ve konumsal

ilişkinin/bağımlılığın derecesini belirleme işlemi gerçekleştirilerek uygulamada kullanılabilecek pratik bir ölçüt oluşturma işlemi gerçekleştirilmiştir. Ölçütlerin oluşturulması için gereken Sill ve Range değerlerinin elde edilmesi için semivaryans değerlerine Exponential (Üstel) ve Spherical (Küresel) geoistatistik modeller uygulanmıştır. Bu modeller uzaktan algılama görüntüleri gibi sürekli yapıya sahip veri setlerinde diğer modellere göre daha iyi sonuçlar vermelerinden dolayı tercih edilmişlerdir. Kullanılacak modellerin belirlenmesinden sonra ham spektral değerleri içeren görüntünün her bir bandından model parametrelerinin belirlenmesi işlemine geçilmiştir. Bu işlem görüntü üzerinde kayan pencereler yöntemiyle gerçekleştirilerek Exponential ve Spherical modellere ait parametre değerleri oluşturulmuştur. Veri setini meydana getiren dört farklı spektral band için gerçekleştirilen bu analizin sonucunda her bir banda ait model parametreleri elde edilerek konumsal bilgiyi içeren dört yeni veri bandı oluşturulmuştur. Daha sonrasında spektral görüntü bandları ile yeni oluşturulan konumsal bilgi bandlarının bir araya getirilerek sekiz band sahip yeni bir görüntü veri setinin meydana getirilmesi işlemi gerçekleştirilmiştir. İki farklı semivariogram modeline göre elde edilen konumsal bilgilerden oluşturulan ölçütlerin spektral bilgiyi taşıyan görüntü bandlarıyla bir araya getirilmesiyle iki adet sekiz banda sahip yeni veri seti oluşturulmuştur. Bir sonraki adım görüntüde var olduğu tespit edilmiş olan doku bilgisinin modellenmesi amacıyla benzerlik ölçütlerini oluşturmak için kullanılan homojen örnek bölgelerinden faydalanılarak konumsal otoregresyon (SAR) yöntemi ile veri setinin incelemesi yapılmıştır. SAR yöntemi ile piksellerin komşuluk bilgileri kullanılarak üretilen doku görüntüleriyle veri setindeki doku bilgisi modellenmiştir. Standart doku ölçütleri, konumsal örüntü görüntüleri ve konumsal bağımlılık bilgileri ile elde edilen ve sadece spektral bilgiyi içeren görüntü bandlarından oluşan toplamda 5 adet veri setine Enviroment for Visualizing Images (ENVI) uzaktan algılama programında bulunan üç farklı sınıflandırma yöntemi uygulanarak sınıflandırma işlemi gerçekleştirilmiştir.

Tüm analizler Intel Core i5-3470 CPU 3.20 GHz'lik bir işlemciye, 4.00GB RAM belleğine ve 64 bit Windows işletim sistemine sahip bir bilgisayar kullanılarak gerçekleştirilmiştir. Şekil 4.1 ile gösterilen ve tez çalışmasının sayısal uygulaması

kısmında gerçekleştirilmiş olan işlem adımları detaylı bir biçimde ilerleyen bölümlerde açıklanmıştır.



Şekil 4.1. İş akış şeması

4.1. Tarımsal Alan Uygulaması

4.1.1. Veri seti


Tarımsal alan uygulaması için görüntü veri seti olarak Amerika Tarım Bakanlığı tarafından yürütülen Ulusal Tarım Görüntüleme Programı kapsamında Indiana eyaletinde bir metre yersel çözünürlüğe sahip dört spektral bandlı ortofoto görüntüsünün kırmızı bandı kullanılmıştır. Belirlenen görüntü, içerisinde çeşitli farklı doku özelliklerini barındıracak şekilde, işlem hacmi ve süresini kısaltmak amacıyla 2000 x 2000 piksel boyutlarında bir alt görüntüye indirgenmiştir (Şekil 4.2).



Şekil 4.2. Veri seti olarak tarım arazilerini içeren ortofoto görüntüsü


4.1.2. Konumsal bağımlılık derecelerinin belirlenmesi

Yapılacak olan sınıflandırma uygulamalarında görüntü üzerinden belirlenen parametrelerin çıkarımı yapılarak birbirleri ile karşılaştırılması yapılmıştır. Bu amaçla ilk olarak konumsal bağımlılığın belirlendiği semivariogramlar incelenmiştir.



Şekil 4.3. Veri seti üzerine uygulanan farklı semivariogram modelleri

Görüntü üzerinde piksel bazlı olarak hesaplanacak korelasyon, bağımlılık, doku v.b. ölçütleri için uygun ölçeğin seçimi oldukça önemlidir. Farklı piksel büyüklükleri için belirlenen bu özelliklerin değişmesi beklenen bir durumdur. Bu uygulamada görüntünün 11x11 piksellik kayan pencerelerle analiz edilmesine ilgili görüntünün semivariogram analizi ile karar verilmiştir. Şekil 4.3'te görüldüğü gibi tüm tarımsal alan görüntüsü üzerine uygulanan semivariogram analizinde Spherical ve Gauss modellerinde görüntü üzerindeki konumsal bağımlılığın yaklaşık olarak 11 piksel civarında olduğu görülmektedir. Bu sebepten ötürü pencere boyutu olarak 11x11 piksel belirlenmiştir. Pencere boyutu belirlendikten sonra görüntü 11x11 boyutlu ve 1 piksel öteleme ile kayan pencereler yöntemi yardımıyla alt görüntülere ayrılmış ve her bir alt görüntünün deneysel semivariogramları hesaplanmıştır. Hesaplanan deneysel semivariogramların her birine semivariogram modelleri uygulanmış ve model parametreleri (Sill, Range ve Nugget) elde edilmiştir. Daha sonrasında elde edilmiş olan bu semivariogram parametrelerinin oranları hesaplanmış ve bu oranlar derecelendirilmiştir. Görüntü analizinde Sill / Range oranı kullanılarak görüntü üzerindeki konumsal bağımlılığın çok yüksek, yüksek, orta, düşük ve çok düşük olmak üzere 5 farklı derecesi belirlenmiştir. Şekil 4.4'te yatay yöndeki semivariogramlardan Sill / Range oranı ile analiz edilmesi sonucu oluşturulan konumsal bağımlılık görüntüsü gösterilmektedir.




Şekil 4.4. Semivariogram parametrelerinden oluşturulan konumsal bağımlılık dereceleri görüntüsü

4.1.3. Sınıflandırma


Çalışmada konumsal bilginin sınıflandırmaya/bilgi çıkarımına hangi oranda katkı yapacağını belirleyebilmek için iki adet sınıflandırma yöntemi belirlenmiştir. Bunlar; En Kısa Mesafe ve Support Vector Machines sınıflandırma yöntemleridir. Bu iki sınıflandırma yönteminin seçilme amacı spektral sınıflandırma aşamasında tek bantlı bir görüntünün veri seti olarak kullanılmasından kaynaklanmaktadır. Seçilen bu iki yöntem tek bantlı görüntülerin sınıflandırılması işlemlerinde kullanılabilmektedirler.

Sınıflandırma işlemini gerçekleştirmek amacıyla belirlenen bu iki yöntemde eğitimli sınıflandırma kategorisinde oldukları için sınıflandırmak istenilen arazi örüntülerine ait eğitim verisine ihtiyaç duymaktadırlar. Bu nedenle tarımsal alana ait olan veri seti üzerinden sınıflandırılması istenilen 4 adet sınıfın eğitim verileri belirlenmiştir. Görüntü üzerindeki bu sınıflar; Yeşil alan, Ekili alan, Ekili olmayan alan ve Yol sınıfı olarak belirlemiş ve bu sınıflara ait eğitim verileri görüntü üzerinden seçilmiştir (Şekil 4.5).




Şekil 4.5. Sınıflandırma işleminde kullanılan eğitim verileri

Eğitim verileri belirlendikten sonra ilk olarak piksel tabanlı sınıflandırma işlemi gerçekleştirilmiştir. ENVI paket programı yardımıyla gerçekleştirilen iki adet sınıflandırma yöntemine ait elde edilen sınıflandırma görüntüleri Şekil 4.6 ve 4.7 'de gösterilmektedir. Spektral değerlere göre yapılan bu sınıflandırmada her iki yöntemde de ekili alan sınıfı ile yol sınıfının birbirine yakın spektral değerlere sahip olmasından dolayı hatalı sınıflamaların olduğu görülmektedir. Ayrıca yine görüntünün tam ortasına denk gelen bölgede ekili olmayan alan sınıfının ekili alan olarak sınıflandırıldığı görülmektedir.




Şekil 4.6. Spektral değerler ile en kısa mesafe yöntemine göre sınıflandırılmış görüntü




Şekil 4.7. Spektral değerler ile SVM yöntemine göre sınıflandırılmış görüntü

Piksel tabanlı sınıflandırma işleminden sonra semivariogram parametrelerinden Sill ve Range değerlerinin birbirleri ile oranlanmasından elde edilen konumsal bağımlılık derece değerleri sınıflandırma işlemine katılarak yeniden sınıflandırma işlemi gerçekleştirilmiştir. Bunun için konumsal bağımlılık derece değerleri de bir görüntü bandı olarak düşünülmüş ve MATLAB ortamında veri setine eklenmiştir. Elde edilen iki bandlık görüntü üzerinden yeniden sınıflandırma işlemi gerçekleştirilerek yeni sonuçlar elde edilmiştir. Konumsal bağımlılık derecelerinin sınıflandırma işlemine katılmasıyla elde edilen görüntüler Şekil 4.8 ve 4.9'da gösterilmektedir. Spektral değerlere göre yapılan sınıflandırma işleminde yol sınıfı ile karışan ekili alan arazi sınıfının, konumsal bağımlılığının yüksek olmasından dolayı yapılan yeni sınıflandırma işleminde sınıflandırma doğruluğunun arttığı görülmektedir. Ayrıca yol sınıfı yine bir önceki sınıflandırma işlemine göre daha yüksek doğrulukta sınıflandırılmıştır.



Şekil 4.8. Spektral ve konumsal değerler ile en kısa mesafe yöntemine göre sınıflandırılmış görüntü



Şekil 4.9. Spektral ve konumsal değerler ile SVM yöntemine göre sınıflandırılmış görüntü

Sınıflandırma işlemleri sonrasında hata matrisleri (confusion matrix) oluşturularak doğruluk değerlendirilmesi yapılmıştır (Tablo 4.1- 4.4). Elde edilen hata matrislerine göre konumsal bağımlılık verilerin sınıflandırma işlemine katılmasıyla sınıflandırma doğruluğunun arttığı gözlemlenmiştir. Sınıflandırma doğruluğunda yöntemlere göre; En Kısa Mesafe yönteminde %6 ‘lık, SVM yönteminde ise %10’luk bir artış gözlemlenmiştir.

Tablo 4.1. Spektral değerler ile gerçekleştirilen en kısa mesafe yöntemine ait hata matrisi

	YG_Yeşil Alan	YG_Ekili Olmayan Alan	YG_Ekili Alan	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Yeşil Alan	64801	1705	0	0	66506	97,44
Ekili Olmayan Alan	8516	206866	37	6	215425	96,03
Ekili Alan	0	3698	135621	58	139377	97,31
Yol	0	0	33816	4465	38281	11,66
Toplam	73317	212269	169474	4529	459589	
Üretici Doğruluğu(%)	88,38	97,45	80,02	98,59		
Genel Doğruluk (%)				Kappa Katsayısı		
89,59				0,8393		

Tablo 4.2. Spektral ve konumsal değerler ile gerçekleştirilen en kısa mesafe yöntemine ait hata matrisi

	YG_Yeşil Alan	YG_Ekili Olmayan Alan	YG_Ekili Alan	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Yeşil Alan	67178	787	0	2	67967	98,84
Ekili Olmayan Alan	5861	199615	101	0	205577	97,10
Ekili Alan	0	11754	169360	2137	183242	92,42
Yol	278	122	13	2390	2803	85,27
Toplam Üretici Doğruluğu(%)	73317	212269	169474	4529	459589	
Genel Doğruluk (%)				Kappa Katsayısı		
95,42				0,9265		

Tablo 4.3. Spektral değerler ile gerçekleştirilen SVM yöntemine ait hata matrisi

	YG_Yeşil Alan	YG_Ekili Olmayan Alan	YG_Ekili Alan	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Yeşil Alan	71326	39089	22	1	110438	64,58
Ekili Olmayan Alan	1990	167357	10	4	169361	98,82
Ekili Alan	1	5823	154942	138	160904	96,29
Yol	0	0	14500	4386	18886	23,22
Toplam Üretici Doğruluğu(%)	73317	212269	169474	4529	459589	
Genel Doğruluk (%)				Kappa Katsayısı		
86,60				0,7976		


Tablo 4.4. Spektral ve konumsal değerler ile gerçekleştirilen SVM yöntemine ait hata matrisi

	YG_Yeşil Alan	YG_Ekili Olmayan Alan	YG_Ekili Alan	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Yeşil Alan	72909	6496	0	6	79411	91,81
Ekili Olmayan Alan	408	200872	55	0	201335	99,77
Ekili Alan	0	4901	168847	1706	175454	96,23
Yol	0	0	572	2817	3389	83,12
Toplam Üretici Doğruluğu(%)	73317	212269	169474	4529	459589	
Genel Doğruluk (%)				Kappa Katsayısı		
96,92				0,9511		

4.2. Kentsel Alan Uygulaması

4.2.1. Veri seti

Tez çalışmasının uygulama aşamasında veri seti olarak 2011 ve 2012 yıllarında hizmet vermeye başlayan aynı güneş eş zamanlı dairesel yörünge üzerinde 180^0 aralıkla konumlanmış, çok yüksek konumsal çözünürlüklü optik veri üretebilen ve dünya üzerindeki bir noktayı günde iki kez ziyaret edebilme kapasitesine sahip olan Pleiades uzaktan algılama platformu tarafından elde edilmiş pankromatik bandta 50 cm, 4 adet multispektral bandta 2 metrelik konumsal ve 12 bitlik radyometrik çözünürlüğe sahip olan uydu görüntüsü kullanılmıştır (URL-3). Gerçekleştirilen analizlerde hesaplama yükü ve zaman açısından tasarruf sağlamak amacıyla görüntü, içerisinde çeşitli doku örneklerini barındıracak bir biçimde, 2000x2000 lik bir alt görüntüye indirgenmiş ve gerçekleştirilen analizlerde veri seti olarak kullanılmıştır (Şekil 4.10).



Şekil 4.10. Çalışmada veri seti olarak kullanılan uzaktan algılama görüntüsü

4.2.2. Benzerlik ölçütlerinin belirlenmesi

Çalışmada benzerlik ölçütlerinin belirlenmesi için görüntü histogramlarını kullanan ve Bölüm 3.4.1’ de bahsedilen 21 adet yöntem kullanılmıştır. Bu 21 adet yöntemin matematik modelleri tarafımdan MATLAB ortamında kodlanarak veri seti olan uzaktan algılama görüntüsüne ait benzerlik ölçütü görüntülerinin elde edilmesi amacıyla kullanılmıştır (Ek-B). Şekil 4.11’de Öklid mesafesinin belirlenmesi amacıyla MATLAB programlama dilinde oluşturulan kod gösterilmektedir.

```
a=1; b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));

for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Oklid_Msf{i,j} = sqrt(sum((P-Q).^2));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end
```

Şekil 4.11. Öklid mesafesinin belirlenmesi için yazılan MATLAB kodu

Analiz aşamasında uzaktan algılama görüntüsü üzerinde doku örnek verileri için üç görüntü belirlenmiştir. Bunlar; su, yeşil alan ve bina doku örnekleridir. Veri seti içerisinde üç adet 100x100 piksellik belirlenen doku örnekleri için homojen özelliğe sahip alanlar belirlenmiştir (Şekil 4.12). Bu örnek alanlar analiz sürecinin sonraki aşamalarında gerçekleştirilecek olan sınıflandırma işlemi için sınıf özelliklerine göre eğitim verisi oluşturulurken de kullanılacaktır. Belirlenen doku örnek görüntülerinin histogram değerleri karşılaştırma verisi olarak kullanılmak üzere elde edilmiştir.

Doku örnek görüntüleri ve bu görüntülere ait istatistik/histogram bilgileri elde edildikten sonra veri seti içerisinde bu örnek doku değerlerine benzer olan alanların belirlenmesi işlemine geçilmiştir. Bu işlem görüntü üzerinde kayan pencereler yöntemi


ile gerçekleştirilmiştir. Bu işlem için homojen bölgelerden elde edilen doku bilgisini görüntü üzerinde kaybetmeden belirleyebilecek olan pencere boyutunun tespit edilmesi gerekmektedir. Bu amaçla veri seti üzerinde çeşitli pencere boyutları denenmiş (5x5, 7x7, 11x11, 15x15) ve yapılan çeşitli karşılaştırmalı analizler sonucunda uygun pencere boyutuna karar verilmiştir. Yüksek konumsal çözünürlüklü görüntülerdeki istatistik/histogram bilgilerinin en optimum şekilde belirlenebileceği boyut olarak 11x11 piksellik pencere boyutunun analizlerde kullanılmasına karar verilmiştir. Pencere boyutuna karar verildikten sonra örnek doku bölgelerine benzer alanların görüntü içerisinde tespit edilmesi işlemine geçilmiştir. Bu amaçla belirlenen 11x11 piksel boyutunda görüntü üzerinde 1 piksel ötelemeli/komşuluklu kayan pencerelerle analizler gerçekleştirilmiştir. 11x11'lik pencerelerin görüntü üzerinde 1 piksel kayarak hareket ettirilmesiyle elde edilmiş olan alt görüntülerin histogram değerlerinin, doku örneklerine ait histogram değerlerine olan mesafe değerlerinin belirlenmesiyle benzerlik ölçüt görüntüleri oluşturulmuştur. Belirlenen mesafe değerinin büyük değere sahip olması iki görüntü parçasının birbirlerine benzemediği, küçük değere sahip olması ise bu görüntülerin birbirlerine benzer olduğu anlamına gelmektedir. Bu işlem Bölüm 3.4.1'de bahsedilen 21 adet benzerlik ölçütü için tekrar edilmiştir.

Bu analiz süreci her bir doku örneğinin veri setinin her bir bandı üzerinde analiz ile 252 adet benzerlik ölçütü görüntüsünün elde edilmesiyle sonuçlanmıştır. Aşağıda tez çalışmasında kullanılan veri setine ait benzerlik ölçüt yöntemleri ile oluşturulan çeşitli örnek görüntüler verilmiştir. Görüntülerde görülen koyu mavi renk ile temsil edilen alanlar örnek doku alanlarına en benzer olan (en yakın) bölgeleri, sarı renk ile temsil edilen alanlar ise örnek doku alanları ile en benzemeyen (en uzak) bölgeleri göstermektedir (Şekil 4.13 – 4.22).

Öklid mesafesine göre oluşturulan benzerlik ölçüt görüntüleri incelendiğinde (Şekil 4.13) bina dokusunun genel olarak doğru bir biçimde belirlendiği tespit edilmiştir. Su dokusunun büyük bir kısmının ayrıştırılabildiği ancak yeşil alanların sadece belirli bir bölgesinin (görüntünün sol alt kısmında kalan bölge) belirlenebildiği görülmektedir.

City block mesafe yöntemine göre oluşturulan benzerlik ölçüt görüntüleri incelendiğinde (Şekil 4.14) su dokusunun neredeyse tam doğrulukla tespit edildiği


görülmektedir. Görüntü içerisindeki bazı yeşil alanlarında su dokusu gibi özellik gösterdiği ve su alanlarına yakın değerler ürettiği belirlenmiştir. Bunun yanında yöntemin yeşil alanlar ile bina dokularını belirlemede su dokusu kadar başarılı olmadığı tespit edilmiştir.




Şekil 4.12. Benzerlik ölçütleri için kullanılan doku örnekleri; (a) su, (b) yeşil alan ve (c) bina doku görüntüleri

Benzerlik yöntemleri arasında en iyi ayırım sonucunu Chi-Kare, Jeffrey, Dice ve Fidelity yöntemleri vermiştir. Her dört yöntemle ait benzerlik ölçüt görüntüleri incelendiğinde (Şekil 4.15, 4.16, 4.18 ve 4.20) her üç adet doku özelliğinin oluşturulan görüntüler üzerinde genel olarak çok iyi bir şekilde ayırt edilebildiği görülmektedir. En iyi yeşil alana ait ayırımı Jeffrey ve Fidelity yöntemleri gerçekleştirmiştir.


Kullanılan 21 adet benzerlik ölçütü yönteminin de görüntünün farklı bandlarında başarılı doku tespitleri yaptığı ve başarılı ayırım değerleri oluşturarak genel anlamda doku özelliklerini ayırt ettiği belirlenmiştir.



(a)




(b)




(c)


Şekil 4.13. Öklid mesafesi kırmızı band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina



(a)




(b)




(c)


Şekil 4.14. City Block mesafesi mavi band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina



(a)




(b)




(c)


Şekil 4.15. Chi Kare mesafesi kırmızı band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina



(a)




(b)




(c)


Şekil 4.16. Jeffrey mesafesi kırmızı band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina



(a)




(b)




(c)


Şekil 4.17. Sorensen mesafesi yeşil band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina



(a)




(b)




(c)


Şekil 4.18. Dice mesafesi kırmızı band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina



(a)




(b)




(c)


Şekil 4.19. Bhattacharyya mesafesi mavi band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina



(a)




(b)




(c)


Şekil 4.20. Fidelity mesafesi kırmızı band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina



(a)




(b)




(c)


Şekil 4.21. Soergel mesafesi yeşil band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina



(a)



(b)



(c)

Şekil 4.22. Jaccard mesafesi kırmızı band renk değerlerine göre oluşturulan benzerlik ölçüt görüntüleri; (a) su, (b) yeşil alan ve (c) bina

4.2.3. Standart doku ölçütleri

Görüntüler üzerinden doku belirlemenin en basit yaklaşımlarından bir tanesi görüntüye ait histogramların istatistiksel bilgilerinin kullanılmasıdır. Hesaplama histogramların kullanılması sadece renk değerlerinin dağılımı hakkında bilgi vermektedir. Oysaki görüntülerin içerisinde bulunan dokuların piksel konumlarının birbirleri ile ilişkileri hakkındaki bilgiyi tespit edememektedir. Histogramlar üzerinden elde edilen birinci derece istatistikler görüntüdeki piksellerin konumsal bilgisini elde etmek için yetersiz kalmaktadır. Bu sebepten ötürü bu analiz aşamasında Bölüm 2.2.3.'te bahsedilen ve İstatistiksel yöntemlerden biri olan Gri Seviye Eş-Oluşum Matrisi (GLCM) kullanılarak standart doku ölçütlerinin elde edilmesi işlemi gerçekleştirilmiştir. GLCM doku belirleme alanında kullanılan en iyi ve en yaygın araçlardan bir tanesidir. Görüntüdeki dokunun özelliklerini, piksel çiftleri arasındaki gri seviye değişimlerinin farklı kombinasyonları ile ilişkili olarak analiz etmektedir. GLCM'nin çalışma prensibi; ikinci dereceden bileşik durum olasılık yoğunluk fonksiyonunun kestirimine dayanmaktadır. GLCM, birbirleri arasında belirli bir mesafe bulunan ve belli bir yöndeki bir çift gri seviyeli pikselin birbirlerine göre oluşma sıklığını temsil eden kare bir matristir. GLCM üzerinden elde edilen ölçütler ikinci derece istatistiklerdir ve görüntü üzerinde bulunan doku bilgisi hakkında istatistiki bilgiler sunmaktadırlar. (Arslan ve diğ., 2017), yaptıkları çalışmalarında GLCM üzerinden elde edilen “ortalama” doku ölçütünün görüntü sınıflandırmasına önemli derecede olumlu katkı sağladığını belirtmişlerdir (Arslan ve diğ., 2017).

Aşağıda tez çalışmasında kullanılan veri setine ait gri seviye eş oluşum matrisi oluşturularak piksellerin renk ve konumsal bilgilerinden yararlanılarak elde edilen 6 adet standart doku ölçütlerine (Entropi, Korelasyon, İkincil Moment, Ortalama v.b) ait görüntüler verilmiştir (Şekil 4.23 – 4.28).

Elde edilen görüntüler incelenecek olursa; Ortalama görüntüsünde veri seti içerisinde bulunan bina dokusunun tespitinin net bir şekilde gerçekleştirildiği görülmektedir. Benzerlik ölçütleri ile elde edilmiş olan bina doku görüntüleriyle benzer sonuçlar elde edilmiştir.

Entropi değişkenliğin (belirsizliğin) bir ölçüsü olduğundan dolayı veri seti içerisinde birbirine çok yakın değerlere sahip olan su ve yeşil alan gibi doku alanlarının değerleri

sıfıra yakın sonuçlar vermiştir ve bu alanlar koyu renk ile temsil edilmiştir. Ancak renk değişiminin/değişkenliğin fazla olduğu bina dokusu alanlarında ise 1 değerine yakın/parlak renk sonuçlar elde edildiği görülmüştür.

Kontrast ölçütü görüntüdeki renk değerlerinin zıtlığının bir ölçütüdür. Bu sebeple elde edilen kontrast görüntüsünde zıtlık değerleri fazla olan bina dokusuna ait alanlarda kontrast değerleri yüksek çıkmıştır. Analiz sonucu oluşan kontrast görüntüsünde binalara ait alanlar net bir şekilde tespit edilebilmektedir.

Korelasyon bir pikselin kendisine komşu piksellerle nasıl ilişkili olduğunun bir ölçüsüdür. Buna göre renk dağılımları homojene yakın olan yeşil ve su alanlarına ait olan piksellerin korelasyon değerlerinin yüksek olduğu tespit edilmiştir. Elde edilmiş olan konumsal bağımlılık dereceleri görüntülerinde de bu durum tespit edilmiş ve bu alanlara ait konumsal bağımlılık dereceleri yüksek değerlerde çıkmıştır.


İkincil açısal moment görüntünün homojenliğinin ölçüsüdür. Görüntü içerisindeki homojenlik artarsa bu ölçütün değeri de büyümektedir. Elde edilen ikinci açısal moment görüntüsü incelendiğinde doku örnekleri bakımından görüntü içerisindeki homojen dağılıma sahip olan su ve yeşil alanların aldığı değerlerin yüksek, bina doku örnekleri gibi homojenlik değeri düşük olan alanların aldığı değerlerin ise düşük olduğu görülmektedir. Konumsal bilgi derece görüntüleri ile karşılaştırıldığında benzer sonuçların elde edilgi gözlemlenmektedir. Her iki yöntemde de su ve yeşil alanların yüksek değerler olarak birbirlerine benzer özellikler taşıdıkları söylenebilir.

Homojenlik görüntünün farklı bölgelerindeki benzerliğin bir ölçüsüdür. Homojenlik doku ölçüt görüntüsü incelendiğinde su ve yeşil alan dokularını birbirinden ayırmakta başarılı sonuç vermese de bina dokusunu her iki diğer doku bilgisinden ayırmakta başarılı olmuştur. Doku ölçütü görüntüsünden bina bilgisinin çıkarımında başarılı sonuçlar alınmıştır.


Standart doku ölçüt görüntüleri genel olarak incelendiğinde detaylı ve hassas bir çıkarım yapılamamasına karşın kontrast, ortalama ve entropi görüntülerinde binaların ve açısal ikinci moment, korelasyon ve homojenlik görüntülerinde ise su ve yeşil alanların çeşitli belirgin özelliklerinin ayırt edilebildiği görülmektedir.



Şekil 4.23. Standart doku ölçütlerinden 5x5 piksellik pencere yöntemiyle oluşturulan ortalama görüntüsü



Şekil 4.24. Standart doku ölçütlerinden 5x5 piksellik pencere yöntemiyle oluşturulan entropi görüntüsü




Şekil 4.25. Standart doku ölçütlerinden 5x5 piksellik pencere yöntemiyle oluşturulan kontrast görüntüsü



Şekil 4.26. Standart doku ölçütlerinden 5x5 piksellik pencere yöntemiyle oluşturulan korelasyon görüntüsü



Şekil 4.27. Standart doku ölçütlerinden 5x5 piksellik pencere yöntemiyle oluşturulan ikinci açısai moment görüntüsü



Şekil 4.28. Standart doku ölçütlerinden 5x5 piksellik pencere yöntemiyle oluşturulan homojenlik görüntüsü

4.2.4. Konumsal örüntü analizi

Çalışmanın bu aşamasında konumsal örüntü analizlerinden olan Morans'I ve Getis-Ord G istatistiklerine ait görüntüler oluşturulmuştur. Veri seti, konumsal bilgi elde edilirken de kullanılan 11 piksel komşulukla analiz edilmiş ve Moran's I ve Getis-Ord G yöntemlerine ait konumsal örüntü görüntüleri elde edilmiştir. Uydu görüntüsünün her bir bandına uygulanan konumsal örüntü analizleri sonucunda yatayda 11 piksel komşulukla dört yeni görüntü bandı oluşturulmuş ve bu yeni bandlar MATLAB ortamında spektral bandlar ile birleştirilmiştir. Sonuç olarak 8 banda sahip hem spektral değerlere hem de Morans'I ve Getis-Ord G konumsal örüntü bilgilerini içeren yeni iki adet veri seti oluşturulmuştur. Oluşturulan bu yeni veri setlerinden Getis-Ord G istatistiği sonuçlarını içeren veri seti 3 adet sınıflandırma işlemine tabi tutularak her bir sınıflandırma yönteminde genel sınıflandırma doğruluğuna yaptığı katkı incelenmiştir. Sınıflandırma görüntüleri ve elde edilen hata matrisleri Bölüm 4.7'de verilerek sonuçlar irdelenmiştir.

4.2.5. Semivaryans parametrelerinin belirlenmesi

Geoistatistik, uzaktan algılanmış görüntüler içerisindeki konumsal bilginin belirlenebilmesi amacıyla son yıllarda sıklıkla tercih edilen yöntemlerdendir. Bölüm 3.2'de bahsedildiği gibi çeşitli yönlerdeki komşu pikseller arasında bulunan bağımlılığın değerini belirleyebilmesinden/derecelendirebilmesinden ötürü tercih edilir.

Çalışmanın ana amacı; görüntülerde bulunan dokunun genel tanımından yola çıkarak belirli bir mesafe komşuluğunda bulunan piksellerin düzenini tanımlamaya yardımcı olan istatistik/histogram ölçüt ve çeşitli metrik ölçülerin kullanımıyla gerçekleştirilen; belirli görüntü bölgelerinde mekansal/uzamsal otokorelasyon ile tanımlanacak olan değişkenlik veya ilişkilerin, metrik/istatistik benzerlik ölçütleri de karşılaştırılarak katkılarının araştırılması ve geoistatistik yaklaşımlar yardımıyla belirlenen konumsal bağımlılık/ilişki bilgileri ile çeşitli uydu görüntüleri için doku özelliklerini optimum biçimde belirleyebilecek ölçütlerin tespit edilmesidir. Bu tespit edilen ölçütlerin kullanımıyla spektral bilgi çıkarım performansını ne ölçüde etkileyeceğini, katkı düzeyi ve potansiyelini ortaya çıkarmaktır.


Geoistatistik yaklaşımlar için ilk işlem adımı uzaktan algılanmış görüntüler içerisindeki konumsal bilginin belirlenmesi amacıyla veri seti olarak kullanılan görüntünün pikselleri arasındaki semivaryans değerlerinin elde edilmesidir. Bu amaçla Bölüm 3.2’de bahsedilen ve Eşitlik 3.9 olarak gösterilen yatay yöndeki semivaryans değerlerinin belirlenmesi sağlayan matematik modelin MATLAB ortamına aktarılması ve bu programlama dilinde çalıştırılması sağlanmıştır (Şekil 4.29).

```
for lag=1:(size(grnt,2)-1)
    toplam=0;
    for i=1:size(grnt,1)
        for j=1:(size(grnt,2)-lag)
            toplam = toplam + ((grnt(i,j)-grnt(i,j+lag)).^2);
        end
    end
    s_varyans(lag)= toplam / (2*(size(grnt,1))*(size(grnt,2)-lag));
    Mesafe(lag)=lag;
end
```


Şekil 4.29. Semivaryans değerlerinin belirlenmesi için yazılan MATLAB kodu

MATLAB kodlama diliyle yazılmış olan kodlar yardımıyla belirlenen semivaryans değerleri ENVI paket programı ile de hesaplanarak karşılıklı olarak kontrol edilmiş ve yapılan işlemin doğruluğu teyit edilmiştir.

Semivaryans değerleri belirlendikten sonra bu değerlere uygulanacak olan modellerin ve model parametrelerinin belirlenmesi işlemi gerçekleştirilmiştir. Bu amaçla yapılan araştırmalar sonucunda, Wolfgang Schwanghart tarafından 2010 yılında MATLAB programlama dilinde yazılmış olan “variogramfit” scriptinin kullanılmasına karar verilmiştir (Ek-A). Bu scriptin çalışma prensibi elde edilmiş olan deneysel semivaryans değerlerine en küçük kareler methodunu uygulayarak çeşitli modeller uydurmak ve bu modellerin parametrelerini (Sill, Range, Nugget) elde etmektir. Şekil 4.30 ve Şekil 4.31’de yazılan kod (Şekil 4.29) yardımıyla tüm görüntüye uygulanarak elde edilen semivaryans değerleri ve çalışmaların genelinde kullanılan spherical ve exponential modelleri ve bu modellere ait parametreleri gösterilmektedir. Bu grafiklerin oluşturulmasında klasik MATLAB komutları/toolları kullanılmıştır.



Şekil 4.30. Veri setinin semivariogram grafiği ve spherical model parametreleri



Şekil 4.31. Veri setinin semivariogram grafiği ve exponential model parametreleri

Veri seti olarak kullanılan kentsel alan uydu görüntüsünün geoistatistik yöntemlerle konumsal bağımlılığının belirlenmesi için benzerlik ölçütlerinde olduğu gibi kayan pencereler yönteminden faydalanılmıştır. Bölüm 4.1’de yapılan tarımsal alan uygulaması ile paralel olacak biçimde çalışma bütünlüğünün sağlanması adına görüntülerin karşılaştırmalı analizlerinin yapılabilmesi için kentsel alan uygulamasında kullanılan uydu görüntüsünde de 11x11 piksellik pencere boyutu kullanılması uygun bulunmuştur. Ayrıca pencere boyutunun belirlenmesi için literatürde belirtilen çok çeşitli çalışmalar olmasına karşın; yerel konumsal bilginin daha etkin bir şekilde tespit edildiği karşılaştırmalı boyut analizleri sonucunda kanıtlanmış 11x11’ lik piksel boyutunun uygun pencere değeri olarak seçilmesine karar verilmiştir.

Pencere boyutuna karar verildikten sonra veri setinin kayan pencereler yöntemiyle analiz işlemi gerçekleştirilmiştir. Bu işlemde görüntü, 11x11’lik pencere boyutu ile 1 piksel ötelemeli/komşuluklu alt görüntülere ayrılarak, bu alanlara ait semivaryans değerleri belirlenmiştir. Kayan pencereler ile belirlenen semivaryans değerlerinden sonra bu değerlere uzaktan algılama görüntüleri gibi sürekli yapıya sahip veri setlerinde diğer modellere göre daha iyi sonuçlar vermelerinden dolayı tercih edilen Exponential ve Spherical geoistatistik modellerin uygulanarak parametrelerinin (Sill, Range, Nugget) elde edilmesi sağlanmıştır.

4.2.5.1. Konumsal bağımlılığın derecelendirilmesi

Semivariogram model parametrelerinden yararlanarak konumsal bağımlılığın nicel olarak belirlenmesi ile ilgili literatürde çeşitli öneriler yapılmıştır. Seidel ve Oliveira (2014)-(2016) ve Barbosa ve diğ. (2017) konu ile ilgili çalışmalarında, sill ve nugget parametre değerlerini kullanarak konumsal bağımlılık dereceleri belirlemeyi amaçlayan bir öneride bulunmuşlardır. Bu derecelendirme yapılırken bağıl nugget etkisi (NE; Relative Nugget Effect) ve konumsal bağımlılık derecelerini (SPD; Spatial Dependence Degree) belirleyen aşağıdaki bağıntılardan yararlanılmıştır. Bağıl nugget etkisi;

$$NE (\%) = \left(\frac{C_0}{C_0+C_1} \right) * 100 \quad (4.1)$$

formülü ile belirlenir. Burada C_0 nugget etkisini, C_0+C_1 ise semivariogramın sill değerini göstermektedir. Elde edilen NE(%) değeri 0 ile 25 arasında ise güçlü, 25 ile 75 arasında ise orta düzeyde ve 75 ile 100 arasında ise zayıf konumsal bağımlılık olarak sınıflandırılmaktadır.

Konumsal bağımlılık ise;

$$SPD (\%) = \left(\frac{C_1}{C_0+C_1} \right) * 100 \quad (4.2)$$

şeklinde gösterilmektedir. Burada C_1 değeri katkı değerini -sill değerinden nugget değerinin farkı-, C_0 ise nugget etki değerini temsil etmektedir. SPD(%) değerinin sınıflandırılması ise 0-25 arasında alınan değerler zayıf, 25-75 arasında olan değerler orta ve 75-100 arasındaki değerler ise güçlü konumsal bağımlılık olarak nitelenmektedir.


Bu konumsal bağımlılık belirleme teknikleri ile veri seti üzerinde Eşitlik 4.1'e göre hesaplanan konumsal bağımlılık derecelerinin digital görüntüleri oluşturulmuş ve elde edilen sonuçların sınıflandırma değerlerinde ise bazı tutarsızlıklar saptanmıştır. Bu tutarsızlıklardan dolayı, mevcut indeks hesabında kullanılan parametrelerin mekansal bağımlılık değerini yeterince yansıtmadığı; oranlamanın farklı semivariogram parametreleri ile yapılmasının daha uygun olacağı tespitiyle, yeni konumsal bağımlılık indeksi oluşturulmasına karar verilmiştir. Bu indeksin oluşturulmasında görüntü pikselleri arasındaki değişkenliğin değerini gösteren Sill ve konumsal bağımlılığın ölçütü olarak kullanılan Range değeri esas alınmıştır. Belirtilen parametrelerin birbirine oranlanması sonrasında elde edilen sonuçlar, yapılan çeşitli eşik değer belirleme denemeleri sonucunda deneysel olarak karar verilen sayısal eşik değerler ile ayrıştırılarak; görüntü üzerinde 5 farklı konumsal bağımlılık dereceleri (1: Düşük, 5: Çok Yüksek) elde edilmiştir (Tablo 4.5). Yapılan eşik değer denemelerinin sınıflandırma işlemine olan etkisi Tablo 4.5'te gösterilmiş olup sınıflandırma/bilgi çıkarımına etkisi en fazla olan değerler eşik değer olarak belirlenmiştir. Belirlenmiş olan eşik değerler her 4 spektral band için ayrı ayrı uygulanarak her banda ait konumsal bağımlılık derece görüntüleri elde edilmiştir. Şekil 4.32 ve Şekil 4.33'de Kırmızı spektral banda ait Exponential ve Spherical modellerden elde edilen konumsal bağımlılık derece görüntüleri gösterilmektedir.

Görüntüler incelendiğinde yeşil alanlarda ve suyu temsil eden bölgelerde konumsal bağımlılıkların çok yüksek çıktığı, yerleşim yerlerinin (binaların) bulunduğu bölgelerde ise konumsal bağımlılıkların düşük ve az değer aldığı görülmektedir.


Tablo 4.5. Sill / Range bağımlılık dereceleri için kullanılan eşik değerler

Dereceler	Eşik Değerler		
Çok Yüksek	$Q < 10$	$Q < 30$	$Q < 50$
Yüksek	$10 < Q < 30$	$30 < Q < 80$	$50 < Q < 100$
Orta	$30 < Q < 50$	$80 < Q < 120$	$100 < Q < 150$
Az	$50 < Q < 80$	$120 < Q < 200$	$150 < Q < 230$
Düşük	$80 < Q$	$200 < Q$	$230 < Q$
Sınıflandırmaya Başarım Etkisi	%2 - %3	%7 - %8	%5 - %6

*Q değeri Sill/Range oranının aldığı değeri temsil etmektedir.




Şekil 4.32. Exponential modele göre oluşturulan konumsal bağımlılık dereceleri görüntüsü



Şekil 4.33. Spherical modele göre oluşturulan konumsal bağımlılık dereceleri görüntüsü

4.2.5.2. Spektral ve konumsal bilginin birleştirilmesi

Konumsal bilginin derecelendirilerek bir kriter oluşturulmasından sonra standart bir uzaktan algılama uygulamasında (sınıflandırma gibi) sağlayacağı faydayı belirlemek adına spektral görüntü ile konumsal bilginin birleştirilmesi gerekmektedir. Böylece gerçekleştirilecek olan sınıflandırma işleminde bütün bilgilerin (spektral + konumsal) kullanılması sağlanmış olacaktır. Spektral ve konumsal bilgi görüntülerinin birleştirilmesi için MATLAB “Tiff class” toolboxından yararlanılmıştır. Tiff class toolu MATLAB’da kullanılan klasik “imread” ve “imwrite” komutlarından farklı olarak bu komutların sağlayamadığı görüntünün özelliklerini değiştirebilme imkanını kullanıcılara sunmaktadır. Bu özelliklerin içerisinde alt görüntüleri okuma, görüntülere yeni eklemeler yapabilme ve çeşitli görüntü özniteliklerini değiştirebilme gibi yetenekler bulunmaktadır. Görüntü üzerinde esnek çalışma sağlamasından dolayı ve klasik olarak kullanılan komutların görüntü birleştirme işleminde etkisiz kalmasından dolayı spektral görüntü ile konumsal görüntülerin birleştirilmesinde “Tiff class” toolboxı kullanımının uygun olduğuna karar verilmiştir.



Şekil 4.34. Spektral bilgi ile analizler sonucunda elde edilen ek bilgilerin birleştirilmesi

Bu toolun çalışma prensibinde uzaktan algılanmış görüntülerdeki band mantığında görüntüler oluşturmak vardır. Konumsal bilgileri içeren görüntüler uzaktan algılanmış görüntünün bir bandı olarak düşünülebilirler ve yapılacak olan analizler için bağımsız bir veri kaynağı olarak kullanılabilirler.

Bu aşamada Tiff class toolboxı yardımıyla spektral bandlar ile bu bandlardan yararlanılarak elde edilen konumsal bilgi görüntüleri bir araya getirilmiş ve başlangıçta dört bandlı olan veri seti sekiz bandlı bir görüntü (spektral + konumsal) şekline dönüştürülmüştür (Şekil 4.34). Konumsal bilginin elde edildiği her iki model için gerçekleştirilen bu işlem sonucunda iki adet ek veri seti oluşturularak veri setinin sayısı üçe çıkarılmıştır.

4.2.6. Otoregresif model (AR)

Otoregresif; bir değişkenin elde edilirken bir önceki iterasyonda elde edilen kendi değerinin kullanılması anlamına gelmektedir. Yani değişken eşitliğin hem sağ hemde sol tarafında kullanılmaktadır.


Otoregresif serilerde, kullanılan verinin hesaplanan değerleri bir önceki adımda hesaplanan değerlere ve gürültü değerlerine (white noise) bağlıdır. Görüntü analizinde otoregresif model görüntüde bulunan bir pikselin sahip olduğu yoğunluk/reng değerinin o pikselin komşularının yoğunluk/reng değerlerinin ağırlıklı ortalaması olduğunu varsayan lokal/yerel etkileşimli bir analiz yaklaşımıdır.

f görüntüsünün sıfır ortalamalı rastgele bir alan olduğu varsayılırsa, AR modeli aşağıdaki şekilde tanımlanabilir;

$$f_s = \sum_{r \in N_s} \theta_r f_r + e_s \quad (4.3)$$

yukarıdaki formülde f_s görüntüdeki s pikselindeki yoğunluk/rengi değerini, e_s bağımsız ve benzer bir biçimde dağılmış olan gürültü değerini, N_s s pikselinin komşu piksellerinin sayısını ve θ ise model parametre vektörünü göstermektedir.

AR modeli diğer konumsal tahmin modellerine göre parametre tahmininde sadelik, basitlik ve etkili sonuç elde etme gibi çeşitli avantajlara sahiptir. AR modeli literatürdeki çeşitli çalışmalarda görüntülerdeki dokunun belirlenmesi için kullanılmıştır.



Şekil 4.35. f_s görüntü pikselinin yerel komşulukları

Görüntünün bir pikseli için (f_s) yerel komşulukların temsili Şekil 4.35'te gösterilmektedir. Burada gölgeli alan ile gösterilen bölge AR modelinde kullanılacak olan komşulukların bulunabileceği bölgeyi göstermektedir. Görüntü bölütleme için AR modelinin kullanılması, belirli bir görüntü bölgesi için model parametrelerinin tanımlanmasından ve daha sonra doku belirleme için elde edilen parametre değerlerinin kullanılması aşamalarından oluşur. Buna göre Şekil 4.35'te gösterilen örnek göz önüne alınarak 4 adet piksel komşusu için 5 adet bilinmeyen model parametresi bulunmaktadır. Bu parametreler e_s gürültü değerinin ait standart sapması (σ) ve model parametre vektörü $\theta = [\theta_1, \theta_2, \theta_3, \theta_4]$.

Karesel hata toplamının minimize edilmesi ile;

$$\sum_s e_s^2 = \sum_s (f_s - \hat{\theta} w_s)^2 \quad (4.4)$$

parametre değerleri aşağıdaki eşitlikler yardımıyla bulunabilir;

$$\hat{\theta} = (\sum_s w_s w_s^T)^{-1} (\sum_s w_s f_s) \quad (4.5)$$

$$\sigma^2 = N^{-2} \sum_s (f_s - \hat{\theta} w_s)^2 \quad (4.6)$$

burada $w_s = \text{col}[f_i, i \in N_s]$, ve N görüntüsü kare bir görüntü kabul edilir (Materka ve Strzelecki, 1998).

Konumsal otoregresyon (spatial autoregression) otoregresif modelin özelleşmiş bir halidir ve veri setini oluşturan dataların konumsal bağımlılık bilgilerinin kullanarak analizini gerçekleştirir. Tobler ilk yasasını “Herşey birbiriyle ilişkilidir, ancak yakın olanlar uzak olanlara göre birbirleriyle daha da ilişkilidir.” şeklinde açıklayarak birbirlerine yakın olan nesnelerin benzerliklerinin uzak olanlara göre daha fazla olduğundan bahsetmiştir.

Konumsal otoregresyon (Spatial autoregression, SAR);

$$y = X\beta + z + \varepsilon \quad (4.7)$$

eşitliği ile tanımlanmaktadır. Burada X değeri veri seti değerlerini, β lineer regresyon model parametrelerini, z değeri konumsal rastgele hata değerini ve ε ($\varepsilon \sim N(0, \sigma_\varepsilon^2 I)$) değeri ise bağımsız hata değerini temsil etmektedir.

Eşitlik (4.7)’de bulunan z değeri;

$$z = Bz + v \quad (4.8)$$

şeklinde modellenir. Burada B konumsal bağımlılık matrisini, z değeri bağımlı değişkeni ve v ($v \sim N(0, \sigma_z^2 I)$) ise hata değerini temsil etmektedir.

Bu denklemde bilinmeyen z değerinin çözümü için $(I - B)^{-1}$ mutlaka bilinmesi, y değerinin sıfır ortalamaya sahip olması ve kovaryans matrisinin $\Sigma = \sigma_z^2 \left((I-B)(I-B^T) \right)^{-1}$ şeklinde elde edilmesi gerekmektedir.

SAR modelinde konumsal bağımlılık B matrisinden temsil edilmektedir. Bu matriste herbir rastgele değişkenin komşularıyla olan bağımlılık değerleri tutulmaktadır. Bu matris oluşturulurken $B = \rho W$, W ağırlık matrisinin simetrik olmasına gerek yoktur. Çünkü bu değer doğrudan kovaryans matrisinin tersinden gelen değer olmaz.


Yapılan en son konumsal bağımlılık matrisinden elde edilen ağırlık matrisinin kullanılmasıyla yapılan düzenlemelerle birlikte Eşitlik (4.7);

$$y = \rho Wy + X\beta + \varepsilon \quad (4.9)$$

şeklini almaktadır. Burada ρ ise otoregresyon parametresini temsil etmektedir (Ver Hoef ve diğ., 2018).

Eşitlik (4.9)'da görüldüğü gibi otoregresif modelin tanımında olduğu gibi birinci iterasyonda hesaplanan y değeri ikinci itersayonda girdi verisi olarak kullanılarak iteratif çözümde konumsal bilginin kullanılması sağlanmış olur.

Tez çalışmasında benzerlik ölçüt görüntüleri ile SAR modelinden elde edilen konumsal bağımlılık model görüntülerinin karşılaştırılması yapılabilmesi için bu model ile oluşturulan görüntülerde benzerlik ölçütleri için seçilen aynı doku örnek bölgelerinden faydalanılmıştır (Şekil 4.12). Doku örnek bölgeleri yardımıyla SAR modeli ile çeşitli doku ölçüt görüntüleri oluşturulmuştur. Şekil 4.36 ile gösterilen ve 5x5 piksel pencere boyutlu 4 piksel komşuluk ile oluşturulan SAR modeline ait kontrast görüntüsü gösterilmektedir. Tablo 4.6 ve 4.7'de SAR modeline ait model dönüşüm parametreleri ve kontrast görüntüsünün SAR modeli özellikleri gösterilmektedir.



Şekil 4.36. SAR modeli ile 5x5 boyutlu pencere ve 4 piksel komşuluk ile oluşturulan kontrast görüntüsü

SAR görüntüsü ile Benzerlik Ölçütü yöntemleri yardımıyla bina dokusuna ait örnek bölgeden oluşturulan benzerlik ölçütü görüntüleri incelendiğinde her iki görüntünün benzer sonuçlar ürettiği söylenebilir. Her iki yöntem de görüntü içersinideki bina dokusunun tespiti başarılı bir yüzde ile gerçekleştirmişlerdir. SAR modeli ile GLCM yöntemiyle elde edilen standart doku ölçütlerine ait kontrast görüntüsü karşılaştırıldığında SAR modelinin daha iyi sonuç verdiğini ve görüntü üzerinde bulunan yol detaylarını daha hassas ve doğru bir biçimde ayırt etmeyi başardığı görülmüştür.

Tablo 4.6. 5x5 boyutlu pencere ve 4 piksel komşuluklu SAR modeli ile oluşturulan kontrast görüntüsüne ait model parametreleri

Model Parametreleri			
Teta1	0,47104376	0,71818367	0,79452256
Teta2	-0,25217517	-0,44675753	-0,5959532
Teta3	0,50678878	0,53249987	0,71760683
Teta4	0,0024148577	0,12730572	0,069905613
Sigma	0,7694473	0,46022703	0,27457554

Tablo 4.7. 5x5 boyutlu pencere ve 4 piksel komşuluklu SAR modeli ile oluşturulan kontrast görüntüsüne ait özellikler

Model Özellikleri			
S(4,0)	1,8641245	6,9715458	66,610348
S(0,4)	1,9031541	8,3019921	69,160204
S(4,4)	1,852451	7,3361936	80,30173
S(4,-4)	1,875	8,2271294	90,801233

Şekil 4.37 ile gösterilen ve 5x5 piksel pencere boyutlu 4 piksel komşuluk ile oluşturulan SAR modeline ait açısıl ikinci moment görüntüsü gösterilmektedir. Tablo 4.8 ve 4.9’da SAR modeline ait model dönüşüm parametreleri ve açısıl ikinci moment görüntüsünün SAR modeli özellikleri gösterilmektedir.

SAR yöntemiyle oluşturulan açısıl ikinci moment görüntüsü incelendiğinde, GLCM yöntemiyle oluşturulan aynı doku ölçütü karşılaştırıldığında her iki yönteminde benzer alanları ön plana çıkardıkları görülmüştür. Her iki yöntem de su ve yeşil alanlara ait bölgeleri tespit etmeyi başarmışlardır. Geoistatistik yöntem yardımıyla oluşturulan konumsal bağımlılık derece görüntüleriyle karşılaştırıldığında ise SAR yönteminin bağımlılık dereceleri yüksek olan bölgeleri belirgin olarak ön plana çıkardığı gözlemlenmiştir. Benzerlik ölçütleri ile karşılaştırıldıklarında ise özellikle

su dokusuna ait benzerlik ölçüt görüntüleri ile benzer sonuçlar verdiği tespit edilmiştir.



Şekil 4.37. SAR modeli ile 5x5 boyutlu pencere ve 4 piksel komşuluk ile oluşturulan açısal ikinci moment görüntüsü

Tablo 4.8. 5x5 boyutlu pencere ve 4 piksel komşuluklu SAR modeli ile oluşturulan açısal ikinci moment görüntüsüne ait model parametreleri

Model Parametreleri			
Teta1	0,47104376	0,71818367	0,79452256
Teta2	-0,25217517	-0,44675753	-0,5959532
Teta3	0,50678878	0,53249987	0,71760683
Teta4	0,0024148577	0,12730572	0,069905613
Sigma	0,7694473	0,46022703	0,27457554

Tablo 4.9. 5x5 boyutlu pencere ve 4 piksel komşuluklu SAR modeli ile oluşturulan açısıl ikinci moment görüntüsüne ait özellikler

Model Özellikleri			
S(4,0)	0,10027777	0,027886335	0,0028029066
S(0,4)	0,10016659	0,027128392	0,0027627034
S(4,4)	0,099774336	0,027802102	0,0025462191
S(4,-4)	0,09992911	0,027344285	0,0024327327

4.2.7. Sınıflandırma işlemi

Uydu görüntüleri yeryüzüne -arazi kullanım sınıflarına v.b- ilişkin sağladığı spektral, konumsal ve zamansal çözünürlükteki yüksek hassasiyetli verileri sebebiyle son yıllarda sıklıkla tercih edilmekte ve çeşitli uygulamalarda yaygın olarak kullanılmaktadır. Uydu görüntülerinin uzaktan algılama platformları tarafından algılandıkları ilk halleri ham görüntü olarak kabul edilmektedir. Sınıflandırma işlemi ham görüntüdeki her bir piksele ait yansıma (spektral) verisinden faydalanmaktadır. Yeryüzü üzerinde bulunan her bir özellik grubu veya nesne türü doğasında bulunan karakterden ötürü elektromanyetik spektrumda farklı spektral yansıtım değerine sahiptir. Bu özellik sebebiyle bu nesneler uydu görüntülerinde farklı dijital numaralarla (DN) temsil edilirler. Bu DNler yardımıyla yeryüzüne ait farklı bilgilerin çıkarılabilmesi için çeşitli istatistiksel analiz teknikleri kullanılmaktadır. Uzaktan algılama verilerini bilgiye dönüştürmek için kullanılan en yaygın istatistiksel analiz yöntemi bu verilerin sınıflandırılması işlemidir.

Uzaktan algılamada sınıflandırma, görüntü içerisindeki benzer yansıma (spektral) özelliklerine sahip olan anlamlı grupların belirlenmesi işlemidir. Yeryüzünde bulunan cisimlerin farklı spektral yansıma değerleri esasına dayanarak, görüntü içerisindeki her bir görüntü elemanının ait olduğu özellik grubuna (arazi örtüsü/kullanımı sınıfı) otomatik olarak atanması işlemi olarak tanımlanmaktadır.

Uzaktan algılamada sınıflandırma işlemi genel olarak kontrollü (eğitilmiş) ve kontrolsüz (eğitimsiz) olarak iki şekilde gerçekleştirilmektedir. Bunların yanı sıra

son yıllarda kullanımları artış gösteren makine öğrenmesi ve yapay sinir ağları gibi analiz yöntemleri de sınıflandırma işleminde kullanılmaktadır.

Kontrollü sınıflandırma; görüntü üzerindeki arazi örtüsü/kullanımı sınıflarına ait öncül bilgiler kullanılır. Bu bilgiler yardımıyla oluşturulmak istenen sınıflara ait eğitim verileri oluşturulur. Oluşturulan bu eğitim verilerinden elde edilen istatistik bilgilerin görüntüye uygulanması ile görüntüyü oluşturan her bir pikselin çeşitli karar kuralları kullanılarak hangi sınıfa ait olduğu belirlenir ve ilgili piksel o sınıfa ait olarak etiketlenir. Uydu görüntülerinin sınıflandırılmasında kontrollü sınıflandırma, kontrolsüz sınıflandırmaya oranla daha yüksek doğruluk derecesine sahip olması ve güvenilirliği nedeniyle daha çok tercih edilen yöntemler arasındadır.

Kontrollü sınıflandırma işlemi, genel olarak aşağıdaki işlem adımlarından oluşmaktadır:

1. Yeryüzü özelliklerini ayırt edebilecek sınıfların belirlenmesi ve bu alanlara ait kontrol bölgelerinin seçimi.
2. Yapılacak olan analize göre görüntü ve spektral band belirlenmesi.
3. Belirlenen sınıflara ait eğitim ve test alanlarının seçimi.
4. Çalışma amacına yönelik olan sınıflandırma yönteminin belirlenmesi.
5. Sınıflandırma sonrasında meydana gelen görüntü için doğruluk analizi.

Kontrollü sınıflandırma, parametrik ve parametrik olmayan yöntemler olmak üzere ikiye ayrılmaktadır. Bu ayrım da eğitim verisinin istatistiksel dağılımının varsayım durumuna göre yapılmaktadır. Parametrik yöntemler, eğitim verisini istatistiksel olarak genellikle normal (Gauss) dağılımı olarak kabul ederek çalışırlar. Parametrik olmayan yöntemlerde ise verinin dağılımına ait herhangi bir istatistiksel dağılım varsayımı yapılmaz. Son yıllarda uzaktan algılama görüntülerinin sınıflandırılması ile ilgili yapılan çalışmaların literatürüne bakıldığında kullanılan sınıflandırma teknikleri arasında Maximum Likelihood, Neural Network (Yapay Sinir Ağları (YSA)) ve Support Vector Machines (SVM) yöntemlerinin sıklıkla kullanıldığı görülmektedir. Bu tez çalışmasında da bu üç yöntemden faydalanılmıştır.

En çok tercih edilerek kullanılan yöntem uygulama kolaylığı ile çeşitli paket programlarında kolaylıkla erişim sağlanabilen, parametrik bir yöntem olan Maximum

Likelihood yöntemidir. Yapay sinir ağı ise parametrik olmayan yapısı ile verinin istatistiksel dağılımı üzerine bir varsayım yapmaması sebebiyle birçok problemin çözümünde iyi sonuçlar verdiği tespit edilmiştir. Ancak bu başarının kullanılan sinir ağı mimarisinin ve algoritmaların seçimine bağlı oluşu bu yöntemin en büyük kısıtlayıcı özelliklerinden birisidir. Yapay sinir ağı, istatistiksel sınıflandırma yöntemleri ile karşılaştırıldığında veri setinin içerdiği gürültü miktarından etkilenmemesiyle ve doğrusal olmayan ilişkilerin öğrenilmesinde etkili ve başarılı olmasıyla dikkat çeken bir yöntemdir. YSA'nın en güçlü özelliği parametrik olmayan yani veri setinin dağılımı hakkında bir ön bilgiye gereksinim duymamasıdır. Sınıflandırma amacıyla oluşturulan eğitim verisinin yapısını iteratif bir şekilde öğrenmelerinden dolayı bağımsız teknikler olarak adlandırılırlar. YSA'ların en önemli avantajlarını şu şekilde sıralayabiliriz:

- * Parametrik olmayan bir yapıdadırlar,
- * Sınıflandırma aşamasında uygulanacak kurallar eğitim ile veriler üzerinden oluşturulur,
- * Farklı yapıdaki verilerin birleştirilmesine/kullanılmasına imkân verirler,
- * Genelleştirme kabiliyetleri yüksektir,
- * Diğer sınıflandırma yöntemlerinin aksine gürültüye karşı daha güçlüdür.

YSA'nın çalışmasında giriş ve çıkış verileri arasında önceden belirlenmiş olan hata sınır değerlerine ulaşılmış ise ağ elde ettiği değerler ile eğitimini gerçekleştirmiş olur. Ağırlıkların sürekli iteratif bir biçimde ağı ürettiği sonuç değerlerinin hedef değerlerle karşılaştırılarak oluşturulan hata değerinin minimize edilerek güncellenmesiyle, istenilen değere ulaşınca kadar geçen sürece öğrenme adı verilmektedir. YSA öğrenme işlemini tamamladıktan sonra daha önce bilinmeyen/yeni giriş verileri kullanılarak ağı çıkış değerleri izlenir. Bu işleme ağı eğitilmesi denilmektedir. Ağ eğitildikten sonra test verileri kullanılarak ağı veri setini temsil etme başarısı gözlemlenir.

Diğer yöntemlere nazaran daha başarılı sonuçlar üretmesine rağmen, YSA bazı dezavantajlara da sahiptir. Daha fazla eğitim süresine ihtiyaç duyması, ağ eğitim zamanını ve sınıflandırma başarısını doğrudan etkileyen parametre değişimlerine karşı hassas olması bunların en önemlileri arasındadır. Günümüzde uydu

görüntülerinin sınıflandırılması için en sık kullanılan yapay sinir ağı modeli çok katmanlı algılayıcıdır. Çok katmanlı algılayıcılar esnek ve çok sayıdaki lineer olmayan nöronlardan oluşurlar. Nöronlar genellikle, döngü oluşturmeyen ileri iletimli bağlantılara sahiptirler. İstatistiksel öğrenme (makine öğrenmesi) varsayımına dayanan Support Vector Machines (Destek Vektör Makineleri) yöntemi, yüksek sınıflandırma yeteneğine ve kullandığı sınırlı sayıdaki eğitim verisi ile diğer yöntemlere göre bir adım öne çıkmaktadır ve özellikle son yıllarda tercih sebebi olmaktadır (Özkan, 2001; Kansu, 2006; Çölkesen, 2009; Atasever, 2011; Dağdeviren, 2013; Üstüner, 2013; Taşçı, 2018).

Çalışmada, sınıflandırma işleminde bir önceki aşamada bahsedildiği gibi standart doku bilgisi, konumsal örüntü bilgisi ve konumsal bilgilerin eklenmesiyle sayısı beşe çıkan veri setleri analiz edilerek karşılaştırılmaları yapılmıştır. Bu görüntülerden ilki sadece spektral değerlerden oluşan ham uydu görüntüsü, ikincisi standart doku ölçütlerinden oluşan 6 bandlı görüntü, üçüncüsü konumsal örüntü görüntüleri ile oluşturulan sekiz bandlı görüntü, dördüncüsü spektral bilgi ve exponential model parametrelerinden oluşturan konumsal bilgi ile birleştirilmiş olan sekiz bandlı görüntü ve beşincisi ise yine spektral bilgi ve spherical model parametrelerinden elde edilen konumsal bilgi ile oluşturulan sekiz bandlı görüntüdür. Bu beş görüntü veri seti üzerinde 3 farklı kontrollü (eğitilmiş) sınıflandırma yöntemi olan Maximum Likelihood, Support Vector Machines ve Neural Network sınıflandırma yöntemleri uygulanmış ve sonuçları hata matrisleri yardımıyla incelenmiştir. Böylece tezin ana amacını oluşturan konumsal bilgi kriterinin klasik bir uzaktan algılama işlemi olan sınıflandırma işlemine nasıl bir katkı sağladığı araştırılarak ortaya koyulmuştur.


Sınıflandırma işlemi için uydu görüntülerinin analizinde ENVI paket programı tercih edilerek kontrollü (eğitilmiş) sınıflandırma işlemi gerçekleştirilmiştir. Kontrollü (eğitilmiş) sınıflandırmanın çalışma prensibinde ilk olarak tespit edilmesi istenilen sınıflara ait eğitim alanlarının belirlenmesi vardır. Eğitim alanları seçildikten sonra bu alanların spektral olarak ayırt edilebilirliği incelenir. Seçilen eğitim alanlarının sayısının yeterli miktarda olması ve homojen olarak seçilmesi, yapılacak olan sınıflandırma işlemi için önemlidir. İkinci adım olarak görüntüdeki her bir piksel sayısal değer olarak eğitim alanlarındaki değerler ile karşılaştırılırlar. Pikseller çeşitli istatistiki analizler sonucunda en çok hangi sınıf ile benzerlik gösteriyorsa o ilgili

sınıfa atanarak sınıflandırma işlemi gerçekleştirilir. ENVI' de yapılan kontrollü (eğitimli) sınıflandırma işlemi için Şekil 4.38'de gösterilen eğitim alanları görüntü üzerinden toplanmış ve eğitim veri seti olarak kullanılmıştır.

Sınıf eğitim verilerinde; Bina sınıfı için 8236 piksel, Yeşil alan sınıfı için 10175 piksel, Su sınıfı için 10185 piksel ve Yol sınıfı için 2689 piksel sayısında eğitim verisi toplanmıştır.


Gerçekleştirilen sınıflandırma işleminden sonra yapılan bu işlemin doğruluğunun tespitinin araştırılması gerekmektedir. Bu amaçla yapılan sınıflandırma işlemlerinin doğruluğunu belirlemek amacıyla görüntü üzerinden yer gerçeklik verileri belirlenmiş ve bu veriler yardımıyla hata matrisleri (confusion matrix) oluşturularak sınıflandırma doğruluğunun tespiti gerçekleştirilmiştir. Yer gerçeklik verisi olarak; Bina sınıfı için 16087 piksel, Yeşil alan sınıfı için 31734 piksel, Su sınıfı için 16551 piksel ve Yol sınıfı için 3952 piksellik veri elde edilmiştir (Şekil 4.39).

Doğruluk analizi, eğitim verisi olarak belirlenmiş olan alanların dışında kalan alanlardaki piksel değerlerinin, yer gerçeklik verileri ile istatistiksel olarak karşılaştırılması ilkesine dayalı bir kontrol metodudur. Genel Doğruluk (Overall Accuracy), doğru olarak sınıflandırılmış olan piksellerin toplam piksel sayısına oranı olarak ifade edilmektedir. Genel doğruluğun belirlenmesinde yer gerçeklik verisi ile sınıflandırılmış veri karşılaştırılır.



Şekil 4.38. Sınıflandırma işleminde kullanılan eğitim verileri

Bir başka yaklaşım ise, olasılık matrisi yardımıyla elde edilmiş bilgiyi özetleyen Kappa katsayısıdır. Sınıflandırılmış sonuç görüntü ile yer gerçeklik verileri arasındaki uyumun istatistiksel bir ölçütüdür. Yer gerçeklik verileri ve sınıflandırılmış pikseller arasındaki gerçek uyum ile yer gerçeklik verileri ve rastgele sınıflandırılmış piksellerin şans uyumu arasındaki farkı gösterir. Sınıflandırma sonrasında elde edilen hata (confusion) matrislerindeki genel doğruluk (köşegen elemanlara dayanan) ile olasılıklı doğruluk (köşegen olmayan elemanları içeren) arasındaki fark olarak tanımlanmaktadır. Gözlenen uyumluluk ile tesadüfî uyumluluk arasında bir karşılaştırma oluşturmaktadır (Özkan, 2001).



Şekil 4.39. Sınıflandırma işleminin doğruluğu tespit etmek için belirlenen yer gerçeklik verileri

4.2.7.1. Maximum Likelihood yöntemi

Maximum Likelihood yöntemi, uzaktan algılanmış görüntü verilerinin sınıflandırılmasında başvurulan yöntemlerden en çok tercih edilenidir. Bu yöntem, görüntüdeki spektral değişiklikleri kullanarak analiz işlemini gerçekleştirir. Bu sınıflandırma metodu normal dağılım (Gauss) modelini kullanılır ve belirlenmesi istenilen her bir sınıf için oluşturulan eğitim verisinin normal dağılımda olduğunu kabul eder. Varyans-kovaryans, ortalama değer v.b. istatistik bilgilerin hepsi yapılacak olan sınıflandırma işleminde dikkate alınır.

Yöntem sınıflandırma aşamasında pikselleri yalnızca parlaklık (renk) değerlerine göre değil, her sınıf için farklılık meydana getirecek olan varyans-kovaryans matris değerlerine göre belirler. Böylece piksellerin özellik uzayındaki dağılımları da göz önüne alınarak analiz işlemine katılmış olur. Bu yöntem Bayes Teorisine dayanmaktadır ve görüntüde bulunan pikseller, herhangi bir sınıfa ait olma olasılık değerlerine göre en yüksek olan sınıfa atanırlar. Belirlenen eğitim setlerine göre oluşturulan sınıflar için olasılık fonksiyonları hesaplanarak uydu görüntüsünü oluşturan piksellerin hangi sınıfa daha yakın olduğuna karar verilmekte ve en yüksek olasılık değerine sahip oldukları sınıfa atanmaktadır. Eğer belirlenen sınıfların başlangıç olasılıkları hakkında bilgi yoksa bütün sınıflar eşit olasılıklı olarak kabul edilir. Görüntüdeki piksellerin hangi sınıfa ait olma olasılığı aşağıdaki denklem ile belirlenmektedir.


$$D = \ln(a_C) - [0.5 * \ln(|Cov_C|)] - \left[0.5 * (X - M_C)^T * (Cov_C^{-1}) * (X - M_C) \right] \quad (4.10)$$

Bu denklemde; D, uzaklık ağırlıklı olasılık değerini; C, belirlenmiş herhangi bir sınıfı; X, aday pikselin ölçü vektörünü; M_C , C örnek sınıfının ortalama vektörünü; a_C , aday olan pikselin C sınıfına ait olma yüzdesini, Cov_C , C örnek sınıfındaki piksellerin varyans-kovaryans matrisini temsil etmektedir (Özkan, 2001; Kansu, 2006; Çölkesen, 2009; Üstüner, 2013; Taşçı, 2018).

Bütün bu bilgiler ışığında veri setini oluşturan 5 adet görüntünün Maximum Likelihood sınıflandırma yöntemine göre yapılan analizi sonucunda oluşturulan sınıflandırma sonuç görüntüleri aşağıda verilmiştir (Şekil 4.40 – 4.44). Ayrıca gerçekleştirilen sınıflandırma işlemlerine ait olan hata (confusion) matrisleri de görüntülerle birlikte verilmiştir.

Buna göre; toplanan eğitim setleri ile sadece spektral bandlardaki renk değerleri kullanılarak yapılan Maximum likelihood sınıflandırma işleminde genel doğruluk değeri %80,9635, kappa katsayısı ise 0,7199 olarak belirlenmiştir (Tablo 4.10). Sınıflandırma görüntüsü (Şekil 4.40) incelendiğinde kıyı şeridinin genel olarak yanlış sınıflandırıldığı görülmektedir. Su sınıfına ait olması gereken bölgelerin bina sınıfı olarak sınıflandırıldığı, ayrıca görüntünün sol alt bölümünde bulunan ormanlık alana

ait olan kısımda yeşil alan olarak sınıflandırılması gereken kısımda yine bina sınıfı olarak belirlenen alanların olduğu görülmektedir.



Şekil 4.40. Maximum Likelihood yöntemiyle spektral değerlere göre sınıflandırılmış görüntü


Bu durum hata matrisi (Tablo 4.10) incelendiğinde de açıkça görülmektedir. Bina sınıfında toplanan verilerin birçoğunun diğer sınıflara atandığı, üretici doğruluğunun %95,13 olmasına rağmen kullanıcı doğruluğunun %56,97 olduğu görülmektedir. Yeşil alan ve yol sınıfları için belirlenen yer gerçeklik verilerinin sırasıyla %80,24 ve %83,04 oranında doğru olarak sınıflandırıldığı görülmektedir. Yol sınıfının sonuçlarında ise toplanan verilerin genellikle bina sınıfı olarak atandığı bu sebeple sınıflandırma doğruluğunun %14,39 olarak kaldığı tespit edilmiştir.

Tablo 4.10. Spektral değerler ile gerçekleştirilen Maximum Likelihood sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	15303	5895	2774	2888	26860	56,97
Yeşil Alan	20	25462	0	187	25669	99,19
Su	0	0	13744	0	13744	100
Yol	764	377	33	517	1691	30,57
Toplam	16087	31734	16551	3592	67964	
Üretici Doğruluğu(%)	95,13	80,24	83,04	14,39		
Genel Doğruluk (%)					Kappa Katsayısı	
80,9635					0,7199	

Ham spektral değerler ile yapılan sınıflandırma işleminden sonra konumsal örüntü analizi olan Getis-Ord G ile elde edilen görüntülerle oluşturulan 8 bandlı yeni veri setine sınıflandırma işlemi uygulanmıştır. Maximum Likelihood sınıflandırma yöntemi kullanılarak yapılan sınıflandırma işlemi sonrasında elde edilen genel doğruluk değeri %83,0866 olduğu belirlenmiştir. Böylece sadece spektral değerlerle yapılan sınıflandırma sonucuna göre %2,1231' lik bir doğruluk artışı elde edilmiştir (Tablo 4.11). Kappa katsayısı değeri ise 0,7491 olarak belirlenmiş ve yine spektral değerlerle elde edilen kappa katsayısı değerine göre 0,0292' lik bir artış olduğu belirlenmiştir.

Sınıflandırma görüntüsü (Şekil 4.41) incelendiğinde spektral sınıflandırmaya göre görüntünün sol alt bölgesinde bulunan ağaçlık alanın daha yüksek doğrulukla, daha başarılı bir biçimde sınıflandırıldığı görülmektedir. Dikkat çekici bir diğer kısım ise yol sınıfının tespitinde gerçekleşmiştir. Sahil seridinde bulunan yol sınıfına ait olan kesimlerin konumsal örüntü görüntüleri ile daha doğru bir biçimde belirlendiği görülmektedir. Ayrıca yine görüntünün sol alt bölümünde bulunan yol sınıfı da spektral değerlerle yapılan sınıflandırmaya göre daha doğru bir biçimde tespit edilmiştir. Yeşil alanların sınıflandırılması ele alındığında konumsal örüntü görüntülerinin sınıflandırmaya eklenmesiyle bu alanların daha doğru ve belirgin biçimde ayrıştırıldığını görmek mümkündür. Ancak buna rağmen kıyı şeridinin spektral sınıflandırmaya göre çok daha kötü biçimde sınıflandırıldığı, su sınıfına ait olması gereken alanların bina ve yol sınıfı olarak belirlendiği açık bir şekilde görülmektedir.



Şekil 4.41. Maximum Likelihood yöntemiyle spektral ve konumsal örüntü değerlerine göre sınıflandırılmış görüntü

Yapılan sınıflandırmaya göre oluşturulan hata matrisi (Tablo 4.11) incelendiğinde bir önceki sınıflandırmada %95,13 olan bina sınıfına ait olan üretici doğruluğu konumsal örüntü bilgisinin sınıflandırma işlemine eklenmesiyle birlikte %99,47 olarak belirlenmiştir. Yeşil alana ait olan üretici doğruluğu %80,24'ten %90,83'e çıkarak iyi bir doğruluk artışı sağlanmıştır. Su sınıfına ait olan üretici doğruluğu %83,04'ten %67,08'e düşmüştür, yol sınıfına ait olan %14,39'luk üretici doğruluğu ise %15,06'ya yükselmiştir. Yol sınıfında çok büyük bir atış olmamasına rağmen bina ve yeşil alanlardaki doğruluk artışı tatmin edici düzeylerde. Su sınıfında yaşanan büyük doğruluk düşüşünün sebebi kıyı şeridinin ham spektral değerlerle yapılan sınıflandırmada olduğu gibi belirlenememiş olmasından kaynaklıdır. Su sınıfına ait olması gereken kıyı şeridinde bulunan belirli bir kısım alanın yol ve bina sınıfı olarak

sınıflandırılmasından ötürü su sınıfının doğruluk değerinde büyük bir düşüş yaşanmıştır.


Tablo 4.11. Spektral ve konumsal örüntü değerleri ile gerçekleştirilen Maximum Likelihood sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	16001	2284	3001	2927	24213	66,08
Yeşil Alan	0	28824	0	124	28948	99,57
Su	0	0	11103	0	11103	100,00
Yol	86	626	2447	541	3700	14,62
Toplam	16087	31734	16551	3592	67964	
Üretici Doğruluğu(%)	99,47	90,83	67,08	15,06		
Genel Doğruluk (%)					Kappa Katsayısı	
83,0866					0,7491	

Konumsal örüntü görüntüleri ile yapılan sınıflandırma işleminden sonra standart doku ölçütleri ile oluşturulan görüntülerden Kontrast ve Açısal ikinci moment görüntüleri kullanılarak oluşturulan yeni veri setine sınıflandırma işlemi uygulanmıştır. Doku görüntülerinden Kontrast ve Açısal ikinci momentin kullanılmasının sebebi uygulanmış olan SAR yönteminde görüntü üzerindeki doku bölgelerini en iyi şekilde temsil eden ölçütler olmasından kaynaklanmaktadır. İki adet doku ölçüt görüntüsünün MATLAB yazılım programında tiff class komutu ile uydu görüntüsüne eklenmesiyle birlikte elde edilen 6 bandlı görüntü Maximum Likelihood sınıflandırma yöntemi kullanılarak sınıflandırılmıştır. Sınıflandırma işlemi sonrasında elde edilen genel doğruluk değeri %85,8499 olarak tespit edilmiştir. Böylece sadece spektral değerlerle yapılan sınıflandırma sonucuna göre %4,8864' lük, konumsal örüntü görüntülerine göre ise %2,7633' lük bir doğruluk artışı elde edilmiştir (Tablo 4.12). Kappa katsayısı değeri ise 0,7899 olarak belirlenmiş ve yine spektral değerlerle elde edilen kappa katsayısı değerine göre 0,07' lik, konumsal örüntü görüntülerine göre ise 0,0408' lik bir artış olduğu belirlenmiştir.

Sınıflandırma görüntüsü (Şekil 4.42) incelendiğinde spektral sınıflandırmaya göre görüntünün sol alt bölgesinde bulunan ağaçlık alanın, bir önceki sınıflandırmaya göre daha yüksek doğrulukla, daha başarılı bir biçimde sınıflandırıldığı tespit edilmiştir. Dikkat çekici bir diğer kısım ise görüntünün tam orta bölgesine düşen ve yeşil bir alan olan futbol sahasının spektral değerlere göre yapılan sınıflandırmada farklı bir

sınıf olarak belirlenmesine rağmen doku ölçütleri eklendiğinde bu alanın büyük bir bölümünün gerçek sınıfı olan yeşil alan olarak sınıflandırıldığı görülmektedir. Ancak buna rağmen kıyı şeridinin spektral sınıflandırmaya göre daha da kötü sınıflandırıldığı, su sınıfına ait olması gereken yerlerin bina sınıfı olarak belirlendiği açık bir şekilde görülmektedir. Standart doku ölçüt görüntülerinin su sınıfını konumsal örüntü görüntülerine göre daha iyi bir biçimde tespit ettiğini söylemek mümkündür.



Şekil 4.42. Maximum Likelihood yöntemiyle spektral ve standart doku ölçütlerine göre sınıflandırılmış görüntü

Yapılan sınıflandırmaya göre oluşturulan hata matrisi (Tablo 4.12) incelendiğinde bir önceki sınıflandırmada %95,13 olan bina sınıfına ait olan üretici doğruluğu konumsal bilginin sınıflandırma işlemine eklenmesiyle birlikte %95,64 olarak belirlenmiştir.

Yeşil alana ait olan üretici doğruluğu %80,24'ten %88,94'e çıkarak doğruluk artışı sağlanmıştır. Su sınıfına ait olan üretici doğruluğu %83,04'ten %84,39'a, yol sınıfına ait olan %14,39'luk üretici doğruluğu ise %21,44'e yükselmiştir. Bina ve su sınıflarında çok büyük bir artış olmamasına rağmen yeşil ve yol alanlardaki doğruluk artışı tatmin edici seviyelerdedir. Bu duruma sebep olarakta bu alanların doku bilgilerinden gelen –özellikle açısız ikinci moment doku ölçütünden– yardımcı verinin bu alanların sınıflandırılmasında olumlu katkı yaptığının bir göstergesidir.


Tablo 4.12. Spektral ve standart doku ölçütleri ile gerçekleştirilen Maximum Likelihood sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	15386	1808	739	2595	20528	74,95
Yeşil Alan	2	28224	898	227	29351	96,16
Su	0	0	13967	0	13967	100,00
Yol	699	1702	947	770	4118	18,70
Toplam	16087	31734	16551	3592	67964	
Üretici Doğruluğu(%)	95,64	88,94	84,39	21,44		
Genel Doğruluk (%)					Kappa Katsayısı	
85,8499					0,7899	

Spektral ve exponential model ile elde edilen konumsal bilgilerin birleştirilmesiyle oluşturulan 8 bandlı görüntünün sınıflandırılmasıyla elde edilen genel doğruluk değeri %87,3271 olarak tespit edilmiştir. Böylece sadece spektral değerlerle yapılan sınıflandırma sonucuna göre %6,3636'lık, konumsal örüntü görüntülerine göre %4,2405'lik, standart doku ölçütü görüntülerine göre ise %1,4772'lik bir sınıflandırma genel doğruluk artışı elde edilmiştir (Tablo 4.13). Kappa katsayısı değeri ise 0,8112 olarak belirlenmiş ve yine spektral değerlerle elde edilen kappa katsayısı değerine göre 0,0913' lük, konumsal örüntü görüntülerine göre 0,0621'lik, standart doku ölçütü görüntülerine göre ise 0,0213' lük bir artış olduğu belirlenmiştir. Bu katsayının artması değerlerin tesadüfi/şans eseri sınıflandırılmasının daha az olduğu anlamına gelmektedir.

Sınıflandırma görüntüsü (Şekil 4.43) incelendiğinde spektral ve doku ölçüt görüntüleri sınıflandırmasına göre kıyı çizgisinin/şeridinin çok daha belirgin ve bu bölümdeki su sınıfının çok daha iyi bir doğrulukla sınıflandırıldığı açık bir şekilde görülmektedir. Spektral sınıflandırmada bina sınıfı olarak sınıflandırılan su bölgeleri konumsal bağımlılıklarının yüksek değerlerde olmasından dolayı konumsal +

spektral bilgilerin kullanıldığı sınıflandırmada daha yüksek doğrulukla sınıflandırılmışlardır. Ayrıca görüntünün sol alt bölgesinde bulunan ağaçlık alanın, önceki sınıflandırmalara göre çok daha yüksek doğrulukla, daha başarılı bir biçimde sınıflandırıldığı tespit edilmiştir. Dikkat çekici bir diğer kısım ise görüntünün tam orta bölgesine düşen ve yeşil bir alan olan futbol sahasının spektral değerlere göre yapılan sınıflandırmada tamamının farklı bir sınıfa atanmasına rağmen konumsal değerler yardımıyla yapılan sınıflandırmada doku ölçütlerinde olduğu gibi kısmen de olsa yeşil alan olarak sınıflandırıldığı görülmektedir.



Şekil 4.43. Maximum Likelihood yöntemiyle spektral ve konumsal (exponential) değerlere göre sınıflandırılmış görüntü

Yapılan sınıflandırmaya göre oluşturulan hata matrisi (Tablo 4.13) incelendiğinde bir önceki sınıflandırmada %95,13 olan bina sınıfına ait olan üretici doğruluğu konumsal

bilginin sınıflandırma işlemine eklenmesiyle birlikte %95,24 olarak belirlenmiştir. Yeşil alana ait olan üretici doğruluğu %80,24'ten %91,83'e çıkararak büyük bir doğruluk artışı sağlanmıştır. Su sınıfına ait olan üretici doğruluğu %83,04'ten %86,68'e, yol sınıfına ait olan %14,39'luk üretici doğruluğu ise %15,09'a yükselmiştir. Su ve yol sınıflarında çok büyük bir artış olmamasına rağmen yeşil alanlardaki doğruluk artışı göz ardı edilemeyecek boyutlardadır. Bunun sebebi olarakta bu alanların konumsal bağımlılıklarının çok yüksek olarak derecelendirilmesi gösterilebilir. Bu sınıf göz önüne alındığında sınıflandırma işleminde ki %11,59'luk doğruluk artışı önerilen yöntemin olumlu sonuçlar verdiğinin bir göstergesidir.


Tablo 4.13. Spektral ve Konumsal (Exponential) değerler ile gerçekleştirilen Maximum Likelihood sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	15322	793	1828	2877	20820	73,59
Yeşil Alan	10	29141	126	173	29450	98,95
Su	0	0	14346	0	14346	100,00
Yol	755	1800	251	542	3348	16,19
Toplam	16087	31734	16551	3592	67964	
Üretici Doğruluğu(%)	95,24	91,83	86,68	15,09		
Genel Doğruluk (%)					Kappa Katsayısı	
87,3271					0,8112	

Spektral ve spherical model ile elde edilen konumsal verilerin bir araya getirilmesiyle oluşturulan 8 bandlı görüntünün sınıflandırılmasıyla elde edilen genel doğruluk %88,4807 olarak tespit edilmiştir (Tablo 4.14). Spherical model yardımıyla elde edilen görüntünün sınıflandırılmasıyla elde edilen genel doğruluk spektral değerlere göre %7,5172, konumsal örüntü görüntülerine göre %5,3941'lik, standart doku ölçütü görüntülerine göre %2,6308 ve exponential modele göre ise %1,1536'lık bir doğruluk artışına sebep olmuştur. Kappa katsayısı ise 0,8269 olarak belirlenmiştir. Spektral değerlerle elde edilen kappa katsayısına göre 0,1070'lik, konumsal örüntü görüntülerine göre 0,0778'lik, standart doku ölçütü görüntülerine göre 0,0370'lik ve exponential görüntüye göre ise 0,0157'lik bir artış olmuştur.

Sınıflandırma görüntüsü (Şekil 4.44) incelendiğinde exponential görüntüde olduğu gibi kıyı çizgisinin bu görüntünün sınıflandırılmasında da daha belirgin olduğu ve su

sınıfının daha iyi bir doğrulukla tespit edildiğini görmek mümkündür. Spektral görüntüde bina sınıfı olarak belirlenen su kısımları bu görüntüde daha hassas ve doğru bir biçimde su sınıfına atanmışlardır. Yeşil alanların sınıflandırılması her dört görüntüye göre çok daha iyi bir doğrulukla gerçekleştirilmiştir. Hata matrisindeki değerler bu tespiti destekler niteliktedir. Beş sınıflandırma görüntüsü de incelendiğinde yeşil alanları en doğru biçimde belirleyen/sınıflayan görüntünün spherical model ile oluşturulan görüntü olduğu açıkça görülmektedir. Görüntünün sol ve sağ alt bölümlerindeki yeşil alanlar incelendiğinde diğer dört görüntüde bina sınıfı olarak atanan piksellerin bu görüntüde yeşil alan olarak sınıflandırıldığı görülmektedir. Bir önceki görüntüde dikkat çekici kısım olarak nitelenen görüntünün ortasında kalan futbol sahasının sınıflandırma doğruluğu bu görüntüde daha da üst seviyelere çıkarak neredeyse tamamen doğru olarak sınıflandırılmıştır.




Şekil 4.44. Maximum Likelihood yöntemiyle spektral ve konumsal (spherical) değerlere göre sınıflandırılmış görüntü

Gerçekleştirilen sınıflandırmaya ait hata matrisi (Tablo 4.14) incelendiğinde üretici doğruluklarının bina sınıfı için %95,34, yeşil alan sınıfı için %94,46, su sınıfı için %86,51 ve yol sınıfı için is %14,03 olduğu tespit edilmiştir. Bu sonuçlara göre en iyi bina sınıflandırmasını %99,47 üretici doğruluk değeri ile konumsal örüntü görüntüsü gerçekleştirmiştir. Yeşil alandaki sınıflandırmayı %94,46’lık bir başarımla ile spherical model ile oluşturulan görüntü, su sınıfının en iyi sınıflandırma başarımla %86,68’lik değer ile exponential model görüntüsü gerçekleştirmiştir. En iyi yol sınıflandırmasını ise %21,44’luk değer ile yine standart doku ölçütü görüntüsü gerçekleştirmiştir.

Tablo 4.14. Spektral ve Konumsal (Spherical) değerler ile gerçekleştirilen Maximum Likelihood sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	15337	597	1751	2858	20543	74,66
Yeşil Alan	23	29976	267	230	30496	98,29
Su	0	0	14318	0	14318	100,00
Yol	727	1161	215	504	2607	19,33
Toplam	16087	31734	16551	3592	67964	
Üretici Doğruluğu(%)	95,34	94,46	86,51	14,03		
Genel Doğruluk (%)					Kappa Katsayısı	
88,4807					0,8269	

Spherical model görüntüsü ve spektral değerler ile yapılan sınıflandırma başarımla yönünden incelendiğinde bina sınıfında %0,21’lik, yeşil alan sınıfında %14,22’lik, su sınıfında %3,47’lik artış olmasına rağmen yol sınıfında %0,36’lık küçük bir düşüş gerçekleştiği görülmüştür. Bina ve yol verisinde oluşan ufak artış ve düşüşün sebebinin bu alanlara ait olan kısımlardaki konumsal bilginin düşük derecelerde tespit edilmiş olması gösterilebilir.




Şekil 4.45. Maximum Likelihood yöntemiyle veri setlerine ait elde edilen sınıflandırma doğruluk yüzdeleri

Şekil 4.45'te kullanılan beş adet veri setine ait Maximum Likelihood yöntemi ile yapılan sınıflandırma işlemi genel doğruluk değerleri gösterilmektedir. Buna göre; en yüksek sınıflandırma başarımını Spherical model ile oluşturulan veri seti elde etmiştir. Daha sonra sınıflandırma başarımında sırasıyla Exponential model, Doku ölçütleri, Konumsal Örüntü ve son olarak ham spektral değerlerin kullanıldığı veri setleri gelmektedir.

4.2.7.2. Support Vector Machines (SVM) yöntemi

Support Vector Machines (SVM) istatistiksel öğrenme teorisi alanında önerilen, Alexey Chervonenkis ve Vladimir Vapnik tarafından geliştirilmiş ve birçok gerçek problemde başarılı sonuçlar vermiş bir makine öğrenmesi yöntemidir. Temelleri 1960'lı yıllarda atılan ve 1970'li yıllarda gelişen başarılı bir çalışmanın sonucudur. Ancak, 1990'lı yıllarda ilk başarılı uygulamalarını gerçekleştirerek, çeşitli bilim alanlarının ilgi odağı olmuştur. SVM'nin ana düşüncesi, doğrusal olarak ayrıştırılabilen veri setleri için en iyi ayırıcı düzlemin tanımlanabilmesidir (Şekil 4.46). Doğrusal olmayan örnek uzayı için ise, veri seti örneklerinin doğrusal olarak ayrıştırılabileceği bir yüksek boyuta aktararak farklı örnekler arasındaki optimum sınır değerinin bulunması amacına dayanmaktadır (Karagülle, 2008; Atasever, 2011).




Şekil 4.46. Doğrusal olarak ayrılabilen veri seti ve destek vektörleri (URL-4)

Makine öğrenmesi yöntemleri geçmişteki verileri kullanarak, verinin ve yapılacak işlemin niteliğine göre (sınıflandırma, regresyon) en uygun modeli hesaplamayı amaçlamaktadır. SVM’lerde kullanılacak örnek sayısının önemi yoktur. SVM yönteminin aşamalarından birisi olan eğitim aşaması esnasında, analiz edilmeyen verileri de sorunsuz bir şekilde belirleyebilmektedir. Bu SVM’nin genelleştirebilme özelliğini gösterir. Bu özellik SVM’yi benzer makine öğrenmesi tekniklerine göre – YSA gibi– daha iyi bir alternatif yapmaktadır. Son yıllarda ise örüntü tanıma, metin sınıflandırma, biyoinformatik, kimlik, el yazısı, rakam, yüz bulma ve tanıma, veri madenciliği, görüntü sınıflandırma gibi geniş bir yelpazede kendisine kullanım imkânı bulmuştur (Karagülle, 2008; Atasever, 2011; Karakaynak, 2014).

SVM yönteminin çalışmasında, analizi yapılacak olan verilerin doğrusal olarak ayrılabilmeleri ve ayrılamamaları olarak iki yapı bulunmaktadır. Doğrusal olarak ayrılmış olan verilerin birbirlerinden ayrıldığı maksimum sınırın bulunması oldukça kolay olmasına karşın, doğrusal olarak ayrılamayan verilerden bu maksimum sınırın bulunması o kadar kolay değildir. Böyle bir durumla karşılaşıldığında verilerin çeşitli çekirdek (kernel) fonksiyonları ile daha yüksek boyutlu ve doğrusal olarak ayrılabildikleri yeni bir veri uzayına aktarılıp, çözümün aktarılan bu yeni uzayda aranması gerekir (Şekil 4.47). Gerçek hayat verilerinin çok azı doğrusal olarak ayrılabilir. SVM’nin en önemli özelliklerinden bir tanesi, yöntemin temelinde

yer alan doğrusal görünümlü olan çerçevesinin kolayca doğrusal olmayan duruma genişletilebilir olmasıdır. Bu genişletmenin arkasındaki ana fikir verilerin doğrusal olarak ayrılamayan veri uzayından, doğrusal olarak ayrılabilirdiği daha yüksek boyutlu bir özellikler uzayına dönüştürülebilmesidir. Birçok problemde olduğu gibi uzaktan algılanmış görüntülerinin sınıflandırılması işleminde de veri seti olarak kullanılan uydu görüntüsünün doğrusal olarak ayrıştırılması mümkün olamamaktadır. Böyle bir durum ile karşılaşıldığında, eğitim verilerinin bir bölümünün belirlenen düzlemin farklı taraflarında bulunması problemi meydana gelir ve problem pozitif hataları ifade eden, yapay bir değişkenin optimizasyona eklenmesi ile çözülmeye çalışılır (Demirci, 2007; Atasever, 2011; Karakaynak, 2014).




Şekil 4.47. Doğrusal olarak ayrılamayan verilerin kernel(çekirdek) fonksiyonuyla üst boyutlu uzaya aktarılması (URL-4)


SVM’de çok sınıf (iki sınıftan fazla) probleminin çözümü için; teke tek, birine karşı tümü ve döngüsel olmayan graf gibi çeşitli metodlar geliştirilmiştir. Teke tek yönteminde örnek veri setleri, diğer veri setleriyle birbirlerinden bağımsız şekilde eğitilir. Birine karşı tümünde, her örnek veri seti bir sınıfı belirtirken, geriye kalan veri setlerinin hepsi tek bir sınıfı temsil edecek şekilde kabul edilir ve eğitilip sınıflandırma işlemi gerçekleştirilir. Döngüsel olmayan graf yönteminde, test aşaması dışında bire karşı bir yöntemi ile aynı şekilde çalışır. Sınıfların eğitimi teke tek yöntemine göre gerçekleştirilir. Yöntemin test edilmesi adımı, eğitim verisi örneklerinin kontrolü yerine, sınıflandırılması istenen veri seti elemanının ait olmadığı düşünülen sınıfların elenmesiyle sınıflandırma işlemi gerçekleştirilir (Atasever, 2011; Güneren, 2015).

Eđitim veri setleri yardımıyla sadece spektral bandlardaki renk deęerleri kullanılarak yapılan SVM sınıflandırma işleminin genel doęruluk deęeri %84,7566, kappa katsayısı ise 0,7768 olarak belirlenmiştir (Tablo 4.15).

Sınıflandırma görüntüsü (Şekil 4.49) incelendiğinde SVM yönteminin spektral deęerleri kullanarak Maximum Likelihood yönteminin belirleyemediğı kıyı şeridini genel olarak doęru tespit ettiğı görölmektedir. Kıyı şeridini doęru bir biçimde belirlemesine rağmen su sınıfına ait olan alanların tespitinde çeşitli hatalar meydana gelmiştir. Yöntem su sınıfına ait olması gereken alanları büyük bir doęrulukla belirlemiş olmasına rağmen arazinin topoğrafyası dikkate alınarak incelendiğinde yeşil alanlar içerisinde bulunan vadiler sebebiyle bu bölgelere denk gelen piksellerin renk deęerlerinin su sınıfı ile birbirlerine yakın olmasından ötürü hatalı olarak sınıflandırıldığı görölmüştür (Şekil 4.48). Yöntemin bu alanları spektral deęerleri kullanarak ayıramadığı tespit edilmiştir. Bina sınıfının genel olarak doęru sınıflandırıldığı üretici doęruluęuna bakılarak söylenebilir. Ancak aynı durum yol sınıfı için geçerli değildir. Bu sınıfın bilgileri bina sınıfı ile karışarak hatalı bir sınıflandırmanın gerçekleşmesine sebebiyet vermiştir. Sınıflandırma doęrulukları incelendiğinde spektral deęerlere göre yapılan yol sınıfına ait sınıflandırmanın üç yöntem içerisinde en düşük deęere sahip olduğu belirlenmiştir.



Şekil 4.48. Yeşil alanlara ait belirli bir bölgenin topoğrafyasına ait genel görünüm



Şekil 4.49. SVM yöntemiyle spektral değerlere göre sınıflandırılmış görüntü

Sınıflandırmaya ait hata matrisi (Tablo 4.15) incelendiğinde bina sınıfının %95,55 üretici doğruluğu ile yüksek bir değerde sınıflandırıldığı görülmektedir. Yeşil alan sınıfına ait olan üretici doğruluğu %81,64 olarak belirlenmiştir. Diğer yöntemlere göre düşük değerde elde edilen bu sınıfa ait sınıflandırma doğruluğunun sebebi yeşil alan olarak sınıflandırılması gereken alanların su sınıfı olarak tespit edilmiş olmasıdır. Su sınıfı için üretici doğruluğu %97,50 olmasına rağmen kullanıcı doğruluğu %83,01 olarak belirlenmiştir. Su sınıfının bu kadar yüksek değerde başarılı olarak sınıflandırılmasında görüntüde bulunan yol ile kara parçası arasında kalan küçük üç adet alandan oluşan ve yer gerçeklik verisi olarakta seçilen bölgenin bu yöntem tarafından tespit edilerek doğru sınıfa atanmasından kaynaklanmaktadır. Yol sınıfının üretici doğruluğu %9,74 olarak belirlenmiştir. Bu değer üç adet


sınıflandırma yöntemi arasında elde edilen en düşük değerdir. Hata matrisi incelendiğinde yol sınıfına ait birçok pikselin bina sınıfı olarak sınıflandırıldığı görülmektedir.

Tablo 4.15. Spektral değerler ile gerçekleştirilen SVM sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	15210	336	0	3061	18607	81,74
Yeşil Alan	91	25907	0	158	26156	99,05
Su	1	3278	16137	23	19439	83,01
Yol	785	2213	414	350	3762	9,30
Toplam	16087	31734	16551	3592	67964	
Üretici Doğruluğu(%)	94,55	81,64	97,50	9,74		
Genel Doğruluk (%)					Kappa Katsayısı	
84,7566					0,7768	

Konumsal örüntü analizi Getis-Ord G istatistiği ile oluşturulan 8 bandlı yeni veri setinin SVM yöntemiyle sınıflandırılmasıyla elde edilen genel sınıflandırma doğruluğu %84,7964 olarak tespit edilmiştir. Böylece sadece spektral değerlerle yapılan sınıflandırma sonucuna göre %0,0398' lik bir doğruluk artışı elde edilmiştir (Tablo 4.16). Kappa katsayısı değeri ise 0,7799 olarak belirlenmiş ve yine spektral değerlerle elde edilen kappa katsayısı değerine göre 0,0031' lik bir artış olduğu tespit edilmiştir.

Sınıflandırma görüntüsü (Şekil 4.50) incelendiğinde spektral sınıflandırmaya göre görüntünün sol alt bölgesinde bulunan ağaçlık alanın yapılan yanlış sınıflandırılmasının giderildiği, spektral değerler ile gerçekleştirilen sınıflandırmada su sınıfı olarak belirlenmiş olan alanların konumsal örüntüler ile yapılan sınıflandırma işleminde gerçek sınıfı olan yeşil alan sınıfına atandığı görülmektedir. Ancak diğer yeşil alanlarda yapılan sınıflandırmanın başarıya ulaşmayıp hatalı sınıflandırmaların olduğu belirlenmiştir. Görüntünün orta kısımlarında kalan yeşil alanların bir kısmının halen su sınıfı olarak sınıflandırıldığı görülmektedir. Kıyı şeridi spektral sınıflandırmada olduğunu gibi belirgin bir biçimde ortaya çıkarılmıştır. Yol sınıfına ait olan alanlarda ise spektral sınıflandırmaya oranla doğruluk artışının olduğu tespit edilmiştir.



Şekil 4.50. SVM yöntemiyle spektral ve konumsal örüntü değerlerine göre sınıflandırılmış görüntü


Yapılan sınıflandırmaya ait oluşturulan hata matrisi (Tablo 4.16) incelendiğinde bir önceki sınıflandırmada %94,55 olan bina sınıfına ait olan üretici doğruluğu konumsal örüntü bilgisinin sınıflandırma işlemine eklenmesiyle birlikte %99,50 olarak belirlenmiştir. Yeşil alana ait olan üretici doğruluğu %81,64'ten %79,41'e düşerek bir doğruluk azalması meydana gelmiştir. Bunun sebebi ise hata matrisi incelendiğinde görülmektedir. Yeşil alana ait olması gereken alanların büyük bir kısmı yol sınıfı olarak tespit edilmiştir. Su sınıfına ait olan üretici doğruluğu %97,50'den %95,58'e, yol sınıfına ait olan %9,74'lük üretici doğruluğu ise %9,50'e inmiştir.

Tablo 4.16. Spektral ve konumsal örüntü değerleri ile gerçekleştirilen SVM sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	16007	71	25	2237	18340	87,28
Yeşil Alan	0	25201	0	751	25952	97,11
Su	0	1495	15819	0	17314	91,37
Yol	80	4967	707	604	6358	9,50
Toplam Üretici Doğruluğu(%)	16087	31734	16551	3592	67964	
Genel Doğruluk (%)					Kappa Katsayısı	
84,7964					0,7799	

Standart doku ölçütleri ile oluşturulan 6 bandlı görüntü SVM sınıflandırma yöntemi kullanılarak sınıflandırılması sonrasında elde edilen genel doğruluk değeri %87,0534 olarak tespit edilmiştir. Böylece sadece spektral değerlerle yapılan sınıflandırma sonucuna göre %2,2968' lik, konumsal örüntü görüntülerine göre ise %2,2570'lik bir doğruluk artışı elde edilmiştir (Tablo 4.17). Kappa katsayısı değeri ise 0,8098 olarak belirlenmiş ve spektral değerlerle elde edilen kappa katsayısı değerine göre 0,033' lük, konumsal örüntü görüntülerine göre ise 0,0299'luk bir artış olduğu belirlenmiştir.

Sınıflandırma görüntüsü (Şekil 4.51) incelendiğinde spektral sınıflandırmaya göre görüntünün sol alt bölgesinde bulunan ağaçlık alanın, daha yüksek doğrulukla ve daha başarılı bir biçimde sınıflandırıldığı tespit edilmiştir. Ancak diğer yeşil alanlarda yapılan sınıflandırmanın başarıya ulaşmadığı görülmektedir. Görüntünün orta kısımlarında kalan yeşil alanların bir kısmının halen su sınıfı olarak sınıflandırıldığı görülmektedir. Bu durumda standart doku ölçütlerinin bu alanlar için yeterince bilgi sağlayamadığının kanıtı olarak gösterilebilir. Kıyı şeridi spektral sınıflandırmada olduğunu gibi belirgin bir biçimde ortaya çıkarılmıştır. Yol sınıfına ait olan alanlarda ise spektral sınıflandırmaya göre doğruluk artışı gerçekleşmiştir.



Şekil 4.51. SVM yöntemiyle spektral ve standart doku ölçütlerine göre sınıflandırılmış görüntü


Yapılan sınıflandırmaya göre oluşturulan hata matrisi (Tablo 4.17) incelendiğinde spektral sınıflandırmada %94,55 olan bina sınıfına ait olan üretici doğruluğu konumsal bilginin sınıflandırma işlemine eklenmesiyle birlikte %95,80 olarak belirlenmiştir. Yeşil alana ait olan üretici doğruluğu %81,64'ten %84,11'e çıkarak bir doğruluk artışı sağlanmıştır. Su sınıfına ait olan üretici doğruluğu %97,50'den %99,64'e, yol sınıfına ait olan %9,74'lük üretici doğruluğu ise %15,92'e yükselmiştir. Maximum Likelihood yönteminde olduğu gibi SVM yönteminde de standart doku ölçüt görüntüleri sınıflandırma doğruluğunu arttıran bir etki yapmıştır.

Tablo 4.17. Spektral değerler ve standart doku ölçütleri ile gerçekleştirilen SVM sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	15411	453	0	2714	18578	82,95
Yeşil Alan	27	26691	0	273	26991	98,89
Su	2	1893	16491	33	18419	89,53
Yol	647	2697	60	572	3976	14,39
Toplam	16087	31734	16551	3592	67964	
Üretici Doğruluğu(%)	95,80	84,11	99,64	15,92		
Genel Doğruluk (%)					Kappa Katsayısı	
87,0534					0,8098	

Spektral ve exponential model ile elde edilen konumsal verinin birleştirilmesiyle oluşturulan 8 bandlı görüntünün sınıflandırılmasıyla elde edilen genel doğruluk %86,7606 olarak belirlenmiştir. Spektral sınıflandırmaya göre %2,004'lük, konumsal örüntü görüntülerine göre ise %1,9642'lik bir doğruluk artışı meydana gelmiştir. Standart doku ölçütlerine göre ise %0,2928'lik bir doğruluk azalması meydana geldiği tespit edilmiştir. Sınıflandırma sonucu kappa katsayısı ise 0,8066 olarak belirlenmiştir. Spektral sınıflandırmaya göre 0,0298'lik, konumsal örüntü görüntülerine göre ise 0,0267'lik bir artış gerçekleşmiştir. Standart doku ölçütleri görüntülerine göre ise 0,0032'lik bir azalma meydana gelmiştir (Tablo 4.18).

Sınıflandırma görüntüsü (Şekil 4.52) incelendiğinde kıyı çizgisini spektral değerlerle yapılan sınıflandırma da olduğu gibi nerdeyse hatasız bir biçimde ortaya çıkardığı böylece su sınıfının yüksek bir doğrulukla sınıflandırıldığı görülmektedir. Ayrıca konumsal bağımlılık bilgilerinin eklenmesiyle birlikte spektral değerlerle su sınıfıyla karıştırılarak hatalı bir şekilde sınıflandırılan yeşil alanların bu sınıflandırma da neredeyse tam olarak doğru bir şekilde sınıflandırıldığı görülmektedir. Yeşil alanların sınıflandırılmasında diğer yöntemler gibi yüksek doğruluk değeri elde edilmiştir. Ancak konumsal bağımlılık bilgisi ile birlikte Maximum Likelihood sınıflandırma yönteminde belirli bir oranda doğru olarak sınıflandırılması gerçekleştirilmiş olan ve görüntünün tam ortasında kalan futbol sahasının bu yöntemde yol sınıfı olarak sınıflandırılarak doğru bir sınıflama başarısının elde edilemediği gözlemlenmiştir. Bina sınıfının yine yüksek bir doğruluk değeriyle sınıflandırıldığı görülmektedir. Yol sınıfının ise konumsal bilginin eklenmesi ile birlikte doğruluk değerinde iki puanlık bir artışın olduğu görülmüştür.



Şekil 4.52. SVM yöntemiyle spektral ve konumsal (exponential) değerlere göre sınıflandırılmış görüntü

Sınıflandırmaya ait hata matrisi (Tablo 4.18) incelendiğinde üretici doğruluklarında bina sınıfında %96,19'luk bir başarımla elde edilmiştir. Yeşil alanların sınıflandırılmasında %83,89'luk, su sınıfında ise %99,37'lik bir sınıflandırma doğruluğu başarımla elde edilmiştir. Su sınıfının bu kadar yüksek değerde başarılı olarak sınıflandırılmasında daha önceden de belirtildiği gibi görüntüde bulunan yol ile kara parçası arasında kalan küçük üç adet alandan oluşan ve yer gerçeklik verisi olarak da seçilen bölgenin de yöntem tarafından belirlenerek doğru sınıfa atanmasından kaynaklanmaktadır. Maximum Likelihood sınıflandırma yönteminde bu alanlar yol veya bina verisi olarak sınıflandırıldıklarından dolayı bu sınıfa ait olan doğruluk değerleri o yöntem için oldukça düşük değerde kalmıştır. Yol sınıfının

üretici doğruluk değeri %11,75 olarak belirlenmiş ve spektral sınıflandırmaya göre belirli bir düzeyde gelişme görülmüştür.


Tablo 4.18. Spektral ve Konumsal (Exponential) değerler ile gerçekleştirilen SVM sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	15474	106	0	2896	18476	83,75
Yeşil Alan	41	26623	0	274	26938	98,83
Su	0	840	16447	0	17287	95,14
Yol	572	4165	104	422	5263	8,02
Toplam	16087	31734	16551	3592	67964	
Üretici Doğruluğu(%)	96,19	83,89	99,37	11,75		
Genel Doğruluk (%)					Kappa Katsayısı	
86,7606					0,8066	

Spektral ve spherical model ile elde edilen konumsal verilerin kullanılarak bir araya getirilmesiyle oluşturulan 8 bandlı görüntünün sınıflandırılmasıyla elde edilen genel doğruluk değeri %87,0549 olarak belirlenmiştir. Konumsal bilginin eklenmesiyle spektral sınıflandırmaya göre meydana gelen doğruluk artışı %2,2983, konumsal örüntü görüntülerine göre %2,2585'lik, exponential görüntüye göre %0,2943 ve standart doku ölçüt görüntülerine göre ise %0,0015' lik doğruluk artışı meydana gelmiştir. Kappa katsayısı 0,8106 olarak belirlenmiş ve spektral görüntüye göre 0,0338, konumsal örüntü görüntülerine göre 0,0307'lik, exponential görüntüye göre 0,0040 ve standart doku ölçüt görüntülerine göre ise 0,0008'lik küçük bir artış olduğu tespit edilmiştir (Tablo 4.19).

Sınıflandırma görüntüsü (Şekil 4.53) incelendiğinde kıyı çizgisinin bir önceki görüntüde olduğu gibi yine neredeyse hatasız bir biçimde tespit edilip, su sınıfının yüksek doğrulukla sınıflandırıldığını görmek mümkündür. Yeşil alanların sınıflandırılmasında bir önceki görüntüde olduğu gibi yine başarılı bir sonuç elde edilmiştir. Konumsal bağımlılık derecelerinin sınıflandırmaya katılmasıyla birlikte spektral sınıflandırma da su sınıfına atanan piksellerin bu görüntüde doğru sınıf olan yeşil alan sınıfına atandığı görülmektedir. Ancak buna rağmen görüntünün orta bölgesinde bulunan ve Maximum Likelihood yönteminde spherical modelden elde edilen konumsal bilgi ile doğru olarak sınıflandırılması gerçekleştirilmiş olan futbol sahasının bu yöntemde de doğru olarak sınıflandırılmadığı tespit edilmiştir. Kara ile

yol arasında kalan su bölgelerinin sınıflandırılması bu yöntem ve görüntüde de doğru olarak sınıflandırılmayı başararak yüksek sınıf doğruluğuna ulaşmayı başarmıştır.




Şekil 4.53. SVM yöntemiyle spektral ve konumsal (spherical) değerlere göre sınıflandırılmış görüntü

Sınıflandırmaya ait hata matrisi (Tablo 4.19) incelendiğinde üretici doğruluklarında bina sınıfında %96,44'lük bir başarımla elde edilmiştir. Yeşil alanların sınıflandırılmasında %84,55'lik bir başarımla ve su sınıfında ise %99,06'lık bir sınıflandırma doğruluğu başarımla elde edilmiştir. Su sınıfının bu kadar yüksek değerle başarılı olarak sınıflandırılmasında yine görüntüde bulunan yol ile kara parçası arasında kalan küçük üç adet alandan oluşan ve yer gerçeklik verisi olarak da seçilen bölgenin yine bu görüntüde de doğru bir şekilde tespit edilerek doğru sınıfa atanmasından kaynaklanmaktadır. Maximum Likelihood sınıflandırma yönteminde

bu alanlar yol veya bina verisi olarak sınıflandırıldıklarından dolayı bu sınıfa ait olan doğruluk değerleri o yöntem için oldukça düşük değerlerde bulunmuştur. Yol sınıfının üretici doğruluk değeri %11,83 olarak belirlenerek bir önceki görüntünün elde ettiği değerin daha da geliştirildiği tespit edilmiştir.

Tablo 4.19. Spektral ve Konumsal (Spherical) değerler ile gerçekleştirilen SVM sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	15514	100	0	2889	18503	83,85
Yeşil Alan	33	26831	0	278	27142	98,85
Su	0	828	16396	0	17224	95,19
Yol	540	3975	155	425	5095	8,34
Toplam	16087	31734	16551	3592	67964	
Üretici Doğruluğu(%)	96,44	84,55	99,06	11,83		
Genel Doğruluk (%)					87,0549	Kappa Katsayısı
						0,8106



Şekil 4.54. SVM yöntemiyle veri setlerine ait elde edilen sınıflandırma doğruluk yüzdeleri

Şekil 4.54'te kullanılan veri setlerine ait SVM yöntemi ile yapılan sınıflandırma işlemi genel doğruluk değerleri gösterilmektedir. En yüksek sınıflandırma başarımını bir önceki yöntem olan Maximum Likelihood yönteminde olduğu gibi yine Spherical model ile oluşturulan veri seti elde etmiştir. Daha sonrasında sırasıyla Doku ölçütleri, Exponential model, Konumsal Örüntü ve son olarak yine ham spektral değerlerin kullanıldığı veri setleri gelmektedir.

4.2.7.3. Neural Network (Yapay Sinir Ağı, YSA) yöntemi

Yapay Sinir Ağları (YSA) insan beyninin yapısı ve çalışma sisteminden esinlenilerek geliştirilmiş yöntemlerdir. İnsan beyninin ve çalışma şeklinin karmaşık yapıya sahip olmasından dolayı tam olarak açıklamak zordur. En sade anlatımla, insan beyni devamlı olarak vücudun çeşitli organlarından gönderilen bilgiyi alır, işler ve en uygun kararları vererek gerekli olan yerlere geri gönderir. Beyin, insan vücudunun sinir sisteminin merkezi konumundadır. Bu sistemin en temel yapı taşları da sinir hücreleri diğer bir deyişle biyolojik nöronlardır. Merkezde oluşturulan bir sonuç bilgisini ilgili olan alanlara iletiminde birbirleri arasında yoğun bağlantılar bulunan bu nöronlar gerçekleştirir.


YSA, insan beyninin karakteristik özellikleri dikkate alınarak meydana getirilmiş basit sistemler olduğundan dolayı çalışma prensiplerinde de benzerlikler içermektedir. YSA'nın da temel yapı taşları nöronlardır. Bu nöronlar, birbirleriyle bağlantılar kurarak ve katmanlar şeklinde gruplandırılarak yapay sinir ağı sistemini oluşturmaktadırlar. Bir başka ifadeyle, YSA'lar karmaşık, çok yönlü ve güçlü bir karar alma mekanizması olan beynin sadece en basit yapı taşlarını taklit etmeye çalışmaktadır.

Uzaktan algılama uygulamalarında YSA'nın kullanımı 1990'ların ortalarından itibaren çeşitli bilimsel disiplinlerle birlikte hızla gelişmiştir. YSA'ların uygulama alanı ve sayısı bu tarihten itibaren artış göstermeye başlamıştır. Gerçekleştirilen uygulamaların çoğu geri yayılma öğrenme algoritması yardımıyla eğitilen çok katmanlı perseptron (MLP) ağı ile gerçekleştirilmiştir. Bunun yanı sıra Self-Organizing Maps (SOM), Learning Vector Quantization (LVQ) ve Radial Basis Function (RBF) gibi geliştirilmiş olan yapılar da daha sonraki uygulamalarda kendilerine yer bulmuşlardır (Özkan, 2001; Kansu, 2006; Çölkesen, 2009; Atasever, 2011; Dağdeviren, 2013). Ancak bu tezde bu yöntemler tezin temel konusu olmadığından açıklanmamış sadece sınıflandırma amacıyla kullanılmış olan ENVI paket programı içerisinde YSA sınıflandırıcı içinde default olarak gelen RBF yöntemi sınıflandırma işlemi için uygulanarak sonuç görüntüler oluşturulmuştur.

Eđitim veri setleri yardımıyla sadece spektral bandlardaki renk deęerleri kullanılarak yapılan Neural network sınıflandırma işleminde genel doęruluk deęeri %80,2719, kappa katsayısı ise 0,7144 olarak belirlenmiştir (Tablo 4.20).

Sınıflandırma görüntüsü (Şekil 4.55) incelendiğinde yöntemin spektral deęerleri kullanarak kıyı şeridinin genel olarak doęru belirledięi görölmektedir. Kıyı şeridini doęru bir biçimde belirlemesine rağmen su sınıfına ait olan alanların tespitinde çeşitli hatalar meydana gelmiştir. Yeşil alanların bulunduğu bölgedeki vadilerin topoğrafyasından kaynaklı, görüntüdeki bu bölgelere ait piksellerin renk deęerlerinin birbirlerine yakın deęerlerde olmasından ötürü yapılan sınıflandırmanın hatalı olduęu görölmektedir. Yöntemin bu alanları spektral deęerleri kullanarak ayıramadığı tespit edilmiştir. Yeşil alan olarak sınıflandırılması gereken bölgelerin su sınıfı olarak sınıflandırıldığı görölmektedir. Bina sınıfının tespiti ise üretici doęruluęu olarak düşük seviyede kalmıştır. Bu sınıfın bilgileri de yol sınıfı ile karışarak hatalı bir sınıflandırmanın gerçekleşmesine sebebiyet vermiştir.

Sınıflandırmaya ait hata matrisi (Tablo 4.20) incelendiğinde de bu durum tespit edilebilir. Bina sınıfında olması gereken 16087 pikselin 3868 tanesinin yol sınıfına gittięi görölmektedir. Böylece bu sınıfa ait üretici doęruluęu %75,88 olarak belirlenmiştir. Yeşil alan sınıfına ait olan üretici doęruluęu %79,75 olarak yapılan bütün sınıflandırma yöntemleri arasındaki en düşük doęruluk deęeri olarak belirlenmiştir. Bunun sebebi yeşil alan olarak sınıflandırılması gereken alanların su sınıfı olarak tespit edilmiş olmasıdır. Su sınıfı için üretici doęruluęu %99,42 olmasına rağmen kullanıcı doęruluęu %76,73'lük deęer ile tüm sınıflandırma yöntemleri arasındaki en düşük deęere sahip olmuştur. Yol sınıfının üretici doęruluęu %16,29 olarak belirlenmiştir. Hata matrisi incelendiğinde yol sınıfına ait birçok pikselin bina olarak sınıflandırıldığı görölmektedir.



Şekil 4.55. Neural Network yöntemiyle spektral değerlere göre sınıflandırılmış görüntü


Tablo 4.20. Spektral değerler ile gerçekleştirilen Neural Network sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	12207	134	0	2750	15091	80,89
Yeşil Alan	0	25309	0	199	25508	99,22
Su	12	4920	16455	58	21445	76,73
Yol	3868	1371	96	585	5920	9,88
Toplam	16087	31734	16551	3592	67964	
Üretici Doğruluğu(%)	75,88	79,75	99,42	16,29		
Genel Doğruluk (%)					Kappa Katsayısı	
80,2719					0,7144	

Standart doku ölçütleri ile oluşturulan 6 bandlı görüntü, Neural Network sınıflandırma yöntemi kullanılarak sınıflandırılması sonrasında %83,6193 genel doğruluk değeri tespit edilmiştir. Böylece sadece spektral değerlerle yapılan sınıflandırma sonucuna göre %3,3474' lük bir doğruluk artışı elde edilmiştir (Tablo 4.21). Kappa katsayısı değeri ise 0,7609 olarak belirlenmiş ve yine spektral değerlerle elde edilen kappa katsayısı değerine göre 0,0465' lik bir artış olduğu belirlenmiştir.

Sınıflandırma görüntüsü (Şekil 4.56) incelendiğinde spektral sınıflandırmada olduğu gibi yeşil alan ile su alanlarının birbirine karıştığı yeşil alan olarak sınıflandırılması gereken alanların su sınıfına atandığı görülmektedir. Bu durumda standart doku ölçütlerinin bu alanlar için yeterince bilgi sağlayamadığının kanıtı olarak gösterilebilir. Fakat spektral sınıflandırmada farklı sınıflara atanarak doğruluk değeri olarak düşük boyutlarda kalan bina sınıfına ait alanlar doku ölçütlerinin eklenmesiyle birlikte olması gereken sınıfa atanmışlardır. Böylece sınıflandırma başarımında bir gelişme sağlanmıştır. Aynı durum yol sınıfı için de geçerlidir. Spektral sınıflandırmada bina sınıfı ile karışan yol sınıfı doku ölçütleriyle birlikte daha hassas bir şekilde doğru olarak sınıflandırılmıştır. Bu durum görüntünün sol alt kısmında bulunan yol kesitinin doğru olarak sınıflandırılmasından anlaşılmaktadır. Sınıflandırma görüntüsündeki su sınıfı incelendiğinde kıyı çizgisinin spektral yöntemde olduğu gibi doğru bir şekilde tespit edildiği ve yeşil alanlar ile karışan yerler dışında genel olarak doğru sınıflandırıldığı görülmektedir.

Yapılan sınıflandırmaya göre oluşturulan hata matrisi (Tablo 4.21) incelendiğinde spektral sınıflandırmada %75,88 olan bina sınıfına ait olan üretici doğruluğu standart doku ölçütlerinin sınıflandırma işlemine eklenmesiyle birlikte %95,65 olarak belirlenmiştir. Yeşil alana ait olan üretici doğruluğu %79,75'ten %75,29'a inmiştir. Su sınıfı ile karışan yeşil alanlarda ciddi bir sınıflandırma doğruluk kaybı gerçekleşmiştir. Su sınıfına ait olan üretici doğruluğu %99,42'den %99,75'e, yol sınıfına ait olan %16,29'luk üretici doğruluğu ise %28,98'e yükselmiştir. Maximum Likelihood ve SVM yönteminde olduğu gibi Neural Network yönteminde de standart doku ölçüt görüntüleri sınıflandırma doğruluğunu arttırıcı bir etki yapmıştır.



Şekil 4.56. Neural Network yöntemiyle spektral ve standart doku ölçütlerine göre sınıflandırılmış görüntü


Tablo 4.21. Spektral ve standart doku ölçüt değerleri ile gerçekleştirilen Neural Network sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	15388	682	0	1930	18000	85,49
Yeşil Alan	19	23893	0	559	24471	97,64
Su	50	6302	16509	62	22923	72,02
Yol	630	857	42	1041	2570	40,51
Toplam	16087	31734	16551	3592		
Üretici Doğruluğu(%)	95,65	75,29	99,75	28,98		
Genel Doğruluk (%)					Kappa Katsayısı	
83,6193					0,7609	

Getis-Ord G istatistik analizi ile oluşturulan konumsal örüntü görüntüleri eklenerek elde edilen 8 bandlı yeni veri setinin, Neural Network sınıflandırma yöntemi

yardımıyla sınıflandırılması sonrasında %86,2913 genel doğruluk değeri tespit edilmiştir. Böylece sadece spektral değerlerle yapılan sınıflandırma sonucuna göre %6,0194' lük, standart doku ölçütlerine göre ise %2,6720'lik bir doğruluk artışı elde edilmiştir (Tablo 4.22). Kappa katsayısı değeri ise 0,7983 olarak belirlenmiş ve yine spektral değerlerle elde edilen kappa katsayısı değerine göre 0,0839' luk, standart doku ölçütlerine göre ise 0,0374'lük bir artış olduğu belirlenmiştir.

Sınıflandırma görüntüsü (Şekil 4.57) incelendiğinde spektral ve standart doku ölçütleri görüntülerinin sınıflandırılmasında olduğu gibi yeşil alan ile su alanlarının birbirine karıştığı alanların azaldığı görülmektedir. Yeşil alan olarak sınıflandırılması gereken alanların su sınıfına atandığı bölgelerin sayısında belirgin bir düşüş gözlenmektedir. Bu durumda konumsal örüntü görüntülerinin bu alanlar için yeterli miktarda ek bilgi sağlamış olduğu söylenebilir. Spektral sınıflandırmada farklı sınıflara atanarak doğruluk değeri olarak düşük boyutlarda kalan bina sınıfına ait alanlar doku ölçütlerinde olduğu gibi konumsal örüntü görüntülerinde de olması gereken sınıfa atanmışlardır. Böylece sınıflandırma başarımında bir gelişme sağlanmıştır. Ancak aynı durum yol sınıfı içinde geçerli değildir. Spektral sınıflandırmada bina sınıfı ile karışan yol sınıfı doku ölçütleriyle birlikte daha hassas bir şekilde doğru olarak sınıflandırılmasına rağmen konumsal örüntü görüntülerinde bu hassasiyete ulaşamamış ve doğruluk değeri bakımından spektral sınıflandırmanın bile altında kalmıştır. Bu durum görüntünün sol alt kısmında bulunan yol kesitinin doğru olarak sınıflandırılmamasından belli olmaktadır. Bu bölümdeki yol sınıfına ait olan alanlar yeşil alan olarak sınıflandırılmış ve yol sınıfının doğruluk değerinin düşmesine sebep olmuştur. Sınıflandırma görüntüsündeki su sınıfı incelendiğinde kıyı çizgisinin spektral ve standart doku ölçütlerinde olduğu gibi doğru bir şekilde belirlendiği ve yeşil alanlar ile karışan yerler dışında genel olarak doğru sınıflandırıldığı görülmektedir.



Şekil 4.57. Neural Network yöntemiyle spektral ve konumsal örüntü değerlerine göre sınıflandırılmış görüntü

Yapılan sınıflandırmaya göre oluşturulan hata matrisi (Tablo 4.22) incelendiğinde spektral sınıflandırmada %75,88 olan bina sınıfına ait olan üretici doğruluğu konumsal örüntü görüntülerinin sınıflandırma işlemine eklenmesiyle birlikte %93,19'a yükselmiştir. Yeşil alana ait olan üretici doğruluğu %79,75'ten %87,84'e çıkmıştır. Su sınıfı ile karışan yeşil alanların azalması bu sınıfta doğruluk artışına sebep olmuştur. Su sınıfına ait olan üretici doğruluğu %99,42'den %92,04'e, yol sınıfına ait olan %16,29'luk üretici doğruluğu ise %15,26'ya inmiştir. Buna sebep olarak; su sınıfında, kara ile yol arasında kalan bölgedeki su alanlarına ait olan bölgeleri tam olarak ayırt edememesi, yol sınıfı için ise daha önce de belirtildiği gibi görüntünün sol alt kısmında be binaların aralarında kalan yol kısımlarının yanlış sınıfa atanması gösterilebilir. Maximum Likelihood ve SVM yönteminde olduğu gibi


Neural Network yönteminde de konumsal örüntü görüntüleri sınıflandırma doğruluğunu artırıcı bir etki yapmıştır.

Tablo 4.22. Spektral ve konumsal örüntü değerleri ile gerçekleştirilen Neural Network sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	14991	21	0	2483	17495	85,69
Yeşil Alan	0	27875	0	555	28430	98,05
Su	0	1504	15233	6	16743	90,98
Yol	1096	2334	1318	548	5296	10,35
Toplam	16087	31734	16551	3592		
Üretici Doğruluğu(%)	93,19	87,84	92,04	15,26		
Genel Doğruluk (%)					Kappa Katsayısı	
86,2913					0,7983	

Spektral ve exponential model ile elde edilen konumsal verinin birleştirilmesiyle oluşturulan 8 bandlı görüntünün sınıflandırılmasıyla elde edilen genel doğruluk değeri %86,8783 olarak belirlenmiştir. Spektral sınıflandırmaya göre %6,6064'lük, standart doku ölçütlerine göre %3,2590' luk ve konumsal örüntü görüntülerine göre ise %0,5870'lik bir doğruluk artışı meydana gelmiştir. Sınıflandırma sonucu kappa katsayısı ise 0,8086 olarak belirlenmiştir. Spektral sınıflandırmaya göre 0,0942'lik, standart doku ölçütlerine göre 0,0477' lik ve konumsal örüntü görüntülerine göre ise 0,0103'lük bir artış gerçekleşmiştir (Tablo 4.23).

Sınıflandırma görüntüsü (Şekil 4.58) incelendiğinde kıyı çizgisininin nerdeyse hatasız bir biçimde ortaya çıkarıldığı böylece su sınıfının yüksek bir doğrulukla sınıflandırıldığı görülmektedir. Yeşil alanların sınıflandırılmasında diğer yöntemler gibi yüksek doğruluk elde edilmiştir. Ancak Maximum Likelihood sınıflandırma yönteminde belirli bir oranda doğru olarak sınıflandırılması gerçekleştirilebilen ve görüntünün tam ortasında kalan futbol sahasının bu yöntemde yol sınıfı olarak sınıflandırılarak iyi bir sınıflama başarısının elde edilemediği gözlemlenmiştir.



Şekil 4.58. Neural Network yöntemiyle spektral ve konumsal (exponential) değerlere göre sınıflandırılmış görüntü


Sınıflandırmaya ait hata matrisi (Tablo 4.23) incelendiğinde üretici doğruluklarında bina sınıfında %98,00'lık bir başarımla elde edilmiştir. Yeşil alanların sınıflandırılmasında %85,70'lik bir başarımla, su sınıfında ise %92,83'lük bir sınıflandırma doğruluğu başarımla elde edilmiştir. Su sınıfının bu kadar yüksek değerde başarılı olarak sınıflandırılmasında görüntüde bulunan yol ile kara parçası arasında kalan küçük üç adet alandan oluşan ve yer gerçeklik verisi olarak da seçilen bölgenin de yöntem tarafından belirlenerek doğru sınıfa atanmasından kaynaklanmaktadır. Maximum Likelihood sınıflandırma yönteminde bu alanlar yol veya bina verisi olarak sınıflandırıldıklarından dolayı bu sınıfa ait olan doğruluk değerleri o yöntem için oldukça düşük değerde bulunmuştur. Yol sınıfının üretici doğruluk değeri %20,10 olarak belirlenmiştir.

Tablo 4.23. Spektral ve Konumsal (Exponential) değerler ile gerçekleştirilen Neural Network sınıflandırmasına ait hata matrisi

	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	15765	598	0	2654	19017	82,90
Yeşil Alan	2	27195	0	216	27413	99,20
Su	0	72	15364	0	15436	99,53
Yol	320	3869	1187	722	6098	11,84
Toplam	16087	31734	16551	3592	67964	
Üretici Doğruluğu(%)	98,00	85,70	92,83	20,10		
Genel Doğruluk (%)					Kappa Katsayısı	
86,8783					0,8086	

Spektral ve spherical model ile elde edilen konumsal verilerin kullanılarak bir araya getirilmesiyle oluşturulan 8 bandı görüntünün sınıflandırılmasıyla elde edilen genel doğruluk değeri %87,0299 olarak belirlenmiştir. Konumsal bilginin eklenmesiyle spektral sınıflandırmaya göre meydana gelen doğruluk artışı %6,7580, standart doku ölçütlerine göre %3,4106, konumsal örüntü görüntülerine göre %0,7386'lık ve exponential görüntüye göre ise %0,1516'lık bir doğruluk artışı meydana gelmiştir. Kappa katsayısı 0,8106 olarak belirlenmiş ve spektral görüntüye göre 0,0942, standart doku ölçütlerine göre 0,0477, konumsal örüntü görüntülerine göre 0,0123 ve exponential görüntüye göre ise 0,0020 artış olduğu tespit edilmiştir (Tablo 4.24).

Sınıflandırma görüntüsü (Şekil 4.59) incelendiğinde kıyı çizgisinin bir önceki görüntüde olduğu gibi neredeyse hatasız bir biçimde tespit edilip, su sınıfının yüksek doğrulukla sınıflandırıldığını görmek mümkündür. Yeşil alanların sınıflandırılmasında yine başarılı bir sonuç elde edilmiştir. Maximum Likelihood yönteminde görüntüde sol alt kısımda bina sınıfı olarak sınıflandırılan alanların neredeyse tümü bu yöntemde ve konumsal bağımlılık bilgisi yardımıyla doğru sınıf olan yeşil alan sınıfına atanmıştır. Ancak buna rağmen görüntünün orta bölgesinde bulunan ve Maximum Likelihood yönteminde spherical modelden elde edilen konumsal bilgi ile doğru olarak sınıflandırılması gerçekleştirilmiş olan futbol sahasının bu yöntemde de doğru olarak sınıflandırılması gerçekleştirilememiştir. Kara ile yol arasında kalan su bölgelerinin sınıflandırılması bu yöntem ve görüntüde de doğru olarak sınıflandırılmayı başarmıştır.




Şekil 4.59. Neural Network yöntemiyle spektral ve konumsal (spherical) değerlere göre sınıflandırılmış görüntü

Sınıflandırmaya ait hata matrisi (Tablo 4.24) incelendiğinde üretici doğruluklarında bina sınıfında %96,37’lik bir başarımla elde edilmiştir. Yeşil alanların sınıflandırılmasında %87,01’lik bir başarımla, su sınıfında ise %91,40’lık bir sınıflandırma doğruluğu başarımla elde edilmiştir. Su sınıfının bu kadar yüksek değerde başarılı olarak sınıflandırılmasında görüntüde bulunan yol ile kara parçası arasında kalan küçük üç adet alandan oluşan ve yer gerçeklik verisi olarak da seçilen bölgenin de yine bu görüntüde de belirlenerek doğru sınıfa atanmasından kaynaklanmaktadır. Maximum Likelihood sınıflandırma yönteminde bu alanlar yol veya bina verisi olarak sınıflandırıldıklarından dolayı bu sınıfa ait olan doğruluk değerleri o yöntem için oldukça düşük değerde bulunmuştur. Yol sınıfının üretici doğruluk değeri %25,28 olarak belirlenmiştir.

Tablo 4.24. Spektral ve Konumsal (Spherical) değerler ile gerçekleştirilen Neural Network sınıflandırmasına ait hata matrisi


	YG_Bina	YG_Yeşil Alan	YG_Su	YG_Yol	Toplam	Kullanıcı Doğruluğu(%)
Bina	15503	696	0	2525	18724	82,80
Yeşil Alan	13	27611	0	159	27783	99,38
Su	0	0	15127	0	15127	100,00
Yol	571	3427	1424	908	6330	14,34
Toplam	16087	31734	16551	3592	67964	
Üretici Doğruluğu(%)	96,37	87,01	91,40	25,28		
Genel Doğruluk (%)					Kappa Katsayısı	
87,0299					0,8106	

Spherical model görüntüsü ve spektral değerler ile yapılan sınıflandırma başarımlarından incelendiğinde bina sınıfında %20,49'luk, yeşil alan sınıfında %7,26'luk, su sınıfında üretici doğruluğunda %8,02'lik düşüş meydana gelmiştir. Yol sınıfında ise %8,99'luk bir artışın gerçekleştiği görülmüştür.



Şekil 4.60. Neural Network yöntemiyle veri setlerine ait elde edilen sınıflandırma doğruluk yüzdeleri

Şekil 4.60'ta veri setlerine ait Neural Network yöntemi ile yapılan sınıflandırma işlemi genel doğruluk değerleri gösterilmektedir. En yüksek sınıflandırma başarımını diğer iki sınıflandırma yönteminde olduğu gibi yine Spherical model ile oluşturulan veri seti elde etmiştir. Ardından sırasıyla Exponential model, Konumsal Örüntü, Doku ölçütleri ve son olarak yine ham spektral değerlerin kullanıldığı veri setleri gelmektedir.



Şekil 4.61. Sınıflandırma yöntemlerine veri setlerine ait elde edilen sınıflandırma doğruluk yüzdeleri karşılaştırılması

Sınıflandırma görüntüleri ve hata matrisleri incelendiğinde bütün sınıflandırma yöntemleri için en yüksek sınıflandırma doğruluğunu elde eden görüntü spherical modelden elde edilen spektral ve konumsal bilginin birlikte kullanıldığı görüntüdür (Şekil 4.61). Bu sonuçlar da açıkça göstermektedir ki görüntüde bulunan piksellerin konumsal bağımlılıklarının sınıflandırma gibi bir temel uzaktan algılama uygulamasında spektral bilgiye ek/tamamlayıcı olarak kullanılması genel sınıflandırma doğruluğunun artışına sebep olmuştur.

5. SONUÇLAR VE ÖNERİLER

Tez çalışmasında görüntü üzerinde istatistik/histogram değerleri kullanılarak elde edilen klasik standart doku ölçütleri, çeşitli metrik ölçülerin kullanımı ile oluşturulan benzerlik ölçütü görüntüleri ve belirli görüntü bölgelerinde mekânsal değişkenlik veya ilişkileri tanımlayan konumsal otoregresyon yöntemiyle elde edilmiş olan doku görüntülerinin karşılaştırmalı analizinin yapılmasının yanı sıra, literatürde yapılan benzer çalışmaların genelinde; görüntüler üzerindeki konumsal bağımlılığı belirleyen semivariogram analizinin, yapılacak olan spektral sınıflandırma işlemine dahil edilmesi ile sınıflandırma doğruluğunu arttırdığı ileri sürüldüğünden dolayı bu çalışmada; görüntüler üzerinden yapılan semivariogram model parametrelerinden olan Sill ve Range değerlerinin oranlanmasıyla oluşturulan konumsal bağımlılık derecelerinden elde edilen dokuyu belirleyebilecek bir kriter ile birlikte, sınıflandırma işleminin doğruluk değerine hangi seviyede katkı yapabileceğinin etkin bir biçimde belirlenmesi amaçlanmıştır.

Veri seti olarak kullanılacak olan uydu görüntüsü belirlendikten sonra ilk olarak görüntü üzerinde doku örüntülerinin bulunup bulunmadığının tespiti gerçekleştirilmiştir. Bu amaç için görüntünün histogram değerlerinin kullanıldığı benzerlik ölçüt yöntemlerinin uygulanmasına karar verilmiştir. Görüntü içerisinden homojen dağılımlı alanlar belirlenerek 21 adet benzerlik ölçüt yöntemiyle görüntünün her bir bandı için analizler yapılmış ve sonuç olarak 252 adet benzerlik ölçüt görüntüsü oluşturulmuştur. Oluşturulan görüntülerin incelenmesi sonucunda veri setinin doku bilgisine sahip olduğu sonucuna varılmıştır.

Standart doku ölçütlerinin oluşturulmasında GLCM'den yararlanılmış ve 6 adet doku ölçüt görüntüsü elde edilmiştir. Bu doku ölçüt görüntüleri incelendiğinde içlerinden iki tanesinin (açısal ikinci moment ve homojenlik) semivariogram model parametrelerinden elde edilen kriter yardımıyla oluşturulan konumsal bilgi görüntülerine benzer sonuçlar verdiği tespit edilmiştir. Bunun yanı sıra standart doku ölçütlerinin benzerlik ölçütü yöntemleri ile de benzerlikler içerdiği tespit edilmiştir.

Oluşturulan doku ölçütlerinden Kontrast ve Açısal ikinci moment görüntüleri ile spektral değerler bir araya getirilerek 6 banda sahip yeni bir veri seti oluşturulmuş ve yapılan sınıflandırma işleminde bu doku ölçütlerinin doğruluk değerine yaptığı katkı incelenerek, doku ölçüt görüntülerinin sınıflandırma doğruluğunu arttırdığı tespit edilmiştir.

Konumsal örüntü analizi yöntemlerinden olan Getis-Ord G ve Moran's I indeksi analizleri ile veri seti olan uydu görüntüsü analiz edilmiştir. Yapılan analiz işlemi diğer yöntemler ile bütünlük sağlamak adına 11 piksel komşuluğunda ve herbir görüntü bandı için gerçekleştirilmiş ve veri setine ait olan konumsal örüntü görüntüleri elde edilmiştir. Oluşturulan konumsal örüntü görüntüleri spektral değerler ile bir araya getirilerek 8 banda sahip yeni bir veri seti elde edilmiştir. Yeni veri seti tez çalışmasında kullanılan üç adet kontrollü sınıflandırma işlemine tabi tutulmuş ve sınıflandırma sonrası oluşturulan hata matrisleri yardımıyla sınıflandırma doğruluğuna yaptığı katkı incelenmiştir.

Konumsal otoregresyon modeli ile benzerlik ölçütü ve standart doku ölçütleri ile görüntü üzerinde belirlenmiş olan doku parametresinin modellenmesi işlemi gerçekleştirilmiştir. İteratif olarak çalışan ve global ölçütler kullanmak yerine lokal bağımlılıkları inceleyen SAR yönteminde piksel ve komşuları arasındaki konumsal ilişki göz önüne alınarak yapılan modelleme sonucunda standart doku ölçütlerine benzer ölçüt görüntüleri oluşturulmuştur. Bu görüntülerin, benzerlik ölçütleri ve standart doku ölçüt görüntüleri ile karşılaştırması yapılmış ve bu üç farklı veri seti arasında benzerlikler tespit edilmiştir.

Tez çalışmasında çeşitli analiz yöntemleri ile elde edilen doku bilgisinin sınıflandırma başarımına olan etkisini belirleyebilmek için üç adet sınıflandırma yöntemi kullanılmıştır. Bu yöntemler, Maximum Likelihood, Support Vector Machines (SVM) ve Neural Network yöntemleridir. Kullanılmış olan bu sınıflandırma yöntemlerinin birbirlerine karşı olan avantaj veya dezavantajları göz ardı edilerek sadece doku ve konumsal bilginin sınıflandırma işlemine yapacağı katkı araştırılmıştır. Bu sebeple yöntemler arasında herhangi bir kıyaslama yapılmamış, sadece doku ve konumsal bilginin doğruluk değerine yapacağı katkı üzerine yoğunlaşmıştır. Buna göre konumsal bağımlılık bilgisinin sınıflandırma doğruluğuna yaptığı katkının analizi için semivariogram parametrelerinden elde

edilen kriter yardımıyla oluşturulan görüntülerin sınıflandırılması işlemi sonrasında en yüksek doğruluk değerini Spherical model görüntüsü her üç sınıflandırma yöntemiyle de elde etmiştir. Sırasıyla Maximum Likelihood yönteminde %88,4807, SVM yönteminde %87,0549 ve Neural Network yönteminde %87,0299 sınıflandırma doğruluk değerlerine ulaşılmıştır. Exponential model görüntüsüyle elde edilen doğruluk değerleri spherical modele yakın değerlerdir. Yine sırasıyla Maximum Likelihood yönteminde %87,3271, SVM yönteminde %86,7606 ve Neural Network yönteminde %86,8783 sınıflandırma doğruluğu değerleri elde edilmiştir. Standart doku ölçüt görüntülerinin spektral değerlere eklenmesiyle birlikte Maximum Likelihood yönteminde %85,8599, SVM yönteminde %87,0534 ve Neural Network yönteminde ise %83,6193 sınıflandırma doğruluk değeri elde edilmiştir. Konumsal örüntü görüntülerinin spektral değerler ile birleştirilmesiyle birlikte Maximum Likelihood yönteminde %83,0866, SVM yönteminde %84,7964 ve Neural Network yönteminde ise %86,2913'lük sınıflandırma doğruluk değerlerine ulaşılmıştır. Sınıflandırma işleminde en düşük doğruluk değerleri ham spektral değerler ile yapılan sınıflandırmalardan elde edilmiştir. Maximum Likelihood yönteminde %80,9635, SVM' de %84,7566 ve Neural Network yönteminde ise %80,2719 sınıflandırma doğruluk değerlerine ulaşılmıştır.

Sınıflandırma işleminin şans olasılığı gösteren Kappa istatistiği katsayıları incelendiğinde en yüksek değerlere her üç sınıflandırma yönteminde de yine spherical model ile oluşturulan veri setine ait sınıflandırma işleminin eriştiği görülmektedir. Kappa katsayısının 1'e yakın olması ideal durum olarak tanımlanmaktadır ve yapılan sınıflandırma işleminin şans eseri oluşmadığını göstermektedir. Buna göre spherical yöntem ile oluşturulan veri setinin kappa katsayısı değerleri sırasıyla 0,8269, 0,8106 ve 0,8106 olarak tespit edilmiştir. Kappa katsayılarında ikinci en iyi değer exponential model ile oluşturulan veri setinin sınıflandırılmasına ait olan değerlerdir. Exponential model veri setine ait kappa katsayısı değerleri sırasıyla 0,8112, 0,8066 ve 0,8086 olarak hesaplanmıştır. Standart doku ölçüt görüntülerinden elde edilen Kappa katsayıları sırasıyla 0,7899, 0,8089 ve 0,7609 olarak belirlenmiştir. Konumsal örüntü görüntülerinden elde edilen kappa katsayıları sırasıyla 0,7491, 0,7799 ve 0,7983 olarak tespit edilmiştir. Kappa katsayısı değerlendirmesinde en kötü değerleri ham spektral değerler ile yapılan sınıflandırma işlemleri elde etmiştir. Spektral değerler göre yapılmış olan

sınıflandırma işlemi sonucu elde edilen kappa katsayısı değerleri sırasıyla 0,7199, 0,7768 ve 0,7144 olarak belirlenmiştir.

Yöntemler bazında inceleme yapıldığında Maximum Likelihood yönteminde ham spektral değerlere göre yapılmış olan sınıflandırma işlemine göre doğruluk değeri, konumsal örüntü görüntüleri ile %2,1231, standart doku ölçütleri ile %4,8864, konumsal bilgilerden üretilen exponential model görüntüsü ile %6,3636 ve spherical model görüntüsü ile ise % 7,5172'lik artış göstermiştir. Aynı durum kappa katsayılarında da gerçekleşmiştir. Konumsal örüntü görüntüleri ile 0,0292, standart doku ölçütleri ile 0,07, exponential model ile 0,0913 ve spherical model ile ise 0,1070 kadar artış sağlandığı görülmüştür. SVM yönteminde konumsal örüntü görüntüleri ile %0,0398, standart doku ölçütleri ile %2,2968, exponential model görüntüsüyle %2,0040 ve spherical model görüntüsüyle ise %2,2983'lük bir sınıflandırma doğruluğu artışı gerçekleşmiştir. Kappa katsayılarında ise sırasıyla 0,0031, 0,0298, 0,0330 ve 0,0338 değerinde bir gelişme sağlanmıştır. Sınıflandırma yöntemlerinden Neural Network yönteminde ise standart doku ölçütleri ile %3,3474, konumsal örüntü görüntüleri ile %6,0194, exponential model görüntüsü ile %6,6064 ve spherical model görüntüsü ile ise %6,7580'lik doğruluk artışı elde edilmiştir. Kappa katsayılarına bakıldığında sırasıyla 0,0465, 0,0839, 0,0942 ve 0,0962'lik bir artış sağlanmıştır.

Standart bir uzaktan algılama uygulaması olan sınıflandırma işleminin doğruluk başarımını arttırmak için bugüne kadar literatürde bahsedilen birçok yöntem geliştirilmiş/önerilmiştir. Ham spektral değerlerin sınıflandırmada veya arazi örüntülerini tespit etmedeki veri setine bağlı düşük başarımlarından dolayı sınıflandırma işleminde bu başarımları arttıracak ek bilgilere ihtiyaç duyulduğu bilinmektedir. Görüntüler içerisindeki belirli bir bölgede bulunan gri değer yoğunluğunda meydana gelen karakteristik değişim olarak tanımlanan doku parametresi bu ek bilgilerin içerisinde düşünülebilir. Görüntüler içerisindeki dokuyu belirleyen standart doku ölçütleri olan ilk istatistiki/histogram bazlı çalışan yöntemler sadece gri renk değişimlerinin tespiti ile dokuyu belirlemekle ilgilenmişlerdir. Elde edilmiş olan bu istatistiki bilgilerin sınıflandırma işlemine katılması sonucunda sınıflandırma başarımında belirli bir oranda artışa yol açtığı, yapılan bazı çalışmalarla gösterilmiştir. Ancak görüntülerde mevcut dokuların tespitinde

görüntüyü oluşturan piksellerin konumlarının/konumsal ilişkilerinin göz ardı edilerek hesaplandığı bu istatistiki bilgiler ile elde edilen bu başarımlar yeterli görülmemiştir. Standart doku bilgisi çıkarım yaklaşımlarına ek olarak belli komşuluktaki piksellerin mekansal (örüntü) ilişkilerini dikkate alan yaklaşımlara ihtiyaç duyulmuştur. İkinci derece istatistiki (GLCM) bilgilerin kullanılması ile piksellere ait konum bilgileri doku belirleme işlemine katılmışsa da hedeflenen sonucu elde etmede yeteri kadar başarılı olunamamıştır. Yapılan bu tez çalışmasında da literatürde gözlemlenen %3-5 civarındaki doğruluk artışı bu çalışmada da aynı düzeyde gerçekleşerek belirtilen çalışmalar ile paralel bir sonuç vermiştir. Mekansal istatistik yöntemleri ile doku tespitinde, genel ve yerel konumsal örüntü yöntemleri yardımıyla piksellerin konumsal bilgisinin belirlenmesi sınıflandırma doğruluğunda artış sağlamıştır. Belirli komşulukta tanımlanmış doku bilgilerinin mekansal istatistik ölçütleri ile analiz edilmesi ile görüntüler üzerinden bilgi çıkarımında olumlu sonuçlar elde edilmiştir. Mekansal istatistik yöntemleri olan Getis-Ord G, Moran's I ve Anselin Moran's I yöntemleri yardımıyla belirlenmiş olan yerel ve genel konumsal örüntüler ile belirlenen doku bilgisinin sınıflandırma başarımına olan etkisinin standart doku bilgisine göre daha fazla olduğunu belirten literatür çalışmaları bulunmaktadır. Bu tez çalışmasında da Neural Network sınıflandırma yöntemi sonuçları incelendiğinde konumsal örüntü bilgisi ile elde edilen başarımların standart doku ölçütlerine göre daha fazla olduğu görülmektedir. Mekansal örüntü tanımlama ve analizlerinin yanında tamamlayıcı nitelikte geoistatistik yöntemler de kullanılmaktadır. Geoistatistik genel istatistik yöntemlerin örnekler arasındaki ilişkiyi ele alma yöntemlerinden farklı olarak, görüntülerdeki piksellerin konum bilgilerini de ele alarak hesaplama işlemini gerçekleştirip, pikseller arasındaki konumsal bağımlılık/ilişki bilgilerini elden bir analiz yöntemidir. Geoistatistik yöntemler ile elde edilen semivaryans değerlerinin sınıflandırma işlemine katılarak sınıflandırma başarımında olumlu sonuçların alındığı çalışmalar son yıllarda literatürde sıklıkla yer almaktadır. Yapılan bu tez çalışmasında konumsal bağımlılığı temsil eden semivaryans değerlerine ek olarak literatürde henüz denenmemiş olan semivariogram parametrelerinin oran değerleri ile oluşturulmuş bir kriter yardımıyla sınıflandırma başarımı değerlendirilmiştir. Elde edilen sonuçlar göstermektedir ki ham spektral değerlere göre yapılan sınıflandırmaya göre %7 ve %8 değerlerinde bir doğruluk başarımı elde edilmiştir.

Görüntü üzerinden alınan örnek doku verileri kullanılarak, benzerlik ölçütleri yardımıyla görüntüdeki benzer doku bölgelerinin araştırılıp belirlenebileceği yapılmış olan literatür çalışmalarıyla tespit edilmiştir. Bu amaçla gerçekleştirilen çalışmalarda kullanılan yöntemlerin bu çalışmada da kullanılması ile karşılaştırmalı analizleri gerçekleştirilmiştir. Standart doku ölçütleri, mekansal istatistik ve geoistatistik yöntemleri ile görüntü üzerinde belirlenmiş olan doku bölgelerinin benzerlik ölçütleri ile de belirlenip belirlenemeyeceği test edilmiştir. Literatürde genellikle kullanımına başvurulmuş yöntemler olan Ölkid, City-Block, Kosinüs, Jaccard, Jeffrey, Minkowski, Chi-Kare, Bray-Curtis, Dice ve Fidelity gibi analiz yöntemlerinin bu tez çalışmasında da oluşturdukları benzerlik ölçüt görüntüleri ile elde edilen doku görüntüleri arasında benzerlikler olduğu tespit edilmiştir.

Doku belirlemede konumsal bilgiyi/örüntüyü göz ardı edilmeksizin pikseller arasındaki konumsal bağımlılık derecelerini belirleyen yöntemlerin analiz sonuçlarına olumlu/pozitif katkı sağladığı göz önüne alındığında, görüntülerdeki doku bilgisini tespit etmek amacıyla yeni benzerlik ölçütleri geliştirilerek uzaktan algılama uygulamalarına entegre edilmesi faydalı olacaktır.

Elde edilen bilgi ve sonuçlardan yola çıkarak yapılması planlanan ileri çalışmalar için aşağıda maddeler halinde belirtilen çeşitli önerilerde bulunulmuştur.

Semivariogram parametreleri yardımıyla belirlenen konumsal bağımlılığın derecelendirilmesi ve görüntüler üzerinden hesaplanan bu çeşitli ölçülerin farklı sınıflandırma veya bilgi çıkarım yöntemlerinde kullanılarak elde edilecek olan sonuçların irdelenmesi yararlı olabilir.

Standart doku elde etmenin yanı sıra, global ve yerel ölçütler kullanımıyla görüntüler içerisindeki örüntü (otokorelasyon) belirlendikten sonra yapılacak olan mekânsal doku tanımının spektral sınıflandırma/bilgi çıkarımına hangi oranlarda/düzeylerde katkı sağladığı konusunda ileri araştırmalar yapılabilir.

Görüntüler üzerinden üretilen çeşitli benzerlik ölçütü yöntemleri kullanılarak çeşitli yaklaşımlarla veya bilgilerle elde edilen dokuların, özellik ve kalitelerinin araştırılmasında/ayırımında bu benzerlik ölçütlerinin kantitatif bir yöntem olarak kullanılması yararlı olacaktır.

Çeşitli özellikteki görüntülerde tanımlanması/belirlenmesi zor olan doku için, tez çalışması içerisinde önerilen ‘konumsal bağımlılığın derecelendirilmesi ve benzerlik ölçütlerinin kantitatif olarak kullanılması’ yaklaşımı kavramsal olarak yapılacak “yeni parametre tasarımı”na katkı sağlayabilecektir.

Görüntüler içerisindeki yerel mekânsal değişkenliğin otoregresif yöntemler kullanılarak modellenmesiyle (mekânsal kestirim) yerel konumsal doku bilgisinin bilgi çıkarımı/sınıflandırma işlemine olan katkısı konusunda ileri araştırmalar yapılabilir.

Frekans bazlı dönüşümlerde çok çözünürlüklü bileşenler tespit edilip yeni görüntüler oluşturulabilir. Doku tespitinde ölçek parametresi önemli olduğundan dolayı çoklu ölçeklerdeki frekans bileşenleri farklı ölçeklerdeki doku özellikleri ile ilişkilendirilebileceğinden bu yaklaşım mekansal doku özelliklerinin tespitinde kullanılabilir.

Tez çalışması kapsamında gerçekleştirilen çeşitli uygulamaların farklı özellikteki uydu görüntüleri üzerinde farklı parametrelerle denenmesi/test edilmesi yöntemlerin bilgi çıkarımına olan katkı ve potansiyelinin belirlenmesini sağlayacaktır.

KAYNAKLAR

- Akıncı M., Akıncı G. Y., Yılmaz Ö., Dramın Boyutlarının Ölçümü: Terörizmin Sosyo-Ekonomik Belirleyicilerinin Coğrafi Ağırlıklı Regresyon Analizi, *Fiscaoeconomia*, 2017, **1**(3), 68–107.
- Aksakal M., Çılan Ç. A., Türkiye’ye Yönelik Turizm Talebinin Görünürde İlişkisiz Regresyon Modelleri İle İncelenmesi, *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 2015, **7**(14), 235–256.
- Akyürek Ö., Arslan O., Karademir A., SO₂ ve PM₁₀ Hava Kirliliği Parametrelerinin CBS İle Konumsal Analizi: Kocaeli Örneği, *TMMOB Coğrafi Bilgi Sistemleri Kongresi*, Ankara, 11-13 Kasım 2013.
- Akyürek Ö., Arslan O., Kocaeli İli ve Çevresinde (1900-2016) Yılları Arasında Gerçekleşen Tarihsel Depremlerin Konumsal İstatistik Analizi, *Geomatik Dergisi*, 2018, **3**(1), 48–62.
- Aral N., Aytaç M., Türkiye’de İşsizliğin Mekansal Analizi, *Marmara Üniversitesi Öneri Dergisi*, 2018, **13**(49), 1–20.
- Arslan O., Akyürek Ö., Kaya Ş., A Comparative Analysis of Classification Methods for Hyperspectral Images Generated with Conventional Dimension Reduction Methods, *Turkish Journal of Electrical Engineering & Computer Sciences*, 2017, **25**, 58–72.
- Arslan O., Uzaktan Algılamada Konumsal Bilgi İşleme ve Görüntü İşleme, KOU Jeodezi ve Jeoinformasyon Müh. Ders Notları, Fen Bilimleri Enstitüsü, 2019.
- Atalay A., Tortum A., Çodur M. Y., Trafik Kazalarının Coğrafi Ağırlıklı Regresyon Analizi İle Modellenmesi, *TMMOB Coğrafi Bilgi Sistemleri Kongresi*, Ankara, 11-13 Kasım 2013.
- Atasever Ü. H., Uydu Görüntülerinin Sınıflandırmasında Hızlandırma (Boosting), Destek Vektör Makineleri, Rastgele Orman (Random Forest) ve Regresyon Ağaçları Yöntemlerinin Kullanılması, Yüksek Lisans Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri, 2011, 276782.
- Atkinson P. M., Spatial Statistics, Editors: Stein A., Van Der Meer F., Gorte B., *Spatial Statistics for Remote Sensing*, 1st ed., Kluwer Academic, Dordrecht, 57–81, 2002.
- Barbosa I. C., Neto E. A., Seidel E. J., Oliveira M. S., Proposal Of The Spatial Dependence Evaluation From The Power Semivariogram Model, *Bulletin of Geodetic Sciences*, 2017, **23**(3), 461-475.

Baştürk A., Yuğnak Z., Ketencioğlu H., Yüksel M. E., Gabor Dalgacıkları ve Temel Bileşenler Analizi Kullanarak Tekstil Kumaşlarında Hata Denetimi, *Elektrik, Elektronik ve Bilgisayar Mühendisliği Sempozyumu ve Fuarı*, Bursa, Türkiye, 6-10 Aralık 2006.

Bharati M. H., Liu J. J., MacGregor J. F., Image Texture Analysis: Methods and Comparisons, *Chemometrics and Intelligent Laboratory Systems*, 2004, **72**, 57–71.

Bohling G., Introduction to Geostatistics and Variogram Analysis, *Kansas University*, C&PE 940, 1-20, 2005.

Bozoğlu M., Examining The Logistic Points in the Independence War of Turkey Using Spatial Statistic and GIS, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir, 2014, 373987.

Ceyhan E., Coğrafi Ağırlıklı Regresyon İçin Yaklaşık Çözümlerin Geliştirilmesi, Yüksek Lisans Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri, 2013, 335386.

Cha S. H., Taxonomy of Nominal Type Histogram Distance Measures, *American Conference on Applied Mathematics*, Harvard, Massachusetts, USA, 24 - 26 Mart 2008.

Chaurasia K., Garg P. K., A Brief Review on Texture Analysis Methods, *Studies in Surveying and Mapping Science*, 2013, **21**, 759–776.

Chica-Olmo M., Abarca-Hernandez F., Variogram Derived Image Texture for Classifying Remotely Sensed Images, Editors: De Jong S. M., Van Der Meer F. D., *Remote Sensing Image Analysis: Including the Spatial Domain*, 5th ed., Springer, Hollanda, 93–111, 2004.

Chica-Olmo M., Abarca-Hernandez F., Computing Geostatistical Image Texture for Remotely Sensed Data Classification, *Computers & Geosciences*, 2000, **26**, 373–383.

Cohen W. B., Spies T. A., Bradshaw G. A., Semivariograms of Digital Imagery for Analysis of Conifer Canopy Structure, *Remote Sensing of Environment*, 1990, **34**(3), 167–178.

Curran P. J., The Semivariogram in Remote Sensing: An Introduction, *Remote Sensing of Environment*, 1988, **24**, 493–507.

Çölkesen İ., Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması ve Analizi, Yüksek Lisans Tezi, Gebze Yüksek Teknoloji Enstitüsü, Mühendislik ve Fen Bilimleri Enstitüsü, Kocaeli, 2009, 245292.

Dağdeviren E., El Yazısı Rakam Tanıma İçin Destek Vektör Makinelerinin ve Yapay Sinir Ağlarının Karşılaştırması, Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2013, 325664.

Demirci D. A., Destek Vektör Makineleri İle Karakter Tanıma, Yıldız Teknik Üniversitesi, İstanbul, 2007, 201495.

Duran E., Mekansal İstatistiksel Analizler Yoluyla Türkiye’de Su Kaynakları Gelişiminin Değerlendirilmesi, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir, 2018, 517463.

Durrieu M., Ruiz L. A., Balaguer A., Analysis of Geostatistical Parameters for Texture Classification of Satellite Images, *Procs. of the 25th EARSEL Symposium: Global Developments in Environmental Earth Observation from Space (ISBN:9059660420)*, 2005, 11–18.

Emekdaş E. F., İmge Arama Sonuçlarının Baskın Kümeler Kullanılarak Gruplandırılması, Yüksek Lisans Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik Mühendisliği Anabilim Dalı, Ankara, 2010, 295607.

Ergüt Ö., Uzaklık ve Benzerlik Ölçülerinin Kümeleme Sonuçlarına Etkisi, Yüksek Lisans Tezi, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı, İstanbul, 2011, 291467.

Eryılmaz H., Mekansal İstatistikte Nokta Örüntü Teknikleri ve Bir Uygulama, Doktora Tezi, Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir, 2010, 269654.

Fotsing J., Tonye E., Zobo B. E., Saley M. B., Kouame F. K., Rudant J.-P., Characterization of the Texture of Digital Images by Variography Approach : An Application to the Classification of SAR Images, *Geoinformatics & Geostatistics : An Overview*, 2013, **S1**(1), 1–6.

Gayır B., Arslan O., Orman Yangınlarının CBS Tabanlı Konumsal İstatistik Analizi: 2011-2015 Yılları Arasında Muğla Orman Bölge Sınırları İçerisinde Çıkan Yangınlar, *Anadolu Orman Araştırmaları Dergisi*, 2018, **4**(1), 44–60.

Gonzales R. C., Woods R. E., *Sayısal Görüntü İşleme*, 3th ed., Palme Yayıncılık, Ankara, 2014.

Güneren H., Destek Vektör Makineleri Kullanarak Gömülü Sistem Üzerinde Yüz Tanıma Uygulaması, Yıldız Teknik Üniversitesi, İstanbul, 2015, 414160.

Haşiloğlu A., Dalgacık Dönüşümü ve Yapay Sinir Ağları İle Döndürmeye Duyarsız Doku Analizi ve Sınıflandırma, *Turkish Journal Engineering Environment Science*, 2001, **25**, 405–413.

Haralick R. M., Statistical and Structural Approaches to Texture, *Proceedings of the IEEE*, 1979, **67**(5), 405–413.

Kansu O., Uzaktan Algılamada Görüntü Sınıflandırma Yöntemleri Analizi, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon, 2006, 182992.

Karagülle F., Destek Vektör Makinelerini Kullanarak Yüz Bulma, Trakya Üniversitesi, Edirne, 2008, 177378.

Karakaynak Z., Destek Vektör Makineleri İle Sınıflandırma ve Görüntü Tanıma Üzerine Bir Uygulama, Mimar Sinan Güzel Sanatlar Üniversitesi, İstanbul, 2014, 374664.

Kaya Ş., Sertel E., Uzaktan Algılanmış Verilerin Semivariogram Modeli, 1. *Uzaktan Algılama CBS Çalıştay ve Paneli*, İstanbul, Türkiye, 27 - 29 Kasım 2006.

Kemeç S., Düzgün Ş., Sosyo-Demografik Yapıdaki Mekansal Değişimlerin, Mekansal Regresyon Teknikleri İle Analizi: Eskişehir 2002 Genel Seçim Örneği, 1. *Ulusal Uzaktan Algılama - CBS Çalıştay ve Paneli*, İstanbul, Türkiye, 2006.

Materka A., Strzelecki M., Texture Analysis Methods – A Review, *Technical University of Lodz, Institute of Electronics*, COST B11, 1-33, 1998.

Mitchell H. B., *Image Fusion Theories, Techniques and Applications*, 1st ed., Springer, Chennai, India, 2010.

Özkan C., Uydu Görüntü Verisinin Yapay Sinir Ağları İle Sınıflandırılması, Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2001, 112235.

Rodríguez-Galiano V. F., Abarca-Hernández F., Ghimire B., Chica-Olmo M., Atkinson P. M., Jeganathan C., Incorporating Spatial Variability Measures in Land-Cover Classification Using Random Forest, *Procedia Environmental Sciences*, 2011, **3**, 44–49.

Ruiz L. A., Recio J. A., Hermosilla T., Methods for Automatic Extraction of Regularity Patterns and Its Application to Object-Oriented Image Classification, *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2007, **36**, 117–121.

Russ J. C., *The Image Processing Handbook*, 3rd ed., CRC Press, Florida, USA, 1999.

Sakarya A., İbişoğlu Ç., Türkiye’de İllerin Sosyo-Ekonomik Gelişmişlik Endeksinin Coğrafi Ağırlıklı Regresyon Modeli İle Analizi, *Marmara Coğrafya Dergisi*, 2015, **32**, 211–238.

Savran Y., Çok Değişkenli Gauss Karışım Modelleme Yöntemiyle Görsel Doku Analizi, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, İstanbul, 2009, 251904.

Seidel E.J., Oliveira M. S., Novo índice geoestatístico para a mensuração da dependencia espacial, *Revista Brasileira de Ciencia do Solo*, 2014, **38**(3), 699-705.

Seidel E.J., Oliveira M. S., A Classification for a Geostatistical Index of Spatial Dependence, *Revista Brasileira de Ciencia do Solo*, 2016, **40**, 1-10.

Showengerdt R. A., *Remote Sensing: Models and Methods for Image Processing*, 3rd ed., Elsevier, San Diego, California, USA, 2007.

Sklansky J., Image Segmentation and Feature Extraction, *IEEE Transactions on Systems, Man and Cybernetics*, 1978, **8**, 237–247.

Smith T. E., Continuous Spatial Data Analysis, *Notebook for Spatial Data Analysis*, 1st ed., University of Pennsylvania, Philadelphia, 1–33, 2016.

Srinivasan S., Spatial Regression Models, Editors: Shekhar S., Xiong H., Zhou X., *Encyclopedia of GIS*, 1st ed., Springer International Publishing, Boston, MA, 1–6, 2008.

Sunar F., Özkan C., Osmanoğlu B., *Uzaktan Algılama*, Anadolu Üniversitesi, Eskişehir, 2011.

Taşçı İ., Orta Çözünürlüklü Uydu Görüntüleri Kullanarak Yanmış Orman Alanlarının Farklı Sınıflandırma Yöntemleri İle Haritalandırılması, Yüksek Lisans Tezi, Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir, 2018, 509875.

Tat R., Türkiye’de Sektörlere Göre Temel İşgücü Dağılımının İlçe Bazında Yer Seçme Katsayısı (LQ) ve Mekansal İstatistik Yöntemleri İle İncelenmesi, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir, 2008, 244606.

Tosunoğlu N. G., Mekansal İstatistikte Bulanık Uyarlamalı Ağ Yaklaşımı İle Oluşturulan Yerkabuğu Hareket Hızlarının Kestirimi, Doktora Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2007, 213872.

Tuceryan M., Jain A. K., Texture Analysis, Editors: Chen C. H., Pau L. F., Wang P. S. P., *The Handbook of Pattern Recognition and Computer Vision*, 2nd ed., World Scientific Publishing Co., 207–248, 1998.

URL-1:<https://www.mathworks.com/help/images/ref/graycomatrix.html>, (Ziyaret Tarihi: 12 Ekim 2015).

URL-2: Esri, [http://webhelp.esri.com/arcgisdesktop/10.2/index.cfm?id=1905&pid=1904&topicname=Average%20Nearest%20Neighbor%20\(Spatial%20Statistics\)&](http://webhelp.esri.com/arcgisdesktop/10.2/index.cfm?id=1905&pid=1904&topicname=Average%20Nearest%20Neighbor%20(Spatial%20Statistics)&), (Ziyaret Tarihi: 26 Ekim 2015).

URL-3:<https://www.cscrs.itu.edu.tr/assets/downloads/pleiadesuserguide.pdf>, (Ziyaret tarihi: 25 Şubat 2019).

URL-4: Wikipedia, https://en.wikipedia.org/wiki/Support_vector_machine, (Ziyaret Tarihi: 22.11.2018).

Üstüner M., Destek Vektör Makineleri Yöntemi İle Arazi Kullanımı Sınıflandırmasında Kernel Fonksiyonlarına Ait Karşılaştırmalı Parametre Duyarlık Analizi: Rapideye ve SPOT Örneği, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2013, 411514.

Ver Hoef J. M., Peterson E. E., Hooten M. B., Hanks E. M., Fortin M.-J., Spatial Autoregressive Models for Statistical Inference from Ecological Data, *Ecological Monographs*, 2018, **88**(1), 36–59.

Wijaya A., Marpu P. R., Gloaguen R., Geostatistical Texture Classification Of Tropical Rainforest in Indonesia, *Quality Aspect in Spatial Data Mining*, 2008, **1**, 199–210.

Yorulmaz Ö., Dayanıklı Regresyon Yöntemi ve Çeşitli Sosyal Veriler Üzerinde Aykırı Gözlemlerin Tehşisi, *Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 2009, **12**(21), 76–88.

Zeren F., Yurtkur A. K., Türkiye’de Telekomünikasyon Altyapısının Ekonomik Gelişmişliğe Etkisi:Coğrafi Ağırlıklı Regresyon Yöntemi, *Sosyoekonomi*, 2012, **1**, 63–84.





EKLER

Ek-A

Tez Çalışmasında semivaryans ve model parametrelerini elde etmek amacıyla kullanılan “variogramfit” MATLAB fonksiyonu aşağıda verilmiştir.

```
function [a,c,n,S] = variogramfit(h,gammaexp,a0,c0,numobs,varargin)

% fit a theoretical variogram to an experimental variogram
%
% Syntax:
%
%     [a,c,n] = variogramfit(h,gammaexp,a0,c0)
%     [a,c,n] = variogramfit(h,gammaexp,a0,c0,numobs)
%     [a,c,n] = variogramfit(h,gammaexp,a0,c0,numobs,'pn','pv',...)
%     [a,c,n,S] = variogramfit(...)
%
% Description:
%
%     variogramfit performs a least squares fit of various
theoretical
%     variograms to an experimental, isotropic variogram. The user
can
%     choose between various bounded (e.g. spherical) and unbounded
(e.g.
%     exponential) models. A nugget variance can be modelled as
well, but
%     higher nested models are not supported.
%
%     The function works best with the function fminsearchbnd
available on
%     the FEX. You should download it from the File Exchange (File
ID:
%     #8277). If you don't have fminsearchbnd, variogramfit uses
%     fminsearch. The problem with fminsearch is, that it might
return
%     negative variances or ranges.
%
%     The variogram fitting algorithm is in particular sensitive to
initial
%     values below the optimal solution. In case you have no idea
of
%     initial values variogramfit calculates initial values for you
%     (c0 = max(gammaexp); a0 = max(h)*2/3;). If this is a
reasonable
%     guess remains to be answered. Hence, visually inspecting your
data
%     and estimating a theoretical variogram by hand should always
be
%     your first choice.
%
%     Note that for unbounded models, the supplied parameter a0
(range) is
%     the distance where gamma equals 95% of the sill variance. The
%     returned parameter a0, however, is the parameter r in the
model. The
%     range at 95% of the sill variance is then approximately 3*r.
%
```

```

% Input arguments:
%
%     h          lag distance of the experimental variogram
%     gammaexp    experimental variogram values (gamma)
%     a0          initial value (scalar) for range
%     c0          initial value (scalar) for sill variance
%     numobs      number of observations per lag distance (used for
weight
%                  function)
%
% Output arguments:
%
%     a          range
%     c          sill
%     n          nugget (empty if nugget variance is not applied)
%     S          structure array with additional information
%               .range
%               .sill
%               .nugget
%               .model - theoretical variogram
%               .func - anonymous function of variogram model (only
the
%                   function within range for bounded models)
%               .h - distance
%               .gamma - experimental variogram values
%               .gammahat - estimated variogram values
%               .residuals - residuals
%               .Rs - R-square of goodness of fit
%               .weights - weights
%               .exitflag - see fminsearch
%               .algorithm - see fminsearch
%               .funcCount - see fminsearch
%               .iterations - see fminsearch
%               .message - see fminsearch
%
% Property name/property values:
%
%     'model'    a string that defines the function that can be
fitted
%               to the experimental variogram.
%
%               Supported bounded functions are:
%               'bilinear' (bounded linear)
%               'circular' (circular model)
%               'spherical' (spherical model, =default)
%               'pentaspherical' (pentaspherical model)
%
%               Supported unbounded functions are:
%               'exponential' (exponential model)
%               'gaussian' (gaussian variogram)
%               'whittle' Whittle's elementary correlation
(involves a
%                   modified Bessel function of the second
kind.
%                   'stable' (stable models sensu Wackernagel 1995).
Same as
%                   gaussian, but with different exponents.
Supply
%                   the exponent alpha (<2) in an additional
pn,pv

```

```

%                                pair:
%                                'stablealpha',alpha (default = 1.5).
%                                'matern' Matern model. Requires an additional pn,pv
pair.
%                                'nu',nu (shape parameter > 0, default = 1)
%                                Note that for particular values of nu the
matern
%                                model reduces to other authorized
variogram models.
%                                nu = 0.5 : exponential model
%                                nu = 1 : Whittles model
%                                nu -> inf : Gaussian model
%
%                                See Webster and Oliver (2001) for an overview on
variogram
%                                models. See Minasny & McBratney (2005) for an
introduction
%                                to the Matern variogram.
%
%                                'nugget' initial value (scalar) for nugget variance. The
default
%                                value is []. In this case variogramfit doesn't fit
a nugget
%                                variance.
%
%                                'plotit' true (default), false: plot experimental and
theoretical
%                                variogram together.
%
%                                'solver' 'fminsearchbnd' (default) same as fminsearch , but
with
%                                bound constraints by transformation (function by
John
%                                D'Errico, File ID: #8277 on the FEX). The advantage
in
%                                applying fminsearchbnd is that upper and lower
bound
%                                constraints can be applied. That prevents that
nugget
%                                variance or range may become negative.
%                                'fminsearch'
%
%                                'weightfun' 'none' (default). 'cressie85' and 'mcbratney86'
require
%                                you to include the number of observations per
experimental
%                                gamma value (as returned by VARIOGRAM).
%                                'cressie85' uses m(hi)/gammahat(hi)^2 as weights
%                                'mcbratney86' uses
m(hi)*gammaexp(hi)/gammahat(hi)^3
%
%
%
%
% See also: VARIOGRAM, FMINSEARCH, FMINSEARCHBND
%
%
% References: Wackernagel, H. (1995): Multivariate Geostatistics,
Springer.

```

```

% Webster, R., Oliver, M. (2001): Geostatistics for
% Environmental Scientists. Wiley & Sons.
% Minsasny, B., McBratney, A. B. (2005): The Matérn
function as
% general model for soil variograms. Geoderma, 3-4,
192-207.
%
% Date: 7. October, 2010
% Author: Wolfgang Schwanghart (w.schwanghart[at]unibas.ch)

% check input arguments

if nargin == 0
    help variogramfit
    return
elseif nargin>0 && nargin < 2;
    error('Variogramfit:inputargs',...
        'wrong number of input arguments');
end
if ~exist('a0','var') || isempty(a0)
    a0 = max(h)*2/3;
end
if ~exist('c0','var') || isempty(c0)
    c0 = max(gammaexp);
end
if ~exist('numobs','var') || isempty(a0)
    numobs = [];
end

% check input parameters
params.model      = 'spherical';
params.nugget     = [];
params.plotit     = true;
params.solver     = {'fminsearchbnd','fminsearch'};
params.stablealpha = 1.5;
params.weightfun  = {'none','cressie85','mcbratney86'};
params.nu         = 1;
params = parseargs(params,varargin{:});

% check if fminsearchbnd is in the search path
switch lower(params.solver)
case 'fminsearchbnd'
    if ~exist('fminsearchbnd.m','file')==2
        params.solver = 'fminsearch';
        warning('Variogramfit:fminsearchbnd',...
            'fminsearchbnd was not found. fminsearch is used
instead')
    end
end

% check if h and gammaexp are vectors and have the same size
if ~isvector(h) || ~isvector(gammaexp)
    error('Variogramfit:inputargs',...
        'h and gammaexp must be vectors');
end

```

```

% force column vectors
h = h(:);
gammaexp = gammaexp(:);

% check size of supplied vectors
if numel(h) ~= numel(gammaexp)
    error('Variogramfit:inputargs',...
        'h and gammaexp must have same size');
end

% remove nans;
nans = isnan(h) | isnan(gammaexp);
if any(nans);
    h(nans) = [];
    gammaexp(nans) = [];
    if ~isempty(numobs)
        numobs(nans) = [];
    end
end

% check weight inputs
if isempty(numobs);
    params.weightfun = 'none';
end

% create options for fminsearch
options = optimset('MaxFunEvals',1000000,'MaxIter',5000000);

% create vector with initial values
% b(1) range
% b(2) sill
% b(3) nugget if supplied
b0 = [a0 c0 params.nugget];

% variogram function definitions
switch lower(params.model)
    case 'spherical'
        type = 'bounded';
        func = @(b,h)b(2)*((3*h./(2*b(1)))-1/2*(h./b(1)).^3);
    case 'pentaspherical'
        type = 'bounded';
        func = @(b,h)b(2)*(15*h./(8*b(1))-
5/4*(h./b(1)).^3+3/8*(h./b(1)).^5);
    case 'bilinear'
        type = 'bounded';
        func = @(b,h)b(2)*(h./b(1));
    case 'circular'
        type = 'bounded';
        func = @(b,h)b(2)*(1-
(2./pi)*acos(h./b(1))+2*h/(pi*b(1)).*sqrt(1-(h.^2)/(b(1)^2)));
    case 'exponential'
        type = 'unbounded';
        func = @(b,h)b(2)*(1-exp(-h./b(1)));
    case 'gaussian'
        type = 'unbounded';
        func = @(b,h)b(2)*(1-exp(-(h.^2)/(b(1)^2)));
    case 'stable'

```

```

        type = 'unbounded';
        stablealpha = params.stablealpha;
        func = @(b,h)b(2)*(1-exp(-(
(h.^stablealpha)/(b(1)^stablealpha)));
        case 'whittle'
            type = 'unbounded';
            func = @(b,h)b(2)*(1-h/b(1).*besselk(1,h/b(1)));
        case 'matern'
            type = 'unbounded';
            func = @(b,h)b(2)*(1-(1/((2^(params.nu-
1))*gamma(params.nu))) * (h/b(1)).^params.nu .*
besselk(params.nu,h/b(1)));
        otherwise
            error('unknown model')
    end

% check if there are zero distances
% if yes, remove them, since the besselk function returns nan for
% zero
switch lower(params.model)
    case {'whittle','matern'}
        izero = h==0;
        if any(izero)
            flagzerodistances = true;
        else
            flagzerodistances = false;
        end
    otherwise
        flagzerodistances = false;
end

% if model type is unbounded, then the parameter b(1) is r, which
% is
% approximately range/3.
switch type
    case 'unbounded'
        b0(1) = b0(1)/3;
end

% nugget variance
if isempty(params.nugget)
    nugget = false;
    funnugget = @(b) 0;
else
    nugget = true;
    funnugget = @(b) b(3);
end

% generate upper and lower bounds when fminsearchbnd is used
switch lower(params.solver)
    case {'fminsearchbnd'};
        % lower bounds
        lb = zeros(size(b0));
        % upper bounds
        if nugget;
            ub = [inf max(gammaexp) max(gammaexp)]; %

```

```

        else
            ub = [inf max(gammaexp)];
        end
    end

end

% create weights (see Webster and Oliver)
switch params.weightfun
    case 'cressie85'
        weights = @(b,h)
            (numobs./variofun(b,h).^2)./sum(numobs./variofun(b,h).^2);
    case 'mcbratney86'
        weights = @(b,h)
            (numobs.*gammaexp./variofun(b,h).^3)/sum(numobs.*gammaexp./variofun
            (b,h).^3);
    otherwise
        weights = @(b,h) 1;
end

% create objective function: weighted least square
objectfun = @(b) sum(((variofun(b,h)-gammaexp).^2).*weights(b,h));

% call solver
switch lower(params.solver)
    case 'fminsearch'
        % call fminsearch
        [b,fval,exitflag,output] =
            fminsearch(objectfun,b0,options);
    case 'fminsearchbnd'
        % call fminsearchbnd
        [b,fval,exitflag,output] =
            fminsearchbnd(objectfun,b0,lb,ub,options);
    otherwise
        error('Variogramfit:Solver','unknown or unsupported
solver')
end

% prepare output
a = b(1); %range
c = b(2); %sill
if nugget;
    n = b(3); %nugget
else
    n = [];
end

% Create structure array with results
if nargout == 4;
    S.model = lower(params.model); % model
    S.func = func;
    S.type = type;
    switch S.model
        case 'matern';
            S.nu = params.nu;
        case 'stable';
            S.stablealpha = params.stablealpha;
    end
end

```

```

S.range      = a;
S.sill       = c;
S.nugget     = n;
S.h          = h; % distance
S.gamma      = gammaexp; % experimental values
S.gammahat   = variofun(b,h); % estimated values
S.residuals  = gammaexp-S.gammahat; % residuals
COVyhaty     = cov(S.gammahat,gammaexp);
S.Rs         = (COVyhaty(2).^2) ./...
              (var(S.gammahat).*var(gammaexp)); % Rsquare
S.weights    = weights(b,h); %weights
S.weightfun  = params.weightfun;
S.exitflag   = exitflag; % exitflag (see doc fminsearch)
S.algorithm  = output.algorithm;
S.funcCount  = output.funcCount;
S.iterations = output.iterations;
S.message    = output.message;
end

% if you want to plot the results...
if params.plotit
    switch lower(type)
        case 'bounded'
            plot(h,gammaexp,'k.','MarkerSize',6);
            hold on
            fplot(@(h) funnugget(b) + func(b,h),[0 b(1)],'-r')
            fplot(@(h) funnugget(b) + b(2),[b(1) max(h)],'-r')

            case 'unbounded'
                plot(h,gammaexp,'k.','MarkerSize',6);
                hold on
                fplot(@(h) funnugget(b) + func(b,h),[0 max(h)],'-r')
    end
    axis([0 max(h) 0 max(gammaexp)])
    xlabel('lag mesafesi (h)')
    ylabel('\gamma(h)')
    hold off
end

% fitting functions for fminsearch/bnd
function gammahat = variofun(b,h)

    switch type
        % bounded model
        case 'bounded'
            I = h<=b(1);
            gammahat = zeros(size(I));
            gammahat(I) = funnugget(b) + func(b,h(I));
            gammahat(~I) = funnugget(b) + b(2);
        % unbounded model
        case 'unbounded'
            gammahat = funnugget(b) + func(b,h);
            if flagzerodistances
                gammahat(izero) = funnugget(b);
            end
    end
end

```

```

        end
    end
end

end

% subfunction parseargs

function X = parseargs(X,varargin)

%PARSEARGS - Parses name-value pairs
%
% Behaves like setfield, but accepts multiple name-value pairs and
% provides
% some additional features:
% 1) If any field of X is an cell-array of strings, it can only be
% set to
%     one of those strings.  If no value is specified for that
% field, the
%     first string is selected.
% 2) Where the field is not empty, its data type cannot be changed
% 3) Where the field contains a scalar, its size cannot be changed.
%
% X = parseargs(X,name1,value1,name2,value2,...)
%
% Intended for use as an argument parser for functions which
% multiple options.
% Example usage:
%
% function my_function(varargin)
%     X.StartValue = 0;
%     X.StopOnError = false;
%     X.SolverType = {'fixedstep','variablestep'};
%     X.OutputFile = 'out.txt';
%     X = parseargs(X,varargin{:});
%
% Then call (e.g.):
%
% my_function('OutputFile','out2.txt','SolverType','variablestep');

% The various #ok comments below are to stop MLint complaining
% about
% inefficient usage.  In all cases, the inefficient usage (of
% error, getfield,
% setfield and find) is used to ensure compatibility with earlier
% versions
% of MATLAB.

remaining = nargin-1; % number of arguments other than X
count = 1;
fields = fieldnames(X);
modified = zeros(size(fields));
% Take input arguments two at a time until we run out.
while remaining>=2
    fieldname = varargin{count};

```

```

        fieldind = find(strcmp(fieldname,fields));
        if ~isempty(fieldind)
            oldvalue = getfield(X,fieldname); %#ok
            newvalue = varargin{count+1};
            if iscell(oldvalue)
                % Cell arrays must contain strings, and the new value
must be
                % a string which appears in the list.
                if ~iscellstr(oldvalue)
                    error(sprintf('All allowed values for "%s" must be
strings',fieldname)); %#ok
                end
                if ~ischar(newvalue)
                    error(sprintf('New value for "%s" must be a
string',fieldname)); %#ok
                end
                if isempty(find(strcmp(oldvalue,newvalue))) %#ok
                    error(sprintf('"%s" is not allowed for field
"%s"',newvalue,fieldname)); %#ok
                end
                elseif ~isempty(oldvalue)
                    % The caller isn't allowed to change the data type of a
non-empty property,
                    % and scalars must remain as scalars.
                    if ~strcmp(class(oldvalue),class(newvalue))
                        error(sprintf('Cannot change class of field "%s"
from "%s" to "%s"',...
                                fieldname,class(oldvalue),class(newvalue)));
                        %#ok
                    elseif numel(oldvalue)==1 & numel(newvalue)~=1 %#ok
                        error(sprintf('New value for "%s" must be a
scalar',fieldname)); %#ok
                    end
                end
                X = setfield(X,fieldname,newvalue); %#ok
                modified(fieldind) = 1;
            else
                error(['Not a valid field name: ' fieldname]);
            end
            remaining = remaining - 2;
            count = count + 2;
        end
        % Check that we had a value for every name.
        if remaining~=0
            error('Odd number of arguments supplied. Name-value pairs
required');
        end

        % Now find cell arrays which were not modified by the above
process, and select
        % the first string.
        notmodified = find(~modified);
        for i=1:length(notmodified)
            fieldname = fields{notmodified(i)};
            oldvalue = getfield(X,fieldname); %#ok
            if iscell(oldvalue)
                if ~iscellstr(oldvalue)
                    error(sprintf('All allowed values for "%s" must be
strings',fieldname)); %#ok
                elseif isempty(oldvalue)

```

```
        error(sprintf('Empty cell array not allowed for field  
"%s"',fieldname)); %#ok  
    end  
    X = setfield(X,fieldname,oldvalue{1}); %#ok  
end  
end  
end
```



Ek-B

Benzerlik ölçütlerine ait MATLAB kodları aşağıda verilmiştir.

```
% ÖKLİD MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Oklid_Msf{i,j} = sqrt(sum((P-Q).^2));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

% CHEBYSHEV MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Chebyshev{i,j} = max(abs(P-Q));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

% CITY BLOCK MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        City_Block{i,j} = sum(abs(P-Q));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end
```

```

% MINKOWSKI MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(windowsize-1)),b:(b+(windowsize-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Minkowski{i,j}= (sum(abs(P-Q).^n)).^(1/n);

    b=b+komsuluk;
end
a=a+komsuluk;
b=1;
end

% CHI-KARE MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));
        f = ((P-Q).^2)./(P+Q);
        f(isnan(f) | isinf(f)) = 0;
        Squ_chi{i,j}= sum(f);

    b=b+komsuluk;
end
a=a+komsuluk;
b=1;
end

% KULLBACK-LEIBLER MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));P(P==0) = eps;
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));
        Q(Q==0) = eps;
        Kull_Lieb{i,j} = sum(log(P./Q) .* P);

    b=b+komsuluk;
end
a=a+komsuluk;
b=1;
end

```

```

% JEFFREY MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Jeff_Msf{i,j} = dist_jeffrey (P,Q);

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

% KOLMOGOROV-SMIRNOV (DIVERGENCE) MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        f = (((P-Q).^2)./((P+Q).^2));
        f(isnan(f) | isinf(f)) = 0;
        Divergence{i,j} = 2 * sum(f);

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

% BRAY-CURTIS (SORENSEN) MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Sorensen{i,j} = sum(abs(P-Q))/sum(P+Q);

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

```

```

% KOSİNÜS MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Kosinus{i,j}= 1-(dot(P,Q)/(norm(P)*norm(Q)));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

% KORELASYON MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        korelasyon = corrcoef(P,Q);
        Korelasyon{i,j}= korelasyon(1,2);

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

% DICE MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Dice{i,j} = sum((P-Q).^2) / ((sum(P.^2))+(sum(Q.^2)));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

```

```

% BHATTACHARYYA MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Bhattacharyya{i,j} = sqrt(1-(sum(sqrt(P.*Q))));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

% FIDELITY MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        f = sum(sqrt(P.*Q));
        f = 1- f;
        Fidelity{i,j} = f;

        f=[];
        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

% GOWER MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Gower{i,j} = (1/256)* sum(abs(P-Q));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

```

```

% SOERGEL MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Soergel{i,j} = sum(abs(P-Q)) / sum (max(P,Q));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

% JACCARD MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Jaccard{i,j} = sum((P-Q).^2)/((sum(P.^2))+(sum(Q.^2))-
dot(P,Q));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

% TANIMOTO MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-
1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Tanimoto{i,j} = sum(max(P,Q) - min(P,Q))/sum(max(P,Q));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

```

```

% MATUSITA MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Matusita{i,j} = sqrt(2-2*sum(sqrt(P.*Q)));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end
% TOPSOE MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));P(P==0) = eps;
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Q(Q==0) = eps;
        Topsoe{i,j}= sum((log((2*P)./(P+Q)).* P)+(log((2*Q)./(P+Q)).* Q));

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end
% JENSEN-SHANNON MESAFESİ
a=1;b=1;
komsuluk=1;
[satır_G,sutun_G]=size(G);
P=hist(ornek_bolge)/sum(hist(ornek_bolge));P(P==0) = eps;
for i=1:komsuluk:(satır_G-(pencere_boyutu-1))
    for j=1:komsuluk:(sutun_G-(pencere_boyutu-1))
        G_pencere = G(a:(a+(pencere_boyutu-1)),b:(b+(pencere_boyutu-1)));
        Q=imhist(G_pencere)/sum(imhist(G_pencere));

        Q(Q==0) = eps;
        f = (log((2*P)./(P+Q)).* P)+(log((2*Q)./(P+Q)).* Q);
        Jensen_Sha{i,j} = 0.5 * sum(f);

        b=b+komsuluk;
    end
    a=a+komsuluk;
    b=1;
end

```

KİŞİSEL YAYIN VE ESERLER

Akyürek Ö., Arslan O., Karademir A., SO₂ ve PM₁₀ Hava Kirliliği Parametrelerinin CBS ile Konumsal Analizi: Kocaeli Örneği, *TMMOB 4. Coğrafi Bilgi Sistemleri Kongresi*, Ankara, 11-13 Kasım 2013.

Arslan O., **Akyürek Ö.**, LANDSAT 7 ETM+ Görüntüleri Üzerinden Çizgiselliklerin Otomatik Çıkarımı ve Analizi: Van Depremi Örneği, *International 5th Earthquake Symposium*, Kocaeli, 10-12 Haziran 2015.

Arslan O., **Akyürek Ö.**, Spatial Modelling of Air Pollution Concentrations with a Spatial Autoregressive Model A Case Study in Canakkale City, *International Symposium on GIS Applications in Geography & Geosciences*, Çanakkale, 18-21 Ekim 2017.

Arslan O., **Akyürek Ö.**, Spatio-temporal Analysis of Historical Earthquakes in Ayvacik Region in Canakkale city with GIS, *International Symposium on GIS Applications in Geography & Geosciences*, Çanakkale, 18-21 Ekim 2017.

Arslan O., **Akyürek Ö.**, Kaya Ş., A comparative analysis of classification methods for hyperspectral images generated with conventional dimension reduction methods, *Turkish Journal of Electrical Engineering & Computer Sciences*, 2017, **25**, 58-72.

Arslan O., **Akyürek Ö.**, Kaya Ş., Şeker D. Z., Dimension Reduction Methods Applied to Coastline Extraction on Hyperspectral Imagery, *Geocarto International*, 2018.

Akyürek Ö., Arslan O., Kocaeli İli ve Çevresinde (1900-2016) Yılları Arasında Gerçekleşen Tarihsel Depremlerin Konumsal İstatistik Analizi, *Geomatik Dergisi*, 2018, **3(1)**, 48-62.

Arslan O., **Akyürek Ö.**, Spatial Modelling of Air Pollution from PM10 and SO2 concentrations during Winter Season in Marmara Region (2013-2014), *International Journal of Environment and Geoinformatics (IJEgeo)*, 2018, **5(1)**, 1-16.

Akyürek Ö., The Spatial Analysis of Air Pollution Parameters (PM10, SO2 and NO2): A Case Study of the Marmara Region (2014-2017), *Advances in Health and Natural Sciences*, ISBN: 978-1-53614-639-4.

ÖZGEÇMİŞ

Özer AKYÜREK, 1985 yılında Edirne/Uzunköprü’de doğdu. İlk, Orta ve Lise öğrenimini Keşan/Edirne’de tamamladı. 2004 yılında Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Jeodezi ve Fotogrametri Mühendisliği Bölümü’ne başladıktan sonra 2009 yılında mezun oldu. 2009 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalında başladığı Yüksek Lisans eğitimini, 2012 yılında Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Jeodezi ve Jeoinformasyon Mühendisliği Anabilim Dalında “Hiperspektral Görüntülerde Boyut İndirgeme Yöntemlerinin Karşılaştırmalı Analizi” başlıklı Yüksek Lisans tezini tamamlayarak Yüksek Mühendis ünvanı ile mezun oldu. 2012 yılında başlamış olduğu Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Jeodezi ve Jeoinformasyon Mühendisliği Anabilim Dalındaki doktora çalışmasını “Uzaktan Algılama Görüntülerinde Konumsal Doku Analizi” başlığı altında sürdürmektedir. Ayrıca, 2009 yılında Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Jeodezi ve Jeoinformasyon Mühendisliği Anabilim Dalında Araştırma görevlisi olarak çalışmaya başladı ve halen Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Uzaktan Algılama Anabilim Dalında Araştırma Görevlisi olarak görev yapmaktadır.