

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**UZAKTAN ALGILAMA VE COĞRAFI BİLGİ SİSTEMİ YARDIMI İLE
ORTALAMA KAYDIRMA, ÇOKLU ÇÖZÜNÜRLÜKLÜ BÖLÜTLEME VE
KMAENS TEKNİĞİ İLE KARAYOLUNDAKİ ARAÇLARIN TESPİTİ**

Mustafa KAYNARCA

FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA VE COĞRAFI BİLGİ SİSTEMLERİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

OCAK 2019

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMİ YARDIMI İLE
ORTALAMA KAYDIRMA, ÇOKLU ÇÖZÜNÜRLÜKLÜ BÖLÜTLEME VE
KMAENS TEKNİĞİ İLE KARAYOLUNDAKİ ARAÇLARIN TESPİTİ**

Mustafa KAYNARCA

FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

OCAK 2019

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMİ YARDIMI İLE
ORTALAMA KAYDIRMA, ÇOKLU ÇÖZÜNÜRLÜKLÜ BÖLÜTLEME VE
KMEANS TEKNİĞİ İLE KARAYOLUNDAKİ ARAÇLARIN TESPİTİ

Mustafa KAYNARCA


UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Bu tez 18/01/2019 tarihinde jüri tarafından Oybirliği / Oyçokluğu ile kabul edilmiştir.

Dr. Öğr. Üyesi Nusret DEMİR (Danışman)

Doç Dr. Dilek KOÇ SAN

Dr. Öğr. Üyesi Uğur ACAR



ÖZET

UZAKTAN ALGILAMA VE COĞRAFI BİLGİ SİSTEMİ YARDIMI İLE ORTALAMA KAYDIRMA, ÇOKLU ÇÖZÜNÜRLÜKLÜ BÖLÜTLEME VE KMAENS TEKNİĞİ İLE KARAYOLUNDAKİ ARAÇLARIN TESPİTİ

Mustafa KAYNARCA

Yüksek Lisans, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Nusret DEMİR

Ocak 2019; 52 sayfa

Dünyada kentleşmenin hızlı bir şekilde artması ile beraber kentleri ve yerleşim alanlarının birbiri ile bağlantısının sağlanması hayati hale gelmiştir. Karayolları, yerleşim alanlarını birbirine bağlayan üst yapılardır. Yollar artan nüfusa cevap vermek için yoğun şekilde kullanılmaktadır. Yollar, bu nedenle yenilenmekte ve büyütülmektedirler. Yerleşim yerlerindeki iyi ulaşım, yolların sağlıklı işlemesi ve kullanılmasına bağlıdır.

Ülkemizde kentleşmenin artması ile birçok büyükşehir oluşmakta ve bu şehirler ve yerleşimler arasındaki karayolu ulaşım bağlantısı, yolcu taşıma, lojistik faaliyeti hayati öneme sahip olmaktadır. Kentleşmede ve kent planlamada en önemli bileşenlerden biride karayollarıdır. Trafik ise karayollarının planlanması ve yapımında en önemli kriterlerden biridir.

Trafik, karayolları trafik kanununda, yaya, hayvan ve araçların karayolları üzerindeki tüm hareketleri olarak tanımlanmıştır. Araçlar ise trafiğin en önemli bileşenidir. Trafik son yıllarda özellikle birçok büyükşehir ve yerleşim alanlarında en önemli sorunlardan biri haline gelmiştir. Bu nedenlerle dünyada ve ülkemizde karayolu yatırımları çok önemli miktarlara ulaşmıştır. Kent ve ulaşım planlamalarında sağlıklı kararlar almak için birçok alanda Uzaktan Algılama ve Coğrafi Bilgi Sistemleri kullanılmaktadır.

Bu çalışmada karayolunda bulunan araçların herkes tarafından ulaşılabilir veri kaynakları ile tespit edilmesi amaçlanmıştır. Google harita, Yandex harita Bing harita gibi veri kaynaklarına herkesin ulaşması mümkündür. Bu veriler yön bulma, harita oluşturma gibi alanlarda kullanılmakta ve belirli aralıklarla güncellenmektedir. Çalışmada uzaktan algılama tekniklerinden olan ve belirli özellikler taşıyan objelerin gruplandırılması ilkesine dayanan bölütleme işlemleri uygulanarak araçların tespiti hedeflenmiştir. Bölütleme yöntemlerinden, ortalama kaydırma ve nesne tabanlı çoklu çözünürlüklü yöntemler uygulanmıştır. Bu iki yöntemin haricinde kontrolsüz sınıflandırma yapılmış ve bölütleme sonuçları ile karşılaştırılmıştır. Çalışmada bazı CBS teknikleri yardımı ile yapılan düzenlemenin ardından doğruluk analizi yapılarak çalışma tamamlanmıştır. Sonuç olarak %80 doğruluk ile karayolunda yer alan araçların tespit edildiği hesaplanmıştır.

ANAHTAR KELİMELER: Coğrafi Bilgi Sistemleri, Uzaktan Algılama, Trafik, Karayolu, Bölütleme, Araç tespiti.

JÜRİ: Dr. Öğr. Üyesi Nusret DEMİR (Danışman)

Doç Dr. Dilek KOÇ SAN

Dr. Öğr. Üyesi Uğur ACAR

ABSTRACT

DETERMINATION OF VEHICLE WITH REMOTE SENSING AND GEOGRAPHIC INFORMATION SYSTEM IN THE HIGHWAY WITH MEANSHIFT, MULTI RESOLUTION SEGMENTATION AND KMEANS TECHNIQUE

Mustafa KAYNARCA

MSc / PhD Thesis in Remote Sensing and Geographical Information Systems

Supervisor: Asst. Prof. Dr. Nusret DEMİR

January 2019; 52 pages

Urbanization increase rapidly in the world, cities and urban areas connection with each other is so vital important subject. Highways connect residential area with other where. Roads respond to increasing intensive population. For this reasons they are renewed and enlarged. A good transportation in urban area depends on the healthy operation and use of roads.

In our country, increase of urbanization, many metropolitan cities are formed and the transportation between these metropolitan cities and settlements is vital. Highways are one of the most important components in urbanization and urban planning. Traffic is a very important criterion for planning and construction.

Traffic is defined as the traffic law of highways and all movements of pedestrians, animals and vehicles on highways. Vehicle is most important component to traffic. Traffic has become one of the most important problems especially in many metropolitan and residential areas in recent years. For this reasons highway investment reach very much value. Geographic information systems and remote sensing are used urban and transporting planning.

In this study, it is aimed to determine the vehicles on road by means of accessible data sources. Google maps, Yandex maps, Bing maps exc. data source accessible from everyone. These data are used in areas such as navigation, mapping, and updated at regular intervals. The aim of the study is to determine the tools by applying the segmentation procedures based on the principle of grouping of objects with certain features which are remote sensing techniques. The methods of segmentation, mean shift and object-based multi-resolution methods were applied. In addition to these two methods, uncontrolled classification was made and compared with the results of segmentation. The study was completed with the help of some GIS techniques. As a result, it was calculated that road vehicles were detected with 80% accuracy.

KEYWORDS: Geographical Information Systems, Remote Sensing, Traffic, Highway, Segmentation, Vehicle detection

COMMITTEE: Asst. Prof. Dr. Nusret DEMİR (Supervisor)

Assoc. Prof. Dr. Dilek KOÇ SAN

Asst. Prof. Dr. Uğur ACAR

ÖNSÖZ

Gerek ülkemizde gerekse dünyada nüfus artışı, çarpık kentleşme, kaynakların sınırlı hale gelmesi küresel ekolojik sorunları olarak karşımıza çıkmaktadır. Son yıllarda özellikle birçok büyükşehir ve yerleşim alanlarında en önemli sorunlardan biri trafiktir. Artan nüfus ve kentleşme beraberinde trafiği önemli bir sorun olarak karşımıza çıkarmaktadır. Trafik sorununun çözümü ve karayolunda kısa ve güvenli seyahatin sağlanması için gerek dünyada gerekse ülkemizde karayolu yatırımları çok önemli miktarlara ulaşmıştır. Ülkemizde yapılan ve yapımı deva eden köprüler, çift şeritli yollar, geçitler bunlardan bazılarıdır. Bu yapılar ulaşım süresini kısaltarak kaza riskini asgariye indirilmektedir. Kent ve ulaşım planlamalarında sağlıklı kararlar almak için birçok alanda Uzaktan Algılama (UA) ve Coğrafi Bilgi Sistemleri (CBS) kullanılmaktadır. Bu çalışmada da UA ve CBS teknikleri ile karayolunda bulunan araçların ulaşılabilir veri kaynakları ile tespit edilmesi amaçlanmıştır.

Yapılan çalışmada hızlı bir şekilde farklı araçların tespiti, sayılması ve çeşitliliği araştırmaktadır. Bu şekilde hem karayolu projeleri, hem de kent ve imar planlarında karar verme yetisi ve hızı artmakta ve yol planlamasında hata riski asgari düzeye indirilmektedir. Çalışmada karşılaştırmalı farklı teknikler kullanılarak araçların tespiti çalışmayı özgünleştirmektedir. Çalışmanın; Karayolları, Belediyeler gibi kamu kurumları ile karayolu mühendisliği firmalarında kullanılabilir nitelikte olması öngörülmektedir.

Bu çalışmanın hazırlanması sırasında bana büyük emek harcayan danışmanım Sayın Dr. Öğr. Üyesi Nusret DEMİR'e sonsuz teşekkürlerimi sunarım.

Çalışmamdaki katkılarından dolayı Akdeniz Üniversitesi Uzaktan Algılama Araştırma ve Uygulama Merkezi (AKUZAL) personelleri ve eşim Safiye KAYNARCA'ya teşekkürlerimi sunarım.


İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
ÖNSÖZ.....	v
AKADEMİK BEYAN	viii
SİMGELER VE KISALTMALAR	ix
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ	xii
1. GİRİŞ	1
1.1. Coğrafi Bilgi Sistemleri ve Uzaktan Algılama.....	3
1.1.1. Coğrafi bilgi sistemleri.....	3
1.1.2. Uzaktan algılama.....	4
1.1.3. Sınıflandırma ve bölütleme.....	5
1.2. Çalışma Alanı.....	7
2. KAYNAK TARAMASI.....	9
3. MATERYAL VE METOT.....	12
3.1. Materyal	12
3.2. Metot ve Uygulama	15
3.3. Ön İşlemler.....	16
3.3.1. Jeoreferanslama.....	16
3.3.2. Kesme.....	17
3.3.3. Yoğunluk/Intensity görüntü.....	18
3.3.4. Filtreleme.....	18
3.3.4.a. Medyan filtre.....	19
3.3.4.b. Ortama kaydırma yumuşatma filtre.....	20
3.4. Bölütleme.....	22
3.4.1. Ortama kaydırma bölütleme.....	22
3.4.1.a. Raster yeniden sınıflama fonksiyonu.....	26

3.4.1.b. Raster çıkarma fonksiyonu	27
3.4.1.c. Raster hesablama fonksiyonu	28
3.4.1.ç. Vektör veri üretim.....	29
3.4.1.d. En küçük sınır geometri fonksiyonu	29
3.4.2. Obje tabanlı/Çoklu çözünürlüklü bölütleme.....	30
3.4.2.a.Çoklu çözünürlüklü bölütleme parametreleri.....	31
3.4.2.b.En küçük sınır geometri fonksiyonu	33
3.4.2.c.Kaynaştırma fonksiyonu.....	34
3.4.3. Kontrolsüz sınıflandırma/Kmeans algoritması.....	35
3.4.3.a. En küçük sınır geometri fonksiyonu	38
3.5. Araç bölütlerinin ebatlarına göre seçilme kriterleri.....	39
4. BULGULAR VE TARTIŞMA.....	40
4.1. Ortama kaydırma bölütleme sonuçları ve doğruluk analizi.....	40
4.2. Obje tabanlı bölütleme sonuçları ve doğruluk analizi.....	42
4.3. Kmeans kontrolsüz sınıflandırma sonuçları ve doğruluk analizi.....	44
4.4. Doğruluk yüzdeleri.....	46
5. SONUÇLAR	47
6. KAYNAKLAR.....	49
ÖZGEÇMİŞ	

AKADEMİK BEYAN

Yüksek Lisans tezi olarak sunduğum “Uzaktan Algılama ve Coğrafi Bilgi Sistemi Yardımı ile Ortalama Kaydırma, Çoklu Çözünürlüklü Bölütleme ve KMeans Tekniği ile Karayolundaki Araçların Tespiti “ adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

18/01/2019

Mustafa KAYNARCA

SİMGELER VE KISALTMALAR

Simgeler

m ²	: Metrekare
m	: Metre
a	: Alan
g	: Genişlik
u	: Uzunluk
h	: Pencere genişliği.
d	: Aralık.
k	: Toplam eleman sayısı

“01.01” Ondalık Ayırıcı

Kisaltmalar

AÜ	: Akdeniz Üniversitesi
AKUZAL	: Akdeniz Üniversitesi Uzaktan Algılama ve Uygulama Merkezi
CBS	: Coğrafi Bilgi Sistemleri
UA	: Uzaktan Algılama
TÜİK	: Türkiye İstatistik Kurumu.
RADAR	: Radio Detection and Ranging (Radyo dalgası tespiti ve menzil ölçme)
LİDAR	: Light Detection and Ranging (Işık tespiti ve menzil ölçme)
SVM	: Support Vector Machine (Destek vektör makinesi)
RMSE	: Root Mean Square Error (Ortalam karesel hata)
KYM	: Kırmızı Yeşil Mavi
İBB	: İstanbul Büyükşehir Belediyesi
TUFUAB	: Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği
ISPRS	: International Societyt for Photogrammetry and Remote Sensing
KGM	: Karayolları Genel Müdürlüğü

ŞEKİLLER DİZİNİ

Şekil 1.1. Coğrafi Bilgi Sistemleri yapısı	4
Şekil 1.2. Elektromanyetik spektrum.....	5
Şekil 1.3. Piksel tabanlı sınıflandırma gösterimi	5
Şekil 1.4. Nesne tabanlı bölütleme karayolu örneği.....	6
Şekil 1.5. Çalışma alanı genel görünümü.....	7
Şekil 1.6. Birinci çalışma bölgesi 15 Temmuz Şehitler Köprüsü Girişi.....	8
Şekil 1.7. İkinci çalışma bölgesi E-5 Karayolu Atatürk Havalimanı Girişi.....	8
Şekil 3.1. E-5 Karayolu çalışma alanı Google Earth görüntüsü örneği.....	13
Şekil 3.2. D 100 Karayolu çalışma alanı Google Earth görüntüsü örneği.....	13
Şekil 3.3. Temel işlem adımları.....	15
Şekil 3.4. Jeoreferanslama uygulaması ve referans noktalar.....	16
Şekil 3.5. Jeoreferanslama uygulaması sonuçları.....	16
Şekil 3.6. a) Tüm görüntü, b) Kesilmiş görüntü.....	17
Şekil 3.7. Medyan filtre çalışma prensibi gösterimi.....	19
Şekil 3.8. Orfeotoolbox meanshift smooting çalışma ekranı.....	20
Şekil 3.9. Çalışmada kullanılan görüntü ve filtre sonuçları; a) KMY görüntü; b) yoğunluk görüntüsü; c) medyan filtre uygulanmış görüntü; d) meanshift smooting filtre\uygulanmış\görüntü	21
Şekil 3.10. Ortalama kaydırma /mean shift algoritması gösterimi.....	23
Şekil 3.11. Ortalama kaydırma bölütleme sonucu ve gerçek görüntü.....	26
Şekil 3.12. Reclass fonksiyonu ile yeniden değer verilen raster görüntüsü ve tablosu....	27
Şekil 3.13. Çıkarma (Extraction) fonksiyonu uygulanmış görüntü.....	28
Şekil 3.14. Raster hesaplayıcı/ calculater fonksiyonu sonucu.....	28
Şekil 3.15. Ortalama kaydırma raster veriden vektörel veri üretimi.....	29
Şekil 3.16. Ortalama kaydırma bölütleme en küçük sınır geometrisi fonksiyonu uygulaması.....	30
Şekil 3.17. Nesne tabanlı bölütleme ile yerleşim alanında yapılan bir örnek.....	31
Şekil 3.18. Nesne tabanlı bölütleme yazılım ekranı ve parametreleri.....	33
Şekil 3.19. Nesne tabanlı bölütleme en küçük çevreleyen geometri fonksiyonu sonucu.....	34
Şekil 3.20. Kaynaştırma ve birleştirme fonksiyonu gösterimi	34

Şekil 3.21. KMeans algoritması çalışma ekranı.....	35
Şekil 3.22. KMeans sınıflandırma parametreleri a) iterasyon sayısı 1 b) iterasyon sayısı 5.....	36
Şekil 3.23. KMeans algoritması sınıflandırma sonucu.....	37
Şekil 3.24. KMeans algoritması araçobjeleri raster verisi.....	37
Şekil 3.25. KMeans algoritması ile vektörel veri üretim ve en küçük sınır geometrisi fonksiyonu sonucu.....	38
Şekil 3.26. Trafik yönetmeliğine göre azami araç uzunlukları.....	39
Şekil 3.27. Kullanılan yöntemlerin sonuçlarının ekran görüntüsü.....	48

ÇİZELGELER DİZİNİ

Çizelge 1.1. Trafikte yer alan araç sayılarının ve türlere ve yıllara göre dağılımı.....	1
Çizelge 1.2. Karayollarının türlerine göre uzunlukları.....	2
Çizelge 3.1. Çalışmada kullanılan intensity görüntülerin spektral özellikleri	12
Çizelge 3.2. Ortalama kaydırma bölütleme kullanılan parametreler	25
Çizelge 3.3. Nesne tabanlı segmenatasyonda kullanılan parametreler ve bölüt sayıları.....	32
Çizelge 3.4. Araç ebatlarına göre seçim kriterleri.....	39
Çizelge 4.1. \Ortalama\kaydırma\bölütleme sonuçları.....	40
Çizelge 4.2 Ortalama kaydırma bölütleme kesişim (overlay) analizi.....	41
Çizelge 4.3. Ortalama kaydırma bölütleme yöntemi doğruluk analizi sonuçları.....	41
Çizelge 4.4. Nesne tabanlı bölütleme ile üretilen bölüt sayıları.....	42
Çizelge 4.5. Nesne tabanlı bölütleme kesişim (overlay) analizi sonuçları.....	42
Çizelge 4.6. Nesne tabanlı bölütleme doğruluk analizi sonuçları.....	43
Çizelge 4.7 KMeans algoritması ile üretilen bölüt sayıları.....	44
Çizelge 4.8. KMeans sınıflandırması kesişim (overlay) analizi sonuçları.....	44
Çizelge 4.9. KMeans algoritması sınıflandırma doğruluk analizi sonuçları.....	45
Çizelge 4.10. Kullanılan tüm yöntemlerin doğruluk yüzdeleri.....	46

1. GİRİŞ

Kent planlama, imar, altyapı, karayolu planlama uygulamalarından en önemli bileşenlerden biri de trafiktir. Gerek planlamada gerekse uygulamada mevcut trafik yoğunluğunun ve trafikte yer alan araçların tespiti en önemli parametrelerden biridir. Trafik, imar ve kent planlamasında önemli bir girdi olmasının yanı sıra yoğun kentleşmede en önemli sorunlardan biridir. Bu sorunun azaltılması amacı ile ülkemizde de çok büyük ve önemli yatırımlar yapıldığı görülmektedir. Boğaz köprüleri, tüneller, tüp geçitler, çift yönlü yollar örnek olarak sayılabilir. Bu çalışma ve yatırımlarda ulaşılması kolay veriler ile Uzaktan Algılama (UA) ve Coğrafi Bilgi Sistemleri (CBS) teknikleri kullanarak araçların sayılması ve sınıflandırılması mümkün olabilmektedir. Yapılan proje ve çalışmalarda en önemli girdilerden birisi araç sayısı ve türü tespitidir. Araç tespiti akıllı trafik yönetiminin en çok ihtiyaç duyduğu veridir. (Hinz vd. 2003) Bu veri bizlere trafik yoğunluğu ve yükünü belirlemede hızlı ve kontrollü bir veri sağlayacaktır. Böylece karar destek sistemleri hızlı ve güvenilir veriler üzerinde işlem yapabileceklerdir Araç ve trafik yoğunluğunun artması beraberinde sorun olan bölgede teknik, idari ve nihayet mali çalışma gerektirmektedir. Trafikte araç yoğunluğunun kestirilmesinin yanı sıra araç sayısı ve türü tespiti trafik yükü karayolu mühendisliği, çevreyle ilgili çalışmalar açısından önemli bir girdi niteliğindedir.

Ülkemizde trafikte 22.325.033 adet araç olup, trafikte yer alan araçların türlere ve yıllara göre dağılımı Çizelge 1.1'de verilmiştir. (TUIK 2018). Ülkemizin nüfusunun 80.810.525 kişi olduğu göz önüne alınırsa 4 kişiye bir araç düşmektedir. Bu durum kentlerde çok ciddi bir trafik problemi ve buna bağlı altyapı sorunlarını beraberinde getirmektedir (TUIK 2018).

Çizelge 1.1. Trafikte yer alan araç sayılarının türlere ve yıllara göre dağılımı (TUIK 2018)

Motorlu kara taşıt sayısı										
Number of road motor vehicles										
								Özel	Yol ve iş	
								amaçlı	makinaları	
								taşıtlar	Road	
								Special	construction	
Yıl	Toplam	Otomobil	Minibüs	Otobüs	Kamyonet	Kamyon	Motosiklet	purpose	and work	Traktör
Year	Total	Car	Minibus	Bus	Small truck	Truck	Motorcycle	vehicles	machinery	Tractor
2008	13 765 395	6 796 629	383 548	199 934	2 066 007	744 217	2 181 383	35 100	..(1)	1 358 577
2009	14 316 700	7 093 964	384 053	201 033	2 204 951	727 302	2 303 261	34 104	..(1)	1 268 032
2010	15 095 603	7 544 871	386 973	208 510	2 399 038	726 359	2 389 488	35 492	..(1)	1 404 872
2011	16 089 528	8 113 111	389 435	219 906	2 611 104	728 458	2 527 190	34 116	..(1)	1 466 208
2012	17 033 413	8 648 875	396 119	235 949	2 794 606	751 650	2 657 722	33 071	..(1)	1 515 421
2013	17 939 447	9 283 923	421 848	219 885	2 933 050	755 950	2 722 826	36 148	..(1)	1 565 817
2014	18 828 721	9 857 915	427 264	211 200	3 062 479	773 728	2 828 466	40 731	..(1)	1 626 938
2015	19 994 472	10 589 337	449 213	217 056	3 255 299	804 319	2 938 364	45 732	..(1)	1 695 152
2016	21 090 424	11 317 998	463 933	220 361	3 442 483	825 334	3 003 733	50 818	..(1)	1 765 764
2017	22 218 945	12 035 978	478 618	221 885	3 642 625	838 718	3 102 800	60 099	..(1)	1 838 222
2018 ⁽¹⁾	22 325 033	12 106 678	480 061	221 792	3 666 584	841 226	3 105 283	60 746	..(1)	1 842 663
Kaynak: Emniyet Genel Müdürlüğü										
Source: General Directorate of Public Security (1) Veriler Ocak ayı sonu itibarıyla. (1) Data is by the end of January.										

Bilindiği üzere nüfus artışına paralel olarak karayolunda bulunan araç sayısı hızla artmaktadır. Farklı tür ve uzunlukta yollar yapılmaktadır. Karayollarının türlerine göre uzunlukları Çizelge 1.2’de verilmiştir. Yıllar içinde bölünmüş yolların arttığı görülmektedir. Bu durum bazı sorunları da beraberinde getirmektedir. Bunlar araçların ekonomik maliyetleri, yakıt, karayollarında yapılan harcamamalar (imalat, bakım onarım vb), trafik kazaları, zaman ve işgücü kaybı, ekolojik etkiler olarak sayılabilir. Karayolları ve ulaşım yolları ile ilgili yapılan projeler ve bu projelerin hayata geçmesi için çok önemli bütçe imkânları kullanılmaktadır. Karayollarının merkezi bütçeden payı %2.36 dır. Bunun karşılığı 18.104263,00 TL dir (KGM 2018).

Çizelge 1.2. Karayollarının türlerine göre uzunlukları (TUIK 2018)

Karayolu uzunlukları									
Road lengths									
Yıl	Genel Toplam	Toplam		Devlet yolu		İl yolu		Otoyol	Köy yolu
Year	General Total	Bölünmüş Divided road	Diğer Other	Bölünmüş Divided road	Diğer Other	Bölünmüş Divided road	Diğer Other	Motorways	Village road
1995	381 297	3 659	57 583	2 185	29 237	231	28 346	1 243	320 055
1996	381 637	3 956	57 670	2 301	29 111	263	28 560	1 411	320 001
1997	381 759	4 222	58 099	2 450	28 870	302	29 219	1 470	319 448
1998	380 293	4 798	57 715	2 821	28 524	349	29 191	1 628	317 780
1999	384 382	5 035	57 527	3 027	28 361	369	29 166	1 639	321 920
2000	417 406	5 597	57 227	3 424	27 973	439	29 254	1 674	354 642
2001	426 249	5 821	57 180	3 673	27 703	451	29 478	1 698	363 248
2002	427 411	6 040	57 042	3 659	27 459	467	29 583	1 714	364 329
2003	428 415	7 200	56 044	4 925	26 432	521	29 612	1 753	365 171
2004	349 215	8 972	54 604	6 735	24 711	675	29 793	1 662	285 739
2005	349 238	10 178	53 428	7 917	23 454	594	29 974	1 667	285 632
2006	349 304	11 665	51 987	9 135	22 200	542	29 787	1 908	285 632
2007	350 708	12 973	50 847	10 367	20 946	678	29 901	1 908	286 888
2008	351 958	14 458	49 487	11 747	19 584	789	29 923	1 922	288 013
2009	362 660	16 494	47 761	13 606	17 665	852	30 066	2 036	298 405
2010	367 263	18 363	46 002	15 788	15 607	996	30 394	2 080	302 398
2011	370 276	20 273	44 778	17 033	14 339	1 122	30 438	2 119	305 227
2012	385 748	21 193	44 189	17 886	13 489	1 181	30 699	2 127	320 366
2013	388 783	22 079	43 661	18 524	12 817	1 311	30 844	2 244	323 043
2014	236 794	22 563	43 448	18 944	12 336	1 351	31 113	2 278	170 762
2015	238 899	23 107	43 453	19 357	11 856	1 467	31 598	2 282	172 339
2016	242 590	23 831	43 330	19 790	11 316	1 499	32 014	2 542	175 428
Kaynak: Karayolları Genel Müdürlüğü, Mahalli İdareler Genel Müdürlüğü									
Source: General Directorate of Highways, General Directorate for Local Authorities									

Yollar ile ilgili idari sorumluluk şu şekilde ayrılmaktadır. Devlet yolları ve ilçeleri bağlayan yollar Karayolları Genel Müdürlüğünde, 6360 sayılı Büyükşehir yasası ile İl merkezi ve köy yollarının sorumluluğu Büyükşehir belediyelerinde, İlçe merkezlerinde İlgili İlçe Belediyesinde, Büyükşehir olmayan yerlerde köy yolları İl özel İdarelerinin sorumluluğundadır. Görüldüğü üzere ulaşım yolları ve trafikle ilgili sorunlar ve çözümler birçok kurumu ilgilendirmektedir. Birçok kurumun sorumluluğunda olan ulaşım yolları ile ilgili yapılması gerekenler ve sorunların çözümü çoklu disiplinle çalışma ile başarıya ulaşabilir. Birçok kurumu ve mesleki disiplini ilgilendiren trafiğe bağlı sorunların çözümü ciddi maliyet ve yatırım gerektirmektedir. Bu yatırımların yapılması, önlem ve tedbirlerin alınması, karmaşık sorunların çözümü ve uygulamaların hayata geçmesi birçok disipline veri sağlayan, çözüm ve analiz imkânları sunan UA ve CBS ile mümkün olabilmektedir.

Karayolundaki en önemli parametre trafiktir. Trafikteki hacim ve gürültü analiz modellerinde araç sayımı ve dağılımı hesaplanır (Holt vd. 2009). Trafikteki araç yoğunluğu ve türü ile ilgili yapılacak tespit ve değerlendirmeler sorun çözümü ve planlamayı hızlı ve asgari hata ile hayata geçirecektir. Bu çalışmada trafikteki temel parametre olan araçların Uzaktan Algılama ve Coğrafi Bilgi Sistemleri teknikleri ile tespit edilmesi hedeflenmiştir. Çalışmada halka açık verilerin ve kaynakların kullanılması minimum maliyetle çalışmanın yapılmasının yanı sıra ortalama kaydırma, çoklu çözünürlüklü bölütleme ve KMeans yöntemi kullanılmış ve karşılaştırılmıştır. Çalışmada farklı yöntemlerin kullanılması ve karşılaştırılması yöntemlerin avantaj ve dezavantajlarını göstermesinin yanı sıra trafik verilerinin hızlı ve yüksek doğrulukla üretilmesi noktasında destek niteliğindedir. Böylece karar destek sistemlerine ve yöneticilerin ulaşacağı veriler ile planlama, mühendislik ve nihayetinde uygulama ile sonuçlanabilecektir.

1.1. Coğrafi Bilgi Sistemleri ve Uzaktan Algılama

1.1.1. Coğrafi bilgi sistemleri


“CBS; konuma dayalı işlemlerle elde edilen grafik ve grafik olmayan verilerin toplanması, saklanması, analizi ve kullanıcıya sunulması işlevlerini bir bütünlük içinde gerçekleştiren bir bilgi sistemidir” (Yomralıoğlu 2000).

CBS'nin ihtiyaç duyduğu mekânsal veriler için en önemli veri kaynağı UA ile elde edilen verilerdir. Bu nedenle iki sistem birbirine bağlı ve destekleyici niteliklidir. UA ve CBS birçok sektöre veri sağlamakta ayrıca çeşitli analiz olanağı sağlamakta ve karar verici mekanizmalara doğru hızlı ve ekonomik karar imkânı sunmaktadır. CBS aynı zamanda çok gelişmiş mekânsal ve mekânsal olmayan analizlerin yapıldığı bir yapıya sahip olduğu için uzaktan algılamadan elde edilen sonuçların doğruluğunun yorumlanması konusunda destek sağlar.

Birçok uzman CBS'deki hızlı gelişme ile bazı veri toplama ve işleme tekniklerinin gelişimi arasında bir bağlantı olduğunu belirtmekte ve aşağıdaki bilgi sistemlerini örnek olarak göstermektedirler (Yomralıoğlu 2000). CBS yapısının genel olarak 4 farklı bileşenden oluştuğu düşünülmektedir. Şekil 1.1'de CBS'nin yapısı gösterilmektedir.

- Bilgisayar Destekli Tasarım (Computer Aided Desing)
- Bilgisayar Destekli Kartografya (Computer Aided Cartography)
- Veri Taban Yönetim Sistemleri (Data Base Management Systems)
- Uzaktan Algılama (Remote Sensing)

CBS'nin en önemli özelliklerinden birisi de mekânsal analiz yeteneğidir. Çalışmada uzaktan algılama ile bütünleşik olarak üretilen verilerde bazı mekânsal sorgu ve analizler yapılmış ve CBS unsurları aktif olarak kullanılmıştır.




Şekil 1.1. Coğrafi Bilgi Sistemleri yapısı (Yomralıoğlu 2000)

1.1.2. Uzaktan algılama

Uzaktan algılama tekniğinin temeli yeryüzü elemanları ile bunların çevrelerine yönelik bilgilerin hiçbir fiziksel temas olmaksızın belirli uzaklıklardan algılanan görüntülerin ölçümü, sayısallaştırılması ve yorumlanması temeline dayanır. (Altuntaş ve Çorumluoğlu 2006) Uzaktan algılamada Şekil 1.2'de gösterilen elektromanyetik spektrumun farklı bölgelerinden farklı özellikte elde edilen görüntüler kullanılırlar. Uzaktan algılama, mekâna dayalı mesleki disiplinlerinin özellikle arazi kullanımı, doğal kaynak kaybı, su ve toprak yönetimi, gibi çalışma alanlarında kullandıkları önemli yöntem ve teknikleri içermektedir. (Lillesand vd. 2016) Uzaktan Algılama tekniği yüksek doğruluk oranı, kısa çalışma süresi, uzun vadede düşük maliyet vb. nedenlerinden dolayı oldukça tercih edilmektedir. (Kalkan ve Maktav 2010).

Uzaktan algılama, aktif ve pasif olmak üzere ikiye ayrılır. Bunlardan, aktif uzaktan algılama, incelenecek cisim yada yüzeye yapay olarak gönderilen, enerjinin, yansdıktan sonra analiziyle karakterize olur. (Kavak 1998). Bunlara örnek olarak Radar, Lidar sistemleri verilebilir. Pasif uzaktan algılama ise, tamamen doğal yollarla güneş ışınımı, aracılığıyla yayılan elektromanyetik radyasyonun cisim ve yüzeylerle etkileşimde bulunarak onların fiziksel ve kimyasal özellikleri hakkında istenilen bilgileri algılama yönetimidir. (Kavak 1998). Uzaktan algılama teknolojinin hızlı bir şekilde gelişmesiyle birçok alanda kullanılan bir yapıdadır. Uzaktan algılama haritacılık, jeoloji, ekoloji, askeri alanlar gibi bir çok sektör ve disiplinde kullanılmaktadır.




Şekil 1.2. Elektromanyetik spektrum (Tso ve Mather 2009)

1.1.3. Sınıflandırma ve bölütleme

Uzaktan algılama teknikleri yardımı ile yapılan en önemli işlemlerden biri de sınıflandırma ve bölütleme işlemleridir. Sınıflandırma işlemi temel olarak iki bölümde incelenmektedir. Sınıflandırmada iki farklı teknik uygulanmaktadır, Piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırma (Lillesand vd. 2016).

Piksel tabanlı sınıflandırmada kullanıcı görüntüdeki dijital numaralarla gösterilen spektral bilgiyi kullanarak çeşitli bantlar üzerinde spektral özelliklere göre pikselleri sınıflandırır. Bu tip sınıflandırmaya spektral doku tanımlama da denebilir. Burada amaç Şekil 1.3’de piksel tabanlı sınıflandırmada gösterildiği gibi görüntüdeki tüm pikselleri çeşitli sınıflara ya da temalara atamaktır. Sınıflandırma sonucunda oluşan haritada her piksel kendine mahsus bir özelliğe atanmış bir şekilde orijinal görüntünün tematik haritası elde edilmiş olur. (Kalkan ve Maktav 2010)



Şekil 1.3. Piksel tabanlı sınıflandırma gösterimi (Ayhan vd. 2003)

Nesne tabanlı sınıflandırma yönteminde bölütleme aşamasında birbirine benzer yansıtım özelliklerine sahip pikseller gruplandırılır ve böylece milyonlarca piksel ile çalışmak yerine bu ortak özelliklere sahip pikseller birleşerek bölütler oluşur ve bu aşamada bölütlerin kendileri arasındaki heterojenlik en düşük seviyeye indirilmiş olur. Kullanıcı bu aşamada spektral homojenliğin ya da heterojenliğin önemine göre istediği spektral katmanları kullanarak çeşitli ölçek faktörlerinde bölütleme katmanları oluşturur (Baatz ve Schape 2004). Oluşan bölütlerin yansıtım özellikleri yanında doku, uzunluk ve alan gibi özellikleri de kullanılarak sınıflandırma sırasında birçok özelliğin elde edilmesi kolaylaştırılır (Kalkan ve Maktav 2010).

Klasik piksel-tabanlı metotlar, yüksek çözünürlüklü görüntülerdeki nesnelerin genellikle farklı spektral özniteliklere sahip heterojen piksellerden oluşması sebebiyle nesne çıkarımı aşamasında yetersiz kalmaktadırlar (Kavzoğlu ve Tonbul 2017). Şekil 1.4'de Nesne tabanlı bölütleme karayolu örneği gösterilmiş olup bir çok uygulama ve çalışmada da bu yöntem kullanılmaktadır.




Şekil 1.4. Nesne tabanlı bölütleme karayolu örneği


1.2. Çalışma Alanı

Çalışma alanımız olan İstanbul, Türkiye'nin en kalabalık, ekonomik, tarihi ve sosyokültürel açıdan en önemli şehridir. Şekil 1.5'de çalışma alanı genel görünümü gösterilmektedir. Bu alan Türkiye'nin en büyük ve trafiğin en yoğun olduğu kent olan İstanbul ilinden seçilmiştir. İstanbul ili 15.029.231 kişi nüfus ile Ülkemizin en kalabalık şehridir (TUIK 2018). İstanbul 2.6 milyon araç ile ülkemizde en çok aracın bulunduğu ildir. Bununla beraber her ay yaklaşık 15.300 araç İstanbul trafiğine katılmaktadır (İBB, www.ibb.gov.tr 2018). Bu durum beraberinde sürekli artan bir araç ve trafik sorununun çözümü arayışını getirmektedir. Bilindiği üzere kent içi ulaşımdan Belediler sorumludur. Bu noktada İstanbul Büyükşehir Belediyesi tarafından bu sorunların çözümü için çok önemli çalışmalar yapılmaktadır (İBB 2016). İBB Trafik Kontrol Merkezi ile saha ekipleri, kamera vb sürekli takip edilmektedir. İstanbul trafiğine çözüm bulunması amacı ile tüneller, köprüler raylı sistemler yeni toplu taşıma araçları devreye alınmaktadır.


Çalışma, iki farklı alanda yapılmıştır. Birinci çalışma bölgesi D-100 Karayolunun Boğaziçi (15 Temmuz Şehitler) köprüsünün Asya yakası çıkışında yer alan bir bölüm olan ve Şekil 1.6' de gösterilen kısımdır. İkinci çalışma alanı İstanbul'da trafiğin yoğun olduğu Atatürk havaalanı yakınındaki E-5 karayolu karayolunun batı bir kısmıdır ve Şekil 1.7'de gösterilmiştir.



Şekil 1.5. Çalışma alanı genel görünümü



Şekil 1.6. Birinci çalışma bölgesi 15 Temmuz Şehitler Köprüsü Girişi



Şekil 1.7. İkinci çalışma bölgesi E-5 Karayolu Atatürk Havalimanı Girişi

2. KAYNAK TARAMASI

Çalışmada UA ve CBS ile Nesne tabanlı sınıflandırma, ortalama kaydırma/mean shift algoritması uygulamaları, KMeans algoritması ve uygulamaları. UA ve CBS teknikleri ile yapay ve doğal obje çıkartılması konuları ile ilgili önceki çalışmalar incelenmiştir.

Tso ve Mather (2007) tarafında yayımlanan “ Classification methods for remote sesning data” adlı kitapta uzaktan algılama ile ilgili kuramsal bilgiler, sınıflandırma, görünü zenginleştirme teknikleri konuları anlatılmıştır.

Guigues (1996) tarafından yapılan çalışmada fotogrametrik görüntüler kullanılarak istatistiksel bir sınıflandırma metodu olan Naive Bayes ile araçların belirlenmesine çalışılmıştır. Çalışmada araç sınıfları önceden tanımlanmış ve belirlenmiş ardından sınıflandırma yapılmıştır. Çalışma alanında 91 adet örnek veri alınmış, 292 adet aracın 241 çıkarıldığı tespit edilmiştir. Koyu renkli araçlarda istenilen sonucun elde edilmediği belirtilmektedir.

Flores (2005) tarafından yapılan çalışmada 1m çözünürlüklü İkonos pankromatik görüntüleri kullanılmıştır. Çalışmada görüntünün histogramı dört bölüme ayrılmıştır. 1. bölüm bağlantı yolları, 2. bölüm koyu renkli objeler ana yollar ve ağaçlar, 3. bölüm binalar ve su 4. bölüm araçlardır. Bunlar içinde bazı eşik değerler belirlenmiş ve bu değerler göre araçlar tespit edilmeye çalışılmıştır.

Leitloff vd. (2006) tarafından 0.6 m çözünürlüğe sahip Quickbird uydu görüntüsü kullanılarak trafikte yer alan araçların çizgi çıkarım bölütleme tekniği ile çıkartılması yapılmıştır. Çalışmada araç objeleri için bazı eşik uzunluk değeri kabul edilmiş ve çalışma tamamlanmıştır. Çalışmada gerçek araçlara göre yapılan doğruluk analizinde % 60 değeri tutarlılık olduğu tespit edilmiştir.

Tuermer vd. (2010) tarafından Almanya Münih şehrinde yapılan çalışmada 3K kamera ile elde edilen görüntüleri Gaussian filtresi ile görüntü zenginleştirme yapılmıştır. Bu işlemin ardından Histogram of Oriented Gradient (HOG) yöntemi ile karayolunda yer alan araçların çıkarılması araştırılmıştır. Çalışmada karayolundaki araçlardan örnek veri seti tanımlanmıştır. Tanımlanan bu veriler,

Tsai vd. (2011) tarafından araç tespit ve takip ile ilgili çalışmada trafik kameraları görüntüleri kullanılarak araç objelerini içeren bir histogram kütüphanesi oluşturulmuştur. Bu kütüphane yardımı ile araç objeleri kalman filtresi ile görüntü taranarak araç objeleri görüntüler üzerinden elde edilmeye çalışılmıştır.

Zang vd. (2014) yapılan çalışmada, Lidar verileri kullanılmış, lidar verisi ile elde edilen 3d verileri kullanarak sınıflandırma yapılmıştır. Sınıflandırma araç olarak belirlenen sınıflara bazı eşik değerlere göre seçim yapılmıştır. Buna göre yüksekliği 0 ile 2.5 m arasında olan uzunluğu 15 den küçük olan objeler araç olarak kabul edilmiştir. Çalışmada doğruluk analizi yapılmış ve %85 oranında araç objelerinin referans araç objeleri ile örtüştüğü hesaplanmıştır.

Leitloff vd. (2014) yaptığı çalışmada 3K kameranın 0.15 cm yer örnekleme mesafeli olarak ürettiği veriler kullanılarak Support Vector Machine (SVM) sınıflandırma yöntemi ile araçların belirlenmesine çalışılmıştır. Çalışmada üç bantlı KMY verilerin yanı sıra kontrast, yoğunluk verileri de kullanılarak %96 oranında araçların çıkartıldığı hesaplanmıştır.

Ammour vd. (2017) tarafından yapılan çalışmada yüksek çözünürlüklü uydu görüntüleri ile mean shift bölütleme olmak üzere iki farklı veri setinde Support Vector Machine (SVM) sınıflandırma işlemi yapılmıştır. Çalışmada öğrenme veri setleri farklı piksel boyları belirlenerek seçilmiştir. Çalışmada sonucunda küçük araçların %76 doğruluk olarak hesaplanmıştır. Araç boyutlarının büyüdükçe çalışma doğruluğunun arttığı tespit edilmiştir.

Azimi vd. (2018) tarafından yapılan çalışmada yüksel çözünürlüklü İHA görüntüleri kullanılarak yapay sinir ağı sınıflandırma yöntemi ile araçların çıkarılması üzerine bir çalışma yapılmıştır. Çalışmada görüntüye morfoljik filtreleme yapılmış ardından çalışmada öğrenme veri setleri oluşturulmuş ve sınıflandırma tamamlanmıştır. Çalışma alanına ait 185 adet araç çıkarılmıştır.

Baatz ve Schape (2004) tarafından yapılan çalışmada çoklu çözünürlüklü bölütleme işlemi kuramsal olarak anlatılmıştır. Bu yöntem kullanılırken belirlenecek ölçek ve homojenlik parametrelerinin önemi anlatılmış ve bölütleme ye etkileri irdelenmiştir. Ölçek parametresinin artması ile oluşacak bölütlerin büyümekte olduğu yine homojenlik parametrelerin ile obje büyüklüklerinin doğru orantılı olduğu hususu belirtilmektedir.

Kalkan ve Maktav (2010) tarafından nesne tabanlı piksel sınıflandırma yöntemlerinin karşılaştırılması (İkonos Örneği) çalışması yapılmıştır. Çalışmada çok bantlı İkonos uydusuna ait görüntüler kullanılarak nesne tabanlı sınıflandırma ve çoklu çözünürlüklü bölütleme yöntemi ile piksel tabanlı maksimum benzerlik yöntemleri uygulanmış ve bu yöntemler karşılaştırılmıştır. 8 adet sınıf üzerinde yapılan çalışmada nesne tabanlı sınıflandırmanın daha iyi sonuç verdiği tespit edilmiştir.

Kavzoğlu vd. (2015) tarafından yapılan çalışmada obje çoklu çözünürlüklü yöntem ile makine öğrenme algoritmalarının karşılaştırılması yapılmıştır. Çalışmada Worldview-2 çok bantlı uydu görüntüleri kullanılmıştır. Çalışmada günümüzde birçok sınıflandırma uygulanan maksimum benzerlik, SVM, yapay sinir ağı yöntemleri piksel tabanlı yaklaşım olarak uygulanmıştır. Çalışmada ayrıca çoklu çözünürlüklü bölütleme ve nesne tabanlı sınıflandırma uygulanmıştır. Bu iki yöntem karşılaştırılmış ve nesne tabanlı yöntemin daha yüksek doğrulukta sınıflandırma yaptığı belirlenmiştir.

Kavzoğlu ve Tonbul (2017) tarafında yapılan çalışmada Nesne tabanlı sınıflandırmada bölütleme kalitesi irdelenmiştir. Çalışmada Quickbird-2 çoklu çözünürlüklü görüntüler kullanılmıştır. Çalışmada çoklu çözünürlüklü bölütleme uygulanmış ve üç farklı aşamada farklı ölçek parametresinin çalışma ve sınıflandırma doğruluğuna etkisi irdelenmiştir. Ölçek parametresinin sınıflandırma doğruluğuna doğrudan etkisinin olduğu istenilen obje grubuna göre ölçek parametresinin tespitinin önemi vurgulanmıştır.

Holt vd. (2009) tarafından yapılan çalışmada, yüksek çözünürlüklü hava fotoğrafları kullanılarak çoklu çözünürlüklü bölütleme tekniği ile trafikte bulunan araçlar tespit edilmeye çalışılmıştır. Üç farklı çalışma bölgesinde çalışılmış önce bölütleme işlemi yapılmış ardından örnek veri setleri alınarak sınıflandırma yapılmış ve doğruluk analiz ile çalışma tamamlanmıştır. Çalışmada araçlar büyüklüklerine göre türlerine 3 türe ayrılmışlardır. Sonuç olarak yapılan doğruluk analizinde %88 bir oranda araçların tespit edildiği tespit edilmiştir.

Bahram vd. (2012) tarafından yapılan çalışmada Wordview-2 uydusu kullanılmış ve Nesne tabanlı çoklu çözünürlüklü bölütleme yöntemi ile karayolunda bulunan araçların tespit edilmesi hedeflenmiştir. Çalışmada kalite analizi yapılmış ve çalışma alanındaki toplam 272 adet aracın %73 oranında bir doğruluk ile belirlendiği tespit edilmiştir.

Vallabhaneni ve Rajesh (2018) tarafından yapılan çalışmada beyin tümörlerinin ortalama kaydırma kümeleme algoritması yardımı ile belirlenmesi çalışması yapılmıştır. Çalışmada mr(manyetik rezonans) görüntüleri kullanılmış ve öncelikle görüntüdeki gürültüler Weiner filtresi ile giderilmiştir. Bu işlemim ardından görüntüye meanshift bölütleme yapılarak beyinde yer alan tümörlü bölge bölüt olarak çıkarılmıştır.

Napoleon vd. (2014) tarafından yapılan çalışmada Quick Bird ve Landsat görüntüleri kullanılarak KMeans kontrolsüz sınıflandırma yöntemi yardımı ile sınıflandırma işlemi yapılmıştır. Çalışmada yerleşim alanlarından uygulanan çalışmada %78 doğrulukla sınıflandırma yapıldığı sonucuna varılmıştır.

Solak ve Altınbaş (2018) tarafından Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması yapılmıştır. Çalışmada fındık meyvesine ait görüntüler 3x3 morfolojik filtrelere tabi tutulmuş, elde edilen görüntüler ortalama kaydırma bölütleme ve Kmeans sınıflandırma tekniği ile sınıflandırılmış ve fındık türleri %90 oranında belirlenmiştir.

Erdoğan vd. (2018) tarafından yapılan çalışmada destek vektör makineleri, Yapay Sinir Ağları, KMeans ve en yakın komşuluk algoritmaları kullanılarak arı türlerinin tespit üzerine bir çalışma yapılmıştır. Çalışmada arılar vektörel olarak çıkarılmış ve özelliklerine göre ayrılmışlardır.

3. MATERYAL VE METOT

3.1 Materyal

Çalışmada Google Earth verileri kullanılmıştır. Bilindiği üzere Google Earth verileri herkesin kullanımına açık verilerdir. Bu veriler, uydu görüntüleri kullanma, yön bulma, mesafe ölçüm gibi özellikleri ile birçok uygulamada da temel altlık niteliğindedir. Bu veri setinin tercih edilmesi nedeni ise herkesin her an ulaşabildiği güncel ve ücretsiz bir veri kaynağı olması farklı zamanlara ait görüntülere ulaşılabilmesidir. Bilindiği gibi Google haritalama servisinde uydu görüntüsü, karma harita, arazi ve trafik seçenekleri bulunmaktadır. Ayrıca yüksek çözünürlük uydu görüntüleri sağlaması nedeni ile mekânsal doğruluk ve hassasiyet anlamında birçok çalışmada kullanılabilir niteliktedir. Harita uygulamasında cadde ve sokak isimleri, önemli konumlar vb öznitelik bilgileri bulunmakta ve bunlar belirli aralıklarla güncellenmektedir. Google Earth verileri mekânsal çözünürlük anlamında bölge bölge farklı özellikler göstermektedir. Bu nedenle çalışma bölgelerinde görüntüler ayrı ayrı incelenmiş ve değerlendirilmiştir.


Çalışmada yazılım olarak açık kaynak kodlu yazılım olarak Qgis ve orfeotoolbox (www.qgis.org.tr 2018) kullanılmıştır. Bu yazılımlar birçok coğrafi bilgi sistemleri ve uzaktan algılama işlemlerinin yapılabildiği yazılımlar olup sürekli olarak güncellenen yazılımlardır. Arcgis birçok CBS uygulamasını yapılabildiği gelişmiş bir CBS yazılımı, ecognition bölütleme ve sınıflandırma işlemlerinin yapılabildiği yazılım, Envi ise yine Uzaktan Algılama ile ilgili birçok işleminin yapılabildiği yazılımlardır. Coğrafi Bilgi Sistemleri, bir taraftan çok sayıda konumsal veriye gereksinim duyan bir yöntem, diğer taraftan ise bu sistem için kullanılan yazılımların çok pahalı olması, bu konuda çalışanları açık kaynak kodlu yazılımlara yönelmelerine neden olmaktadır (Ayday vd. 2014).

Çalışmada hüresel (Raster) veri seti olarak Google Earth görüntüsü ve vektörel veri olarak CBS yol sınırları verileri kullanılmıştır. Bu veriler kullanılarak bölütleme işlemleri yapılmış görüntü üzerinde mekânsal olarak araçlar belirlenerek referans ve doğrulama verisi elde edilmiştir. Çizelge 3.1'e bölütlemede kullanılan intensity görüntülerin spektral özellikleri verilmiştir.

Bilindiği üzere uydu görüntüleri UA ve CBS çalışmalarında kullanılmaktadır. Ancak yüksek çözünürlüklü görüntülerinin ücretli olması ve hemen ulaşılamaması nedenleriyle ücretsiz veriler cazip ve kullanışlı hale gelmektedir. Yapılan bu çalışmada Google Earth verilerinin kullanılması veriye hızlı ve ücretsiz ulaşılması çalışmanın değerini artıracakı düşünülmektedir. Şekil 3.1 ve Şekil 3.2'de çalışma alanlarına ait Google Earth verileri gösterilmektedir. Ulaşım projeleri ile ilgili temel verilerden biri uydu görüntüleridir (Flores 2005).

Çizelge 3.1. Çalışmada kullanılan görüntülerin (intensity) spektral özellikleri

Çalışma alanı	Standart sapma	Minimum piksel değeri	Maksimum piksel değeri	Ortanca piksel değeri	Piksel boyutu m
E-5	70	59	255	185	0.144
D-100	17	49	250	85	0.220



Şekil 3.1. E-5 Karayolu çalışma alanı Google Earth görüntüsü



Şekil 3.2. D-100 Karayolu çalışma alanı Google Earth görüntüsü


3.2. Metot ve Uygulama

Çalışmada iki farklı bölgeden alınan Google Earth görüntüleri kullanılarak Kontrolsüz sınıflandırma tekniği olan KMeans algoritması kullanılmış ve araç objeleri elde edilmeye çalışılmıştır. KMeans algoritması sınıflandırma çalışmalarında yaygın olarak kullanılmaktadır (Arbab vd. 2016). Çalışmada KMeans algoritması uygulanmadan önce yapılan ön işlemlerde çalışma alanı tespiti, kesme ve konumlandırma işlemi yapılmıştır. KMeans algoritması ile yapılan sınıflandırmada üç bantlı kesilmiş KMY karayolu görüntüler kullanılmıştır. Sınıflandırma sonucu üretilen araç objeleri referans veri ile kesişim (overlay) analiz ile karşılaştırılmıştır.

Çalışmada veriler bazı ön işlemlerden geçirilerek bölütleme işlemlerine hazırlanmıştır. Bunlar; koordinat dönüşümü, maskeleme, kesme, bant oranlama ile yoğunluk verisinin elde edilmesi ve filtreleme olarak yapılmıştır. Görüntü ön işlemleri ile görüntü üzerinde yer alan ve ilgilenilen nesneler daha belirgin ve kolay işlenebilir hale getirilmektedir (Solak ve Altınbaş 2018). Uydu görüntülerinin mekânsal çözünürlüğündeki iyileşmeler, beraberinde görüntülerin analiz edilmesi ve yeryüzü nesnelerine ilişkin bilgi çıkarımında önemli problemler ortaya çıkmıştır. Bunların başında çözünürlük artışı ile birlikte aynı yeryüzü nesnesini ifade eden komşu pikseller arasındaki spektral benzerliğin azalmasına neden olarak görüntüdeki karışık piksellerin sayısının artmasıdır (Kavzoğlu vd. 2015). Bu durum yeryüzündeki arazi örtüsü sınıflarına ait piksellerin kendi içerisinde veya birbirleriyle olan farklılıklarının ayırt edilmesi ve sınıflandırılması problemini karmaşık bir hale getirmektedir. (Zang vd. 2014).

Bölütleme aşamasında birbirine benzer yansıtım özelliklerine sahip pikseller gruplandırılır ve böylece milyonlarca piksel ile çalışmak yerine bu ortak özelliklere sahip pikseller birleşerek bölütler oluşur ve bu aşamada bölütlerin kendileri arasındaki heterojenlik en düşük seviyeye indirilmiş olur (Kalkan ve Maktav 2010). Çalışmada yapılan bölütleme işlemlerinde genel doğruluğu ve çalışma hızımı artırmak için görüntüler 4 adımlık ön işleme tabi tutulmuş ve ardından bölütleme yapılmıştır.

Karayolu verilerinde yer alan asfalt ve araçlar spektral açıdan zaman zaman benzerlik gösterdiği ve üç bantlı görüntü kullanıldığı zaman her bir renk uzayı için ayrı ayrı değerlendirme ile bölütleme yapılacaktır. Bu durumda bölüt sayıları artmaktadır. Çalışmada araçların yansıma ve yoğunluk değerlerinin farklılığının kullanılması amaçlanmış ve yapılan filtrelerle bu belirgin hale getirilmiştir. Bu işlemlerin ardından bölütleme işleme için iki farklı yöntem uygulanmıştır. Bunlar çoklu çözünürlüklü bölütleme ve ortalama kaydırma yöntemleridir. Bölütleme işlemlerinin ardından vektörel olarak üretilen araçlar ile ilgili seçim kriterleri ile seçim yapılmıştır. Son olarak referans veriye göre doğruluk analiz yapılarak çalışma tamamlanmıştır. Çalışmada yapılan uygulamalar, Şekil 3.3’de temel işlem adımları şemasında gösterilmektedir.



Şekil 3.3. Temel işlem adımları şeması


3.3. Ön İşlemler

3.3.1. Jeoreferanslama

Hücresel (Raster) veri seti olarak kullanılan verilerde doğruluk analizinin yapılması ve bazı fonksiyonların kullanılması için metrik düzleme aktarılması gerekmektedir. Görüntüde bunun için koordinat dönüşümü yapılarak görüntüler metrik olan WGS 84 UTM 36° lik projeksiyon sistemine dönüştürülmüş ve koordinatlı hale getirilmiştir. Bu işlem için görüntü üzerinden 4 referans noktası seçilmiş ardından jeoreferanslama (belirli sabit ve koordinatı bilinen noktalar yardımı ile referans verinin koordinatlandırılması işlemi) yapılmıştır. Bu işlem ile bazı verilerde coğrafi ve harita analizleri yapılabilir hale getirilmektedir. Şekil 3.4’de jeoreferanslama uygulaması ve referans noktaları, Şekil 3.5’de ise yapılan uygulamanın sonuçları gösterilmektedir.



Şekil 3.4. Jeoreferanslama uygulaması ve referans noktalar




Şekil 3.5. Jeoreferanslama uygulaması sonuçları


Jeoreferanslama işleminde RMSE (ortama karekök hatası) değerinin 1 den küçük olması dönüşümün doğru ve sağlıklı yapıldığını göstermektedir. Bu işlemde 1 boyutlu affine dönüşümü yapılarak raster veri koordinatlı hale getirilmiştir. Jeoreferanslama işlemi sonucunda RMSE değeri 0.62552 olarak hesaplanmış olup bu değerin 1 den küçük olduğu görülmektedir.

3.3.2. Kesme

Koordinatlı hale getirilen raster veri seti için kesme işlemi yapılmıştır. Bu işlem önemli bir adımdır, sadece karayolunda yer alan objelerin değerlendirmeye alınmasını sağlayarak doğruluğu ve işlem hızını artırması hedeflenmiştir. Bu işlem için vektörel CBS verileri kullanılarak sadece karayolu alanı kesilmiştir. Sonuçta bölütleme ve sınıflandırma işlemleri için sadece karayolu verisi elde edilmiştir. Bu işlem ile ağaç, bina, su gibi yapay ve doğal objeler çalışmaya dâhil edilmemiş, çalışma hızı ve doğruluk artırılmıştır. Bu işlem için ArcGis yazılımının clip-raster fonksiyonu ile tüm görüntüden karayolu verisini içeren görüntünün kesilmesi ile yapılmıştır. Kesme işleminde kırpma boyutunu koruma seçeneği işaretlenmiş olup sadece kesilen alanın verisinin üretilmesi sağlanmış olmaktadır. Şekil 3.6' da tüm görüntü ve kesilmiş görüntü görülmektedir.



a)



b)

Şekil 3.6. a) Tüm görüntü, b) Kesilmiş görüntü

3.3.3. Yoğunluk/intensity görüntü

Sadece karayoluna ait üç bantlı KYM raster verisinin oluşturulmasının sonrasında intensity (yoğunluk) veri seti oluşturulmuştur. Bilindiği gibi insan gözünün algıladığı renk uzayı olan KYM her bir rengin bir eksen olduğu üç boyutlu bir uzaydır. Yoğunluk verisi görüntüdeki Kırmızı Yeşil Mavi bantlarının toplamının band sayısına yani üçe oranı olarak formülle edilmektedir. Bu şekilde her bandın etkisinin eşit olduğu ve karayolundaki araçların asfalt zeminden farklı yansıma özelliğinin elde edildiği bir veri seti oluşturulmuştur. Aslında bu şekilde elde edilen yoğunluk verisi ile bir anlamda parlaklık verisi elde edilmiş olmaktadır. Asfaltın ve araçların spektral olarak farklı yoğunluk değerlerini içermeleri nedeni ile bu veri setinin tercih edilmesinin yanı sıra asfaltın homojen olarak belirli bir parlaklıkta olması ve orfeotoolbox üzerinde çalışmakta olan ortalama kaydırma/meanshift bölütleme algoritması tek bantlı veri seti ile çalışması nedeni ile yoğunluk veri seti tercih edilmiştir. Yoğunluk görüntüsü ile bina elde edilmesinin yanı sıra birçok uygulamada bu görüntü uygulanabilir. (Lin ve Nevetia 1998)

Yoğunluk $= (K+Y+M)/3$ olarak formüle edilmektedir.


3.3.4. Filtreleme

Uzaktan algılamada görüntü filtreleme, görüntüde yer alan farklı özelliklerin veya objelerin aralarındaki ayrımı arttırmak amacı ile uygulanmaktadır. Esasen bu işlem görüntü zenginleştirme teknikleridir. Filtreleme, görüntüdeki spektral ve mekânsal özelliklerin değiştirilmesi ile görüntünün zenginlemesini sağlar (Shrivastava ve Rai 2015). Filtreler görüntüdeki bilgilere daha sağlıklı ulaşmak ve kullanmak amacı ile uygulanırlar. Ham görüntülerde çeşitli nedenlerle gürültü etkileri oluşmaktadır. Görüntüdeki gürültü çalışmanın genel doğruluk ve sonucunu olumsuz etkileyen faktörlerdir. Bu nedenle birçok çalışmada olduğu gibi bu çalışmada da filtreleme yapılmıştır. Yapılacak filtreleme ulaşılması planlanan hedef ve amaca dönük seçilmelidir.

Çalışmada uygulanan filtreler 3x3 piksel boyutlarındaki pencere ile taranarak yapılmıştır. Görüntülerde bu pencere yardımı ile taranarak görüntüdeki piksel değerleri yeniden düzenlenerek ve hatalar azaltılmış olmaktadır. Bu şekilde görüntüde oluşacak fazla segmenlerin oluşması azaltılacak ve bölütleme performansının artırılması hedeflenmiştir. Görüntü iyileştirme, görüntünün girdiği aralığı tüm yansıma aralığını kapsayacak şekilde yayarak görüntünün daha iyi yorumlanmasını sağlar. (Altuntaş ve Çorumluoğlu 2002)

3.3.4.a. Medyan filtre

Bu filtreleme yöntemi uzaktan algılamada sıkça kullanılan bir yöntem olup, Şekil 3.7’de medyan filtrenin çalışma prensibi gösterilmiştir. Bu filtrede görüntüdeki gürültünün obje sınırlarının koruyarak giderilmesi ilkesi ile çalışmaktadır. Bu filtre seçilecek filtre penceresinin büyüklüğüne göre piksellerin ortanca değerinin hesaplanarak merkez piksele atanması ilkesi ile çalışmaktadır. Medyan filtresi görüntüdeki çok yüksek değerler elemine eder ve bu işlemi gerçekleştirirken obje sınırları korunur (Tso ve Mather 2009). Aşağıdaki görüldüğü gibi görüntüde çalışma penceresinin sınırları korunarak merkezdeki değere ortanca değer atanmaktadır.




Şekil 3.7. Medyan filtre çalışma prensibi gösterimi (Kayıroğlu 2018)

Yukarıdaki şekilde ortadaki piksele göre işlemlerimizi yaparsak bu pikselin değeri olan 150 sayısının çevresindeki pikselleri iyi bir şekilde temsil etmediğini görebiliriz. Bu pikselin değerini değiştirirken öncelikle penceredeki piksellerin değerini bir sıraya dizelim. Bunlar (115, 119, 120, 123, 124, 125, 126, 127, 150) değerlerinden oluşur. Bu değerlerin en ortasında ise 124 sayısı vardır. Buna göre 150 rakamı 124 sayısı ile değiştirilir. Burada 124 sayısı görüntüdeki çalışma penceresinin medyan sayısı (orta değer) olmuş olur. Bu şekilde sınırlar korunarak çok uç değerler azaltılmış olur.

Çalışmada 3x3 piksek boyutlarında pencere kullanılarak filtreleme yapılmış olup yoğunluk görüntülerindeki gürültüler belli oranda azaltılmış ve araç sınırları korunmuştur. Çalışma alanlarına ait görüntülerdeki asfalta olan aşırı renk farklılıkları görüntüden kaynaklanan gölgeler belli oranda giderildiği gözlenmiştir.


3.3.4.b. Ortalama kaydırma yumuşatma (meanshift smoothing) filtre

Medyan filtre ile görüntünün sınırları korunarak gürültünün azaltılması işlemi yapılmıştır. Bu filtrenin uygulanmasından sonra, görüntünün obje sınırlarının belirginleştirilmesi ve homojenlik özelliğinin artırılması hedeflenmiştir. Bu nedenle çalışmada araç ve yol objelerinin daha iyi tespit edilmesi amacı ile görüntüdeki homojenliğin belirginleşmesi için bu filtre kullanılmıştır. Filtre, nokta dağılımının en yoğun olduğu yeri bularak iteratif yaklaşım ile piksel değerleri bu noktadaki değerlere göre tekrar oluşturur. Bu filtre için Şekil 3.8’de Orfeotoolbox meanshift çalışma ekranı gösterilmiş olup programın kendi değerleri kabul edilerek işlem yapılmıştır. Bu değerler mekânsal yarıçap (Spatial radius), Aralık yarıçapı (Range radius) ve iterasyon sayısıdır. Bu filtre bölütleme önceki son işlem olup görüntüde yer alan asfalt ve araçların daha belirgin ve homojen olmasını sağlamış ve bölütleme işlemlerinin daha başarılı sonuç vermesini sağlamıştır. Şekil 3.9’da çalışmada kullanılan görüntü ve filtre sonuçları görülmektedir.




Şekil 3.8. Orfeotoolbox meanshift smooting çalışma ekranı


Çalışmadaki yoğunluk görüntülerine 3x3 piksel penceresi olarak yapılan uygulama ile asfalt objeleri daha homojen olmuştur. Böylece çalışmada asfaltın ayrıştırılması daha kolay bir hal almış ve araç objeleri ile karışması azaltılmıştır.




a)



b)



d)



c)

Şekil 3.9. Çalışmada kullanılan görüntü ve filtre sonuçları; a) KMY görüntü; b) yoğunluk görüntüsü; c) medyan filtre uygulanmış görüntü; d) meanshift smooting filtre uygulanmış görüntü

Yukarıda 4 ayrı görüntüde görüldüğü üzere, ilk olarak KMY görüntü kullanılmış bu görüntüden yoğunluk verisi elde edilmiş ardından yoğunluk verisine 3x3 medyan filtre uygulanmış ve son olarak ortalama kaydırma yumuşatma filtresi uygulanarak ön işlemler tamamlanmıştır. Böylece görüntüler bölütleme işlemlerine hazır hale getirilmiş ve araç objeleri daha belirgin hale gelmiştir.

3.4. Bölütleme

Ön işlemler ile sınıflandırma işlemine hazırlık aşaması gerçekleştirilmiş ve çalışmada bölütleme işlemlerine geçilmiştir. Çalışmada iki farklı bölütleme yöntemi uygulanmıştır. Bunlardan birincisi ortalama kaydırma (mean shift) bölütleme diğeri Nesne tabanlı bir yöntem olan çoklu çözünürlüklü bölütleme (multiresolution) yöntemidir.

3.4.1. Ortalama kaydırma (mean shift) bölütleme

Ortalama kaydırma algoritması, parametrik olmayan istatistiksel bir yöntemdir ve nokta dağılımının en yoğun olduğu yeri bulmayı sağlar (Talu ve Türkoğlu 2010). Mean-Shift tabanlı görüntü bölütlemeyi açıklamak için öncelikle kullanılan renk uzayının tanımlanması gerekmektedir. Sağlıklı bir görüntüde bölütleme gerçekleştirebilmek için görüntüde algılanan renk farklılıklarını tanımlayan renk uzayının Öklid metriğine uygun olması gerekmektedir (Altuntaş ve Çorumluoğlu 2002). Görüntülerin doğasında bulunan kırmızı-yeşil-mavi (KYM) renk uzayı Öklid metriğini karşılayamayabilir (Comaniciu ve Meer 2002). Bu nedenle tek bantlı yoğunluk verisi kullanılmıştır. Şekil 3.10'da Ortalama kaydırma /mean shift algoritmasının gösterimi yapılmıştır.


Bu yöntemde sabit bir pencere boyutu seçilir. Pencere seçiminden sonra yoğunluk katsayısı hesaplanır. Bu katsayıya göre piksel değerleri yeniden belirlenir ve sonuç veride kütle merkezi bulunarak yoğunlaşmanın yani kümelenmenin olduğu alan belirlenmiş olur. Meanshift prosedürü her zaman öznitelik uzayında var olan dağılımın en çok artan yönünü göstermekte olduğundan bulunan noktalar yalnızca maksimum veya eyer noktası olabilmektedir (Özyazıcı ve Türker 2007). Dağılımın modları yani yerel maksimum değerleri bulunduktan sonra her modun bulunması sırasında üzerinden geçilen noktalar o modun çekim bölgelerini oluşturmaktadır. Bu çekim bölgesi ise sonuçta otomatik olarak görüntünün bölütlere ayrılmasında kullanılmaktadır. (Comaniciu ve Meer 2002).

Mean-Shift tabanlı görüntü bölütleme algoritması uygulanırken yöntemin performansını optimize etmek için aşağıda belirtilen üç parametrenin iyi incelenmesi gerekmektedir (Comaniciu ve Meer 2002).

Çekirdek tipi: Çeşitli çekirdek tipleri (Düz, Gaussian ve Epanechnikov vb.) ve yeni çekirdekler oluşturabilmek için geliştirilen operatörler tarafından incelenmiştir. Uygulamada genellikle Gaussian veya Epanechnikov çekirdek tipleri iyi sonuçlar vermektedir. Çalışmada Gaussian fonksiyonu seçilmiştir.

Çekirdek boyutu (h): Bölütlemenin başarısının belirleyen en önemli parametredir. Görüntü bölütleme için h şeklinde tanımlanmalıdır. Tahmini yapılan herhangi bir dağılımın modlarının bulunması dolayısıyla bölütlenin çözünürlüğünün belirlendiği parametredir.

Minimum bölge (mr): Bölütleme sonucunda elde edilen her bir bölütün sahip olabileceği en küçük hücre sayısını tanımlamaktadır. Minimum bölge, bölütleme uygulanacak çalışmaya özgü bir nitelikdir ve çalışmanın özelliklerine bağlı olarak değerinin belirlenmesi gerekmektedir.



Şekil 3.10. Ortalama kaydırma /mean shift algoritması gösterimi (Quyang 2015)

Yukarıdaki şekilde de görüldüğü üzere meanshift penceresi görüntüdeki maksimum değerlerin olduğu veriye kayarak yoğunlaşmanın pik olduğu yeri bulmaktadır. Yoğunlaşmanın ve öbekleşmenin en yoğun olduğu alan bulunduktan sonra aşağıda gösterilen parametreler yardımı ile öbekleşmenin sınırları belirlenerek oluşturulması hedeflenen bölütler üretilmiş olmaktadır.

Ortalama kaydırma (mean shift) bölütleme fonksiyonu

Mean shift bölütleme işleminin kuramsal çalışma prensibi aşağıda gösterilmiştir. Bu, görüntüde kümelenmesinin en yoğun olduğu yerin bulunması için oluşturulmuş bir fonksiyondur. Fonksiyonda olup bir anlamda en çok eleman sayısının tespiti için girilen değerler ve orfeotoobox yazılımındaki karşılıkları belirtilmiştir.

$$P(x) = k/(h.d) \quad k = \sum_{i=1}^{i=n} (x - x_i)/h \quad (\text{Akben ve Alkan 2015})$$

Burada x bir örnek veri olmak üzere;

P(x) fonksiyon olmak üzere;

h: Pencere genişliği/Çözünürlük (Çekirdek Boyutu)

d: Aralık.

k Toplam eleman sayısı.

h: Pencere genişliği(spatial radius)/Çözünürlük

Bu işlemde için açık kaynak kodlu yazılım olan orfeo tool box yazılımında spatial radius (mekânsal çap) parametresine karşılık gelmektedir. Parametre piksel değeri olarak girilmiştir. Çalışmada her bir görüntü için 1 piksel olarak değer girilmiştir. Böylece her piksel ayrı değerlendirilmesi hedeflenmiştir.

d: Aralık (range radius)

Bu işlemde için açık kaynak kodlu yazılım olan orfeo tool box yazılımında range radius (aralık çapı) parametresine karşılık gelmektedir. Parametre piksel değeri olarak girilmektedir. Çalışmada her bir görüntü için 1 piksel olarak değer girilmiş buna karşılık oluşacak minimum obje uzunluğu olan 1m ye karşılık gelen aralık miktarı girilmektedir. Örneğin 0.25 çözünürlüklü görüntüde aralık 4 olmaktadır.

Buna göre iki farklı çalışma alanında girilen aralık değerleri;

E5 karayolu için kullanılan görüntünün çözünürlüğü 0.144 m dir Buna göre aralık (1/0.144) olarak hesaplanırsa aralık 7 olarak belirlenmiş olur. Yani 1 metre obje oluşması için 7 adet pikselin kullanılması gereklidir.

D1 (15 Temmuz Şehitler Köprüsü) bağlantı karayolu için kullanılan görüntünün çözünürlüğü 0.22 m dir. Buna göre aralık (1/0.22) 4.54 olup çalışmada 5 olarak alınmıştır. Bir metrelik bir objenin oluşması için 5 pikselin kullanılması hesaplanmıştır.

mr: En küçük obje genişliği (minimum ragon size)

Bu işlemde için açık kaynak kodlu yazılım olan orfeo tool box yazılımında minimum region en küçük obje büyüklüğü değeri gelmektedir. Yukarıda belirtildiği gibi en küçük obje boyutu olarak 1 m alınmıştır. Yani karayolunda aracın ebatları an az 1 m olacak şekilde bir eşik değeri seçilmiştir.

Minimum obje alanı tayini:

(Piksel size)² x mr=1m² olmalıdır. örneğin 0.25 m piksel büyüklüğü için mr =16 olmaktadır. Bilindiği üzere iki farklı çalışma bölgesi vardır buna göre

E-5 karayolu için:

1 m² lik piksel alanı 0,144²=0.02 m² dir.

Minimum ragon size =1/0.02=50 olarak hesaplanmış olup 1 m² lik objenin oluşması için gerekli piksel sayısı yazılımda değeri olarak girilmiştir.

D-100 karayolu için:

1 m² lik piksel alanı 0,22²=0.048 m² dir.

Minimum ragon size =1/0.048=21 olarak hesaplanmış olup 1 m² lik objenin oluşması için gerekli piksel sayısı yazılımda değeri olarak girilmiştir


Mean shift bölütleme ile görüntüdeki piksellerin pik değeri ve yoğunlaştıkları yerler belirlenir ve yukarıda belirtilen parametreler girildikten sonra bölütleme işlemi tamamlanır. Bu şekilde karayolundan yer alan araçlar 1 metre eşik değerinin üzerinde olanlar ayrılarak belirlenmiş olurlar.

Çalışmada en küçük bölütün/ objenin eni ve boyu 1m olarak uygun bulunmuş olup bu bölütlerin oluşması için gerekli değerler belirlenmiştir. Buna göre ortalama kaydırma bölütleme işlemi için orfeo tool box üzerinden yapılacak hesaplamalarda gerekli değerler tespit edilmiştir. Çizelge 3.2’de ortalama kaydırma bölütleme yönteminde kullanılan parametreler gösterilmektedir. Bu parametreler yardımı ile ebatları minimum 1m x 1m olan bölütlerin oluşturulması sağlanmıştır.

Çizelge 3.2. Ortalama kaydırma/ Mean shift bölütleme kullanılan parametreler

Çalışma bölgesi	Spatial radius	Range radius	Minimum ragon size
E-5 (Atatürk Havaalanı)	1	7	50
D-100(15 Temmuz Şeh. Köp.)	1	5	21


Bölütleme sonucu raster veri olarak üretilmiştir. Meanshift bölütleme ile üretilen raster veri değerleri float yapıdadır. Bu veriler ile vektörizasyon yapılması durumunda fazla sayıda bölüt oluşacaktır. Bunun önüne geçilmesi ve mantıksal olarak araç ve yol ayrımının yapılması için bazı işlemlerin yapılması gerekmektedir. Yukarıdaki şekilde ortalama kaydırma/ meanshift bölütleme sonucu görülmektedir. Yapılan bölütlemeye yolların net olarak ayrıldığı. Araç objelerinin sınırlarının korunarak bölütleme yapıldığı Şekil 3.11’de ortalama kaydırma bölütleme sonucu ve gerçek görüntüde görülmektedir.



Şekil 3.11. Ortalama kaydırma bölütleme sonucu ve gerçek görüntü

3.4.1.a. Raster yeniden sınıflama fonksiyonu

ArcGis yazılımı /spatial analyst aracı bölümünde yer alan bu fonksiyonla elde edilen sınıflandırma verisinin piksel değerleri 0-255 arasında değerleri arasında nümerik değerler üretilmesi sağlanmış ve aynı zamanda kategorize edilerek piksellerde kaç adet olduğu belirlenerek sınıflara atanmıştır. Böylece pikseller sayılarına ve değerlerine göre gruplandırılmıştır. Bu fonksiyon yardımı ile nümerik olmayan piksel değerler nümerik hale getirilmiş olup değer ve grup ilişkisi kurulmuştur. Bu işlem ile araç ve yol ayrımının minimum hata ile yapılabilmesi mümkün hale gelmiştir. Bu fonksiyon kullanılırken hesaplanacak sınıf sayısı 255 olarak girilmiştir. Şekil 3.12’de Reclass fonksiyonu ile yeniden değer verilen raster görüntüsü ve tablosu gösterilmektedir.



Şekil 3.12. Reclass fonksiyonu ile yeniden değer verilen raster görüntüsü ve tablosu

3.4.1.b. Raster çıkarma fonksiyonu


Burada float olarak üretilen veride gruplama yapıldığı ve o grupta yer alan piksel değerleri belirlendiği için araç veya yol ayrımı yapmak mümkün olmaktadır. Yeniden çıkarma (Extraction) fonksiyonu ile raster hesaplama fonksiyonundan farklı olarak belirlenen sorgulama kriterleri ile piksel değerleri korunarak veri elde edilmiş olmaktadır. Bu şekilde reclass ile üretilen verilerden sınıfta yer alan piksel sayılarına göre değerlendirilmiştir. Burada hedef asfalt olarak ayrılan sınıfları değerlendirme dışı bırakmaktır. Asfalt olarak ayrılan sınıflarda piksel adetleri çok ve aynı değerler içermektedir. Araç objeleri heterojen yapıda olduğu için ise küçük ve farklı değerler içermektedir.

Sonuç olarak araçların tespiti için bölüt büyüklüklerine göre eşik değerler belirlenmiştir. Bu değerlere göre maksimum bölüt alanı 95m² olarak hesaplanmıştır. Maksimum piksel alanı 0.048 m² olacak olup araç objelerinin piksel sayısı 95/0.048 ile 1980 adetten küçük olmalıdır. Yol verisinin sahip olduğu sınıflardaki piksel sayılarının 1980 den fazla olduğu hesaplandığı için bu sayıdan fazla olan pikseller görüntünün öznetelik tablosundan silinmiş ve böylece yol verisi değerlendirme dışı bırakılmıştır. Şekil 3.13'de Çıkarma (Extraction) fonksiyonu uygulanmış görüntü ve sonuçları gösterilmektedir.

Maksimum araç bölüt alanı: 5m x19m=95 m²

1 adet pikselin alan: 0.048 m² ⇒ Araç sınıfı maksimum alanı =1980 piksel


Yol sınıfı minimum piksel sayısı: 95/0.048 ile 1980 adet olarak hesaplanmıştır.



Şekil 3.13. Çıkarma (Extraction) fonksiyonu uygulanmış görüntü

3.4.1.c. Raster hesaplama fonksiyonu

Bu fonksiyon ile raster verisinde yer alan piksellerin belirtilen değerlere ve seçim kurallarına göre tekrardan üretilmiştir. Bu işlem ile binary veri üretilmiş olmaktadır. Yapılan bu işlem Şekil 3.14’de raster hesaplayıcı/ calculator fonksiyonu sonucu gösterilmektedir. Burada araç objeleri 0 ile 255 arasında değerler yer almakta olup her değer için bir bölüt oluşacaktır. Bu nedenle bu verinin seçim kriteri ile binary veriye dönüştürülmesi gerekir. Bu nedenle **piksel değerler** ≥ 0 seçimi ile araç objeleri üretilmiş olmaktadır. Bu şekilde raster veri tek bir değer olarak araç objeleri için tek bir bölüt elde edilmiştir. Sonuç olarak oluşabilecek fazla bölüt sayısının önüne geçilmiş olup sadece araç objeleri için raster veri üretilmiş olmaktadır. Şekil 3.14’de raster hesaplayıcı fonksiyon sonucu gösterilmektedir.



Şekil 3.14. Raster hesaplayıcı/ calculator fonksiyonu sonucu

3.4.1.ç. Vektör veri üretimi


Çeşitli mekânsal analizlerin yapılması araç objelerinin üretimi için raster verilerin vektörel veriye dönüştürülmesi gerekmektedir. Vektörel veri bilindiği üzere yeryüzündeki objelerin (alan,nokta, çizgi vb) objeleri ile gösterimidir. Bu nedenle; Arcgis yazılımı/conversion araçları bölümünde yer alan ve Raster veri setinin vektörel veriye (çizi, alan, nokta) dönüştüren raster to poly fonksiyonu kullanılmış ve raster veriler vektör alan objelerine çevrilmişlerdir. Ortalama kaydırma yöntemi ile elde edilen vektörel verilerin bazıları Şekil 3.15 de gösterilmiştir.



Şekil 3.15. Ortalama kaydırma raster veriden vektörel veri üretimi

3.4.1.d. En küçük sınır geometrisi fonksiyonu

Meanshift segmentasyonu sonucu üretilen raster verileri çeşitli işlemlerden geçirilerek vektörel veriye dönüştürülmüştür. Ancak oluşan vektörel veri şekil olarak düzensiz ve belirli bir geometrik şekle karşılık gelmemektedir. Bunun ortadan kaldırılması, araçlarda olduğu gibi dikdörtgen şekline dönüştürülmesi amacı ile en küçük sınır geometrisi (minimum bounding geometry) fonksiyonu kullanılmıştır. Bu fonksiyon ile bölütler dikdörtgen şekline dönüştürülmüş aynı zamanda şeklin alan, çevre, en ve boy bilgilerinin üretilmesi sağlanmıştır. Bu fonksiyon çalışması sırasında kullanılacak vektörün dönüştürülmesi işleminde kullanıcılara yumuşatma, geometrik bilgi üretme, üçgen, daire üretme seçeneklerini sunmaktadır. Çalışmada yumuşatma kullanılmamış ve dikdörtgen olarak geometrik verilerin üretme seçeneği kullanılmıştır. Şekil 3.16'de Ortalama kaydırma bölütleme en küçük sınır geometrisi fonksiyonu uygulaması ve sonuçları gösterilmiştir.




Şekil 3.16. Ortalama kaydırma bölütleme en küçük sınır geometrisi fonksiyonu uygulaması

3.4.2. Nesne tabanlı/çoklu çözünürlüklü bölütleme

Nesne tabanlı sınıflandırma, görüntüde yer alan piksellerden homojen objelerin üretilmesi ve bu objeler ile ilgili olarak farklı özelliklerin tanımlanması ilkesi ile çalışmaktadır. Nesne tabanlı sınıflandırma tekniği piksel tabanlı teknikten farklı olarak her bir pikseli değerlendirmeye almayıp piksellerin bir araya geldiği zaman oluşacak objeler üzerinde çalışır. Görüntüdeki benzer ve komşu piksellerin bir araya getirilmesi ile poligonların oluşturulması amaçlanmaktadır. Benzer özelliğe sahip pikseller, seçilen bir pikselden başlayarak en küçük heterojenlik değerini sağlayacak şekilde, detayın geometrisi, spektral özelliklere göre gruplanır. (Benz vd. 2004) Bu işlemler için kullanılan çeşitli yöntemler mevcuttur. Çalışmada çoklu çözünürlüklü bölütleme tekniği kullanılmıştır. Bu teknikte başlangıçta her bir piksel bir görüntü objesi olarak değerlendirilip iteratif yaklaşımla homojen görüntü objeleri elde edilir (Baatz ve Schape 2004). Çalışmada Nesne tabanlı sınıflandırma tekniği uygulamasından Ecognition yazılımı kullanılmıştır. Çoklu çözünürlüklü bölütleme algoritmasında temel olarak ölçek/scale, şekil/shape ve yoğunluk/compactness parametrelerinin kullanıcı tarafından girilmesi gerekmektedir. Bu parametreler, iteratif olarak denemiş ve optimum parametre görüntü üzerinde en uygun bölümlerin oluşmasını sağlayabilecek şekilde belirlenmiştir. Algoritmada en önemli parametrelerden biri ölçek parametresi olup büyük ölçek parametresi büyük objeler, küçük ölçek parametresi küçük objeler oluşmasını sağlar. Şekil ve yoğunluk parametreleri 0 ile 1 arasında değişen değerler almaktadırlar. Bu parametrelerde yine oluşturulacak obje büyüklükleri ile doğru orantılı olarak değişmektedir. Sonuç olarak istenen büyüklüklerde objelerin görüntüden bölütleme işlemi ile üretilmesi sağlanmış olur. Bu yöntemle bina, araç, ağaç vb doğal ve yapay objelerin görüntülerden çıkarılması mümkün olmaktadır. Şekil 3.17’de Nesne tabanlı bölütleme ile yerleşim alanında yapılan bir örnek görülmektedir.

Nesne tabanlı sınıflandırma tekniği ile uygun ölçek parametresi belirlenmesi çalışma doğruluğu ve hızını doğrudan etkileyen faktörlerdir. Bu nedenle, bölütleme kalitesinin değerlendirilmesi, etkili bölütleme yaklaşımlarının seçiminde ve optimum parametrelerin belirlenmesinde Nesne tabanlı görüntü analizi için esastır (Neubert ve Herold 2008). Çalışmada en küçük araç ebatları için bir eşik değeri belirlenmiş ve bu değerlere göre bölütleme işlemi yapılmıştır büyük ölçek parametresi seçildiği zaman küçük araçlar bölütleme dâhil edilmemesi sorunu ortaya çıkmaktadır. Ölçek parametresi çok küçük alındığı zaman çok küçük objeler değerlendirmeye alınarak araç olmayan bölütler oluşmakta ve çalışma doğruluğu azaltabilmektedir.



Şekil 3.17. Nesne tabanlıbölütleme ile yerleşim alanında yapılan bir örnek

Çalışmada kullanılan çoklu çözünürlüklü bölütleme öncesinde genel doğruluk ve çalışma hızını artıracak işlemleri yapılmıştır. Jeoreferanslama ve kesme işlemlerininim ardından uygulanan medyan ve smooth (yumuşatma) filtreleri ile görüntü bölütleme hazır hale gelmiştir. Bu işlemler ile bölütleme hızı ve başarısının artırılması hedeflenmiştir.

3.4.2.a. Çoklu çözünürlüklü bölütleme parametreleri

Ölçek: Çeşitli objelerin kaynaştırılmasından kaynaklanan olası maksimum heterojenlik değişimin belirlendiği bir kriterdir. (Benz vd. 2004).Bu kriter homojenlik kriterinin maksimum standart sapmalarını tanımlamaktadır. Görüntüdeki standart sapmadan ne kadar uzaklaşırsa yani yüksek parametreler değerlendirmeye alınmaya başlanırsa homojenlik artacak ve görüntüdeki kaynaşma sağlanan pikseller artacaktır. Bunun sonucunda için daha büyük bölütler oluşacaktır. Küçük ölçek değerleri homojenliği azaltacak ve küçük objelerin oluşmasını sağlayacaktır. Ölçek parametresi yazılımda e çeşitli değerler girilip denenerek belirlenmiştir.

Homojenlik parametreleri:

Şekil: Obje bazlı sınıflandırma homojenlik katsayıları ile obje büyüklüklerinin doğru orantılı olduğunu belirtilmişti. Şekil Parametresi 0 ile 1 arasında değerler almaktadır. Bu parametre arttıkça zaman oluşacak bölütlerde kaynaşma fazla olacak ve büyük bölütler elde edilecektir. Bu nedenle 0.1 değeri alınmıştır.

Yoğunluk: Obje bazlı sınıflandırma homojenlik katsayılarından olan yoğunluk parametresi 0 ile 1 arasında değerler almaktadır. Yine bu parametre arttıkça zaman oluşacak bölütlerde kaynaşma fazla olacak ve büyük bölütler elde edilecektir.

Bu parametreler formüle edilecek olursa. (Quyang 2015)

$$\text{Yoğunluk} = l/\sqrt{n}$$

$$\text{Şekil} = l/b$$

l = çevre (piksel değeri)


n = piksel sayısı

b = Oluşacak en küçük pikselin uzunluğu (m)

Yukarıda belirtilen parametrelerden de anlaşılacağı üzere piksel çözünürlüğü arttıkça zaman bölüt büyüklüğü ve homojenlik artmaktadır. Yine homojenlik ile şekil ve yoğunluk parametreleri doğru orantılıdır. Buna göre iki farklı görüntü için çalışmada çoklu çözünürlüklü bölütleme için kullanılan parametreler minimum 1 metre maksimum 19 metre araç uzunluklarını elde etmek için yazılım üzerinden Şekil 3.18’de Nesne tabanlı bölütleme için yazılım ekranı ve parametreler görülmektedir. Parametreler iteratif olarak denenmiş ve en uygun parametreler belirlenmiştir. Çizelge 3.3’de Nesne tabanlı bölütlemeye kullanılan tüm parametreler görülmektedir.

Çizelge 3.3. Nesne tabanlı bölütlemeye kullanılan parametreler

Çalışma alanı	Ölçek	Şekil	Yoğunluk	Çalışma alanı m ²
E 5 karayolu	75	0.2	0.1	10.726
D-100	50	0.2	0.1	9.358



Şekil 3.18. Nesne tabanlı bölütleme yazılım ekranı ve parametreler

Çalışmada iki farklı çalışma alanı kullanıldığı için parametreler değişmektedir. D100 karayolu çalışma alanında çözünürlük daha büyük olduğu için ölçek parametresi artırılmıştır. Çalışmada iki farklı bölgede iteratif yaklaşımla en uygun parametreler belirtilenerek Nesne tabanlı bölütleme işlemi Ecoqnation yazılımı yardımı ile yapılmıştır. Yapılan bölütleme işlemlerinde değerlendirmeye alınmayacak ve araç objesi olmayan birçok bölüt oluştuğu için bazı kriterler belirlenmesi gerekmektedir. Bu nedenle araç bölütlerini ayırmak için bazı eşik değerleri belirlenmiş ve bu eşik değerlere göre tablodan seçimler yapılacak araç bölütleri ayrılmış olmaktadır.

3.4.2.b. En küçük çevreleyen geometri fonksiyonu


ArcGis yazılımı/data management/features araçları bölümünde yer alan bu fonksiyon ile birçok köşegene sahip polygon objelerinden kare, dikdörtgen olarak şekiller üretilmekte ve alan ve çevre bilgileri elde edilmektedir. Bu şekilde oluşan ve düzgün bir geometrik yapıya sahip olmayan bölütlerden kare ve dikdörtgen şeklinde objeler üretilmiş olmaktadır. Şekil 3.19. Nesne tabanlı sınıflandırma en küçük çevreleyen geometri fonksiyonu sonucu örnek gösterimi yapılmıştır.



Şekil 3.19. Nesne tabanlısınıflandırma en küçük çevreleyen geometri fonksiyonu sonucu

3.4.2.c Kaynaştırma, ayrıştırma fonksiyonu

Nesne tabanlı bölütleme işleminde fazla miktarda bölüt oluşması ve birçok bölütün tek araca karşılık gelmesinden dolayı bu fonksiyonlar kullanılmıştır. Bu işlemler ile bu problem giderilmiştir. Arcgis yazılımında yer alan Kaynaştırma (dissolve) fonksiyonu ile bu bölütler birleştirilmiştir. Fonksiyon çalıştırılırken multipart seçeneği de kullanılmış olup, Şekil 3.20’de gösterimi yapılmıştır




Şekil 3.20. Kaynaştırma ve birleştirme fonksiyonu gösterimi

3.4.3. Kontrolsüz sınıflandırma /KMeans algoritması


Kontrolsüz sınıflandırma, görüntüden örnek veri almaksızın veriyi çeşitli algoritmalar yardımıyla bölümlere veya sınıflara bölmeyi amaçlar. Çalışmamızda KMeans kümeleme algoritması kullanılmıştır. KMeans kümeleme, objelerin kullanıcı tanımlı 'K' sayıda kümelerine gruplandığı bölme yöntemidir. KMeans sınıflandırma algoritmasında başlangıçta sınıf sayısı kadar rastgele merkez nokta seçilir. Her bir verinin merkez noktalarına olan uzaklığı hesaplanır ve kendine en yakın noktaya ait sınıf etiketi ile etiketlenir. Farklı sınıf etiketlerine sahip verilerin ortalaması bulunarak merkez noktalar tekrar hesaplanır ve tekrar her veri merkezlere olan uzaklığa göre sınıf etiketi ile etiketlenir. Bu işlem döngü sayısınca devam eder (Erdoğan vd. 2018).

Çalışmada girdi görüntüsü olarak çok bantlı KYM bantlarını içeren görüntü kullanılmıştır. İki farklı çalışma bölgesi olan D-100 ve E-5 karayolları için ayrı K-Means algoritması ile sınıflandırma yapılmış bu sınıflandırma işleminin sonucunda karayolu objeleri raster hesaplayıcı ile hesaplanmış ve silinerek araç sınıflarına ulaşılmıştır. Bu işlemlerin ardından en küçük sınır geometrisi /minimum bounding geomtry fonksiyonu ile şekilsel olarak dikdörtgenler elde edilmiş ve ebatları tabloya yazılmıştır. Son olarak büyüklük ve alan seçim kriterlerine göre araç sınıfları belirlenmiş ve kesişim analizi uygulanarak doğruluk analizi yapılmıştır. Şekil 3.21'de KMeans algoritması çalışma ekranı gösterilmiştir.




Şekil 3.21. KMeans algoritması çalışma ekranı

Çalışmada, yazılım ekranında sınıf parametresi değeri baştan tanımlı (default) 5 olarak gelmektedir. Bu değer kabul edilerek sınıflandırma işlemi yapılmıştır. İki farklı çalışma bölgesi için bu işlem yapılmış ve sınıflandırma sonucu olarak 5 farklı sınıf oluşmuştur. Bu sınıflardan biri yol diğerleri araç sınıfı olarak belirlendiği görülmektedir. Bu algoritmandaki en önemli parametrelerde biride iterasyon yani döngü sayısıdır. Kümeleme ve sınıflama yapılırken, artık farklı sınıf vermeyecek sayı en uygun iterasyon sayısı olarak belirlenmelidir. Yazılımda bu değer 1 olarak öngörülmüştür. Bu değerın uygun olmadığı farklı iterasyon sayıları girilerek denenmiş ve 5 adet iterasyon sayısının sonra sınıflandırma sonucunun değişmediği anlaşılmıştır. Şekil 3.22’de KMeans algoritmasında kullanılan parametreler gösterilmiş olup, K: (5) sınıf sayısı, İ: (5) iterasyon sayısı olarak belirlenmiştir.




Şekil 3.22. KMeans sınıflandırma parametreleri a) iterasyon sayısı 1 b) iterasyon sayısı 5

KMeans algoritması ile yapılan sınıflandırma işleminde 5 adet sınıf 5 defa döngü yani iterasyon sayısı belirlenerek iki farklı çalışma bölgesi için sınıflandırma yapılmış ve Şekil 3.23 'de KMean algoritması sonuçları gösterilmiştir.



Şekil 3.23. KMeans algoritması sınıflandırma sonucu


KMeans algoritması ile oluşturulan sınıflandırılmış veri yukarıda görüldüğü gibi elde edilmiştir. Sınıflandırma sonucu oluşan 5 adet sınıfın 1 tanesi yol diğer 4 sınıf araç olarak atanmıştır. Raster hesaplayıcı fonksiyonu ile binary olarak Şekil 3.24'deki gibi KMeans algoritması araç objeleri raster verisi olarak gösterilmektedir. Bu işlemin ardından raster öznelik tablosundan yol verileri silinmiştir. Sonuç olarak sadece araç objeleri değerleri içeren raster veri üretilmiş olmaktadır. Çeşitli mekânsal analizlerin yapılması ve araç objelerinin üretilmesi için raster veriler vektör veriye dönüştürülmüştür.



Şekil 3.24. KMeans algoritması araç objeleri raster verisi

3.4.3.a. En küçük sınır geometrisi fonksiyonu

KMeans sınıflandırma ile üretilen vektörel veriler şekil olarak düzensiz ve belirli bir geometrik şekle karşılık gelmemektedir. Bunun ortadan kaldırılması, araçlarda olduğu gibi dikdörtgen şekline dönüştürülmesi amacı ile en küçük sınır geometrisi (minimum bounding geomtry) fonksiyonu kullanılmıştır. Bu fonksiyın ile daha öncede ifade gibi objelerin genişlik ve uzunluk bilgileri hesaplanıp tablosuna yazıldığı için seçim kriterleri ile seçilebilecek hale gelmiştir. Şekil 3.25’de KMeans algoritması ile vektörel veri üretim ve en küçük sınır geometrisi fonksiyonu sonucu gösterilmiştir.




Şekil 3.25. KMeans algoritması ile vektörel veri üretim ve en küçük sınır geometrisi fonksiyonu sonucu

3.5. Araç bölütlerinin boyutlarına göre seçilme kriterleri

Çalışmada her iki bölütleme yöntemi sonucu oluşan bölütler çoklu sınır geometri fonksiyonu ile bölütlerin geometrik olarak düzenlenmesinin ardından araç olarak kabul edilmesi için bazı eşik değerler belirlenmiştir. Bu değerler Çizelge 3.4 de gösterilmektedir. Buna göre bölütlerin öznetelik tablosundan seçim işlemi yapılarak çıkan sonuçlara araç olarak kabul edilmiştir. Eşik değerlerin belirlenmesinde Ülkemizde yürürlükte olan Karayolları trafik yönetmeliğinde azami araç büyüklüğü göz önüne alınarak belirlenmiştir. Şekil 3.26'da Trafik yönetmeliğine göre azami araç uzunlukları gösterilmiştir.

Çizelge 3.4. Araç boyutlarına göre seçim kriterleri (KGM 2018)

ARAÇ	Minimum genişlik m	Maksimum genişlik m	Minimum uzunluk m	Maksimum uzunluk m	Maksimum alan m ²
Uzunluk	1	5	1	19	95



Şekil 3.26. Trafik yönetmeliğine göre azami araç uzunlukları (KGM 2018)

En küçük sınır geometrisi fonksiyonu ile elde edilen objelerin araç olarak kabul edilmesi için öznetelik tablosunda belirlenen eşik değerlere göre yapılan sorgulama işlemi aşağıda gösterilmektedir. Burada 1 m den büyük 19 m küçük obje uzunlukları, 1 m den büyük 5 m den küçük obje genişlikleri ve 95 m² (19x5) den küçük obje alanı seçimi yapılmıştır. **Bu kriterden çıkan sonuçlar araç objeleri olarak kabul edilmiştir**

4. BULGULAR VE TARTIŞMA

Çalışma alanı Türkiye'nin ve dünyanın en önemli şehirlerinden bir olan İstanbul'dan seçilmiştir. Bu ilimizde trafik yoğunluğunun fazla olduğu E5 ve D100 karayollarından bir bölüm belirlenmiştir.

Çalışmada iki farklı yöntem kullanılmış, bu yöntemler yukarıda belirtildiği üzere ortalama kaydırma (mean shift) bölütleme ve çoklu çözünürlüklü (multiresolution) bölütleme yöntemleridir. Bu yöntemler ile üretilen bölütler geometrik olarak düzeltilerek araç objeleri elde edilmiştir. Çalışma alanlarında karayolunda yer alan araçlar uydu görüntüsü üzerinden sayılmış ve her birinin yaklaşık olarak ortasına nokta atılarak mekânsal olarak işaretlenmiş ve referans veri oluşturulmuştur.

4.1. Ortama Kaydırma Bölütleme Sonuçları ve Doğruluk Analizi

Çalışmada ortalama kaydırma bölütleme sonuçları. Çizelge 4.1'de gösterilmiş olup elde edilen veriden araç objelerinin ayıklanması ve belirlenmesi amacı ile belirlenen eşik değerlerdir. Bölüt sayıları ve referans araçları belirtilmiş olup aşağıdaki çizelgede gösterilmektedir. Çalışmada en küçük çevreleyen geometri fonksiyonu uygulandıktan sonra oluşan bölütlere eşik değerlere göre seçim yapılarak araç olarak kabul edilecek bölütler üretilmiş olmaktadır. Buna göre aşağıdaki çizelgede meanshift algoritması ile elde edilen bölüt sayıları, kriterlere göre seçilen ve araç olarak kabul edilecek bölüt sayıları görülmektedir.

Çizelge 4.1. Ortalama kaydırma bölütleme sonuçları

Çalışma alanı	Vektör veride elde edilen ham veri/toplam bölüt sayısı	Kriterlerin uygulanması ile elde edilen araç sayısı	Referans araç sayısı
E 5 karayolu	127	106	111
D100 karayolu	102	96	91

Çalışmanın bu bölümünde Mean shift bölütleme ile üretilen bölütler ile Google Earth üzerinden elde edilen referans verideki gerçek araç objeleri karşılaştırılmıştır. Çizelge 4.2'de ortalama kaydırma bölütleme yönteminde kesişim analizi sonuçları verilmiştir. Bunun ardında iki farklı çalışma bölgesi için doğruluk analizi yapılmış ve mantıksal değerlendirme ile doğruluk yüzdesi hesaplanmıştır. Sonuç olarak gerçek araç objeleri tespit edilmiştir. İki çalışma bölgesinde ayrı ayrı olarak doğruluk analizleri yapılmıştır. Ortalama kaydırma bölütleme yöntemi doğruluk analizi sonuçları Çizelge 4.3'de verilmiştir.

Çizelge 4.2. Ortalama kaydırma bölütleme kesişim (overlay) analizi

Çalışma alanı	Araç Bölüt sayısı	Referans araç sayısı	Kesişmeyen referans araç sayısı	Kesişen araç/referans bölüt sayısı	Kesişmeyen araç bölüt sayısı
E 5 karayolu	127	111	5	106	21
D100	102	91	4	87	15

Gerçek pozitif (TP): Bölütleme sonucu referans veri ile kesişen araçları ifade etmektedir.

Sahte negatif (FN): Bölütleme ile tespit edilemeyen referans veride bulunan araçlar.

Sahte pozitif (FP): Bölütleme ile tespit edilen ancak referans veride olmayan araçlar.

Gerçek negatif (TN): Bölütleme ile tespit edilemeyen ve referans veride olmayan araçlar.

Çizelge 4.3. Ortalama kaydırma bölütleme yöntemi doğruluk analizi sonuçları

E5 Karayolu		Mean shift bölütleme		TOPLAM
		YOK	VAR	
Referans veri	YOK	TN 0	FP 21	21
	VAR	FN 5	TP 106	111
	TOPLAM	5	127	132
D-100 Karayolu		Mean shift bölütleme		TOPLAM
		YOK	VAR	
Referans veri	YOK	TN 0	FP 15	15
	VAR	FN 4	TP 87	91
	TOPLAM	4	102	106

E -5 Karayolunda doğruluk yüzdesi: $(100 \times TP+TN)/TOPLAM = \% 80.03$

D-100 karayolunda Doğruluk yüzdesi: $(100 \times TP+TN)/TOPLAM = \%82.07$

4.2. Nesne Tabanlı Bölütleme Sonuçları ve Doğruluk Analizi

Bilindiği üzere İki farklı çalışma alanında nesne tabanlı çoklu çözünürlüklü bölütleme yöntemi uygulanmıştır. Bu yöntemde ölçek şekil ve yoğunluk parametreleri kullanılarak bölütler üretilmiştir. Üretilen bölütler en küçük geometrik sınır fonksiyonuna tabi tutularak araç bölütleri oluşturulmuştur. Bu bölümde en küçük geometrik sınır fonksiyonun uygulanması akabinde oluşan araç bölütlerinde bütünsellik sağlamak için uygulanan kaynaştırma ve ayrışma fonksiyonu uygulanmıştır. Sonuç olarak oluşan bölütlerin araç olarak kabul edilmesi için gerekli seçim kriterlerine göre seçimler yapılmış ve sonuçta araç bölütleri elde edilmiştir. Çizelge 4.4’de Nesne tabanlı bölütleme ile üretilen bölüt sayıları gösterilmektedir.

Çizelge 4.4. Nesne tabanlı bölütleme ile üretilen bölüt sayıları

Çalışma alanı	Vektör veriden elde edilen ham veri/toplam bölüt sayısı	Kriterlerin uygulanması ile elde edilen araç sayısı kaynaştırma sonucu	Referans araç sayısı
E 5 karayolu	157	119	111
D100 karayolu	148	89	91

Çalışmanın bu bölümünde nesne tabanlı bölütleme ile üretilen bölütler ile Google Earth üzerinden elde edilen referans verideki gerçek araç objeleri kesiştirilmiştir. Çizelge 4.5’de nesne tabanlı bölütleme kesişim analiz sonuçları gösterilmiştir. Buna göre iki farklı çalışma bölgesi için doğruluk analizi yapılmış ve mantıksal değerlendirme ile doğruluk yüzdesi hesaplanmıştır. Sonuç olarak gerçek araç objeleri tespit edilmiştir. İki çalışma bölgesinde ayrı ayrı olarak doğruluk analizleri yapılmış ve sonuçlar Çizelge 4.6’da gösterilmiştir. Yapılan doğruluk analizinde yaklaşık olarak %80 oranında araçların belirlendiği görülmektedir.

Çizelge 4.5. Nesne tabanlı bölütleme kesişim (overlay) analizi sonuçları

Çalışma alanı	Araç Bölüt sayısı	Referans araç sayısı	Kesişmeyen referans araç sayısı	Kesişen araç/referans bölüt	Kesişmeyen araç bölüt sayısı
E 5 karayolu	119	111	11	100	19
D-100 karayolu	89	91	11	80	9

Gerçek pozitif (TP): Bölütleme sonucu referans veri ile kesişen araçları ifade etmektedir.

Sahte negatif (FN): Bölütleme ile tespit edilemeyen referans veride bulunan araçlar.

Sahte pozitif (FP): Bölütleme ile tespit edilen ancak referans veride olmayan araçlar.

Gerçek negatif (TN): Bölütleme ile tespit edilemeyen ve referans veride olmayan araçlar.

Çizelge 4.6. Nesne tabanlı bölütleme doğruluk analizi sonuçları

E-5 Karayolu		Çoklu Çöz. Bölütasyon		TOPLAM
		YOK	VAR	
Referans veri	YOK	TN 0	FP 19	19
	VAR	FN 11	TP 100	111
	TOPLAM	11	119	128
D-100 Karayolu		Çoklu Çöz. Bölütasyon		TOPLAM
		YOK	VAR	
Referasn veri	YOK	TN 0	FP 9	9
	VAR	FN 11	TP 80	91
	TOPLAM	11	89	100

E -5 Karayolunda doğruluk yüzdesi: $100 \times (TP+TN)/TOPLAM = \% 78.13$

D-100 karayolunda Doğruluk yüzdesi: $100 \times (TP+TN)/TOPLAM = \% 80.00$

Çalışmada ortalama kaydırma ve çoklu çözünürlüklü bölütleme yöntemleri ile elde edilen sonucun doğruluğunun %80 civarında olduğu görülmektedir. Bu algoritmalarda spektral özellikleri yanında doku, şekil, yoğunluk gibi özelliklerin kullanılması doğruluğu artıran ve piksel tabanlı sınıflandırmadan üstün kılan hususlar olarak değerlendirilmiştir.

4.3. KMeans Kontrolsüz Sınıflandırma Sonuçları ve Doğruluk Analizi

Çalışmada yapılan iki farklı bölgede KMeans algoritması yardımı ile kontrolsüz sınıflandırma yapılarak araçların belirlenmesi işlemine çalışılmıştır. KMeans algoritması bilimsel ve endüstriyel uygulamalarda en yoğun kullanılan kümeleme algoritmalarından biridir (Dinçer ve Duru 2014). Çalışmada araç kümelerinin çıkartılması amacı ile görüntülerdeki Üç KMY banları kullanılarak öncelikle sınıflandırma işlemleri için parametreleri belirlenmiş daha sonra vektörel veri ve bölütler üretilmiştir. Çizelge 4.7’de KMeans algoritması ile üretilen bölüt gösterilmektedir. Bu veriler düzenlenmiş ve seçim kriterlerine göre seçilerek araç sınıfları belirlenmiştir. Bu işlemlerin ardından çalışmanın doğruluğu araştırılmış ve referans araç verileri ile kesişim (overlay) analiz yapılmış ve Çizelge 4.8’de KMeans sınıflandırma yöntemi için kesişim doğruluk sonuçları verilmiştir. Son olarak yapılan doğruluk hesaplaması Çizelge 4.9’da KMeans algoritması sınıflandırma doğruluk analizi sonuçları ile gösterilmiştir.

Çizelge 4.7 KMeans algoritması ile üretilen bölüt sayıları

Çalışma alanı	Vektör veride elde edilen ham veri/toplam bölüt sayısı	Kriterlerin uygulanması ile elde edilen araç sayısı	Referans araç sayısı
E 5 karayolu	460	121	111
D100 karayolu	118	78	91

Çizelge 4.8. KMeans sınıflandırması kesişim (overlay) analizi sonuçları

Çalışma alanı	Araç Bölüt sayısı	Referans araç sayısı	Kesişmeyen referans araç sayısı	Kesişen araç/referans bölüt	Kesişmeye n araç bölüt sayısı
E 5 karayolu	121	111	27	84	37
D-100 karayolu	78	91	35	56	22

Gerçek pozitif (TP): Bölütleme sonucu referans veri ile kesişen araçları ifade etmektedir.

Sahte negatif (FN): Bölütleme ile tespit edilemeyen referans veride bulunan araçlar.

Sahte pozitif (FP): Bölütleme ile tespit edilen ancak referans veride olmayan araçlar.

Gerçek negatif (TN): Bölütleme ile tespit edilemeyen ve referans veride olmayan araçlar.

Çizelge 4.9. KMeans algoritması sınıflandırma doğruluk analizi sonuçları

E-5 Karayolu		KMeans sınıflandırma		TOPLAM
		YOK	VAR	
Referans veri	YOK	TN 0	FP 37	37
	VAR	FN 27	TP 84	111
	TOPLAM	27	121	148
D-100 Karayolu		KMeans sınıflandırma		TOPLAM
		YOK	VAR	
Referan veri	YOK	TN 0	FP 22	22
	VAR	FN 25	TP 56	91
	TOPLAM	25	78	113

E -5 Karayolunda doğruluk yüzdesi: $100 \times (TP+TN)/TOPLAM = \%56.76$

D-100 karayolunda Doğruluk yüzdesi: $100 \times (TP+TN)/TOPLAM = \% 49.55$

KMeans kümeleme algortması bir kontrolsüz sınıflandırma yöntemi olup, görüntüdeki çalışma alanında de yer alan bölüteleri kullanır (Dhanachandra vd 2015). Yapılan çalışmada KMeans algoritması ile yapılan sınıflandırmanın ortama doğruluk yüzdesi %53.15 olarak hesaplanmıştır. Bu değer hedeflenen değerden uzak bir değerdir. Bunun nedenlerinin şöyle olduğu düşünülmektedir. Referans veri ve sınıflandırma sonucu incelendiği zaman siyah renkli araçlarda sınıflandırma yapmadığı ve yol ile aynı sınıfa atadığı görülmektedir. yine araç ojelerinin heterojen yapıda olması spektral ve şekilsel olarak homojen objelerde daha iyi sonuç verebileceği düşünülebilir.

4.4. Doğruluk Yüzdeleri

Bölütleme işlemlerinde göre genel çalışma doğruluk yüzdesi ortalaması $(81.03+79.07)/2=80.05$ olarak hesaplanmıştır. Elde edilen doğruluk sonuçları Çizelge 4.10'de tüm yöntemlerin doğruluk yüzdeleri olarak gösterilmiştir.

Çalışmada iki farklı bölge için kullanılan KMeans kontrolsüz sınıflandırma yöntemi ile elde edilen sonuçların ortalama doğruluk yüzdesi $(56.46+49.56)/2 = 53.16$ olarak hesaplanmıştır. Yukarıdaki tablodan da anlaşıldığı üzere bölütleme işleminin çalışma doğruluğu KMeans kontrolsüz sınıflandırma doğruluk yüzdesi arasında ciddi bir fark olduğu anlaşılmaktadır.

Çalışmada açık kaynak kodlu yazılım kullanılarak yapılan ortalama kaydırma yöntemi daha iyi sonuç vermekte olup bu yöntem önerilmektedir. Bu yöntemin avantajları görüntü özelliklerine göre parametre kestirimi yapabilme, sınıflarda karışımın az olması, açık kaynak kodlu yazılım kullanılması olarak değerlendirmiştir. Dezavantajları ise raster veriden vektörel veri üremi sırasından bazı işlemlerin yapılması ve çalışma hızı olarak değerlendirilmiştir.

Nesne tabanlı çoklu çözünürlüklü yöntemin avantajları piksel tabanlı sınıflandırmadan daha iyi sonuç elde etme, doğrudan vektörel veri üretimi ve bu verilerin öznetelik bilgilerinin elde edilmesi sayılabilir. Dezavantajları ise ticari yazılım kullanımı, parametre kestiriminde en uygun parametre bulunması olduğu değerlendirilmiştir.

KMeans kontrolsüz sınıflandırmanın avantajları çalışma hızının yüksek olması, dezavantajları en uygun parametre tespiti için itreatif değerlendirme, çalışma doğrul

Çizelge 4.10. Kullanılan tüm yöntemlerin doğruluk yüzdeleri

Çalışma bölgesi	Ortala kayma bölütleme Doğruluk yüzdesi	Çoklu çözünürlüklü bölütleme Doğruluk yüzdesi	KMeans algoritması sınıflandırma Doğruluk yüzdesi.
	Önerilen Yöntem/Orfeotoolbox	Ticari yazılım /Ecognition	Kontrolsüz sınıflandırma/Envi
E 5	80.03	78.13	56.76
D 100	82.07	80.00	49.56
Ortalama	81.03	79.07	53.16

5. SONUÇLAR

Günümüzde uzaktan algılama ve coğrafi bilgi sistemleri birçok alanda kullanılmaktadır. Özellikle teknolojinin gelişmesine paralel olarak kullanılan meteryal ve yöntemlerde gelişmektedir. Son yıllarda uzaktan algılama alanında yaşanan çalışmalardan biri de nesne ve obje çıkarımı üzerinedir. Doğal ve yapay olan objeler görüntülerden çeşitli yöntemlerle çıkarılmaktadır. Bunlardan bazılar trafikte yer alan araçların takibi ve çıkarılmasıdır. Elde edilen sonuçlar

Kentleşme ve nüfus artışı birçok sorunu beraberinde getirdiği bilinmektedir. Bu sorunların en önemlilerinden biride trafik ve lojistik sorunlarıdır. Ülkemizin en önemli büyükşehri İstanbul'dur. Bu şehrimizde iki farklı çalışma bölgesinde çalışılmış ve farklı yöntemler kullanılarak trafikteki araçların çıkarılması hedeflenmiş ve sonuçları karşılaştırılmıştır.

Çalışmada trafiğin yoğun olduğu E5 karayolu ve D100 karayolundan bir bölümünün Google Earth verileri kullanılmıştır. Görüntüler bazı ön işlemlerden geçirilerek çalışma doğruluğunun ve hızının artırılması hedeflenmiştir. Ön işlemlerin ardından araç bölüt ve sınıfının oluşturulması için üç farklı yöntem uygulanmıştır. Çalışmada yapılan sınıflandırma için KMeans kontrolsüz sınıflandırma yöntemi kullanılmış, bölütleme için ortalama kaydırma ve çoklu çözünürlüklü bölütleme yöntemleri kullanılmıştır. Üretilen raster veriler vektörel veriye çevrilmiş ve doğruluk analizleri yapılmıştır.

Çalışmada KMeans algoritmasında istenilen başarı sağlanamamıştır. Bu yöntemde koyu renkli araçların yol sınıfları ile karıştığı gözlemlenmiştir. Ayrıca genelde tıp ile ilgili çalışmalarda bu algoritma kullanılmış ve başarılı sonuçlar alınmıştır. Ancak bir kümeleme algoritma olan KMeans algoritmasında daha ziyade arazi örtüsü veya çalışma alanı ile karışmayan dokularda başarılı performans verdiği görülmektedir.

Çalışmada birçok uzaktan algılama görüntü işleme tekniğinden önce uygulanan görüntülerin filtrelenmesi işlemleri yapılması ile görüntüdeki gürültü olarak tanımlanan hata unsurları minimize edilmiş ve daha doğru ve hızlı sonuç elde edilmesini sağlamıştır.

Piksel tabanlı sınıflandırma yönteminin yanı sıra görüntüdeki doku, şekil farklılığının ortaya çıkarılmasında Nesne tabanlı bölütleme denenmiştir. Çalışmada birçok obje çıkarımla ilgili çalışmalarda kullanılmakta olan çoklu çözünürlüklü bölütleme yöntemi uygulanmış ve %80 doğruluk ile karayolunda yer alan araçların çıkartıldığı ve belirlendiği görülmüştür. Çalışmada kümeleme ve obje görüntü filtreleme ilkesi ile çalışan meanshift algoritması ile araç çıkartılması işlemi sonucunda %80 üzerinde bir doğruluk elde edilmiştir. Meanshift algoritması görüntüdeki doku ve özniteliksel öbekleşmenin belirlenmesi ve bunların bölütlenmesinde kullanılmıştır. Sonuç olarak gerek meanshift gerekse çoklu çözünürlüklü bölütleme algoritmaları ile %80 doğruluk elde edilmiştir. Çalışmada UA tekniklerinin yanı sıra CBS teknikleri de kullanılmıştır. Vektörel olarak bölütlerin araç objesi olarak kabul edilmesi için trafik yönetmeliğindeki araç ebatları

temel alınmış ve belirlenen eşik değerlere uygun olanlar araç objesi olarak kabul edilmişlerdir. Buna göre araçların boyları minimum 1 metre, maksimum 19 m olacak şekilde belirlenmiştir. Bu uzunlulara göre sorgulamalar öznitelik tablolarında yapılmıştır. Yine doğruluk analizi işleminde kesişim analizleri yapılarak çalışmanın doğruluğu araştırılmıştır. Bu işlemlerle CBS teknik ve analizleri uygulanmış ve UA ile CBS eşzamanlı olarak kullanılmıştır. Çalışmada kullanılan üç ayrı yöntemin sonuçları Şekil 3.27 de gösterilmiştir.

Çalışmada bilindiği üzere Google Earth verileri ve açık kaynak kodlu yazılımlar kullanılmış ve bu anlamda uygulanabilirlikte kullanıcılara ve karar destek sistemlerine avantaj ve özgünlük katılmıştır. Google Earth verileri yardımı ile araç çıkarımına literatürde rastlanmamıştır. Ayrıca araç tespiti için kullanılan ortalama kaydırma algoritması ile obje çıkartılması literatürde fazla yer almayan bir yöntemdir. Bu veri ve yöntemin kullanılması çalışmaya özgünlük katmaktadır.



Şekil 3.27. Kullanılan yöntemlerin sonuçlarının ekran görüntüsü

6. KAYNAKLAR

- Altınbaş Ü. 2006. Yeryüzü Kaynak Potansiyelinin Uydu Verileri Bağlamında CORINE Sistemine Göre Belirlenmesi Üzerine Bir Çalışma, *Ege Üniv. Ziraat Fak. Dergisi, İzmir*
- Altuntaş C. ve Çorumluoğlu Ö. 2002. Uzaktan algılama görüntülerinde digital görüntü işleme ve Rs yazılımı, *Selçuk Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Öğretiminde 30. Yıl Sempozyumu, 16-18 Ekim 2002, Konya.*
- Akben B. ve Alkan A. 2015 Öznitelikler arası korelasyonun düşük olduğu veri kümelerinde sınıflandırma başarısını artırmak için yoğunluk temelli öznitelik oluşturma, *Gazi Üniv. Müh. Mim. Fak. Dergisi, Cilt 30.*
- Ammour N., Haikel A., Bazi Y., Benjdira B., Alajlan N. and Zuair M. 2017. Deep Learning Approach for Car Detection in UAV Imagery. Computer Engineering Department, College of Computer and Information Sciences
- Arbab A., Nasir A. and Sahipzade A. 2016. K-Means and Isodata Clustering Algorithms for Landcover Classification Using Remote Sensing, University of Engineering and Technology Peshawar,
- Ayday C., Yaman N., Sabah L. ve Sarıdöl S. 2014. CBS açık kaynak kodlu yazılım kullanılarak potansiyel bina deprem tehlikesi saptanması *Jeouzal, Antalya*
- Ayhan E., Gormus E. ve Karşı F 2003. Uzaktan Algılanmış Görüntülerde Sınıflandırma ve Analiz, [Researchgate.net/publication](https://www.researchgate.net/publication).
- Azimi S., Kurz F. and Reinartz P. 2018. Segment-And-Count: Vehicle Counting In Aerial Imagery Using Atrous Convolutional Neural Networks. *ISPRS 2018*
- Baatz, M. and Schape, A. 2004. Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation, Book, Germany.
- Bahram S., Zhang Y. and Zhong M. 2012. Automatic Moving Vehicles Information Extraction From Single-Pass Worldview-2 Imagery, *Ieee Journal Of Selected Topics In Applied Earth Observations And Remote Sensing, Vol. 5, No. 1*
- Benz U., Hofman P., Willhauck G., Lingenfelder I. and Heynen M. 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information, *ISPRS Journal of Photogrammetry & Remote Sensing 58 (2004) 239– 258.*
- Comaniciu D. and Meer P. 2002. Meanshift; A robust approach toword feaature space analysis, *IEEE Transaction on pattern analysis and machine intelligence Vol:24*
- Dhanachandra N., Manglem K. and Chanu J. 2015. Image Segmentation using KMeans Clustering Algorithm and Subtractive Clustering Algorithm, *Procedia Computer.*

- Dinçer E. ve Duru N. 2014. Gırtlak Kanseri Ameliyat Verilerinin KMeans Yöntemiyle Analizi, <https://www.researchgate.net/publication/228533122>
- Erdoğan P., Demir H. ve Kekeçoğlu M. 2018. Destek Vektör Makineleri, YSA, K-Means ve KNN Kullanarak Arı Türlerinin Sınıflandırılması, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 6 (2018) 47-67 *Science* 54 (2015) 764 771.
- Flores, A. 2005. Evaluation of the Use of High-Resolution Satellite Imagery in Transportation Applications Intelligent Transportation Systems Institute Center for Transportation Studies University of Minnesota.
- Hinz S., Schlosser C. and Reitberger J. 2003. Automatic Car Detection in High Resolution Urban Scenes Based on an Adaptive 3D-Model Chair for Photogrammetry and Remote Sensing, Technische Universität München, Arcisstr. 21, 80333 München, Germany.
- Holt A., Edmund Y., Rivard T. and Goung P. 2009. Photogrammetric Engineering & Remote Sensing Vol. 75, No:7 July 2009 pp871-800
- Guigues L. and Jamet O. 1996. Vehicle detection on aerial images: A structural approach, GueInstitut Gkographique National (IGN) 2, avenue Pasteur, Saint-Mandk, France
- IBB, 2016. www.ibb.gov.tr, (06.09.2018). Kent Ulaşım Raporu, Trafik ve araç istatistikleri ve bilgileri.
- IBB, 2018. www.ibb.gov.tr, (12.10.2018). Trafik ve araç bilgileri.
- Kalkan K. ve Maktav D. 2010. Nesne tabanlı ve piksel tabanlı sınıflandırma yöntemlerinin karşılaştırılması, *III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu*, 11 – 13 Ekim 2010, Kocaeli.
- Kavak Ş. 1998. Uzaktan Algılamanın Temel Kavramları ve Jeoloji'deki Uygulama Alanları <https://www.researchgate.net/publication/236648457>.
- KGM, 2018. www.kgm.gov.tr, (10.11.2018), Karayollarına ilişkin veriler.
- Kavzaoğlu T., Çölkesen ve Şahin E. 2015. Nesne tabanlı yaklaşımda makine öğrenme algoritmalarının sınıflandırma performansının analizi, *2015 Tufuab Konya*.
- Kavzaoğlu T. ve Tonbul H. 2017. Nesne tabanlı sınıflandırmada bölütleme kalitesinin sınıflandırma doğruluğuna etkisi, *2007 Tufuab, Afyon*.
- Leitloff J., Hinz S. and Stilla U. 2006. Automatic Vehicle Detection In Satellite Images Photogrammetry and Remote Sensing, 2 Remote Sensing Technology Technische Universitaet Muenchen, Arcisstrasse 21, 80333 Muenchen, German
- Leitloff J., Rosenbaum D., Kurz F., Meynberg O. and Peter Reinartz 2014. An Operational System for Estimating Road Traffic Information from Aerial Images, *Remote Sens.* 2014, 11, 11315-11341; doi:10.3390/rs61111315

- Lillesand T., Keifer R. and Chipman J. 2016. *Remote sensing and image interpretation 7th edition, U.S.A.*
- Lin C. and Nevatia R. 1998. Building Detection and Description from a Single IntensityImage, Institute for Robotics and Intelligent Systems University of Southern California.
- Napoleon D. and Ramaraj E. 2014. An Efficient Segmentation of Remote Sensing Images For The Classification of Satellite Data Using K-Means Clustering Algorithm, *International Journal for Innovative Research in Science & Technology| Vol. 1*
- Neubert M. and Herold H. 2008. Assessment of remote sensing image segmentation quality, roceedings Geobia, Calgary, Canada
- Özyazıcı A. ve Türker M. 2007. Fiel based Classification of Different Resolution Images and the Filtering Effects on the Accuracies 3 rd *International Conference on Recent Advanced in Space Technologies –Rast 2007*
- Qgis ve orfeotoolbox . www.qgis.org.tr. (08.10.2018)
- Quyang Z. 2015. Object-Based Classification & ECognition software book.
- Shrivastava N. and Rai K. 2015. Automatic building extraction based on multiresolution segmentation using remote sensing data, Indian Institute of Remote Sensing, Dehradun
- Solak S. ve Altınışık Ü. 2018. Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22 (1), 56–65, Sakarya
- Talu F. ve Türkoğlu İ. 2010. Ortalama kaydırma Algoritması Kullanılarak Gerçek Zamanlı Çekirdek Tabanlı Nesne Takibi, 18.Sinyal işleme ve iletişim uygulamaları kurultayı – Diyarbakır
- Tso B. and Mather P. 2009. Classification Methods for Remotely Sensed Data, Book, London, England
- Tuermer S., Leitloff J., Reinartz P. and Stilla U. 2010. Automatic Vehicle Detection In Aerial Image Sequences Of Urban Areas Using 3d Hog Features, Remote Sensing Technology Institute, Germany
- TUIK 2018. www.tuik.gov.tr, Nüfus ve bütçe verileri.(01.10.2018)
- Tsai Y., Huang Y. and Chen L. 2011. An intelligent vision-based vehicle detection and tracking system for automotive applications, *IEEE InternationalConference on Consumer Electronics (ICCE)*.
- Vallabhaneni B. and Rajesh V. 2018. Brain tumour detection using mean shift clustering and GLCM features with edge adaptive total variation denoising technique, *Alexandria Engineering Journal*.

- Yomralioğlu T. 2000. Coğrafi Bilgi Sistemleri Temel Kavramlar ve Uygulamaları Kitabı,
- Zang J., Duan M., Yan Q. and Lin X. 2014. Automatic Vehicle Extraction from Airborne LiDAR Data Using an Object-Based Point Cloud Analysis Method, *Remote Sensing*, ISSN 2072-4292.

ÖZGEÇMİŞ

Mustafa KAYNARCA

mustafakaynarca78@gmail.com



ÖĞRENİM BİLGİLERİ

Yüksek Lisans 2016-2019	Akdeniz Üniversitesi Fen Bilimleri, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı, Antalya
Lisans 1997-2002	Yıldız Teknik Üniversitesi İnşaat Fakültesi, Jeodezi ve Fotogrametri Mühendisliği, İstanbul

MESLEKİ VE İDARİ GÖREVLER

Mühendis 2008-Devam Ediyor	ASAT Genel Müdürlüğü Etüt ve Plan Dairesi Başkanlığı
-------------------------------	---

ESERLER

Ulusal bilimsel toplantılarda sunulan ve bildiri kitaplarında basılan bildiriler

- 1- Kaynarca M. (2011). Antalya Altyapı Bilgi Sistemi Uygulamaları, Coğrafi Bilgi Sistemleri Kongresi (Bildiri)
- 2- Kaynarca M. (2013). ASAT Genel Müdürlüğü Altyapı Bilgi Sistemi Uygulamaları, Coğrafi Bilgi Sistemleri Kongresi (Poster).
- 3- Kaynarca M. ve San Koç D. (2015). Karacaören içmeuyu havzasının arazi kullanımının/örtüsünün ve koruma kuşaklarındaki durumun Landast8 uydu görüntülerinden belirlenmesi, Jeolojik uzaktan algılama sempozyumu (Bildiri)

- 4- Demir N. and Kaynarca M. and Selim O. (2016).Extraction of coastlines with fuzzy approach using Sentinel-1 Sar images, Isprs (Bildiri)
- 5- Demir N. and Kaynarca M. (2017). Nesne tabanlı sınıflandırma ile karayolunda bulunan araçların tespiti, Tufuab (Bildiri)