

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

JEODEZİ VE JEODİFORMASYON MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

LİDAR VERİLERİ İLE DESTEKLENMİŞ ORTOFOTO
GÖRÜNTÜLERİNDEN BİNA TESPİTİ PERFORMANS
DEĞERLENDİRMESİ

VURAL GERİM

KOCAELİ 2019

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

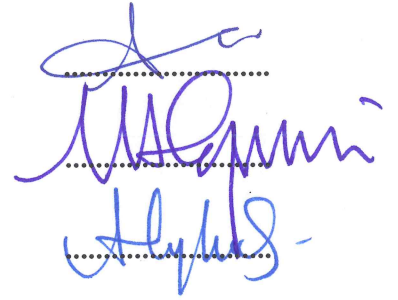
JEODEZİ VE JEODİNFORMASYON MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

LİDAR VERİLERİ İLE DESTEKLENMİŞ ORTOFOTO
GÖRÜNTÜLERİNDEN BİNA TESPİTİ PERFORMANS
DEĞERLENDİRMESİ

VURAL GERİM

Doç. Dr. Arzu ERENER
Danışman, Kocaeli Üniv.
Doç. Dr. Murat Selim ÇEPNİ
Jüri Üyesi, Kocaeli Üniv.
Dr. Öğr. Üyesi Arzu Taylan SUSAN
Jüri Üyesi, Bursa Teknik Üniv.



Tezin Savunulduğu Tarih: 29.05.2019

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışması ile Coğrafi Bilgi Sistemleri (CBS), ortofoto, LİDAR, halihazır haritalar ve arazi çalışmalarından elde edilen bilgilerle oluşturulan model yardımıyla bina tespitinin performans değerlendirilmesi gerçekleştirilmiştir.

Bu çalışmanın yürütülmesi sırasında desteğini esirgemeyen, çalışmalarına yön veren, bana güvenen ve yüreklendiren danışman hocam Doç. Dr. Arzu ERENER'e teşekkür ederim.

Yoğun çalışmalarım sırasında bana güç veren, her aşamada sıkıntılarımı ve mutluluklarımı paylaşan sevgili eşim Emine GERİM, sürekli çalışmama izin verdiği için kızım Eylül GERİM'e, çalışmalarım sırasında ümit verdiği ve destek olduğu için kardeşim Birol GERİM'e sonsuz teşekkürlerimi sunarım.

Akademik çalışmalarım sırasında görüşleri ile çalışmalarına katkıda bulunan, karşılaştığım her zorlukta desteğini ve zamanını esirgemeyen Jeodezi ve Jeoinformasyon Mühendisliği Bölümündeki tüm hocalarıma teşekkür ediyorum.

Mayıs – 2019

Vural GERİM

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iii
TABLolar DİZİNİ	v
SİMGELER VE KISALTMALAR DİZİNİ	vi
ÖZET.....	viii
ABSTRACT	ix
GİRİŞ	1
1. GENEL BİLGİLER.....	6
1.1. Uzaktan Algılama (UA)	6
1.1.1. LİDAR.....	7
1.1.2. Görüntü sınıflandırma yöntemleri	9
1.1.2.1. Destek vektör makinesi (DVM).....	11
1.1.2.2. En büyük olasılık yöntemi (EBO)	15
1.1.3. Sınıflandırma doğruluğu	16
1.2. Coğrafi Bilgi Teknolojileri	16
2. AMAÇ VE KAPSAM	19
3. METODOLOJİ.....	21
3.1. Çalışma Alanı ve Kullanılan Veriler	23
4. UYGULAMA.....	26
4.1. Ortofoto ile Bina Tespiti.....	26
4.2. LİDAR Ek Bandı Oluşturulması ve Bina Tespiti.....	31
4.2.1. LİDAR verisi ön analizleri ve modelleme	31
4.2.2. nSYM modelinin oluşturulması	35
4.3. LİDAR Verilerinin Yardımı İle Bina Tespiti	36
5. DOĞRULUK ANALİZİ	39
6. PERFORMANS DEĞERLENDİRİLMESİ	41
7. SONUÇLAR VE ÖNERİLER	44
KAYNAKLAR	48
KİŞİSEL YAYINLAR VE ESERLER	51
ÖZGEÇMİŞ	52

ŞEKİLLER DİZİNİ

Şekil 1.1.	LİDAR sisteminin genel yapısı	9
Şekil 1.2.	Doğrusal olarak ayrılabilen iki sınıflı DVM ve optimum hiperdüzlem.....	12
Şekil 1.3.	Doğrusal olarak ayrılamayan iki sınıflı DVM ve optimum hiperdüzlem.....	13
Şekil 3.1.	Çalışma akış şeması, OV*B1,B2,B3: Ortofoto Verisi ve 3 bandı, OV**B1,B2,B3,3BV: 3 Boyut Verisi eklenmiş ortofoto verisi	21
Şekil 3.2.	Çalışma alanı İstanbul Küçükçekmece ilçesi	23
Şekil 3.3.	Ham LİDAR verisine ait farklı profil kesitlerine ait görüntüler	24
Şekil 4.1.	Çalışma alanındaki farklı bina özellikleri a.1. Yeşil çatılı sanayi binası, 2. Kırmızı çatılı orta boyutta apartman, 3. Yeşil çatılı orta boyutta apartman b.4. Çatısız orta boyutta beton bina 5. Metal çatılı ince uzun bina 6. Kiremit rengi çatılı orta boyutta bina	27
Şekil 4.2.	Çekim açısı dolayısı ile oluşan bina önü ve yola düşen gölge alanlar (1, 2, 3, 4)	28
Şekil 4.3.	Örnekleme eğitim sınıfları a. Bina, b. Yol	28
Şekil 4.4.	Örnekleme eğitim sınıfları c. Yeşil alan, d. Araç	28
Şekil 4.5.	a. Ortofoto b. EBO ile sınıflandırılmış ortofoto verisi (OV B1,B2,B3).....	29
Şekil 4.6.	a. Ortofoto b. DVM ile sınıflandırılmış ortofoto verisi (OV B1,B2,B3).....	29
Şekil 4.7.	a. Ortofoto b. EBO ile sınıflandırılmış ortofoto verisi kesiti.....	30
Şekil 4.8.	a. Ortofoto b. EBO ile sınıflandırılmış ortofoto verisi kesiti.....	30
Şekil 4.9.	a. Ortofoto b. DVM ile sınıflandırılmış ortofoto verisi kesiti	30
Şekil 4.10.	a. Ortofoto b. DVM ile sınıflandırılmış ortofoto verisi kesiti	30
Şekil 4.11.	Çalışma alanı a. Ortofoto görüntüsü, b. .shp nokta bulutu.....	31
Şekil 4.12.	TIN üçgen mozağı ile fiziksel arazi yüzeyinin temsili a. Ortofoto görüntü, b. TIN modeli	33
Şekil 4.13.	a. Ortofoto görüntü, b. SAM modeli	34
Şekil 4.14.	a. Ortofoto görüntü, b. DVM modeli	35
Şekil 4.15.	SAM, DVM, nSYM	35
Şekil 4.16.	Çalışma alanı, a. Ortofoto b. nSYM.....	36
Şekil 4.17.	a. Ortofoto b. DVM ile sınıflandırılmış ek bant eklenmiş ortofoto verisi (OV B1,B2,B3,3BV)	37
Şekil 4.18.	a. Ortofoto b. EBO ile sınıflandırılmış ek bant eklenmiş ortofoto verisi (OV B1,B2,B3,3BV)	37
Şekil 4.19.	a. EBO ile sınıflandırılmış ortofoto verisi (OV B1,B2,B3), b. EBO ile sınıflandırılmış ek bant eklenmiş ortofoto verisi (OV B1,B2,B3,3BV)	38

Şekil 4.20.	a. DVM ile sınıflandırılmış ortofoto verisi (OV B1,B2,B3), b. DVM ile sınıflandırılmış ek bant eklenmiş ortofoto verisi (OV B1,B2,B3,3BV)	38
Şekil 6.1.	a. Bina taban izi haritası, b. Sınıflandırılmış görüntü.....	42



TABLULAR DİZİNİ

Tablo 1.1.	Kernel türleri ve matematiksel ifadeleri.....	14
Tablo 1.2.	Kernel ve sahip olunan parametreler.....	15
Tablo 3.1.	Çalışma alanında kullanılan veriler.....	24
Tablo 5.1.	Sınıflandırma performansı, Hata matrisi.....	40
Tablo 6.1.	Farklı haritalara ait bina alanları ve doğruluk analizi sonuçları.....	42



SİMGELER VE KISALTMALAR DİZİNİ

a_b	: Aday pikselin b sınıfına ait olma yüzdesi
b	: Bias (eğilim değeri)
$^{\circ}C$: Santigrat derece
C	: Düzenleme (penaltı) parametresi
Cov_b	: b sınıfının kovaryans matrisi
d	: Polinom derecesi
D	: Olasılık değeri
$f(x)$: x bilinmeyenli fonksiyon
$f(x) = \text{sign}$: Karar fonksiyonu
$K(x, x_i)$: Kernel fonksiyonu
M_b	: b örneğin sınıfının ortalama vektörü
γ	: Gama
ξ_i	: Yapay değişken
λ_i	: Lagrange çarpanları
x_i	: Hiperdüzlem üzerindeki nokta
w	: Hiperdüzlemi normali
y_i	: Sınıf etiketleri

Kısaltmalar

ABD	: Amerika Birleşik Devletleri
ALS	: Airborne Based (Hava Platform Temelli)
CBS	: Coğrafi Bilgi Sistemleri
cm	: Centimeter (Santimetre)
.dgn	: Design (Dizayn)
DVM	: Destek Vektör Makineleri
DSM	: Digital Surface Model (Digital Yüzey Modeli)
DTM	: Digital Terrain Model (Digital Arazi Modeli)
EBO	: En Büyük Olasılık Yöntemi
GIS	: Geographical Information Systems (Coğrafi Bilgi Sistemleri)
GPS	: Global Positioning System (Global Konumlandırma Sistemi)
IMU	: Inertial Measurement Unit (Atalet Ölçü Birimi)
İSTAÇ A.Ş	: İstanbul Çevre Yönetimi Sanayi ve Ticaret Anonim Şirketi
las	: Laser (Lazer)
LİDAR	: Light Detection and Ranging (Işık Algılama ve Değişme)
m	: Meter (Metre)
MLC	: Maximum Likelihood Classifier (Maksimum Olasılık Sınıflandırması)
mm	: Millimeters (Milimetre)
nDEM	: Normalize Digital Elevation Model (Dijital Yükseklik Modelini Normalleştir)
NDVI	: Normalized Difference Vegetation Index (Normalize Fark Vejetasyon İndeksi)

nDSM	:	Normalized Digital Elevation Model (Normalize Edilmiş Digital Yüzey Modeli)
nSYM	:	Normalize Edilmiş Sayısal Yükseklik Modeli
.shp	:	Shape (Şekil)
SAM	:	Sayısal Arazi Modeli
SAR	:	Synthetic Aperture Radar (Sentetik Açıklıklı Radar)
SYM	:	Sayısal Yüzey Modeli
TDD	:	Toplam Doğruluk Değeri
TIN	:	Triangulated Irregular Network (Düzensiz Üçgen Modeli)
tiff	:	Tagged-Image File Format (Etiketli Resim Dosyası Biçimi)
UA	:	Uzaktan Algılama
YRA	:	Yapısal Risk Azalımı
WLC	:	Weighted Linear Combination (Ağırlıklı Doğrusal Kombinasyon)



LİDAR VERİLERİ İLE DESTEKLENMİŞ ORTOFOTO GÖRÜNTÜLERİNDEN BİNA TESPİTİ PERFORMANS DEĞERLENDİRMESİ

ÖZET

Kent yönetiminde, yapılaşmaların takip edilmesi, kentsel değişimlerin zamansal izlenmesi ve mevcut veri tabanının kısa sürede güncellenmesi kontrol ve karar verme süreçleri için oldukça önemlidir. Şehirlerde dönüşüm projelerinin yürürlüğe girmesi ile birlikte mevcut binalara ait güncel hızlı ve doğru veriye olan ihtiyaç daha da artmıştır. UA (Uzaktan Algılama) ve CBS (Coğrafi Bilgi Sistemleri), kentlerin kısa sürede haritalanması ve görüntülenmesi bakımından oldukça kolaylıklar sunan modern araç ve tekniklerdir. Yüksek çözünürlüklü uydu görüntülerinden yarı ya da tam otomatik nesne çıkarımı, yansımaların benzerlik taşıdığı, tonal farklılıkların düşük olduğu, sık bina yapılarının bulunduğu alanlarda oldukça zor olmaktadır. Bu nedenle bu tür problemlere çözüm oluşturacak yöntemlere gerek duyulmaktadır. LİDAR, bina tespitinin otomasyonunda ve 3B topoğrafik veri tabanlarının oluşturulmasında önemli bir role sahip olabilmektedir.

Bu kapsamda bu çalışmanın hedefi, Marmara havzası, İstanbul Küçükçekmece bölgesinde yer alan binaların belirlenme performansının LİDAR verisi ile desteklenmiş ortofoto görüntülerinden uzaktan algılama ve CBS teknikleriyle tespit edilmesini sağlamaktır. Performans karşılaştırması iki farklı kapsamda yapılmıştır. Bunlar sırası ile alana ait ortofoto görüntüsü üzerinden farklı sınıflandırma yöntemleri ile performans değerlendirmesi ve LİDAR nokta bulutundan elde edilmiş 3B verisinin ek bant olarak ortofoto verisine eklenmesi sonucu performans değerlendirmesidir. Çalışmada hücre tabanlı ve makine öğrenmesine dayalı iki farklı sınıflandırma yöntemi uygulanmıştır. Bunlar En Büyük Olasılık Sınıflandırma (EBO) ve Destek Vektör Makinaları (DVM) sınıflandırma yöntemleridir. Ayrıca LİDAR nokta bulutu yardımı ile normalize edilmiş sayısal yükseklik modeli (nSYM) oluşturulmuş ve 3B ek bant bilgisi olarak ortofoto görüntüsüne eklenmiştir. Yapılan çalışma sonucunda, EBO algoritmasına göre DVM sınıflandırma yönteminin performansının daha yüksek olduğu, ayrıca 3B bilgisi ek bant olarak eklenmiş verinin mevcut bant sınıflandırmasına göre daha etkili olduğu belirlenmiştir.

Anahtar Kelimeler: Bina Tespiti, CBS, DVM, EBO, LİDAR.

BUILDING DETECTION PERFORMANCE EVALUATION OF ORTHOPHOTO IMAGES SUPPORTED BY LIDAR DATA

ABSTRACT

In urban management, monitoring of the developments, timely monitoring of urban changes and updating of the existing database in a short time is very important for control and decision making processes. With the entry into force of transformation projects in cities, the need for up-to-date fast and accurate data for existing buildings has increased further. UA (Remote Sensing) and GIS (Geographic Information Systems) are modern tools and techniques that offer a lot of convenience in terms of mapping and visualization of cities in a short time. Semi-or full-automatic object extraction from high-resolution satellite images is very difficult in the areas where reflections are similar, tone differences are low, and frequent building structures are present. Therefore, methods are needed to solve such problems. LIDAR can play an important role in the automation of building detection and in the creation of 3D topographic databases.

In this context, the aim of this study is to detect the determination performance of the buildings located in the Küçükçekmece area of the Marmara basin by using remote sensing and GIS techniques from the orthophoto images supported by LIDAR data. These are the performance evaluation with different classification methods based on the orthophoto image of the field, and the performance evaluation as a result of the addition of the 3D data obtained from the LIDAR point cloud to the orthophoto data as an additional band. In the study, two different classification methods based on cell-based and machine learning were applied. These are the Maximum Likelihood Classification (MLC) and Support Vector Machines (SVM) classification methods. In addition, the digital elevation model (nDSM) which was normalized with the help of LIDAR point cloud, was created and added to the orthophoto image as a 3D band information. According to the results of the study, it was realized that the performance of Support Vector Machines (SVM) method is higher than Maximum Likelihood Classification (MLC) algorithm, also, the 3D information data added as an additional band was more effective than current band classification.

Keywords: Building Determination, GIS, SVM, MLC, LIDAR.

GİRİŞ

Şehirler her zaman ekonomik faaliyetlerin yoğunlaştığı ve toplumsal değişimlerin yaşandığı önemli mekanlar olarak geçim kaynakları için fırsatlar oluşturmuşlardır. Sanayileşmesini tamamlamış Batı ülkelerinde, kentlerin daha düzenli geliştikleri ve kentsel nüfus artışının nispeten yavaşladığı günümüz dünyasında, gelişmekte olan ülkelerin sanayileşme ve kentleşme sürecinin devam ettiği görülmektedir. Gelişmekte olan ülkelere kentsel nüfus artışı kontrolsüz bir şekilde artarken, kentlerin büyümesi de kontrol edilemediğinden, ekonomik ve kentsel gelişimlerini sürdürülebilir hale getirmekte yeni ve farklı zorluklarla karşılaşmaktadırlar [1]. Bu ülkelerde hızlı kentleşmenin bir sonucu olarak kentsel yaşam seviyesinin düşük seviyelerde kaldığı gözlenmektedir.

Kentsel yaşam kalitesinin iyileştirilmesi, şehir planlaması ile yakından ilişkilidir. Şehir Planlama, kentlerde kaliteli bir yaşam sağlamak için kentsel gelişimi yönlendirmek ve yönetmek üzere benimsenen hedeflere ulaşmak için alternatif politika seçeneklerini belirlemek ve değerlendirmekle ilgilidir. Bunun için planlama sürecinde, kentsel mekanı nicel ve nitel olarak analiz etmeyi sağlayan araştırma yöntem ve tekniklerini kullanmaktadır. Buna göre şehrin planlanması, yönetim, mühendislik, mimarlık, ekonomi, tarih, sosyoloji, coğrafya, çevre, kamu yönetimi, istatistik, demografi, hukuk, psikoloji gibi farklı alanlarda uzmanları içeren multidisipliner bir yaklaşım gerektirmektedir.

Gelişmekte olan ülkelere şehirlerin alansal olarak büyümesine ve kentsel nüfusun hızlı artışına rağmen, kentsel yaşam kalitesi düşük seviyelerdedir. Şehirlerde iyi bir yaşam kalitesi için akıllı büyümeler gerekmektedir.

Son yıllarda ise, şehir planlamada bilgi teknolojilerinin kullanılması yoluyla akıllı kentler ve akıllı büyüme modelleri geliştirilmektedir. Özellikle CBS (Coğrafi Bilgi Sistemleri), GPS (Global Positioning System) ve UA (Uzaktan Algılama), kentsel gelişimin zamansal takibi, farklı bilgilerin bir arada değerlendirme olanağı ile planlanması ve kentlerin kısa sürede haritalanması ve görüntülenmesi bakımından

oldukça kolaylıklar sunan modern araç ve tekniklerdir. Buna göre, CBS yardımıyla, aynı çalışma alanına ait elde edilen farklı bilim alanlarındaki dijital haritaların bir arada değerlendirilmesi ile fiziksel, sosyal, kültürel, ekonomik ve diğer fenomenleri inceleme ve bilgi üretme olanağı elde edilebilmektedir. Farklı zaman dilimlerindeki uydu görüntüleri, hava fotoğrafları ve taranmış haritalar vektörel verilerin elde edilmesi için altlık olarak kullanılabilen, bu kapsamda sayısallaştırılıp öznelik verileri elde edilebilmekte, mekânsal ve zamansal analizler için veri tabanı yönetim yazılımları yardımıyla bir araya getirilip birleştirilebilmektedir. Ayrıca son dönemlerde oldukça yaygın kullanım alanı bulmaya başlayan LİDAR teknolojisi de, doğru coğrafi bilgi üretmek için oldukça önemli bir veri kaynağı haline gelmiştir. LİDAR, bina tespitinin otomasyonunda ve 3B yeryüzü üstü nesnelere ve topoğrafik veri tabanlarının oluşturulmasında önemli bir role sahip olabilmektedir. Bu çalışmada ise uzaktan algılama yöntemlerinden LİDAR verisi, ortofoto görüntüleri ve CBS teknolojileri kullanılarak bina tespitinde performans değerlendirmesi yapılmıştır. Bu kapsamda farklı sınıflandırma yöntemleri ile ortofoto görüntülerinden ve ortofoto görüntülerine ek bant olarak eklenen LİDAR verileri ile ayrı ayrı analizler yapılarak elde edilen sonuçlar CBS ortamında karşılaştırılmıştır. Elde edilen sonuçların bina performansı değerlendirmesindeki etkisinin tespiti için yer gerçeği verileri ile doğruluk analizi gerçekleştirilmiştir.

Çalışma kapsamında kullanılacak tekniklere yönelik literatürde yapılmış yerli ve yabancı birçok çalışma bulunmaktadır. Literatür çalışması kapsamında bu çalışmalardan bazıları sunulmuştur.

Kontrollü sınıflandırma ve Hough dönüşüm ile Lee ve ark. İkonos görüntülerinden binaları çıkarmak için yeni bir yöntem sunmaktadır. Önerilen model yapılarının, doğru ve detaylı bina çatıları seti elde etmek için denetlenen sınıflandırma yöntemine bağlı olduğunu göstermişlerdir [2].

Erener, çalışmasında bina tespitinde en yaygın kullanılan iki farklı sınıflandırma algoritmalarından MLC ve DVM yöntemlerinin performansını basitten kompleks yapıya sahip altı farklı kentsel bölgede karşılaştırmıştır. Çalışmada performans karşılaştırması için Quickbird görüntülerine temel bileşenler ve yoğunluk görüntüleri

ek bant olarak eklenmiş, hücre tabanlı ve nesne tabanlı doğruluk değerlendirmeleri ile farklılıklar ortaya konulmuştur [3].

Ayrıca, İnglada insan yapımı nesnelere yüksek çözünürlüklü optik uzaktan algılama görüntülerinden tespit etmek için geometrik görüntü özelliklerini, destek vektör makineleri sınıflandırmasında (DVM) kullanmıştır. DVM'yi öğrenmek için sadece SPOT 5 uydu görüntülerinin orijinal bantlarını kullanmıştır. Daha sonra, NDVI, nDSM gibi ek bantlar ve çeşitli doku ölçüleri ek olarak kullanılmıştır. Ek bantların bir etkisi olarak, bina algılama metodunun doğruluğunun yaklaşık yüzde on oranında arttığı görülmüştür [4].

Yastıklı LİDAR ve hava fotoğraflarının füzyonu ile nesne tabanlı sınıflandırma yöntemini kullanarak otomatik bina çıkarımı gerçekleştirmiştir. Bu amaca ulaşmak için bulanık mantığa dayalı sınıflandırma, farklı segmentasyonlar NDVI ve Hough dönüşümü ile yardımcı veri setleri üretimini ve analizlerini içeren kural setleri gerçekleştirmişlerdir. Çalışmanın sonunda doğruluk analizi ve değerlendirmeler yapılmıştır. Bu şekilde kentsel alanlara ilişkin geliştirilen kural setleri ve geliştirilen yöntemin, kaçak yapılaşmanın takibi ve önlenmesi, doğal afet ve kriz yöntemi gibi önemli birçok alanlarda kullanılabileceğini ispatlamışlardır [5].

Sefercik ve ark. yaptıkları çalışmalarında yüksek çözünürlüklü Quickbird uydu görüntüleri kullanarak otomatik bina tespiti performansının artırılmasına yönelik yeni bir yaklaşım sunmuşlardır. Çalışmada Türkiye'nin her bölgesine ait mevcut olan hava fotoğraflarından normalize sayısal yüzey modelleri (nDSM) üreterek uydu görüntülerinden otomatik bina çıkarımında yükseklik verisi sağlanmış bu veri segmentasyon aşamasında ağırlığı düşük bir bant olarak eklemiştir. Çalışma sonucuna göre uygulamanın doğruluğu %24, tamlığının %2,5 ve genel kalitesinin %22,7 oranında arttığını söylemişlerdir. Ayrıca referans hava fotoğraflarındaki binaların alansal büyüklüğünden olan farkında %21,64'ten %8,54'e düştüğünü ispatlamışlardır [6].

Miller ABD Stafford eyaletinde yapılan çalışmada LİDAR verisini kullanarak bina sınırlarını belirlemeye çalışmıştır. Çalışmanın sonuçlarına göre istatistiksel analizler geleneksel zamanlı etkisiz ve maliyetli fotogrametrik süreçleri yerine

koyma ya da takviye etme yaklaşımı konusunda büyük bir katkı sağlanmasını göstermektedir [7].

Kausika ve ark. yaptıkları çalışmalarında yüksek çözünürlüklü LİDAR verilerini ve Coğrafi Bilgi Sistemlerini kullanarak güneş fotovoltaik potansiyelini tahmin etmek için bir çalışma modeli sunmuşlardır. Çalışmanın yeniliği, yüksek çözünürlükteki potansiyeli tahmin etmek ve çatının güneş ışınlama, eğim ve yönlendirme gibi faktörlere dayanan güneş fotovoltaik tesisler için uygun olup olmadığı sınıflandırmasını belirlemeye çalışmıştır. Hollanda'da Apeldoorn şehrini çalışma alanı olarak seçmişlerdir. Modelin, çatı katında fotovoltaik tesisler için uygun yerleri başarıyla bulabildiğini, ek olarak, tesisler için uygun alan ve potansiyel güç çıkışının da hesaplandığını ispatlamışlardır [8].

Yang ve ark. yaptıkları çalışmalarında, 1 ila 60 m LİDAR DEM'lerin akım karakterizasyonu üzerindeki etkisini incelemişlerdir. DEM bazlı hidrografik ekstraksiyon işleminin daha hassas bir çözünürlükte daha ayrıntılı hidrografik özellikler sunduğunu bulmuşlardır. Bilinen kanal konumu ve modellenen konumlar arasındaki RMSE genellikle daha büyük hücre boyutu DEM ile artmıştır. Sinüsiyona ilişkin duyarlılık analizleri, LİDAR data'dan elde edilen akış biçimlerinin, referans verisi ile en iyi çözünürlükte olan en yüksek çözünürlük yerine ara hücre boyutunda en iyi şekilde eşleştiğini göstermişlerdir [9].

Tooke, Coops, Webster, yaptıkları çalışmalarında rastgele makine öğrenme yaklaşımı kullanarak çok sayıda bina için bina yaşı ve enerji performansının öngörülmesini arttırmak için havadan alınan ışık algılama ve değişken (LİDAR) verilerinin kullanımı incelemişlerdir. Kanada'da bir yerleşim bölgesi için analiz yapılmıştır. Belediyelere sunulan mekânsal verilerin artan karmaşıklığını temsil etmek için dört ayrı model geliştirmişlerdir. Sonuçlar, yalnızca LİDAR'dan türetilmiş bina özelliklerini kullanan rastgele orman modelinin, 16,8 yıllık ortalama hata (RMSE) ve açıklanan varyansın % 33,5 ile yaşını öngördüğünü görülmüştür. Tüm özellikler çeşitli veri kümelerinden birleştirildiğinde, modelin öngörücü kapasitesinin %20 arttığı ve ortalama hatanın 15,8 yıla düştüğünü gözlemlemişlerdir. Ayrıca, değişken öneminin incelenmesi, LİDAR verilerinden türetilen ortalama bina yüksekliğinin, yaş tahmini için en önemli özellik olmasına rağmen, sıralanan üç

değişkenin, LİDAR'a dayalı olmayan özelliklerle ilişkili olduğunu göstermiştir. Seçici tahmin değişkenleri ile bina yaşı arasındaki gözlemlenebilir eğilimler ve bina enerji modellemesi ve simülasyon çabaları için sonuçlar tartışılmıştır [10].

Zolkos, Goetz, Dubayah yaptıkları çalışmalarında, karasal vejetasyonun biokütlesini tahmin etmek ve aynı zamanda ormansızlaşma ve orman bozulması (REDD) ile ilişkili karbon emisyonlarını azaltma üzerindeki etkisini incelemişlerdir. Farklı uzaktan algılama kullanarak 70'ten fazla hakemli makaleden rapor edilen biokütle doğruluğu tahminlerinin bir analizini yapmışlardır. Biokütlenin uzaktan algılanmasının ilk meta-analizi LİDAR'ın diğer sensörlerden daha doğru olduğunu göstermişlerdir [11].

Næsset, Bollandas, Gobakken, Gregoire, Stahl yaptıkları çalışmalarında, Ormansızlaşma ve gelişmekte olan ülkelerde orman bozulmasından (BM REDD) gelişmekte olan ülkelerde orman karbon kaybından emisyonlarını azaltmak için kapasite gelişimine katkıda bulunmak amacıyla çalışma başlatmışlardır. Bu çalışmanın amacı “duvardan duvara” LİDAR verilerinin değişim tahmini için nasıl kullanılabileceğini, “ormansızlaşma”, “bozulma” ve “el değmemiş” gibi insan faaliyetlerini temsil eden kategorilerin alan değişiklikleri için tahmincilerin sunulduğu. Karşılık gelen varyans tahmin edicilerin de sağlandığı. Ayrıca, tanımlanmış aktivite kategorileri ve tüm ilgi alanı için biyoküttele net değişimin, LİDAR uzaktan algılama verilerini destekleyen ve içermeyen bir saha örneklem araştırmasından tahmin edilebildiği ve belirsizliğin karşılık gelen varyans tahminleriyle nasıl ölçülebildiği gösterilmiştir. Yapılan çalışmalar sonucunda ormansızlaşma ve bozulma alanının LİDAR ile model yardımlı tahmin, %18–84 oranında azaltılmış standart hata sağladığından dolayı LİDAR destekli tahmini önermişlerdir [12].

1. GENEL BİLGİLER

1.1. Uzaktan Algılama (UA)

Uzaktan algılama, uydu teknolojilerini kullanan bir teknolojidir. Tanım olarak; yeryüzündeki doğal ya da yapay objelerin, uydulara yerleştirilen sensörler yardımı ile algılanmasıdır. Temel prensip, yeryüzündeki objelerden yansıyan elektromanyetik enerjinin, uydu sensörleri vasıtası ile algılanmasıdır. Elde edilen veriye göre yeryüzü objelerinin analizi gerçekleştirilir. Bugün, yeryüzünün fiziksel yapısı hakkındaki pek çok bilgi, uzaktan algılama teknikleri ile elde edilmektedir. Uydu görüntüleri bu tekniğin temel veri kaynaklarıdır. Kullanıcıların bu tür verilere ihtiyacı gittikçe artmaktadır. Bu nedenlerden dolayı, uzaktan algılama özellikle gelişmekte olan ülkeler için değerli bir veri kaynağıdır. Bu teknoloji ile geniş alanların görüntüleri elde edilebilmekte, bu sayede ekonomik yoldan güncel veriye ulaşılmaktadır. Uydu görüntüleri, ülkemizde, başta yasal olmayan hızlı yapılaşmanın takibi olmak üzere, kentleşmenin, yerleşim bölgelerinin, orman alanlarının, baraj havzalarının ve yapılaşmanın takibinde, tarım ürünlerinin rekoltesinin tahmini gibi uygulamalarda kullanılmaktadır [13].

UA yoluyla elde edilmiş görüntüler yeryüzüne ait birçok bilgiyi içinde barındırır. Bu bilgiler yeryüzünden yansıyan elektromanyetik enerjinin uyduların alıcıları tarafından algılanarak çeşitli bantlara kaydedilmesi yoluyla toplanır. Her bir bantta o bandın hassasiyet gösterdiği özelliklere ait yansıma değerleri bulunur. Birden fazla bant bir araya gelerek bir görüntü oluşturabildiği gibi, tek bir banttan oluşan görüntüler de mevcuttur [14].

UA metotları ile elde edilen uydu görüntüleri, şehirsiz bölgelerde arazi örtüsü bilgilerini geniş ve kesintisiz olarak kaydedebilmektedir. Yüksek mekânsal çözünürlüklü görüntülerden bir kentsel alanda bulunan binalar birbirinden farklı olarak algılanabilir. Bu sebeple, yüksek çözünürlüklü uydu görüntüleri, orta çözünürlüklü uydu görüntülerine göre tanımlanması zor olan binaların zemin taban alanları ve konumlarını elde etmek için oldukça yararlıdır.

Ayrıca son dönemlerde oldukça yaygın kullanım alanı bulmaya başlayan LİDAR teknolojisi de, UA metotları ile doğru coğrafi bilgi üretmek için oldukça önemli bir veri kaynağı haline gelmiştir.

1.1.1. LİDAR

Bugün dünya nüfusunun yarısından fazlası kentsel alanlarda yaşamakta olup dünyanın dört bir yanındaki büyük şehirler mekânsal anlamda yayılmaya ve daha fazla nüfuslu hale gelmeye başlamaktadır. Bu bağlamda şehir planlaması, kriz yönetimi, görselleştirme, mimari ve çevre düzenlemesi gibi uygulamalar için üç boyutlu (3B) şehir modelleri giderek daha fazla önem kazanmaktadır [15]. Bu ihtiyaçlar, bu tür verilerin oluşturulması için otomatik ve yarı otomatik araçların geliştirilmesini amaçlayan araştırma çabalarını artırmıştır. Bu otomatik ve yarı otomatik yöntemler de, işgücü ve maliyetler düşük tutulurken, doğru jeo-uzamsal bilgi üretmeye ihtiyaç duyulur. LİDAR, doğru coğrafi bilgi üretmek için önemli veri kaynağı haline gelmiş olup dünyada kapsamlı olarak kullanılan yeni nesil bir haritalama yöntemidir. Bu nedenle LİDAR, bina tespitinin otomasyonunda ve 3B topoğrafik veri tabanlarının oluşturulmasında önemli bir role sahip olabilmektedir [16]. Yukarıdaki nedenlerden ötürü, LİDAR verileri üzerine otomatik teknikler kullanılarak bina çıkarımı, bina izleri ve modelleme kullanan uygulamalara yönelik talepleri karşılamak için yapılan araştırma çalışmaları büyük bir potansiyele sahiptir. Hâlihazırda bina izi ve modelleme kullanan uygulamalar, felaket senaryolarının, haritacılık, kentsel planlama ve yönetim, kablosuz ağ planlaması, görüş hattı analizi, sanal turlar ve diğer pek çok şeyin simülasyonundan oluşmaktadır [17].


LİDAR sistemi lazer tarayıcı, IMU, GPS ve kameranın hava aracına bütünleşmesinden oluşmaktadır. Hava aracı belli bir hızla giderken lazer tarayıcı saniyede yüz binlerce ölçüm yapmaktadır. Araçta bulunan GPS ise uçuş esnasında anlık olarak konum belirler. Yer istasyonu ve IMU'dan alınan verilerle bu konum dengelenmiş olur. Hava aracı planlanan uçuş güzergâhı boyunca giderken lazer tarama ile aynı zamanlı olarak çekilen fotoğraflardan yüksek çözünürlüklü ortofoto elde edilir. Tarama sonrası oluşturulan LİDAR verisi gerekli hesaplamalar yapılarak nokta bulutuna dönüştürülür. Bu nokta bulutu topografya, bitki örtüsü, bina, enerji iletim hatları gibi sınıflara ayrılır. Bu sınıflandırılmış verinin topografya sınıfı

kullanılarak arazinin çok hassas Sayısal Yükseklik Modeli veya DEM (Digital Elevation Model) eş yükselti eğrileri ayrıca arazi ve üzerindeki bina, bitki örtüsü, gibi bütün objeleri tanımlayan Sayısal yüzey modeli (SYM) veya DSM (Digital Surface Model) üretilir. Karayolu, demiryolu, boru hatları, enerji iletim hatları gibi koridor tipi projelerin planlanması ve etüt çalışmalarında LİDAR sistemi kullanılarak hassas mühendislik hesaplamaları yapılabildiği gibi, enerji iletim hatlarının modellenmesi, yaklaşım mesafeleri analizleri için LİDAR verisi etkin olarak kullanılabilir. Geniş arazi kullanımı olan ormancılık ve tarım sektöründe de LİDAR en hızlı ve doğru çözümü sunar. LİDAR verisi ile üretilen sayısal yüzey modelinde araziye ait tüm detaylar bulunduğu için sel taşkın modellerinde doğru sonuçlar elde edilir. Kent modeli ve şehir planlama çalışmaları için üç boyutlu altlık veriyi üreten Hava LİDAR ölçüm sistemleri birçok alanda çözüm üretmektedir [18].

1960'ların başlarında bir uçağın denizaltı tespiti için LİDAR veya 3D lazer taraması geliştirilmiş ve 1970'lerin başlarında erken modeller başarıyla kullanılmıştır. Günümüzde, çevresel incelemeleri, Işık Algılama ve Değişen (LİDAR) ve Radyo dalgası Algılama ve Değişen (RADAR) gibi uzaktan algılama teknikleri kullanılmadan hayal etmek zordur. Ölçümlerin yüksek mekânsal ve progresif çözünürlüğü, ortam koşullarında atmosferi gözleme olasılığı ve yerden yüksekliği 100 km'den fazla yüksekliğe kadar kaplayabilme potansiyeli LİDAR cihazlarının çekiciliğini oluşturur. LİDAR sisteminin çalışma prensibi oldukça basittir. Havadan tarama yapan LİDAR sistemleri, LİDAR sensörü, IMU ve dâhili bilgisayardan oluşurken karadan tarama yapan sistemlerde IMU bulunmaz. Bunların yanında GPS ve INS gibi birçok teknolojide yardımcı olarak kullanılır. Her iki tür LİDAR sistemlerinde lazer kaynağından çıkan ışınlar sürekli olmayıp periyodik olarak yansıtıcıya çarpıp tarama yapılacak olan alana yönlendirilir. Böylece hava aracından veya karada tripot üzerinden tarama yapılacak alanın saniyede 20.000 ila 150.000 noktanın taraması gerçekleştirilir. Bir birimlik sinyal herhangi bir zemine ulaştığı vakit o yüzeyden tekrar yansiyarak önce yansıtıcıya sonrada alıcı sensöre ulaşır. Bu esnada sinyalin gidişi ile dönüşü arasındaki zaman farkı dâhili bilgisayar tarafından ölçülür. Bu zaman farkı ışık hızı ile çarpılıp ikiye bölündüğünde sensör ile görüntüsü alınan obje arasındaki uzaklığı verir denklem (1.1),

$$\text{Mesafe} = (\text{Işık Hızı} \times \text{Uçuş Süresi}) / 2 \quad (1.1)$$

Bu işlemler sırasında havadan taramada GPS anlık olarak hava aracının coğrafi koordinatlarını alırken, IMU ise platformunun dikey eksene göre konum bilgisini alarak bu bilgiler lazer sensöründen alınan bilgilerle dâhili bilgisayarda eşleştirilerek haritalandırılma gerçekleştirilir [19].



Şekil 1.1. LİDAR sisteminin genel yapısı [20].

1.1.2. Görüntü sınıflandırma yöntemleri

Uydu görüntülerinden yeryüzüne ait bilgilerin elde edilmesinde kullanılan en yaygın yöntem görüntülerin sınıflandırılması işlemidir. Görüntü sınıflandırma, görüntüyü oluşturan her pikselin tüm bantlardaki değerlerinin diğer pikseller ile karşılaştırılarak benzer piksellerin kullanıcının belirlediği sınıflara ayrılması işlemidir [21]. Ayrıca; sınıflandırma, yeryüzü objelerinin farklı spektral yansıma değerlerinin tespiti yapılarak görüntü üzerindeki her pikseli ait olduğu sınıfa atama işlemidir. Sınıflandırma sonucu elde edilen görüntüler tematik harita olarak adlandırılır. Tematik haritaların yorumlanması sonucu, araziye ait bilgilere hızla ulaşılması imkânı, kullanıcıya daha hızlı bilgi sunulması ve araziye ait sınıflar hakkında bilgi alınarak zamansal değişimin takibi yapılabilmektedir.

Sınıflandırma işleminde genel olarak kontrollü ve kontrolsüz sınıflandırma olarak adlandırılan iki yöntem vardır.

Kontrolsüz sınıflandırma yöntemi; piksellerin, kullanıcı müdahalesi olmadan algoritmalar yardımı ile otomatik olarak kümelendirilmesi temeline dayanmaktadır. Bu yöntem karar kuralı olarak, minimum uzaklığı kullanır. Pikseller, görüntünün sol

üst köşesinden başlanarak soldan sağa ve satır satır analiz edilir. Aday piksel ile her bir küme ortalaması arasında spektral uzaklık hesaplanır ve en yakın kümeye atanır. Öncelikle istenilen sınıf sayısı kadar oluşturulan kümenin ortalaması hesaplanır ve her iterasyondan sonra, her bir kümenin yeni ortalaması hesaplanarak, bu ortalamalar bir sonraki iterasyon kümelerinin tanımlanmasında kullanılır. Kontrolsüz sınıflandırma yöntemleri içerisinde en yaygın olarak kullanılan ISODATA (Iterative Self Organizing Data Analyses Technique=Tekrarlı veri Analizi Yöntemi)'dir. Bu yöntem, tekrarlı olarak tüm sınıflandırmayı gerçekleştirme ve uygulanan her iterasyon sonrasında yeniden istatistik hesaplamasını temel alır. Self Organizing ise, minimum girdi ile kümelerin oluşturulmasıdır. Kontrolsüz sınıflandırma; görüntüdeki veri tanımlanamadığında başvurulan bir yöntemdir. Bu yöntemde, arazi örtüsü tipini bilinmesine gerek yoktur, öncelikle sınıf sayıları belirlenir (bu aralığın geniş tutulması faydalıdır). Ayrıca, veri bandı değerleri yardımı ile benzer piksellerin otomatik olarak bulunması temel alınmaktadır. Tanımlanan bu pikseller sembol, değer ya da etiketlere atanır, gerektiğinde de aynı tip sınıflarla birleştirilir.

Kontrollü sınıflandırma yönteminde ise çalışma alanındaki yeryüzü özelliklerini tanımlayan yeteri sayıdaki örnek bölgeler (test alanlar) kullanılarak, sınıflandırılacak her bir cisim için spektral özellikleri tanımlı özellik dosyaları oluşturulur. Bu dosyaların görüntü verilerine uygulanması ile her bir görüntü elemanı (piksel), hesaplanan olasılık değerlerine göre en çok benzer olduğu sınıfa atanmaktadır.

Kontrollü sınıflandırmada; kontrol aşaması, sınıflandırma aşaması ve çıktı aşaması şeklinde üç aşamadan oluşur. Kontrol aşaması; bu aşamada incelenecek alanda bilinen sınıfları temsil edecek kontrol alanları seçilir. Bu alanlar, sınıflandırmada kullanılacak her bilgi sınıfı için yeterli düzeyde homojen ve temsil edici şekilde belirlenir. Kontrol alanları her özellik tipi ile ilgili spektral özellikleri tanımlayan bir sayısal yorumlama anahtarı düzenlemek için kullanılır. Sınıflandırma aşaması; görüntüdeki her bir piksel sayısal olarak yorumlama anahtarı içindeki her bir sınıf ile karşılaştırılarak, sınıflardan en çok hangisine benzediği saptanır ve ilgili sınıfın adı ile etiketlenir. Bilinmeyen pikseller ve araştırma seti pikselleri arasındaki bu karşılaştırmayı yapmak için kullanılabilir çok sayıda sayısal yöntem vardır. Bu çalışma istatistiksel kavramlara dayalı sınıflandırma yöntemleri olarak; ortalama en az uzaklık yöntemi, paralel kenar yöntemi, en yüksek olasılık yöntemi sunulmuştur.

Çıktı aşaması; çıktı ürünleri sınırsız sayıda üretilebilir. En yaygın kullanılan çıktı formları; grafik ürünler, çizelge çıktı ürünler ve sayısal bilgi dosyaları şeklindedir. Kontrollü sınıflandırma yanında yaygın olarak kullanılan sınıflandırma algoritmalarından bazıları, Support Vector Machine (DVM) veya Destek Vektör Makinesi (DVM), Yapay Sinir ağları (YSA) veya Neural Network (NN) ve obje tabanlı sınıflandırma yöntemleridir [22].

Bu çalışma kapsamında hücre tabanlı ve makine öğrenmesine dayalı iki farklı sınıflandırma yöntemi uygulanmıştır. Bunlar En Büyük Olasılık metodu (EBO) ya da uluslararası literatürde bilinen en yaygın adı ile Maximum Likelihood Classification (MLC) ve Destek Vektör Makinaları (DVM) ya da diğer bilinen adı ile Support Vector Machine (DVM) kontrollü sınıflandırma yöntemleridir.

1.1.2.1. Destek vektör makinesi (DVM)

1970'li yılların sonlarına doğru Rus Bilim adamı Vladimir Vapnik ve arkadaşları tarafından geliştirilen destek vektör makinelerinin uzaktan algılama alanındaki ilk uygulamaları 1990'lı yılların sonlarında görülmektedir. Uzaktan algılama alanında DVM ile yapılan ilk bilimsel içerikli çalışmada hiperspektral uydu görüntüleri sınıflandırılmıştır. Daha sonraları da çalışmalar çok bantlı uydu görüntülerinin sınıflandırması ile devam etmiştir [23].

Destek vektör makineleri (DVM) istatistiksel öğrenme teorisine dayalı parametrik olmayan bir sınıflandırma yöntemidir [24]. DVM, ikili sınıflandırmalar için geliştirilmiş olup az sayıda örnekleme verisi ile doğru sınıflandırma sonuçları elde etmeye olanak sağlamaktadır. Başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması için tasarlanmış olan yöntem, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için geliştirilmiştir. Destek vektör makineleri, Yapısal Risk Azalımı (YRA) prensibine dayanmaktadır. Bu prensip, iki hiperdüzlem arasındaki sınır mesafesini maksimum hale getirmektedir [24].

Örneğin iki sınıflı, r sayıda örnekten oluşan ve birbirinden ayrılabilir $(x_1, y_1), (\dots), (x_r, y_r)$ şeklinde tanımlanan bir eğitim verisi verilsin; burada $x \in \mathbb{R}^N$ olup N boyutlu bir uzayı, $y \in \{+1, -1\}$ olup sınıf etiketlerini temsil etmektedir ve bu iki sınıf çeşitli $N-1$ boyutlu hiperdüzlemler tarafından ayrılabilir. Bu iki sınıfı birbirinden

ayırabilen, iki sınıf türü için de kendisine en yakın noktalar arasındaki uzaklığı maksimuma çıkarabilen tek bir hiperdüzlem vardır [25].

Bu hiperdüzlem optimum hiperdüzlem olarak adlandırılır (Şekil 1.2). Bir hiperdüzlem (1.2);

$$w \cdot x_i + b = 0 \quad (1.2)$$

olarak tanımlanır.

Burada x_i hiperdüzlem üzerindeki noktayı, w hiperdüzlemin normalini ve b ise hiperdüzlemin orijinden olan uzaklığı olarak ifade edilen biası (eğilim değeri) temsil etmektedir (Şekil 1.2). İki sınıflı doğrusal olarak ayrılabilen veriler için, ayırım yapan hiperdüzlem (1.3 ve 1.4);

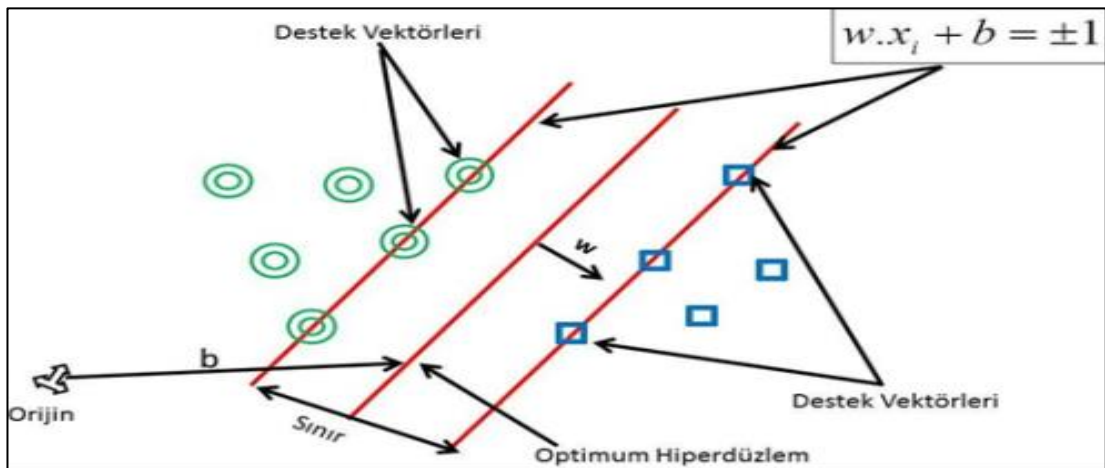
$$w \cdot x_i + b \geq +1, \text{ her } y = +1 \text{ için} \quad (1.3)$$

$$w \cdot x_i + b \leq -1, \text{ her } y = -1 \text{ için} \quad (1.4)$$

olarak tanımlanabilir. Yukarıdaki iki eşitsizlik bir eşitsizlik haline getirilirse (1.5);

$$y_i (w \cdot x_i + b) - 1 \geq 0, y_i \in \{1, -1\} \quad (1.5)$$

şeklini alır.



Şekil 1.2. Doğrusal olarak ayrılabilen iki sınıflı DVM ve optimum hiperdüzlem

Optimum hiperdüzleme paralel ve

$$w \cdot x_i + b = \pm 1 \quad (1.6)$$

eşitliği ile tanımlanan ayırım yapabilen iki hiperdüzlem üzerinde bulunan ve sınır genişliğini belirleyen noktalar destek vektörleri (1.6) olarak adlandırılır [25]. Bu iki hiperdüzlem arasındaki sınır genişliği (marjin) $2/\|w\|$ 'dir. İki sınıfı maksimum sınır genişliği ile ayıran optimum hiperdüzlem, $\|w\|^2$ ifadesinin (1.5)'deki sınırlamalara bağlı olarak minimum hale getirilmesi (1.7) ile bulunabilir [25];

$$\min \left[\frac{1}{2} \|w\|^2 \right] \quad (1.7)$$

Bu problem Lagrange denklemleri kullanılarak çözülebilecek bir optimizasyon problemidir ve çözüm için karar fonksiyonu (1.8);


$$f(x) = \text{sign} \left(\sum_{i=1}^r \lambda_i \cdot y_i (x \cdot x_i) + b \right) \quad (1.8)$$

şeklinde olur.

Burada; $\lambda_i, i=1, 2, \dots, r$ Lagrange çarpanlarını temsil etmektedir.

Eğer sınıflar doğrusal olarak ayrılamıyorsa (Şekil 1.3), (1.7) ifadesi ve ona ait sınırlamalar ayırım yapılabilmesi için yetersiz kalmaktadır. Problem ξ_i yapay değişkeninin tanımlanması ve (1.5)'e eklenmesi ile çözülebilmektedir. ξ_i yapay değişkeni pozitif değerler almaktadır ve sınıflandırma hatalarını ifade etmektedir (1.9) [26].

$$y_i(w \cdot x_i + b) - 1 + \xi_i \geq 0 \quad (1.9)$$



Şekil 1.3. Doğrusal olarak ayrılamayan iki sınıflı DVM ve optimum hiperdüzlem

Optimum hiperdüzlem aşağıdaki optimizasyon probleminin çözümü ile bulunabilir (1.10);

$$\min \left[\frac{\|w\|^2}{2} + C \sum_{i=1}^r \xi_i \right] \quad (1.10)$$

Hiperdüzlemin (karar yüzeyinin) doğrusal eşitlikler yardımıyla belirlenememesi durumunda, bu problem kernel (çekirdek) fonksiyonları yardımıyla çözülebilir. Girdi uzayında doğrusal olarak ayrılamayan verinin, kernel fonksiyonları aracılığıyla yüksek boyutlu uzay görüntülenerek doğrusal olarak ayrımı sağlanır [27].

Kernel fonksiyonları genel ifadesi aşağıdaki gibidir (1.11);

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (1.11)$$

Bu durumda karar fonksiyonu (1.12);

$$f(x) = \text{sign} \left(\sum_{i=1}^r \lambda_i \cdot y_i \cdot K(x, x_i) + b \right) \quad (1.12)$$

şeklinde olur.

Burada λ_i , $i=1, 2, \dots, r$ Lagrange çarpanlarını, $K(x, x_i)$ kernel fonksiyonu temsil etmektedir.

Destek vektör makinelerinde yaygın olarak kullanılan kernel fonksiyonları genel olarak lineer (doğrusal), polinom, radyal tabanlı ve sigmoid kernelleri olmak üzere 4 gruba ayrılmaktadır (Tablo 1.1) [25].

Tablo 1.1. Kernel türleri ve matematiksel ifadeleri

Kernel Türü	Matematiksel
Lineer (Doğrusal) Kerneli	$K(x_i, x_j) = x_i \cdot x_j$
Polinom Kerneli	$K(x_i, x_j) = (\gamma(x_i \cdot x_j) + b)^d$, $\gamma > 0, \delta > 0$
Radyal Tabanlı Fonksiyon	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2)$, $\gamma > 0$
Sigmoid Kerneli	$K(x_i, x_j) = \tanh(\gamma(x_i \cdot x_j) - b)$, $\gamma > 0, \delta > 0$

Tablo 1.1’de görülen matematiksel ifadelerde;

$K(x, x_i)$ kernel fonksiyonunu, d polinom derecesini, b bias parametresini, γ gamma parametresini ve C düzenleme (penalty) parametresi temsil etmektedir [25].

Tablo 1.2. Kernel ve sahip olunan parametreler

Parametre Türü	Kernel Türü
Polinom derecesi (d)	Polinom
Bias (b)	Polinom, Sigmoid
Gama (γ)	Polinom, Radyal Tabanlı, Sigmoid
Düzenleme (Hata) Parametresi (C)	Lineer, Polinom, Radyal Tabanlı, Sigmoid

Tablo 1.2’de kernel türlerine ait parametreler ve her bir parametre türünün hangi kernel türünde bulunduğu görülmektedir.

Başlangıçta iki sınıflı verilerin sınıflandırılması amacıyla tasarlanmış olan destek vektör makineleri, çeşitli yöntemler aracılığıyla çok sınıflı verilerin sınıflandırılması işleminde de başarıyla kullanılmaktadır. Bu yöntemlerden en yaygın iki tanesi “Bire karşı bir (one against one- Pairwise classification strategy)” ve “Bire karşı hepsi (one against all)” yaklaşımlarıdır. Bu iki yöntemde de temel mantık çok sınıflı verilerin sınıflandırılması problemini, iki sınıflı verilerin sınıflandırılması problemine dönüştürerek temel DVM yaklaşımının kullanılmasını sağlamaktır [28].

N sayıda sınıftan oluşan bir eğitim verisinde herhangi bir sınıf türü için, bire karşı hepsi yaklaşımında diğer tüm sınıf türleri tek bir sınıf (küme) gibi ele alınıp bir adet ikili sınıflandırıcı yardımıyla sınıflandırma işlemi gerçekleştirilirken, bire karşı bir yaklaşımında diğer her bir sınıf türü ayrı ayrı ele alınarak her bir sınıf çifti için bir adet ikili sınıflandırıcı kullanılarak bu işlem gerçekleştirilir [28], [29].

1.1.2.2. En büyük olasılık yöntemi (EBO)

En Çok Benzerlik yöntemi, uzaktan algılanmış verilerin sınıflandırılması işleminde kullanılan kontrollü sınıflandırma yöntemlerinden en yaygın olanıdır [30]. Bu yöntemde normal dağılım modeli kullanılır ve her bir sınıf için eğitim verisinin normal dağılımında olduğu kabul edilir. Bu kabul ile birlikte bir sınıf, piksellere ait gri (parlaklık) değerlerinin yanı sıra o sınıfa ait ortalama vektörü ve kovaryans matrisi yardımıyla ayırt edilebilir [30], [31].

EÇB sınıflandırma yöntemi Bayes Teorisine dayalıdır ve bu yöntemde piksel, herhangi bir sınıfa ait olma olasılık değerlerinden en yüksek olan sınıfa atanır [32].

$$D = \ln(a_b) - [0,5 \cdot \ln(|\text{Cov}_b|) - [0,5 \cdot (\mathbf{X} - \mathbf{M}_b)^T \cdot (\text{Cov}_b^{-1}) \cdot (\mathbf{X} - \mathbf{M}_b)]] \quad (1.13)$$

Yukarıdaki eşitlikte; D olasılık değerini, b örnek bir sınıfı, X aday pikselin ölçüm vektörünü, \mathbf{M}_b b örnek sınıfının ortalama vektörünü, a_b aday pikselin b sınıfına ait olma yüzdesini, Cov_b b sınıfının kovaryans matrisini göstermektedir. [33].

1.1.3. Sınıflandırma doğruluğu

Doğruluk analizi, eğitim alanı olarak ayrılan bölgeler dışında kalan test alanlarına ilişkin piksel değerlerinin, referans kabul edilen, haritalar ya da arazi hakkında kesin bilgi veren bir kaynakla istatistiksel olarak karşılaştırma ilkesine dayalı bir kontrol yöntemidir [34].

Hatalar, piksellerin yanlış sınıflandırılmasından dolayı oluşmaktadır. Analizde hata derecesi yerine doğruluk derecesi de araştırılabilir. Eğer çok sayıda sınıflandırılmamış piksel varsa, eğitim veri setlerinin gerçeği temsil etme oranları düşer. Sınıflandırmada doğruluk derecesinin gösterilmesinde en yaygın kullanılan metot k*k düzensizlik, hata (confusion) matrisinin oluşturulmasıdır. Matris referans verileri, yani yer gerçeği kullanılarak oluşturulur [35].

1.2. Coğrafi Bilgi Teknolojileri

Coğrafi Bilgi Sistemi (CBS) dünya üzerindeki karmaşık sosyal, ekonomik, çevresel vb. sorunların çözümüne yönelik mekâna/konuma dayalı karar verme süreçlerinde kullanıcılara yardımcı olmak üzere, büyük hacimli coğrafi verilerin; toplanması, depolanması, işlenmesi, yönetimi, mekânsal analizi, sorgulaması ve sunulması fonksiyonlarını yerine getiren donanım, yazılım, personel, coğrafi veri ve yöntem bütünüdür.

CBS, genel bir kavram olup; çeşitli kullanım alanlarına ve tematik konulara yönelik olarak geliştirilen CBS uygulamaları vardır. Bu CBS uygulamaları, Kent Bilgi Sistemi, Orman Bilgi Sistemi, Karayolları Bilgi Sistemi, Arazi Bilgi Sistemi, Tapu ve Kadastro Bilgi Sistemi, Lojistik Bilgi Sistemi, İç Güvenlik Bilgi Sistemi, Araç

İzleme Bilgi Sistemi, Trafik Bilgi Sistemi, Kampüs Bilgi Sistemi, Deprem Bilgi Sistemi, Harita Bilgi Sistemi, vb. şekilde adlandırılırlar.

CBS, kavramsal bir sınıflamada hiyerarşik olarak öncelikle Sistem, sonra Bilgi Sistemi kategorisi altında yer alır. İşlevsel bir sınıflamada ise CBS, öncelikle Teknoloji, sonra Bilgi Teknolojisi altında yer alır.

CBS, İngilizce Geographical Information Systems (GIS) ifadesinin Türkçeye çevrilmiş hali olup, kullanıcıların çok farklı disiplinlerden olması nedeniyle, bu kavram da değişik şekillerde tanımlanmaktadır. Özellikle CBS'nin dünyada konumsal bilgi ile ilgilenen kişi, kurum ve kuruluşlar arasında geniş bir merak uyandırması, gelişmelerdeki hızlı değişiklikler, özellikle ticari beklentiler, farklı uygulama ve fikirler, CBS'nin standart bir tanımının yapılmasına henüz izin vermemiştir. CBS, bazı araştırmacılara göre konumsal bilgi sistemlerin tümünü içeren ve coğrafi bilgiyi irdeleyen bir bilimsel kavram, bazılarına göre; konumsal bilgileri dijital yapıya kavuşturan bilgisayar tabanlı bir araç, bazılarına göre de; organizasyona yardımcı olan bir veri tabanı yönetim sistemi olarak nitelendirilmektedir. Buna göre en genel haliyle CBS tanımı aşağıdaki şekildedir;

CBS; konuma dayalı gözlemlerle elde edilen grafik ve grafik-olmayan bilgilerin toplanması, saklanması, işlenmesi ve kullanıcıya sunulması işlevlerini bütünlük içerisinde gerçekleştiren bir bilgi sistemidir [36].

CBS teknolojisi; bilimsel araştırmalar, kaynak yönetimi, varlık yönetimi, alt yapılar (doğalgaz, elektrik, su), arkeoloji, çevresel etki değerlendirmesi, peyzaj mimarlığı, kentsel planlama, kartografya, kriminoloji, coğrafi tarih, pazarlama, lojistik, maden haritalama, haritacılık, tarım ekili tarım alanlarının tespiti ve toplam mahsulün hesaplanması, askeri uygulamalar, hava, deniz ve kara trafiği izleme araç takip sistemleri, meteoroloji, arama kurtarma ve diğer amaçlar için kullanılabilir. Örneğin, CBS doğal afetlerde acil müdahaleleri kolaylaştırmak için hesaplamalar yapmaya olanak tanır. CBS yeni sulak alanların bulunmasında ve bu alanların korunmasında kullanılabilir. CBS bazı şirketler tarafından avantaj sağlaması amacıyla yeni pazar alanları bulmak için kullanılabilir. Daha genel manada CBS, analizler yapma imkânı sunan ve bu analiz sonuçlarına göre doğru kararlar vermeyi kolaylaştıran bir sistemdir.

Uzaktan Algılama ve CBS yöntemleri kullanılarak günümüzde farklı alanlardaki hava ve uydu görüntülerinden otomatik bina tespiti, yayılım haritalarının oluşturulması ve güncellenmesi, kentsel modellemeler ve kentsel izleme uygulamaları, yeşil alan tespiti, en uygun alan tespiti, çevresel ve ekolojik değişim analizleri, hidrolojik alanda analizler, risk ve deprem değerlendirmeleri, arazi kullanım alanı haritalaması gibi uygulamalarda önemli sorunlar çözülmektedir. Hızla büyüyen kentleşme ve belediye bölgelerine göre, uzaktan algılama görüntülerinden yapılan otomatik algılama, ilgi uyandıran bir konu olup, etkin bir araştırma alanı olmuştur.

Bina tespiti ve çıkarımı kapsamında çok sayıda çalışma yapılmıştır. Multispektral görüntüler, nSYM, SAM, SAR, LİDAR veri kümeleri gibi bina tespiti için kullanılan veri türü göz önünde bulundurulduğunda, mevcut yöntemler iki gruba ayrılabilir: birincisi 3B görüntü sağlayıcı veri setlerini kullanarak bina algılama ve ikincisi ise optik sistemler kullanarak bina tespiti. Son zamanlarda, algılama görüntülerinden binaları tespit etmek ve çıkarmak için sınıflandırma yöntemlerine dayanan farklı yöntemler önerilmiştir.

2. AMAÇ VE KAPSAM

Yarı ya da tam otomatik bina tespiti kapsamındaki çalışmalar, 3B şehir modelleri için veri toplamada ve bu verilerin uygun bir ayrıntı düzeyinde sunulması maliyetlerini azaltma hedefi ile önemli bir araştırma konusudur. Hava görüntülerine dayanan fotogrametrik tekniklere ek olarak, LİDAR sensörleri tarafından sağlanan nokta bulutlarından 3B bina modellerinin üretilmesi de önem kazanmaktadır. Bu gelişme, havadaki lazer tarayıcıları kullanarak çok yoğun nokta bulutlarının elde edilmesini mümkün kılan sensör teknolojisindeki ilerlemeyle tetiklenmiştir. LİDAR verisi metrekare başına onlarca nokta yoğunluklarıyla üretilmekte olup sadece binaları ve bunların yaklaşık dış hatlarını tespit etmekle kalmayıp, aynı zamanda düzlemsel çatı yüzeylerini çıkararak, çatı yapılarına doğru bir şekilde benzeyen modeller oluşturmaktadır. Şehirsal bölgelerde toprak örtüsü ve tasarrufu, insan yapımı yapıların inşası ile beraber hızlı bir varyasyon göstermektedir. Şehir planlamasında bu varyasyonun izlenmesi son derece önemli olup, birçok CBS uygulamasında güncel ve doğru veri kullanım bilgisinin yetersiz kalması yüzünden problem oluşmaktadır. Bu nedenle, oluşturulmuş olan haritaların sürekli olarak güncellenmesi gerekmektedir. Hava fotoğrafları ve uydu görüntülerinden coğrafi ayrıntıların oluşturulması halen deneyimli personeller tarafından normal bilinen yöntemler ile yapılmakta olup elde edilen coğrafi detayların pozisyonel doğruluğu yüksektir. Ancak coğrafi ayrıntıların normal bilinen yöntemlerle oluşturulması işlemi uzun zaman almakla birlikte nitelikli personel ihtiyacını da ortaya çıkarmaktadır. Bu sebepten dolayı, yüksek çözünürlüklü uydu görüntülerinden yarı ya da tam otomatik nesne çıkarımı son zamanlardaki modern coğrafi bilgi teknolojileri uygulamalarında önemli bir konu haline gelmiştir.

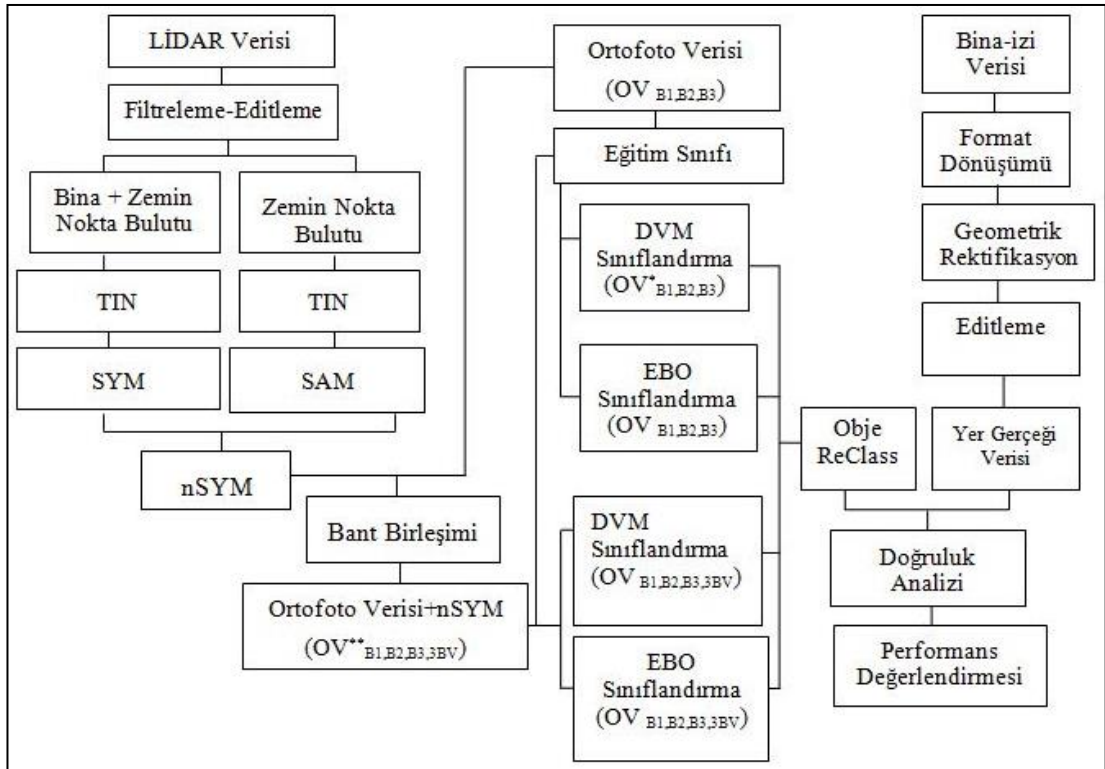
Yüksek çözünürlüklü uydu görüntülerinden yarı ya da tam otomatik nesne çıkarımı çalışmalarında, binaların ya da odaklanılan nesnelerin sık olmadığı yayılımın geniş aralıklı olduğu alanlarda ya da yansıma değerleri büyük değişim gösteren, tonal farklılıkların net olduğu alanlarda yüksek performans elde edilebilmektedir. Fakat konut, ticari, sanayi vb. gibi farklı bina yapılarını bulunduğu; yol, bina çatısı, toprak

yol gibi yansımaların benzerlik taşıdığı; tonal farklılıkların düşük olduğu ve geniş olmayan dar sokakların bulunduğu, sık bina yapılarının bulunduğu alanlarda ise obje tespitleri oldukça zor olmaktadır. Bu nedenle bu tür problemlere çözüm oluşturacak yöntemlere gerek duyulmaktadır. Bu kapsamda bu çalışmanın hedefi, Marmara havzası, İstanbul Küçükçekmece bölgesinde yer alan binaların belirlenme performansının LİDAR verisi ile desteklenmiş ortofoto görüntülerinden uzaktan algılama ve CBS teknikleriyle tespit edilmesini sağlamaktır. Performans karşılaştırması iki farklı kapsamda incelenmiştir bunlar: 3B kullanım etkisi ve farklı sınıflandırma yöntemlerinin kullanım etkisidir. Buna göre dört farklı veri seti oluşturulmuştur. Öncelikle var olan bant gurubu ile ortofoto görüntüye sınıflandırma uygulaması yapılmıştır. Çalışmada EBO ve DVM sınıflandırma teknikleri kullanılmış ve iki farklı sınıflandırma sonucu, yapılan doğruluk analizleri karşılaştırılmıştır. Daha sonra LİDAR nokta bulutu yardımı ile normalize edilmiş sayısal yükseklik modeli (nSYM) oluşturulmuş ve ek bant olarak ortofoto görüntüsüne eklenmiştir. 3B ek bant verisi içeren ortofoto, EBO ve DVM sınıflandırma teknikleri ile yeniden sınıflandırma işlemine tabi tutulmuştur. Çalışmanın doğruluğunun kontrol edilebilmesi için bina taban izi harita verileri ile karşılaştırma işlemi yapılarak bina tespiti performansının farklı sınıflandırma yöntemleri kapsamında ve LİDAR verisinden elde edilen 3B bilgisi sunan ek bant katkısı ile nasıl etkilendiği değerlendirilmiştir. Sonuç olarak sınıflandırma modeli etkileri ve 3B verisinin etkisi bütün olarak değerlendirilmiştir.

3. METODOLOJİ

Çalışma Şekil 3.1’de gösterildiği gibi altı temel adımdan oluşmaktadır. Bu aşamalar genel olarak aşağıdaki gibi sıralanabilir:

- ❖ Verilerin ön analizi,
- ❖ Ortofoto verisi (OV_{B_1,B_2,B_3}) (B_1, B_2, B_3 batlarından oluşan Ortofoto Verisi) kullanılarak EBO ve DVM sınıflandırma teknikleri ile obje belirleme çalışması,
- ❖ LİDAR ile nSYM oluşturulması,
- ❖ nSYM’nin ek bant (3BV: 3Boyut Verisi) olarak Ortofoto verisine ilave edilmesi ($OV_{B_1,B_2,B_3,3BV}$) ve EBO ve DVM sınıflandırma teknikleri ile bina ve diğer objelerin tespiti,
- ❖ Sınıflandırılmış haritaların Bina izi verisi (yer gerçeği) ile karşılaştırılıp doğruluk analizi,
- ❖ Bina tespitinde yöntemlerin performans değerlendirmesi,



Şekil 3.1. Çalışma akış şeması, $OV^*_{B_1,B_2,B_3}$: Ortofoto Verisi ve 3 bandı, $OV^{**}_{B_1,B_2,B_3,3BV}$: 3 Boyut Verisi eklenmiş ortofoto verisi

Çalışma alanına ait alımı yapılan LİDAR, Ortofoto ve bina izi verileri öncelikle ön analizden geçirilmiştir. LİDAR verisi çalışma alanında bulunan binalara ait 3B verisi elde etmek için kullanılmıştır. Bu nedenle nokta bulutundan SYM ve SAM oluşturabilmek amacı ile veri filtrelenip editlenmiştir. “.dgn” veri formatında alınan bina izi verilerine ise öncelikle format dönüşümü yapılmış, daha sonra güncel Google Earth verilerinden faydalanılarak güncelliği kontrol edilmiştir. Ortofoto görüntüsü ile farklı projeksiyonda olan bina izi verilerinin tam örtüşme sağlaması için geometrik rektifikasyonu yapılmıştır.

Veri ön analizleri tamamlandıktan sonra sınıflandırma işlemleri için 3 banda sahip Ortofoto verisi için en uygun renk kombinasyonu açılarak arazi üzerindeki farklı sınıflar için eğitim sınıfı verisi hazırlanmıştır. Çalışmanın amaçlarından biride farklı sınıflandırma yöntemlerinin karşılaştırmasıdır. Bu nedenle ortofotonun 3 bandına ($OV_{B1,B2,B3}$) öncelikle EBO sınıflandırma yöntemi, daha sonra aynı eğitim sınıfı kullanılarak DVM sınıflandırma yöntemi uygulanmıştır.

Çalışma amaçlarından bir diğeri de bina tespitinde 3B verisinin etkisini görmektir. Bu nedenle LİDAR nokta bulutundan elde edilen SAM ve SYM arasındaki farkla yer üzerindeki varlıklara ait yükseklik bilgisi içeren nSYM verisi oluşturulmuştur. Daha sonra oluşturulan bu 3B verisi ek bant olarak ortofotoya eklenmiştir ($OV_{B1,B2,B3+3BV}$). Dört bana sahip olan ortofoto verisi tekrar aynı eğitim sınıflarını kullanarak öncelikle EBO sınıflandırma yöntemi, daha sonra DVM sınıflandırma yöntemi ile sınıflandırılmıştır. Çalışmanın temel amaçlarından biri olan binalar içinde ayrıca doğruluk değerlendirmesi yapılmıştır. Bu nedenle yapılan sınıflandırma haritalarının her birine yeniden sınıflandırma (Reclass) yöntemi uygulanarak haritalar bina ve diğer olarak yeniden oluşturulmuştur. Performans değerlendirmesi için her bir bina haritası yer gerçeği verisi ile örtüştürülmüştür. Bina izi altında kalan raster formatındaki binalar için bina var ise 1 değeri, yok ise 0 değeri çekilerek bina izi veri tabanına yazdırılmıştır. Oluşturulan bu veri tabanına göre daha sonra bina izi haritaları ile sınıflandırma sonrası elde edilen bina sınıfı alan büyüklükleri olarak karşılaştırılmıştır. Alanda sınıflandırma çalışması sonrası belirlenen her bir kategori için doğruluk analizi alana rastgele atanan 320 adet yer gerçeği verileri ile ve hata matrisi oluşturularak yapılmıştır.

3.1. Çalışma Alanı ve Kullanılan Veriler

Çalışma alanı olarak seçilen Küçükçekmece bölgesi İstanbul ili Marmara havzasının orta kısmında ve yaklaşık 11.845 hektarlık yüz ölçüme sahiptir. Çalışma alanı koordinatları 28°47'38" -28°48'00" Doğu boylamları, 41°00'00"- 41°00'23"Kuzey paralelleri arasında yer almaktadır. Şekil 3.2 çalışma alanının konumunu göstermektedir. Bölgenin Akdeniz iklimine sahip olup yazın sıcak ve az yağışlı, kışlar ılıman ve yağışlı, zaman zaman karlı ve soğuk geçer. Meteoroloji Genel Müdürlüğü verilerine göre bölgenin yıllık en yüksek sıcaklık değeri 44,1, en düşük sıcaklık değeri -18,0, yıllık ortalama sıcaklığı 14,9 °C, yıllık ortalama yağış miktarı ise 814,7 mm olarak ölçülmüştür [37].



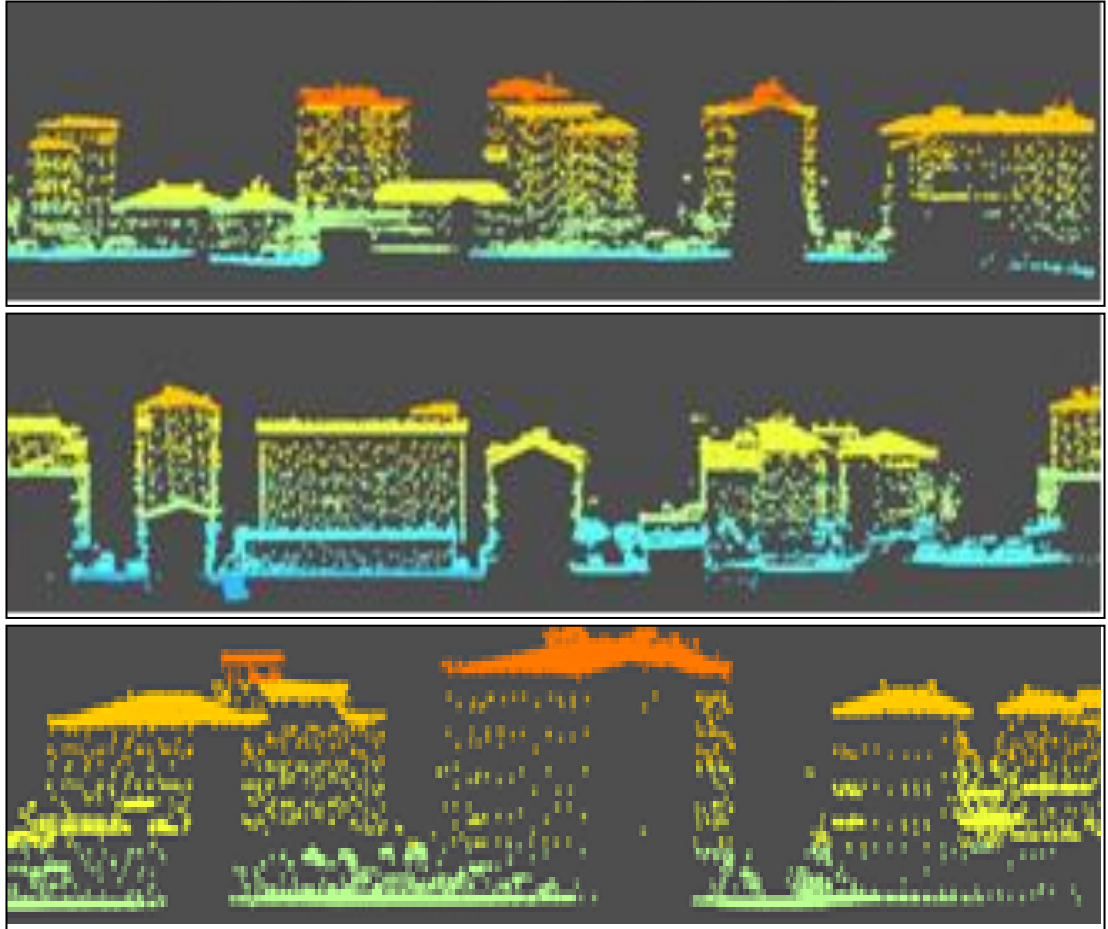
Şekil 3.2. Çalışma alanı İstanbul Küçükçekmece ilçesi

Çalışmada kullanılan veriler İSTAÇ A.Ş. ve Dünya Harita firması kurumlarından temin edilmiş olup verilere ilişkin bilgiler Tablo 3.1.'de sunulmuştur. Sayısal veri olarak LİDAR, ortofoto ve halihazır haritalardan faydalanılmıştır.

Tablo 3.1. Çalışma alanında kullanılan veriler

	Format	Ölçek	Tür	Yıl	Kaynak
LİDAR	Nokta bulutu	1/1000	.las	2013	İSTAÇ A.Ş.
Ortofoto	Raster	1/1000	Ortofoto	2013	İSTAÇ A.Ş.
Bina kat bilgisi	Excel	-	Tablo	2013	Dünya Harita
Bina taban izi haritası	.shp	1/1000	.dgn	2013	Dünya Harita

Bölgede bulunan binaların tespiti için kullanılan LİDAR ham verisi 0.3m.örnekleme aralığındaki nokta bulutu, ALS sisteminde olup kalibre yapılarak georeferanslandırılmıştır. Çalışma kapsamında kullanılan LİDAR verisine ait üç farklı profil kesitine ait görüntüler Şekil 3.3.'de sunulmaktadır. Şekil 3.3.'de görüldüğü gibi alanda birbirinden farklı yükseklikte, farklı genişlikte bina yapıları ve bitki dokusu bulunmaktadır.



Şekil 3.3. Ham LİDAR verisine ait farklı profil kesitlerine ait görüntüler

Çalışmada kullanılan 25 cm konumsal çözünürlüklü ortofoto 8 bit radyometrik çözünürlükte .TIFF formatında kaydedilmiştir. Görüntü üzerinden çalışma bölgesi incelendiğinde, alanda sık binalar, farklı bina yapıları (meskun, ticari, sanayi vb.), yeşillik alanlar, dar sokaklar ve sokak aralarında çeşitli araçların bulunduğu görülmüştür.

Yapılan analizlerin doğruluk tespiti için ise bina izi haritaları kullanılmıştır. Bina izi haritaları .shp formatında olup binalara ait öz nitelik bilgileri Excel ortamında yer almaktadır. Binalara ait veri tabanının düzenlenmesi için bina ID ortak niteliğe göre öznitelik bilgileri CBS ortamına aktararak, mekânsal anlamda farklılıkları gözlemleyebilmek amacı ile haritalanmıştır.



4. UYGULAMA

Çalışmanın temel amacı farklı bant kombinasyonu ve farklı sınıflandırma modelleri kullanımının bina tespiti performansına etkisini araştırmaktır. Çalışmada öncelikle üç banda sahip ortofoto üzerine iki farklı sınıflandırma türü uygulanmış ve sonuçlar analiz edilmiştir. Çalışmada literatürde en çok tercih edilen sınıflandırma türlerinden kontrollü sınıflandırmadan en büyük olasılık yöntemi (EBO) ve çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması işleminde tercih edilen Support Vector Machine (DVM) sınıflandırma yöntemleri kullanılmıştır.

Çalışmada daha sonra ortofotonun üç bandına ek bant eklemesi yapılmıştır. Ek bant LİDAR verilerinden üretilen ve binalara ait yükseklik bilgisi taşıyan nSYM verisidir. Bu durumda literatürde sıklıkla rastlanan binaların toprak zemin, asfalt yol vs. ile karışma durumlarından sakınılacağı öngörülmüştür. Buna göre ek bant ile beraber dört banda sahip ortofotoya tekrar EBO ve DVM sınıflandırmaları yapılarak performans karşılaştırmaları yapılmıştır.


4.1. Ortofoto ile Bina Tespiti

Uzaktan algılama verilerinden üretilen arazi kullanımı ve arazi örtüsü sınıflandırma değerli yönetim ve planlama aracı sayılmaktadır. Uydu görüntülerinin sınıflandırılması, birçok araştırma alanı ile karmaşık bir sorundur. Eşik yöntemlerden özel tasarlanmış ve uyarlanmış sinir ağları gibi son derece karmaşık sınıflandırma yöntemlerine kadar geniş bir yelpazede yayınlar bulunmaktadır. Yer gerçeği (eğitim alanları ve test seti) uzaktan algılama sınıflandırmalarında önemli bir rol oynamaktadır. Eğitim alanları, uydu görüntüsünün bir parçasının hava fotoğrafı yorumundan ve karasal ölçümden elde edilmektedir.

Bu çalışmada ise kontrollü sınıflandırma yöntemlerinden EBO ve DVM sınıflandırma yöntemleri kullanılmıştır. Bu yöntemlerden EBO bir olasılık yoğunluk fonksiyonuna değinir, yani sınıflandırıcı, belirli bir pikselin belirli bir sınıfa ait olduğu olasılığı tahmin eder. DVM yöntemi ise çok sınıflı ve doğrusal olmayan

verilerin sınıflandırılması işleminde kullanılmıştır. Uygulama ArcGIS10.5 yazılımı ortamında yapılmıştır.

Sınıflandırma öncesi alana ait ortofoto görüntüsü incelenerek arazi sınıfları tespit edilmiştir. Çalışmada kullanılacak ortofoto oldukça yüksek bir çözünürlüğe sahip olduğu için alanında bulunan bina, yol, yeşil alan gibi sınıfların yanında araç gibi detay sınıfı da sınıf kategorisine dahil edilmiştir. Sınıflandırma öncesi belirlenen bu dört farklı sınıf için görüntü üzerinden eğitim sınıfları toplanmıştır. Arazide çok sık yapıda, farklı özellik, tür ve boyutta bina objesi bulunmaktadır. Arazide bulunan farklı bina yapılarından bazıları Şekil 4.1’de sunulmuştur. Bu birbirinden farklılık gösteren her bir bina kategorisi için ayrı olacak şekilde örnekler toplanıp daha sonra tek bir bina sınıfı olarak birleştirme (aggregate) işlemi yapılmıştır. Görüntüde çekim açısı nedeni ile gölge alanlar oluşmuştur. Gölge alanlar özellikle yol araları ve bina önlerine düşecek şekilde gözlemlenmektedir (Şekil 4.2). Bu nedenle yol sınıfları için yapılan eğitim sınıfları çalışması kapsamında yol ve gölge örnekleri ayrı ayrı toplanmış sınıflandırma işlemi sonrası, birleştirme işlemi uygulanarak yol olarak atanmıştır. Alanda ayrıca yol kenarına park etmiş araçlarda detay olarak çok net şekilde tespit edilmektedir (Şekil 4.2. 1, 2, 3, 4). Araçlarda bu nedenle sınıflandırma işleminde ayrı bir sınıf olarak değerlendirilmiştir.




Şekil 4.1. Çalışma alanındaki farklı bina özellikleri a.1. Yeşil çatılı sanayi binası, 2. Kırmızı çatılı orta boyutta apartman, 3. Yeşil çatılı orta boyutta apartman b.4. Çatısız orta boyutta beton bina 5. Metal çatılı ince uzun bina 6. Kiremit rengi çatılı orta boyutta bina



Şekil 4.2. Çekim açısı dolayısı ile oluşan bina önü ve yola düşen gölge alanlar

Çalışmanın ilk amacı sınıflandırma modelleri farklılığının değerlendirmesidir ve farklı eğitim sınıfları farklı sonuçlar üretecektir. Bu nedenle eğitim sınıfı bir kez toplanmış ve sonraki yapılan her sınıflandırma çalışması için kullanılmıştır. Yani eğitim sınıfı bir seferlik oluşturulmuş ve her uygulama için aynı eğitim veri seti kullanılmıştır. Buna göre bina için %64 oranında, yol için %10 oranında, bitki için %8 oranında ve araç için %18 oranında örneklem toplanmıştır. Arazide bulunan eğitim sınıfları Şekil 4.3 ve Şekil 4.4’de sunulmuştur.

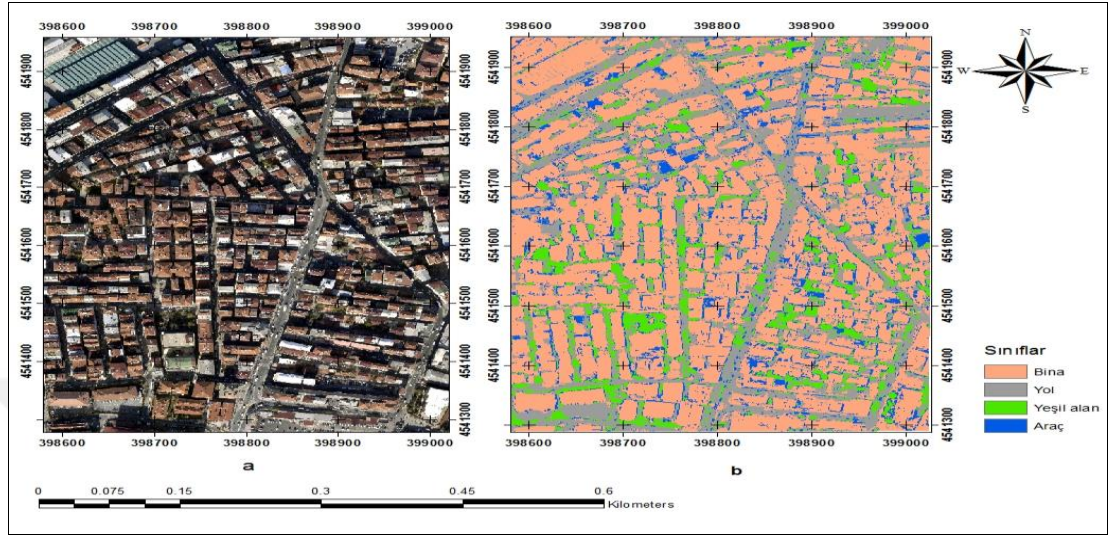


Şekil 4.3. Örneklem eğitim sınıfları a. Bina, b. Yol

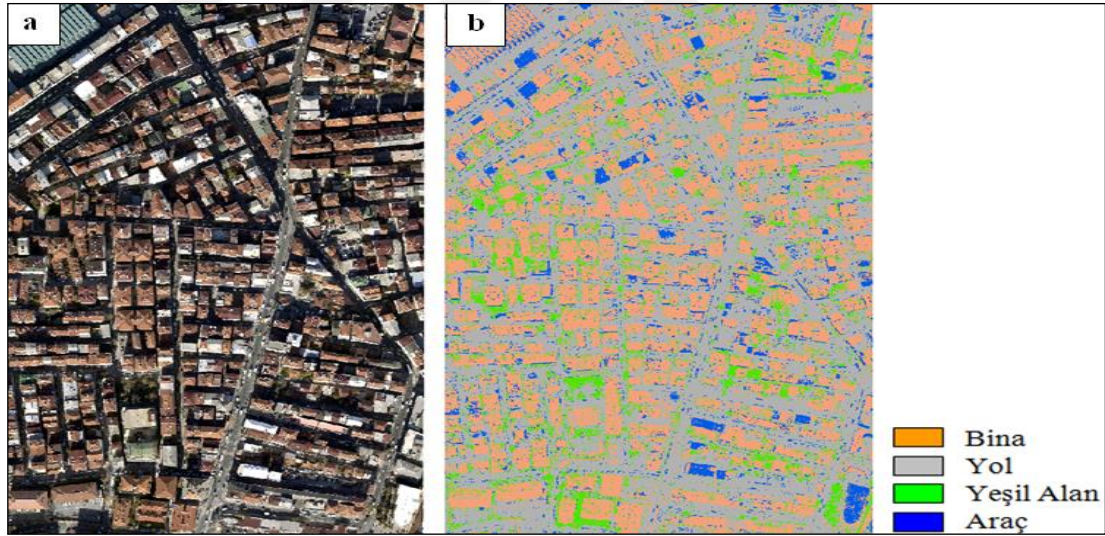


Şekil 4.4. Örneklem eğitim sınıfları c. Yeşil alan, d. Araç

Eđitim sınıfları için toplanan örneklem işlemleri sonrası sınıflandırma işlemleri için öncelikle EBO daha sonra DVM yöntemleri uygulanarak sınıflandırma haritaları oluşturulmuştur.




Şekil 4.5. a. Ortofoto b. EBO ile sınıflandırılmış ortofoto verisi (OV_{B1,B2,B3})




Şekil 4.6. a. Ortofoto b. DVM ile sınıflandırılmış ortofoto verisi (OV_{B1,B2,B3})

Sınıflandırma sonrasında oluşan harita incelendiğinde bazı sınıflarda karışıklık olduğu gözlenmiş ve oluşan bu durumlardan bazıları alana yaklaşarak sunulmuştur (Şekil 4.7, Şekil 4.8). EBO ile yapılan sınıflandırma işleminde piksellerin benzerlik göstermesi sonucu sarı renkli olan aracın yeşil alan sınıfına atandığı (Şekil 4.7 a.1, b.2), bina olması gereken sınıfın ise (Şekil 4.8 a.1) araç sınıfına atandığı gözlemlenmiştir (Şekil 4.8 b.2).




Şekil 4.7. a. Ortofoto b. EBO ile sınıflandırılmış ortofoto verisi kesiti




Şekil 4.8. a. Ortofoto b. EBO ile sınıflandırılmış ortofoto verisi kesiti

DVM ile yapılan sınıflandırma işleminde piksellerin benzerlik göstermesi sonucu bina olması gereken sınıfın araç sınıfına atandığı (Şekil 4.9. a.1, b.2), beyaz renkli olan araçların ise bina sınıfına atandığı gözlemlenmiştir (Şekil 4.10. a.1, b.2).



Şekil 4.9. a. Ortofoto b. DVM ile sınıflandırılmış ortofoto verisi kesiti



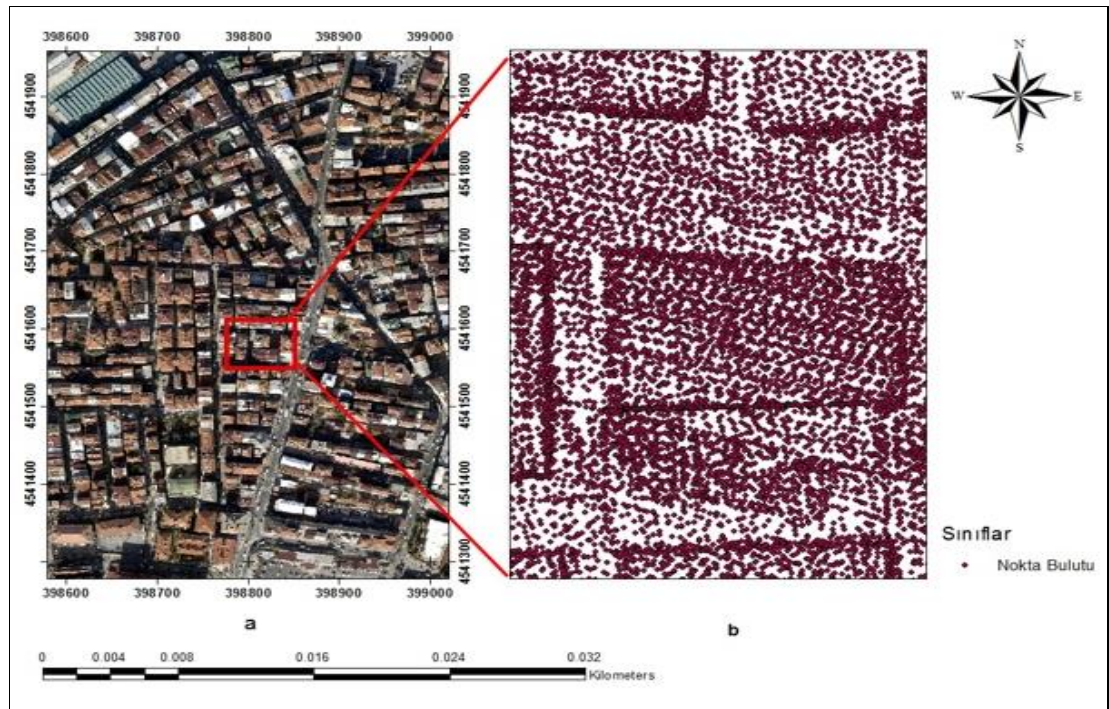
Şekil 4.10. a. Ortofoto b. DVM ile sınıflandırılmış ortofoto verisi kesiti

4.2. LİDAR Ek Bandı Oluşturulması ve Bina Tespiti

Çalışmanın temel amaçlarından biri sınıflandırma yöntemleri arasındaki farkı incelemek iken, bir diğeri ise 3B etkisinin sınıflandırma üzerindeki etkisini analiz etmektir. Bu kapsamda bu bölümde alana ait LİDAR verisinin öncelikle ön analizi yapılmış daha sonra 3B veri katmanı oluşturulmuştur. Ön analiz kapsamında LİDAR verisi filtrelenerek zemin ve zemin üstü objeler tespit edilerek iki farklı sınıfa atanmıştır. Daha sonra her bir sınıf için modelleme çalışmaları yapılmış ve binalara ait 3B veri katmanı oluşturulmuştur. Oluşturulan ek katman ek bant olarak ortofoto görüntüsüne eklenerek, farklı sınıflandırma analizleri ile bina tespiti yapılmıştır.

4.2.1. LİDAR verisi ön analizleri ve modelleme

Yeryüzü, tanımlanamayacak derecede üç boyutlu düzensiz bir yüzeye sahiptir. Bu yüzeyin tanımlanabilmesi için sonsuz sayıda noktaya gereksinim vardır. Haritacılık alanında veri üretme metodu olarak çoğunlukla yersel yöntemler ve fotogrametri kullanılırdı. Günümüzde ise LİDAR teknolojisi oldukça yüksek çözünürlükte bilgi üretme imkânı sağlayan bir teknoloji olarak yaygın bir şekilde kullanılmaktadır. LİDAR verisi, alım sıklığına bağlı olarak, yüzeyde ölçülen her bir veriye ait yatay konum ve yükseklik bilgisi içeren nokta bulutu verisidir (Şekil 4.11).



Şekil 4.11. Çalışma alanı a. Ortofoto görüntüsü, b. .shp nokta bulutu

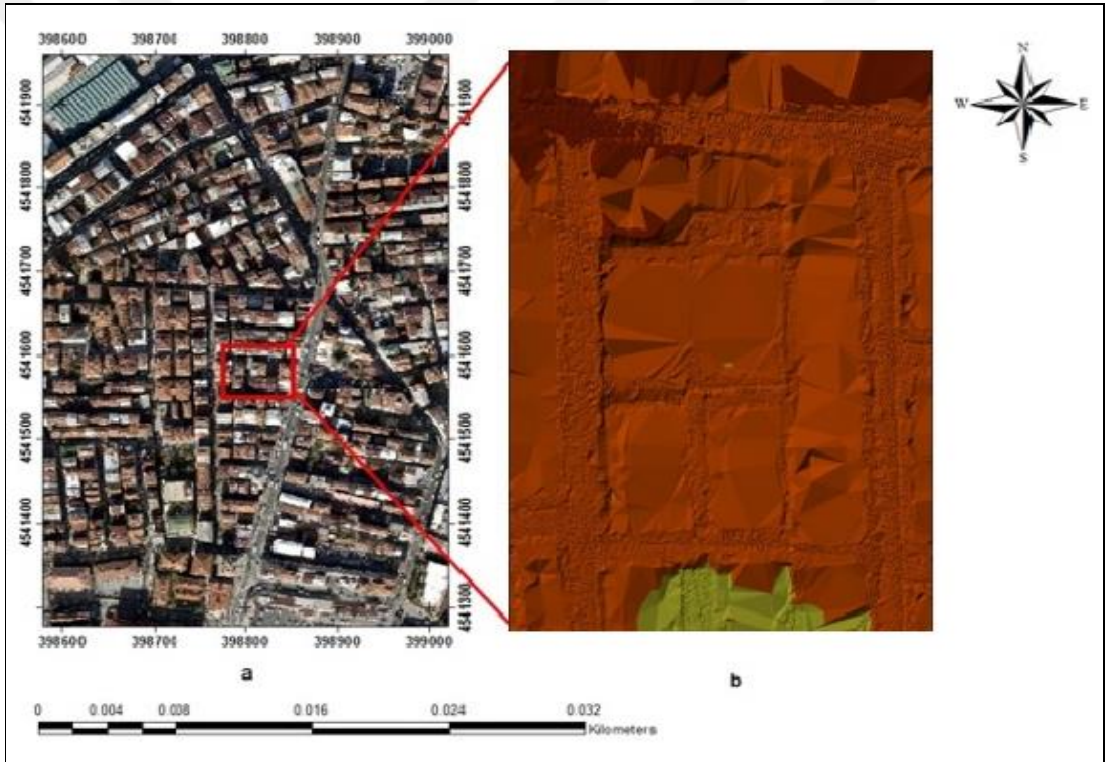
LİDAR sayesinde deęişen yükseklik deęerleriyle dolu büyük bir nokta bulutu elde edilir. Ancak yükseklik, binaların çatısından, ağacın farklı yükseklikte bulunan dallarından, enerji hatlarından ve dięer özelliklerden kaynaklanabilir. Bu nedenle nokta bulutu çıplak yüzeyin yanında yüzey üzerinde bulunan doğal ya da yapay objeleri de (bina, ağaç, araba vb.) içermektedir. LİDAR kısa sürede sayısal arazi modeli (SAM veya DTM) ve Sayısal yüzey modeli (SYM, DSM) üretimine imkân vermektedir. SAM (Sayısal Arazi Modeli) veya DTM (Digital Terrain Model) yeryüzünün modelini oluşturmak için yüzeye ait konum ve yükseklik bilgilerinden yararlanılarak hesaplanan matematiksel bir yüzeydir. Bu yüzey modelinde bitki örtüsü, ağaç, elektrik direęi ve bina gibi detay noktaları olmayıp sadece çıplak arazi yüzeyi ve arazinin morfolojisini yansıtan şev, dere, vadi gibi detaylar olmaktadır (<https://bimtas.istanbul/lttmDem.aspx>).

Sayısal Yükseklik Modeli veya DEM (Digital Elevation Model) kavramı ise arazinin morfolojisine ait detayların dâhil edilmedięi SAM'nin bir alt birimi olarak da düşünülebilir. SAM, telekomünikasyon, şehir planlama ve havacılık için 3 boyutlu modellemede kullanışlıdır. Bir SAM aksine, SYM ya da DSM yeryüzünü temsil eder ve tüm nesnelere (orman, bina, bitki örtüsü vb. detayları) içerir.

Çalışmanın temel amacı bina tespiti olduęu için yüzey üstünde kalan objelerin çıplak yeryüzünden ayrıştırılması gerekmektedir. Bu işlem için öncelikle çıplak yeryüzüne ait SAM oluşturulması gerekmektedir. Bu hedefe ulaşmak için LİDAR nokta bulut verisine yükseklik filtresi uygulanarak zemin ve dięer topografyayı temsil eden objeler sınıflandırılmıştır. Buna göre araziye temsil eden noktalar bir sınıfa geri kalan noktalar (yeşillik, binalar, araçlar vb.) ise farklı bir sınıfa ayrılmıştır. Sadece zemine ait bilgiye erişebilmek için nesne sınıfı veri tabanından filtrelenmiştir. Elde edilen verinin CBS ortamında çalıştırılabilmesi için CBS'ye uygun formata (.shp) dönüştürülmüştür. Elde edilen .shp nokta bulutu kullanılarak öncelikle düzensiz üçgen modeli (TIN) oluşturulmuştur.

TIN (Triangulated Irrigular Network), bir yüzeyin vektör tabanlı bir temsilidir. TIN'ler, araziye içeren uygulamalarda yaygın olarak kullanılmasına rağmen, yüzeyler olarak kavramsallaştırılabilen dięer deęişkenleri temsil etmek için de kullanılabilir. TIN olarak adlandırılan üçgenli düzensiz ağ veri modeli, sürekli

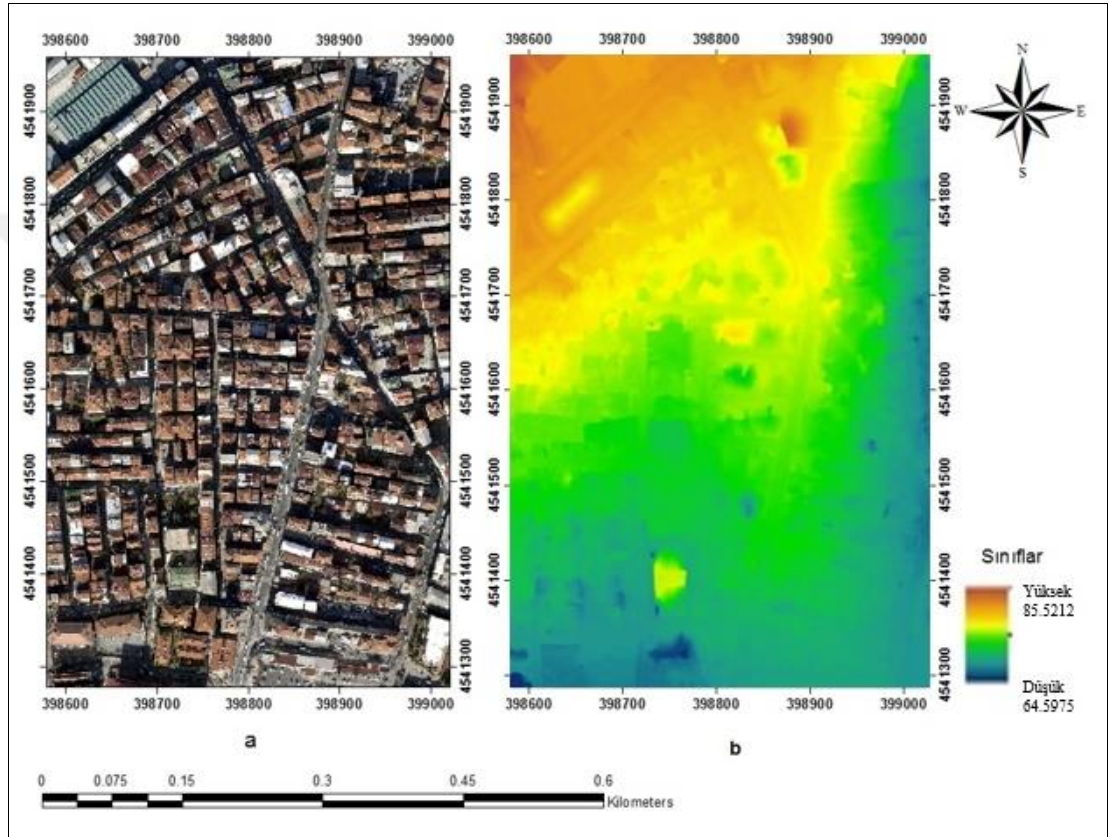
yüzeyleri temsil etmek için raster veri modellerine bir alternatif sayılmaktadır. Arazi ve diğer yüzey türlerini analiz etmek ve görüntülemek için yüzey modellerinin verimli bir şekilde üretilmesini sağlamaktadırlar. TIN'ler, yüzler olarak bilinen bir dizi bitişik, örtüşmeyen üçgenlerden oluşmaktadır. Onlar her noktayı en yakın komşularına bağlayan bir ağın üçgen yüzleri oluşturmak üzere inşa edildiği delaunay üçgenleme denilen bir teknik kullanarak bir dizi noktadan inşa edilmiştir. TIN'lerin verilerin depolanmasında çok daha verimli olmaları nedeniyle raster bazlı temsillere göre bazı avantajları vardır, çünkü temsilin çözünürlüğü, daha fazla veya daha az nokta dâhil edilerek yüzeyde mevcut değişkenlik ölçeğine eşleştirilebilmektedir. Çalışma alanının TIN haritası şekil 4.12'de gösterilmektedir.



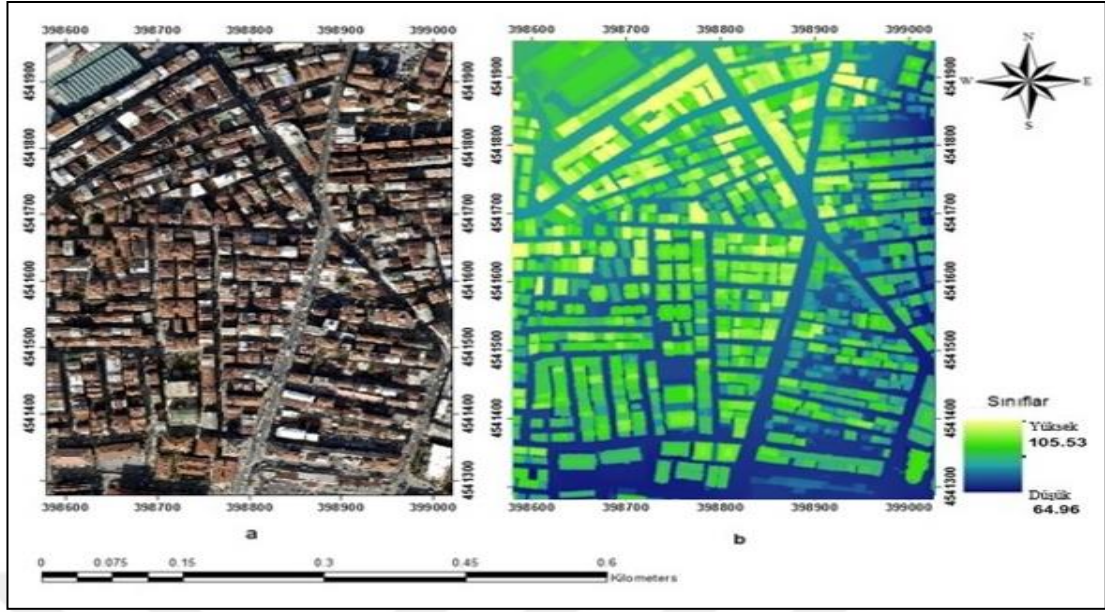
Şekil 4.12. TIN üçgen mozağı ile fiziksel arazi yüzeyinin temsili a. Ortofoto görüntü, b. TIN modeli

SAM'leri her bir raster hücresi için yükseklik verilerine sahip raster dosyalarıdır. SAM'leri hesaplamaların, manipülasyonların ve bir alanın daha fazla analiz edilmesinde ve daha spesifik olarak yükselmeye dayalı analizler için popülerdir. Köprüler ve yollar gibi yerüstü objelerinin olmadığı noktalar filtrelendiğinde, düzgün bir dijital yükseklik modeli elde edilmektedir.

Bu çalışmada ise oluşturulan TIN modeli raster formatına dönüştürülmüş olup SAM üretilmiştir. SAM'ni oluşturan her bir hücre verisi mekânsal pozisyonu ve deniz seviyesinden olan yükseklik değerini içermektedir. SAM çıplak toprak yüzeyinin ortalama deniz yüzeyinden olan yükseklik bilgisine sahip bir model olarak Şekil 4.13'da sunulmuş olup arazideki yükseklik 64.5975 m. ile 85.5212 m. arasında değişmektedir.



Çalışmada binalara odaklanıldığı için yüzey üstü objelere ait yükseklik bilgisine ihtiyaç duyulmaktadır. Bu nedenle çalışmada SYM veya DSM oluşturulması için tüm noktalar kullanılmıştır. Bu amaçla önce TIN oluşturulmuş ve daha sonra hücresel formata dönüştürülerek SYM veya DSM oluşturulmuştur (Şekil 4.14). SYM yüzeydeki tüm objelerin denizden olan yükseklik bilgisine sahip bir model olarak Şekil 4.14'da sunulmuş olup arazideki yükseklik 64.96 m. ile 105.63 m arasında değişmektedir.



Şekil 4.14. a. Ortofoto görüntü, b. SYM modeli

4.2.2. nSYM modelinin oluşturulması

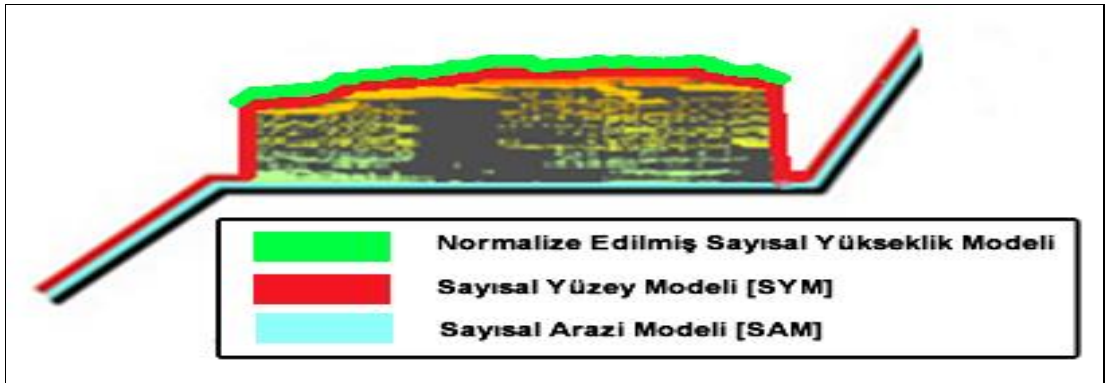
nSYM, bir Sayısal Arazi Modeli ve Sayısal Yüzey Modelinin bir türevidir. SYM, özelliklerin yüksekliğini ölçtüğünde, SAM, zeminin yüksekliğini ölçer, böylece nSYM, zeminin veya SYM'in çıkarılmasıyla özelliklerin mutlak yüksekliğini ölçer.

$$\text{SAM} - \text{SYM} = \text{nSYM} \quad (4.1)$$

SAM: Sayısal Arazi Modeli

SYM: Sayısal Yüzey Modeli

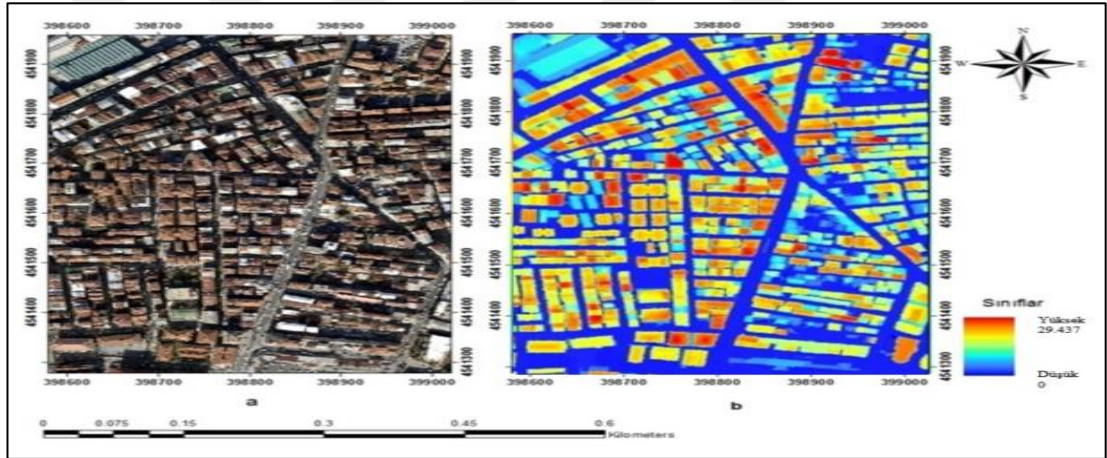
nSYM: Normalize Edilmiş Sayısal Yükseklik Modeli



Şekil 4.15. SAM, SYM, nSYM

SYM ve SAM gibi iki veri kullanımı sonucu oluşan bu donenin doğruluğu, bu iki veri ile bağlantılı olup çalışma alanına göre raster veya vektör olarak kullanılabilir. nSYM verisi birçok uygulamalarda kullanılmakta olup özellikle nesne çıkarımı açısından çok kullanışlı bir yöntemdir.

Çalışma alanında mevcut olan bina izlerini elde edilmesi için SYM ve SAM modellerinin farklarının çıkartılması gerekmektedir. Dolayısıyla ArcMap yazılımının Raster Calculator araç kutusunu kullanılarak iki normalize edilmiş model elde edilmiştir. Normalize edilmiş model (nSYM) ile rasterlerin farkları çıkartılarak yeryüzündeki nesnelere ait veriler üretilmiştir. Oluşturulan nSYM verisi şekil 4.16'da sunulmuştur. Alandaki yüzey üstü varlıklara ait yükseklik bilgisi 0 ile 29.437 arasında değişim göstermektedir.

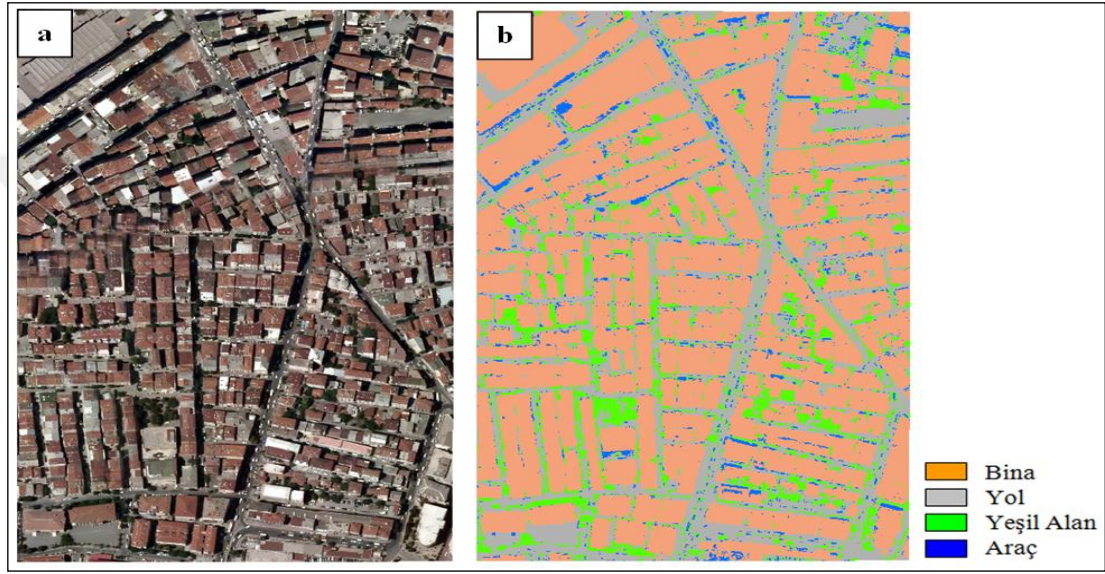


Şekil 4.16. Çalışma alanı, a. Ortofoto b. nSYM

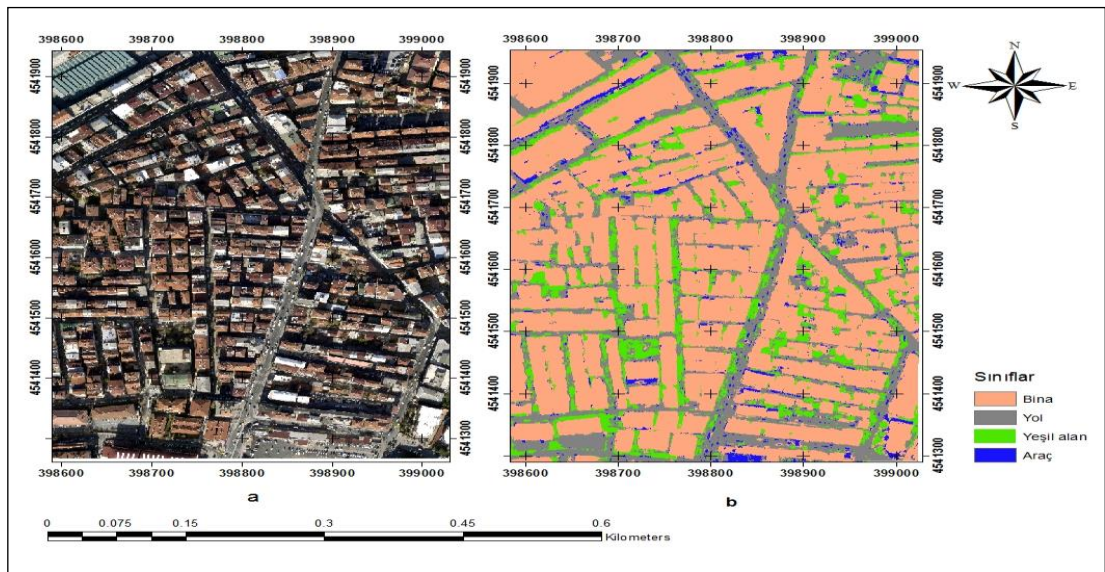
4.3. LİDAR Verilerinin Yardımı İle Bina Tespiti

Bu aşama LİDAR verilerinden oluşturulan nSYM donesinin, ortofoto görüntü bantlarına ek bant olarak ilave edilerek bina tespiti yapılması işlemi kapsamaktadır. Oluşturulan nSYM verisi 3Boyut bilgisi taşımaktadır ve arazi çıplak yüzeyi üstünde bulunan objelerin yükseklik bilgisini içermektedir. Bu bilgi ile yol bina gibi benzer yansıma sunan ve bu nedenle karışan sınıf objelerindeki hatalar giderilmiş olacaktır. Spatial Analyst fonksiyonunun Combine aracı ile ortofoto görüntüsünün üç bandına ($OV_{B1,B2,B3}$) ek bant olarak nSYM eklenmiştir. Böylelikle dört banda sahip ortofoto oluşturularak analize hazır hale getirilmiştir ($OV_{B1,B2,B3,3BV}$).


3B ek verisinin bina tespitindeki etkisinin belirlenebilmesi için ek bant sonrası tekrar sınıflandırma işlemi uygulanmıştır. Sınıflandırma işleminde farklılık oluşturmaması için aynı örnekleme alanları tekrar kullanılarak sınıflandırma işlemi ek bant eklenmiş veriye uygulanmıştır. Çalışma alanında objeler dört sınıfa (bina, yol, yeşil alan ve araçlar) ayrılmış ve öncelikle kontrollü sınıflandırma daha sonra DVM yöntemleri ile görüntü sınıflandırılmıştır. Sınıflandırma sonuçları Şekil 4.17 ve Şekil 4.18’de sunulmuştur.



Şekil 4.17. a. Ortofoto b. DVM ile sınıflandırılmış ek bant eklenmiş ortofoto verisi (OV_{B1,B2,B3,3BV})

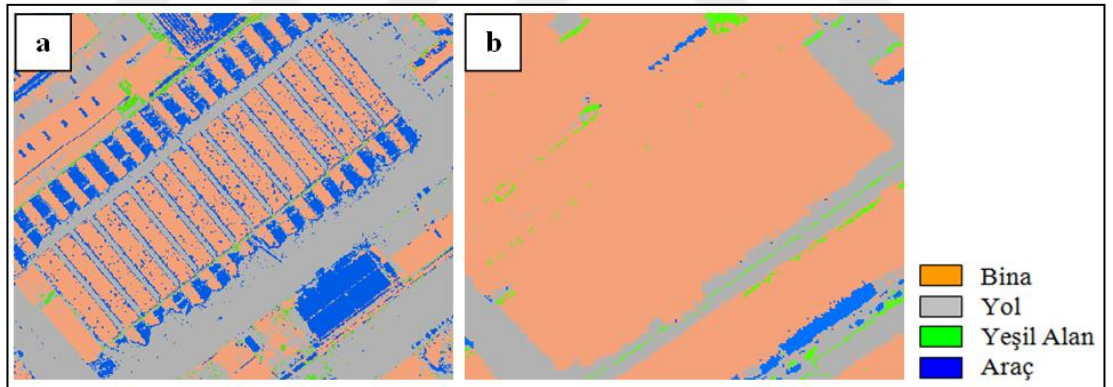


Şekil 4.18. a. Ortofoto b. EBO ile sınıflandırılmış ek bant eklenmiş ortofoto verisi (OV_{B1,B2,B3,3BV})



Şekil 4.19. a. EBO ile sınıflandırılmış ortofoto verisi ($OV_{B1,B2,B3}$), b. EBO ile sınıflandırılmış ek bant eklenmiş ortofoto verisi ($OV_{B1,B2,B3,3BV}$)

EBO algoritması ile ortofoto verisi ($OV_{B1,B2,B3}$) üzerinden yapılan kontrollü sınıflandırma işlemi sonucunda görüldüğü gibi hatalı olan bina sınıfının (Tablo 4.19. a), ek bant olarak eklenmiş ortofoto verisi ($OV_{B1,B2,B3,3BV}$) kullanılarak yapılan sınıflandırma işlemi ile (Tablo 4.19. b) doğru sınıfa atandıkları bina sınıfının daha belirgin ve daha sağlıklı sonuçlar ürettiği diğer sınıflarda gözle görünür değişiklikler olmadığı doğruluk değerinin yükseldiği gözlemlenmiştir.



Şekil 4.20. a.DVM ile sınıflandırılmış ortofoto verisi ($OV_{B1,B2,B3}$), b. DVM ile sınıflandırılmış ek bant eklenmiş ortofoto verisi ($OV_{B1,B2,B3,3BV}$)

DVM algoritması ile ortofoto verisi ($OV_{B1,B2,B3}$) üzerinden yapılan kontrollü sınıflandırma işlemi sonucunda görüldüğü gibi, hatalı olan bina ve yol sınıflarının (Tablo 4.20. a), ek bant olarak eklenmiş ortofoto verisi ($OV_{B1,B2,B3,3BV}$) kullanılarak yapılan sınıflandırma işlemi ile (Tablo 4.20. b) doğru sınıfa atandıkları bina ve yol sınıflarının daha belirgin ve daha iyi sonuçlar verdiği ve doğruluk değerinin yükseldiği gözlemlenmiştir.

5. DOĞRULUK ANALİZİ

Doğruluk analizi, herhangi bir sınıflandırma projesinin önemli bir parçasıdır. Sınıflandırılmış görüntüyü, doğru veya temel gerçek veriler olarak kabul edilen başka bir veri kaynağı ile karşılaştırır. Zemin gerçekleri sahada toplanabilir; bununla birlikte, bu zaman alıcı ve pahalıdır. Çalışmada yer gerçeği verileri her bir sınıf için 80 nokta olacak şekilde toplamda 320 nokta belirlenmiştir. Alana rastgele olarak atılan yer gerçeği noktalarının ortofoto görüntüsü üzerinden yer gerçeği türleri öncelikle belirlenmiş ve veri tabanına kaydedilmiştir. Daha sonra bu noktaların altında kalan kategori türleri her bir sınıflandırma için çekilerek veri tabanına eklenmiştir. Bölgeye ait başarı değerlendirmesinin yapılabilmesi için, .dgn veri formatında alınan bina izi verilerine öncelikle format dönüşümü yapılmış, daha sonra güncel Google Earth verilerinden faydalanılarak güncelliği kontrol edilmiş ve Ortofoto görüntüsü ile farklı projeksiyonda olan bina izi verilerinin tam örtüşme sağlanması için geometrik rektifikasyonu yapılmıştır. Akabinde oluşturulan bina taban izi haritası ile EBO ve DVM kontrollü sınıflandırma sonuçlarının karşılaştırılması ile başarı değerlendirilmesi gerçekleştirilmiştir.

Doğruluk analizi her bir sınıflandırma sonucu için yapılarak, yer gerçeği verilerinden bir hata matrisi oluşturulmuştur. Oluşturulan hata matrisi için, Formül (3)'e göre kappa değeri ve formül (4)'ye göre ise toplam doğruluk değeri (TDD) hesaplanmıştır [38].

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_i \cdot x_{+i}}{N^2 - \sum_{i=1}^r x_i \cdot x_{+i}} \quad (5.1)$$

r= kat sayısı; x_{ii} hata matrisinin köşegen elemanları

x_{i+} satır toplamı; x_{+i} =sütun toplamı

N = Hata matrisindeki toplam kat sayısı

$$TDD = \frac{N \sum_{i=1}^r X_{ii}}{N} \quad (5.2)$$

TDD= Toplam Doğruluk Değeri

Tablo 5.1. Sınıflandırma performansı, Hata matrisi

EBO (OV B1,B2,B3)									
Bilinen Sınıf Tipi Referans Verisi	SINIFLAR	1	2	3	4	I	II	III	IV
	1	65	5	0	10	80	81,25	15	15
	2	13	60	3	4	80	75,00	20	20
	3	0	3	77	0	80	96,25	3	3
	4	21	8	0	51	80	63,75	29	29
	V	80	80	80	80	320		67	67
DVM (OV B1,B2,B3)									
Bilinen Sınıf Tipi Referans Verisi	SINIFLAR	1	2	3	4	I	II	III	IV
	1	64	0	8	0	72	88,89	8	16
	2	16	80	0	0	96	83,33	16	0
	3	0	0	72	0	72	100	0	8
	4	0	0	0	80	80	100	0	0
	V	80	80	80	80	320		24	24
EBO (OV B1,B2,B3,3BV)									
Bilinen Sınıf Tipi Referans Verisi	SINIFLAR	1	2	3	4	I	II	III	IV
	1	80	0	0	0	80	100	0	0
	2	6	66	6	2	80	82,50	14	14
	3	3	2	75	0	80	93,75	5	5
	4	1	22	6	51	80	63,75	29	29
	V	80	80	80	80	320		48	48
DVM (OV B1,B2,B3,3BV)									
Bilinen Sınıf Tipi Referans Verisi	SINIFLAR	1	2	3	4	I	II	III	IV
	1	79	0	0	0	80	98,75	0	1
	2	0	80	0	0	80	100	0	0
	3	0	0	80	0	80	100	0	0
	4	1	0	0	80	80	100	1	0
	V	80	80	80	80	320		1	1
	Bina	Yol	Yeşil Alan	Araç					

Tablo 5.1 I = Satır toplamı; II = Her bir sınıfın yüzde olarak sınıflandırma doğruluğu, III = Referans verisinde i sınıfına ait olan, fakat sınıflandırma sonucu i sınıfına atanmamış piksel sayısı, IV = Sınıflandırma sonucu i sınıfına atanmış olan, fakat referans verisinde i sınıfında olmayan piksel sayısı V = Sütun toplamını ifade eder.

6. PERFORMANS DEĞERLENDİRİLMESİ

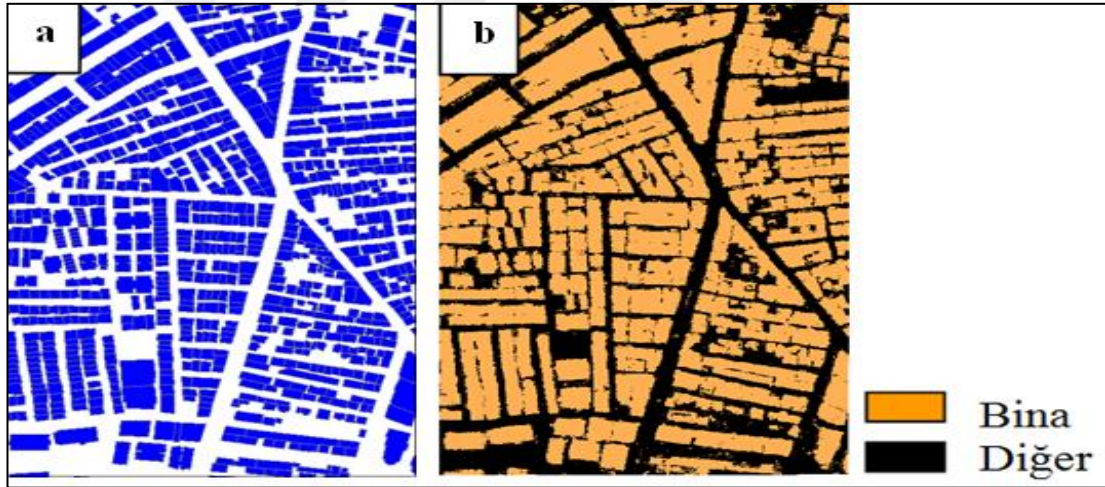
Görüntü sınıflandırması, arazi örtüsü sınıflarını piksellere ayırma işlemidir. Genel olarak bunlar uzaktan algılamada üç ana görüntü sınıflandırma tekniğine ayrılmaktadır: kontrollü görüntü sınıflandırması, kontrolsüz görüntü sınıflandırması ve nesne tabanlı sınıflandırma. Kontrollü görüntü sınıflandırması ve kontrolsüz görüntü sınıflandırması teknikleri en yaygın iki yaklaşımlardır. Ancak, nesne tabanlı sınıflandırma daha yüksek oranda kullanıldığından, yüksek çözünürlüklü veriler için yararlıdır. Bu çalışmada ise kullanılan ortofoto verisi yüksek çözünürlükte olduğu için sınıflandırma tekniği olarak kontrollü sınıflandırma yöntemlerinden EBO ve DVM seçilmiştir. Buna göre her nesne için eğitim alanları belirlenerek uygulama yapılmıştır.

Ortofoto verisi üzerinden yapılan kontrollü sınıflandırma yöntemlerinden EBO (OV_{B1,B2,B3}) sınıflandırmasında bina, yol, yeşil alan ve araç için doğruluk sırasıyla %81,25, %75, %96,25 ve %63,75 iken, DVM (OV_{B1,B2,B3}) sınıflandırmasında doğruluk değerleri sırasıyla %88,89, %83,33, %100 ve %100 olarak arttığı belirlenmiştir. Ayrıca LİDAR'dan elde edilmiş bina verilerinin ek bant olarak eklenmesi ile yapılan kontrollü sınıflandırma işleminde ise EBO (OV_{B1,B2,B3,3BV}) sınıflandırmasında yol, yeşil alan ve araç için doğruluk sırasıyla %82,50, %93,75 ve %63,75 iken DVM (OV_{B1,B2,B3,3BV}) sınıflandırmasında doğruluk değerleri %100 olarak arttığı, bina sınıfında ise küçükte olsa azalma olduğu belirlenmiştir.

LİDAR, günümüzde hem kentsel hem de kırsal alanlarda geniş araziler ve manzara alanlarını doğru olarak ölçmenin en hızlı ve verimli yöntemi olarak kabul edilmektedir. Binaların sık olmadığı alanlarda ise binaya ait bilgiler yüksek doğrulukla elde edilebilmektedir. Farklı bina yapıları bulunan, farklı yükseklikte ve sık bina yapısı bulunan alanlar için ise LİDAR'ın performansı çok çalışılmış konulardan değildir. Bu nedenle farklı (konut, ticari, sanayi vb.) ve sık bina yapılarının (geniş olmayan dar sokakların bulunduğu) ve yeşil alanlara sahip bir bölge çalışma alanı olarak seçilmiştir. Bu alanda ortofoto görüntülerinden bina tespiti

performansının değerlendirilmesi LİDAR verileri ile desteklenmiştir. Elde edilen neticelere göre bu alanda binalar karmaşık bir dokuya sahip olmasına rağmen alana ait ortofotoya, LİDAR verileri yardımı ile elde edilen nSYM'nin ek bant olarak eklenmesi ile bina tespiti performansının olumlu şekilde etkilendiği görülmüştür.

Bu çalışmada yalnızca ortofoto kullanıldığında yapıların tespitinin başarısının zayıf olduğu ve LİDAR veri yardımı ile nSYM'nin ilave bant olarak ortofoto ile birleştirildiğinde bina tespiti performansının başarısının yükseldiği ispat edilmiştir. Başarı değerlendirmesi bölgeye ait bina taban izi haritası (Şekil 6.1) ile EBO ve DVM kontrollü sınıflandırma sonuçlarının karşılaştırılması ile gerçekleştirilmiştir. Bu değerlendirme için yapılan sınıflandırmalarda sadece bina sınıfı dikkate alınmıştır. Bu nedenle yapılan sınıflandırmalar yeniden sınıflandırma ile bina ve diğer sınıfı olarak iki kategoriye atanmıştır. Daha sonra bina izi haritaları ile karşılaştırılmıştır. Her bir sınıflandırma sonrası elde edilen toplam bina alanları yer gerçeği olarak kullanılan 2013 bina izi taban alanları ile karşılaştırılmıştır.



Şekil 6.1. a. Bina taban izi haritası, b. Sınıflandırılmış görüntü

Tablo 6.1. Farklı haritalara ait bina alanları ve doğruluk analizi sonuçları

Harita	Bina Sayısı (Adet)	Bina Alanı (m ²)	Genel Doğruluk	Kappa Katsayısı
EBO (OV _{B1,B2,B3})	510	140073,31	%79	0,72
EBO (OV _{B1,B2,B3,3BV})	815	160019,23	%85	0,80
DVM (OV _{B1,B2,B3})	600	161601,68	%92	0,71
DVM (OV _{B1,B2,B3,3BV})	890	158318,76	%99	0,87
Bina taban izi haritası	900	158559,63	-	-

Tablo 6.1.'e göre EBO sınıflandırması ile bina tespitinde sadece ortofoto kullandığında bina sayısı ile bina taban izi haritası karşılaştırıldığında 390 adet bina farkı ortaya çıkmaktadır. Ancak ortofoto verisine LİDAR verilerinden elde edilen bina izleri haritası ek bant olarak eklediğinde 85 adet bina farkı gözükmemektedir. DVM sınıflandırma yöntemi ile bina tespitinde ise ortofoto kullandığında bina sayısı bina taban izi haritası ile karşılaştırıldığında 300 adet bina farkı oluşmaktadır. Ortofoto verisine LİDAR verilerinden elde edilen bina izleri haritası ek bant olarak eklediğinde 10 adet bina farkı oluşmaktadır. Buna göre LİDAR verileri bina tespiti performansı çalışmalarına yönelik kullanıldığı zaman, hem çalışmanın doğruluğunu artırmakta hem de gerçeğe daha yakın ve daha duyarlı sonuç elde edilebileceğini göstermektedir.

Tablo 5.1. ve Tablo 6.1'de görüldüğü gibi ortofoto verisi üzerinden yapılan kontrollü sınıflandırma yöntemlerinden EBO sınıflandırmasında hatalı olan sınıfların (bina, yol, yeşil alan ve yol), DVM sınıflandırmasında doğru sınıfa atandıkları ve daha iyi sonuçlar verdiği doğruluk değerinin %79'dan %92'ye yükseldiği gözlemlenmiştir. Ayrıca Tablo 5.1. ve Tablo 6.1'den anlaşılacağı gibi LİDAR'dan elde edilmiş bina verilerinin ek bant olarak eklenmesi ile yapılan kontrollü sınıflandırma işleminde ise EBO sınıflandırmasında küçük farklılıklar olduğu, DVM sınıflandırmasında ise bina, yol ve araç sınıflarının daha belirgin, anlamlı bir ölçüde önemli bir gelişme kaydedildiği doğruluk değerinin %92'den %99'a yükseldiği görülmüştür.

7. SONUÇLAR VE ÖNERİLER

Günümüzde arazi kullanım haritalarının uygulanması kentsel planlama için bilgi üretme konusundaki kritik konulardan biridir. Arazi kullanım haritalarının hazırlanmasında uydu ve ortofoto görüntülerinin kullanılması uygun bir strateji olarak önerilmiştir. Farklı geçmişlere ait görüntüleri kullanarak, bu verilerin yetenekleri ve kısıtlamaları tanınabilir. Ayrıca LİDAR sistemleri bilim insanlarına haritalama alanındaki hem doğal hem de yapay alanların azami hassasiyet ve doğrulukta incelenmesine imkân sağlamaktadır. Bilim insanları daha hassas kıyı haritalarının üretilmesinde, dijital yükseklik modellerinin oluşturulmasında ve diğer birçok alanlarda LİDAR kullanmaktadırlar.

Bütün algoritmaların artısı veya eksisi vardır. Kentin özellikleri, zayıf ve güçlü yönleri dikkate alınarak en iyi algoritma seçilmelidir. Her ne kadar en iyi algoritma seçimine ilişkin bazı düşünceler sağlamak çok zor olsa da, bu çalışma, sınıflandırma ve farklı veri kaynaklarının ek bant olarak kullanıldığı çalışmalar kapsamında çıktılar sunmaktadır. Bu çalışmada, Ortofoto ve LİDAR verileri ile İstanbul İli Küçükçekmece bölgesinde EBO ve DVM algoritmaları kullanılarak arazi kullanımı sınıflandırma teknikleri uygulanmıştır. EBO ve DVM algoritmaları, orijinal veriler ve farklı bant kombinasyonu sınıflandırma işlemi için kullanılmış ve sınıflandırma algoritmalarının performans karşılaştırması yapılmıştır. Şekil 4.17, Şekil 4.18 ve Tablo 5.1’de görüldüğü gibi ortofoto verisi üzerinden yapılan kontrollü sınıflandırma yöntemlerinden EBO sınıflandırmasında hatalı olan sınıfların (bina, yol, yeşil alan ve yol), DVM sınıflandırmasında doğru sınıfa atandıkları ve daha iyi sonuçlar verdiği görülmüştür. EBO (OV_{B1,B2,B3}) sınıflandırmasında bina, yol, yeşil alan ve araç için doğruluk sırasıyla %81,25, %75, %96,25 ve %63,75 iken, DVM (OV_{B1,B2,B3}) sınıflandırmasında doğruluk değerleri sırasıyla %88,89, %83,33, %100 ve %100 olarak arttığı belirlenmiştir. Ayrıca kappa istatistiğinin 0,72’den 0,80’e, genel doğruluk değerinin ise %79’dan %85’e yükseldiği gözlemlenmiştir. Ayrıca LİDAR’dan elde edilmiş bina verilerinin ek bant olarak eklenmesi ile yapılan kontrollü sınıflandırma işleminde ise EBO ve DVM sınıflandırmasında, bina, yol ve

araç sınıflarının daha belirgin, anlamlı bir ölçüde önemli bir gelişme kaydedildiği tespit edilmiştir (Şekil 4.19, Şekil 4.20 ve Tablo 5.1.'de). EBO (OV B1,B2,B3,3BV) sınıflandırmasında yol, yeşil alan ve araç için doğruluk sırasıyla %82,50, 93,75 ve %63,75 iken, DVM (OV B1,B2,B3,3BV) sınıflandırmasında doğruluk değerleri %100 olarak arttığı belirlenmiştir. Ayrıca kappa istatistiğinin 0,80'den 0,87'ye, doğruluk değerinin %92'den %99'a yükseldiği görülmüştür.

Aynı sınıflandırma yöntemleri, ek veri almış ve almamış olarak karşılaştırıldığında LİDAR ek bant etkisi daha net izlenebilmektedir. Buna göre, EBO sınıflandırma farklarına bakıldığında EBO (OV B1,B2,B3) sınıflandırması %79 genel doğruluk sunar iken, ek bant almış EBO (OV B1,B2,B3,3BV) sınıflandırma genel doğruluğu %85'e yükselmiştir. Aynı şekilde DVM (OV B1,B2,B3) sınıflandırması %92 genel doğruluk sunar iken, ek bant almış DVM (OV B1,B2,B3,3BV) sınıflandırma genel doğruluğu %99'a yükselmiştir.

Sonuç olarak, EBO sınıflandırmasına göre DVM sınıflandırma yönteminin performansının daha yüksek olduğu, ayrıca 3B bilgisi ek bant olarak eklenmiş verinin mevcut bant sınıflandırmasına göre daha etkili olduğu ortaya çıkmıştır. Fakat burada doğruluk matrisi analizlerinde unutulmamalıdır ki sınıf doğrulukları, genel sınıflandırma doğruluğu ve kappa doğruluğu seçilmiş olan yer gerçeği noktalarına bağlıdır. Rastgele seçilmiş olan bu 320 noktanın değişmesi durumunda sunulmuş olan bu doğruluk değerlerinin bir miktar değişim göstereceği belirtilmelidir.

Bu nedenle yapılan ikinci değerlendirme ise bina izi verilerini ele alarak alansal karşılaştırmalar ile yapılmıştır. Her iki yöntemdeki sınıflandırmaların sonuçları elde tutulan bina taban izi haritası ile doğrulanmıştır. EBO ve DVM sınıflandırmaları ile bina tespitinde sadece ortofoto kullandığında bina sayısı ile bina taban izi haritası karşılaştırıldığında bina sınıfında olması gereken sınıfların bina izi poligonlarındaki güncel olmayan veriler ile benzer yansıma veren hatalı sınıflara (yol, yeşil alan ve araç) atanmaları sonucu sırasıyla 390 adet ve 300 adet eksik bina ortaya çıkmaktadır. Ancak LİDAR veri yardımı ile nSYM'nin ilave bant olarak ortofoto ile birleştirildiğinde EBO sınıflandırması ile bina tespitinde benzer yansıma veren hatalı olarak atanan objelerin bir kısmının bina sınıfına atanması, bina taban izi poligonlarındaki yıkılmış binalar ve fabrika binalarındaki ilave sundurmaların ayrı

yapı olarak gösterilmesi gibi güncel olmayan verilerden kaynaklı 85 adet eksik bina ortaya çıkmaktadır. DVM sınıflandırılması ile bina tespitinde ise benzer yansıma veren hatalı olarak atanan objelerin tamamının bina sınıfına atanması sonucu 10 adet eksik bina olduğu eksik olan bu binaların bir kısmının bina taban izi poligonlarındaki güncel olmayan verilerden(yıkılmış binalar ve fabrika binalarındaki ilave sundurmaların ayrı yapı olarak gösterilmesi) kaynaklandığı görülmektedir. Buna göre LİDAR verileri bina tespiti performansı çalışmalarına yönelik kullanıldığı zaman, hem çalışmanın doğruluğunu artırmakta hem de gerçeğe daha yakın ve daha duyarlı sonuç elde edilebileceğini göstermektedir. DVM, üstün sınıflandırma kabiliyetine sahip olması nedeniyle uzaktan algılama uygulamalarında özellikle son yıllarda sıklıkla kullanılan ve güzel sonuçlar veren bir yöntemdir. DVM sınıflandırma yönteminin başarısı, kullanıcı tarafından belirlenen en uygun (optimum) parametre setinin ve uygun kernel türünün seçimine bağlıdır. En uygun parametre seti/uygun kernel türü görüntüden görüntüye ve kullanılacak eğitim verisine göre değişiklik göstermekte ve sınıflandırma öncesinde bilinmemektedir. O nedenle en uygun parametre seti ve kernel türü aranmalıdır. Ortofoto görüntülerinin sınıflandırması işleminde en uygun parametre seti ve uygun kernel türünün seçimi ile DVM sınıflandırma yönteminin, EBO yöntemine kıyasla daha yüksek sınıflandırma doğruluğuna sahip olduğu literatürde birçok çalışma ile ispatlanmıştır. Bu tez çalışmasında uygun kernel türü ve en uygun parametre setinin belirlenmesi ile, kullanılan ortofoto görüntüsü için de DVM sınıflandırma yöntemi sonucu elde edilen görüntülerin sınıflandırma doğruluğu EBO sınıflandırma yöntemi sonucu elde edilen görüntülerin sınıflandırma doğruluğundan daha yüksektir. DVM sınıflandırma yöntemi, EBO yöntemine göre performans olarak üstün olmasına rağmen, karmaşık matematiksel yapısı nedeniyle sınıflandırma işlemi zamansal olarak EBO yöntemine göre uzun sürmektedir. DVM algoritması, arazi kullanım haritalarının çıkarılması için en yüksek doğruluğu ve çalışma alanıyla daha iyi tutarlı olması nedeniyle en uygun sınıflandırıcı olarak önerilmiştir. Ayrıca 3B verisi sunan LİDAR'ın ek bant olarak eklendiği görüntülerde de, yer üstü objelerinin tespitine katkı sağladığı; asfalt yol, toprak yol gibi objelerle benzer yansıma veren bina objelerinin ayrımının daha kolay yapılabildiği, doğruluk yönünden etkili bir yöntem olduğu tespit edilmiştir. LİDAR pahalı bir teknoloji olduğundan 3B verisini elde etmek için alternatif olarak drone'den elde edilmiş 3B verisi bu tür çalışmalar için kullanılabilir.

Çalışma başarısını olumsuz yönde etkileyen faktörler şehrin metropoliten bir yapıya sahip olması, denetleme verilerinin kontrol edilememesi, binaların iç içe karmaşık ve farklı yapılara sahip olması gibi nedenler sıralanabilir. Çalışma alanında farklı bina yapıları ve farklı arazi sınıflarının olması yapılan çalışmaya gerçekçi ve genel bir bakış açısı konusunda önem kazandırmıştır. LİDAR sayesinde spektral hata kaynakları minimize edilmiştir. Yapılacak bu türden çalışmalar şehrin planlanması konusunda model oluşturulmasında, kaçak yapılaşmanın önüne geçilmesinde, hasarlı ve hasarsız binaların tespit edilmesi ve hasar tahmini gibi çeşitli uygulamalar için destek sağlamaktadır.



KAYNAKLAR

- [1] Kiamba A., The Sustainability of Urban Development in Developing Economies, *The Journal of Sustainable Development*, DOI: 10.7916/D8XD11C8.
- [2] Lee D.S., Class-Guided Building Extraction from Ikonos Imagery, *Fotogrametrik Engineering and Remote Sensing Journal*, 2003, **69**(2), 143-150.
- [3] Erener A., Classification Method, Spectral Diversity, Band Combination and Accuracy Assessment Evaluation for Urban Feature Detection, *International Journal of Applied Earth Observation and Geo information*, DOI: 10.1016/j.jag.2011.12.008.
- [4] Inglada J., Automatic Recognition of Man-made Objects in Highresolution Optical Remotesensing İmag Esby SVM Classification of Geometric İmage Features, *ISPRS Journal of Photogrammetry and Remote Sensing*, 2007, **62**(3), 236-248.
- [5] Yastıklı N., LİDAR ve Hava Fotoğraflarının Füzyonu ile Otomatik Bina Çıkarımı, *XIII. Türkiye Harita, Bilimsel ve Teknik Kurultayı*, Ankara, Türkiye, 18-22 Nisan 2011.
- [6] Sefercik U.G., Yüksek Çözünürlüklü Optik Uydu Görüntülerinden Otomatik Bina Çıkarımı Performansının Arttırılmasına Yönelik Yeni Bir Yaklaşım-Quicbird Örneği, *V. Uzaktan Algılama-CBS Sempozyumu*, İstanbul, Türkiye, 14-17 Ekim 2014.
- [7] Miller J., Building Extraction From LİDAR Using Edge Detection, Department of Geoin Formatics and Geospatial Intelligence, George Mason University Fairfax, Virginia, 2015, 10503.
- [8] Kausika BB., Dolla O., Folkerts W., Siebenga B., Hermans P., Yüksek Çözünürlüklü LİDAR Verileri Kullanarak Potansiyelin Hesaplanması İçin Bir Çalışma Modeli, *2015 Uluslar arası Akıllı Şehirler ve Yeşil Bilişim Sistemleri Konferansı (SMARTGREENS)*, Lizbon, Portekiz, 20-22 Mayıs 2015.
- [9] Yang P., Ames D.P., Glenn N.F., Anderson D., Effects of LİDAR Derived DEM Resolution on Hydrographic Feature Extraction, *AGU Fall Meeting Abstracts*, 2010.
- [10] Myung I.J, Tutorial on Maximum Likelihood Estimation, *Journal of Mathematical Psychology*, DOI: 10.1016 / S0022-2496 (02) 00.028-7.

- [11] Zolkos S.G., Goetz S.J., Dubayah R., LİDAR Uzaktan Algılama Kullanarak Karasal Yer Üstü Biyokütle Tahmininin Meta-analizi, *Elsevier Çevrenin Uzaktan Algılanması*, DOI: 10.1016/j.rse.2012.10.017.
- [12] Næsset E., Bollandas O.M., Gobakken T., Gregoire T.G., StahlG., Havadaki LİDAR Tarafından Desteklenen Bir Örnek Anket Çalışmasında, 11 Yıllık Bir Süre İçinde Orman Biyokütlesindeki Değişimin Model Yardımlı Tahmini, *Elsevier Çevrenin Uzaktan Algılanması*, DOI: 10.1016/j.rse.2012.10.008.
- [13] Bilgi S., Fotogrametri ve Uzaktan Algılamada Veri Elde Etme Yöntemlerinin Gelişimi ve Kısa Tarihçeleri, *Harita Dergisi*, 2007, **1**(96), 48-55.
- [14] Sabins F.F., *Remote Sensing Principles and Interpretation*, 3rd ed., Waveland Pr Inc, Los Angeles, 2007.
- [15] Tolt G., Soderman U., Ahlberg S., 3D Urban Models From Laser Radar Data, *Urban Remote Sensing Joint Event*, DOI: 10.1109/URS.2017.371813.
- [16] Lee D.H., Lee K.M., Lee S.U., Fusion of LİDAR and Imagery for Reliable Building Extraction, *Photogrammetric Engineering and Remote Sensing*, DOI: 10.14358/PERS.74.2.215.
- [17] San D.K., Türker M., Building Extraction From High Resolution Satellite Images Using Hough Transform, *International Archives of Photogrammetry, Remote Sensing, and Spatial Information Sciences*, 2010, **38**(8), 1063-1068.
- [18] Yılmaz M., Hava LİDAR Nokta Bulutunun Sayısal Yüksek Modeli Doğruluğunda Etkisi, *Harita Teknolojileri Elektronik Dergisi*, DOI: 10.15659/hartek.15.12.108.
- [19] Agarval T., LİDAR Systems and Applications, Elprocus, <https://www.elprocus.com/LİDAR-light-detection-and-ranging-working-application>, (Ziyaret tarihi: 15 Mayıs 2018).
- [20] Polat N., Uysal M., Hava Lazer Tarama Sistemi, Uygulama Alanları ve Kullanılan Yazılımlara Genel Bir Bakış, *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 2016, **16**(3), 679-692.
- [21] Campbell, J.B., *Introduction to Remote Sensing*, 2nd ed., Guilford Press, New York, 1996.
- [22] Guillen C., Supervised Classification, Humboldt Devlet Üniversitesi, http://gsp.humboldt.edu/olm_2015/Courses/GSP_216_Online/lesson6-1/supervised.html, (Ziyaret tarihi: 20 Ekim 2017).
- [23] Gualtieri J.A., Cromp R.F., Support Vector Machines for Hyperspectral Remote Sensing Classification, *International Society for Optics and Photonics*, DOI: 10.1117/12.339824.
- [24] Vapnik V.N., *The Nature of Statistical Learning Theory*, 2nd ed., Springer, New York, 2000.

- [25] Song X., Duan Z., Jiang X., Comparison of Artificial Neural Networks and Support Vector Machine Classifiers for Land Cover Classification in Northern China Using a SPOT-5 HRG Image, *International Journal of Remote Sensing*, **33**(10), 3301-3320.
- [26] Foody G.M., Mathur A., Toward Intelligent Training of Supervised Image Classifications: Directing Training Data Acquisition for SVM Classification, *Remote Sensing of Environment*, **93**(1-2), 107-117.
- [27] Mathur A., Foody G.M., Multiclass and Binary SVM Classification: Implications for Training and Classification Users, *IEEE Geoscience and Remote Sensing Letters*, **5**(2), 241-245.
- [28] Çölkesen İ., Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması ve Analizi, Yüksek Lisans Tezi, Gebze Üniversitesi, Gebze Yüksek Teknoloji Enstitüsü, Kocaeli, 2009, 245292.
- [29] Akar Ö., Güngör O., Classification of Multispectral Images Using Random Forest Algorithm, *Journal of Geodesy and Geoinformation*, **1**(2), 105-112.
- [30] Campell J.B., Wynne R.H., *Introduction to Remote Sensing*, 5th ed., Guilford Publications, New York, 2011.
- [31] Mather P.M., Koch M., *Computer Processing of Remotely-Sensed Images*, 4th ed., Wiley-Blackwell, Oxford, 2011.
- [32] Sunar F., *Uzaktan Algılama*, Anadolu Üniversitesi Yayını, Eskişehir, 2010.
- [33] Kavzoglu T., ve Colkesen I., A Kernel Functions Analysis for Support Vector Machines for Land Cover Classification, *International Journal of Applied Earth Observation and Geoinformation*, **11**(5), 352-359.
- [34] Evsahibioglu N.A., Uzaktan Algılama Temel Eğitimi Kurs Notları, *Tübitak Marmara Araştırma Merkezi Uzay Bilimleri Teknolojisi Bölümü*, Gebze, Türkiye, 3-7 Mayıs 1993.
- [35] Mather P.M., *Computer Processing of Remotely Sensed Images*, Wiley, 1999, **25**(1), 145-146.
- [36] Kapluhan E., Coğrafi Bilgi Sistemleri'nin(CBS) Coğrafya Öğretiminde Kullanımının Önemi ve Gerekliliği, *Marmara Coğrafya Dergisi*, DOI: 10.14781/MCD.2014298120.
- [37] T.C Meteoroloji Genel Müdürlüğü, www.mgm.gov.tr/veridegerlendirme/il-veilceler-istatistik.aspx?m=Kocaeli, (Ziyaret tarihi: 2 Mart 2018).
- [38] Congalton R.G., 1991, A Review of Assessing the Accuracy of Classification of Remotely Sensed Data, *Remote Sensing of Environment*, **37**(1), 35-46.

KİŞİSEL YAYINLAR VE ESERLER

- [1] Erener A., **Gerim V.**, LİDAR Verileri İle Desteklenmiş Ortofoto Görüntülerinden Bina Tespiti Performans Değerlendirilmesi: İstanbul, Küçükçekmece Örneği, *Dergi Park*, 2018, 1(2), 53-61.



ÖZGEÇMİŞ

Vural GERİM 1979'da Zonguldak'ta doğdu. Lise öğrenimini Fener Lisesi'nde tamamladı. 1997 yılında girdiği Afyon Kocatepe Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Bölümünden 2002 yılında mezun oldu. Lisans eğitimini bitirdikten sonra 2003 yılında Teğmen olarak askerlik görevini tamamladı. Askerlik sonrası 2 yıl özel şirkette, 11 yıl Kamuda çalışmış olup şuan özel bir şirkette çalışmaktadır. 2015 yılın başında Kocaeli Üniversitesi Jeodezi ve Jeoinformasyon Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. Yüksek lisans eğitiminde "LİDAR Verileri ile Desteklenmiş Ortofoto Görüntülerinden Bina Tespiti Performans Değerlendirmesi konusunda çalışmaları bulunmaktadır.