



Yüksek Çözünürlüklü Uydu Görüntüleri ve Derin Öğrenme Kullanılarak 3 Boyutlu Kent Modeli Oluşturulması

Harita Mühendisliği Ana Bilim Dalı

Yüksek Lisans Tezi

Arzu Ece ATİLA

ORCID 0000-0002-5091-7410

Tez Danışmanı: Dr. Öğr. Üyesi Osman Sami Kırtıloğlu

Haziran 2022

İzmir Kâtip Çelebi Üniversitesi Fen Bilimleri Enstitüsü öğrencisi **Arzu Ece ATİLA** tarafından hazırlanan **Yüksek Çözünürlüklü Uydu Görüntüleri ve Derin Öğrenme Kullanılarak 3 Boyutlu Kent Modeli Oluşturulması** başlıklı bu çalışma tarafımızca okunmuş olup, yapılan savunma sınavı sonucunda kapsam ve nitelik açısından başarılı bulunarak jürimiz tarafından YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

ONAYLAYANLAR:

Tez Danışmanı: **Dr. Öğr. Üyesi Osman Sami KIRTILOĞLU**
İzmir Kâtip Çelebi Üniversitesi

Jüri Üyeleri:

Doç. Dr. Zeynel Abidin POLAT
İzmir Kâtip Çelebi Üniversitesi

Dr. Öğr. Üyesi Osman ORHAN
Mersin Üniversitesi

Savunma Tarihi: 22.07.2022

Yazarlık Beyanı

Ben, **Arzu Ece ATILA** başlığı **Yüksek Çözünürlüklü Uydu Görüntüleri ve Derin Öğrenme Kullanılarak 3 Boyutlu Kent Modeli Oluşturulması** olan bu tezimin ve tezin içinde sunulan bilgilerin şahsıma ait olduğunu beyan ederim. Ayrıca:

- Bu çalışmanın bütünü veya esası bu üniversitede Yüksek Lisans derecesi elde etmek üzere çalıştığım süre içinde gerçekleştirilmiştir.
- Daha önce bu tezin herhangi bir kısmı başka bir derece veya yeterlik almak üzere bu üniversiteye veya başka bir kuruma sunulduysa bu açık biçimde ifade edilmiştir.
- Başkalarının yayımlanmış çalışmalarına başvurduğum durumlarda bu çalışmalara açık biçimde atıfta bulundum.
- Başkalarının çalışmalarından alıntıladığımda kaynağı her zaman belirttim. Tezin bu alıntılar dışında kalan kısmı tümüyle benim kendi çalışmamdır.
- Kayda değer yardım aldığım bütün kaynaklara teşekkür ettim.
- Tezde başkalarıyla birlikte gerçekleştirilen çalışmalar varsa onların katkısını ve kendi yaptıklarımı tam olarak açıkladım.

Tarih: .../.../2022

Yüksek Çözünürlüklü Uydu Görüntüleri ve Derin Öğrenme Kullanılarak 3 Boyutlu Kent Modeli Oluşturulması

ÖZ

Bilgi teknolojisi alanındaki gelişmeler ile mekânsal verilere ait ihtiyaç hem artmış hem de nitelikli veri elde etme ihtiyacı doğrultusunda yöntem arayışlarına sebep olmuştur. Uzaktan algılama ürünleri ile mekânsal verilere ait bilgilerin hızlı ve kolay erişilip, değerlendirilmesi de bu ürünleri son zamanlarda daha da popüler hale getirmiştir. Mekânsal verilerin farklı formatlarda saklanıp, değerlendirilmesine olan ihtiyacın artması ile de 3 boyutlu kent modellerini çekici hale getirmiştir. Böylelikle de uzaktan algılama verileri ile elde edilen mekânsal verilerin; 3 boyutlu modeller şeklinde sunulmasına yönelik çalışmalar da artmaktadır. Bu çalışmada İzmir ili Bayraklı ilçesi Mansuroğlu mahallesi için yüksek çözünürlüklü uydu verileri ile binalara ait çatı sınıfları derin öğrenme yöntemi ile belirlenmiştir. Çatı sınıflandırma işlemi tamamlandıktan sonra sayısal yükseklik modeli ile binalara ait yükseklik verileri elde edilmiş; elde edilen veriler öznitelik tablosunda tanımlanarak, ArcGIS Pro yazılımında CityGML LOD2 standartlarında çalışma alanının 3 boyutlu basit kent modeli elde edilmiştir. Elde edilen 3B modelleme yönteminin kullanılabilirliğini belirlemek model üzerinde farklı özelliklere sahip 3 farklı alanda veriler değerlendirilmiştir. Değerlendirilen verilere göre eğitim verisi örneklerinin ve epok sayısının artışının sınıflandırmadaki başarıyı arttırdığı görülmüştür. Yapılaşma koşullarının çatı tiplerinin ayırt edilmesinde önemli olduğu; bitişik nizam yapılarda çatı tiplerinin daha zor ayırt edildiği, yapılaşma koşullarının benzer olduğu alanlarda sınıflandırmanın daha başarılı olduğu gözlemlenmiştir.

Derin öğrenme yönteminde kullanılan epok sayısı ve eğitim örneklerinin artması ile kırma ve beşik çatı tipinin sınıflandırma doğruluklarının %80 'e kadar çıkabildiği; düz çatı tipinin ise bu durumla ters orantılı olarak doğruluk derecesinin aşağılarda kaldığı gözlemlenmiştir. 300 eğitim verisi ve 250 epokla yapılan işlemdeki doğrulukların %80'leri bulduğu; Eğitim verisi sayısının ve epok sayısının artması ile kırma çatı tipi sınıflandırma doğruluğunun %80 düzeyine çıktığı gözlemlenmiştir. Düz çatı tipindeki sınıflandırma doğruluğunun %70'lere kadar çıkabildiği; beşik çatı tipindeki sınıflandırma doğruluğunun ise düz ve kırma çatı tipleriyle daha çok karıştırılmasından dolayı bu çatı yoğunlukta olduğu alanlarda %80 düzeyinde doğru sonuçlar verdiği gözlemlenmiştir. Karmaşık çatı tiplerinin bulunduğu alanlarda eğitim örneklerinin ve bu örneklerin eğitilmesini sağlayan epok sayısının doğru sonuçların elde edilmesi açısından önemli olduğu tespit edilmiştir.

Anahtar Sözcükler: Coğrafi Bilgi Sistemleri, Çatı Tipi Belirleme, Yüksek Çözünürlüklü Uydu Görüntüleri, 3 Boyutlu Kent Modelleri, Derin Öğrenme, ArcGIS Pro

Creating A 3D Urban Model Using High Resolution Satellite Images and Deep Learning Model

Abstract

According to developments in the field of information technology, the need for spatial data has both increased and led to the search for methods in line with the need to obtain quality data. Quick and easy access and evaluation of spatial data with remote sensing products has made these products even more popular recently. With the increasing need for storing and evaluating spatial data in different formats, 3D city models have become attractive. Thus, studies on presenting spatial data obtained with remote sensing data in the form of 3D models are emerging. In this study, the roof classes of buildings were determined by deep learning method with high resolution satellite imagery for Mansuroglu neighborhood of Bayrakli district of Izmir. After the roof classification process was completed, the height data of the buildings were obtained with the digital elevation model; by defining the obtained data in the attribute table, a simple 3D city model of the study area was obtained in ArcGIS Pro software in accordance with CityGML LOD2 standards. To determine the usability of the obtained 3D modeling method, data were evaluated in 3 different areas with different features on the model. According to the evaluated data, it was seen that the training data samples and the increase in the number of epochs increased the success in classification. Construction conditions are important in distinguishing roof types; it has been observed that the roof types are more difficult to distinguish in adjacent structures and the classification is more successful in areas where the construction conditions are similar. With the increase in the number of epochs and training examples used in the deep learning method, the classification accuracies of the hipped and gable roof types can reach up to 80%. It has been observed that the flat roof type has a lower level of accuracy inversely proportional to this situation.

The accuracy in the process with 300 training data and 250 epochs was 80%. It has been observed that with the increase in the number of training data and the number of epochs, the classification accuracy of the hipped roof type increased to 80%. The classification accuracy of the flat roof type can reach up to 70%. The classification accuracy of the gable roof type is more confused with the flat and hipped roof types, giving accurate results at the level of 80% in areas with this roof density. It has been determined that the training samples and the number of epochs that enable these samples to be trained in areas with complex roof types are important in terms of obtaining accurate results.

Keywords: Geographic Information Systems, Roof Type Determination, High Resolution Satellite Images, 3D City Models, Deep Learning, ArcGIS Pro

Aileme.

Teşekkür

Tez sürecim boyunca bilgi, birikim ve tecrübeleriyle bana yol gösterip; süreçte desteğini esirgeyemeyen danışman hocam Sayın Dr. Öğr. Üyesi Osman Sami Kırtılođlu'na sonsuz teşekkürlerimi ve saygılarımı sunarım.

Çalışmam süresince her konuda destek sağlayan sevgili meslektaşlarım harita mühendisi Ali İhsan Dalođlu ve harita mühendisi Esra Cesur'a,

Bu süreçte yanımda olan, destekleyen değerli arkadaşlarıma ve sevdiklerime,

Hayatım boyunca her zaman her koşulda destekleriyle bugünlere gelmemde en büyük katkısı olan sevgili annem, babam ve kız kardeşime son teşekkürlerimi sunarım.

Arzu Ece ATİLA

İzmir - 2022

İçindekiler Tablosu

Yazarlık Beyanı.....	ii
Öz	iii
Abstract.....	v
Teşekkür	viii
İçindekiler Tablosu.....	ix
Şekiller Listesi	x
Tablolar Listesi	xi
Kısaltmalar Listesi	xii
Bölüm 1	1
Giriş	1
1.1 Literatür Araştırması	2
Bölüm 2	6
Materyal ve Yöntem	6
2.1 Çalışma Alanı	6
2.2 Kullanılan Veri ve Özellikleri.....	6
2.3 Yöntemler	10
Bölüm 3	26
Bulgular	26
Bölüm 4	31
Sonuç	31
Kaynaklar	33
Özgeçmiş	38

Şekiller Listesi

Şekil 2.1	Uygulama alanı sınırı	7
Şekil 2.2	Geometrik düzeltmeden önce ve sonra bina örnek görüntüleri	9
Şekil 2.3	Uygulama iş akış şeması	11
Şekil 2.4	Görüntü keskinleştirme işlemi konsepti.....	12
Şekil 2.5	Gram-Schmidt algoritması	13
Şekil 2.6	Yapay sinir ağları mimarisinin temel elemanları	15
Şekil 2.7	Temel bir evrişimli sinir ağı mimarisi gösterimi.....	16
Şekil 2.8	Görüntü matrisi ve filtre matrisi örneği	17
Şekil 2.9	Tamamen bağlı katman örneği.....	17
Şekil 2.10	Uygulama alanında bulunan çatı tipi örnekleri	19
Şekil 2.11	SSD mimarisi yapısı örneği	20
Şekil 2.12	ResNET mimarisi.....	21
Şekil 2.13	ResNET34 mimarisi.....	21
Şekil 2.14	Binalara ait mahya ve saçak yükseklikleri gösterimi örneği.....	23
Şekil 2.15	Aynı binanın CityGML ayrıntı düzeylerindeki gösterimi.....	24
Şekil 3.1	Uygulama sonucu oluşturulan 3 boyutlu modelden kesitler	26
Şekil 3.2	Analiz yapılması için seçilen bölgelerin görüntüleri	27
Şekil 3.3	1.alan Uydu Görüntüsü	28
Şekil 3.4	2. alan Uydu Görüntüsü	29
Şekil 3.4	3. alan Uydu Görüntüsü	30

Tablolar Listesi

Tablo 2.1	Kullanılan bilgisayarın özellikleri.....	6
Tablo 2.2	Kullanılan veri tipleri ve kaynakları.....	9
Tablo 3.1	Doğruluk analizi tablosu	27

Kısaltmalar Listesi

CNN	Convolutional Neural Network (Evrifimli Sinir Ađları)
GML	Cođrafi İřaretleme Dili
IHS	Yođunluk Ton Doygunluk
ILSVRC	ImageNet Byk lekli Grsel Tanıma Yarıřması
LIDAR	Light Detection and Ranging
LOD	Ayrıntı Dzeyleri
LTSM	Uzun Kısa Vadeli Sinir Ađları
OGC	Aık Mekn Konsorsiyumu
RCNN	Blgesel Tabanlı Konvolsyonlu Sinir Ađı
ResNET	Atık Sinir Ađları
RNN	Tekrarlayan Sinir Ađları
SAM	Sayısal Arazi Modeli
SSD	Single Shot Detector (Tek Atıř Detektr)
SWIR	Kısa Dalga Kıızıltesi
SYM	Sayısal Ykseklik Modeli
TIN	Trianugulated Irregular Network (Dzensiz gen Ađı)
TUREF	Trkiye Ulusal Referans Sistemi
UTM	Universal Tranverse Mercator
XML	Geniřletilebilir İřaretleme Dili
YOLO	You Look Only Once

Bölüm 1

Giriş

Yüksek çözünürlüklü uydu görüntüleri günümüzde kullanılan önemli bir veri kaynağıdır. Dünya üzerinde bulunan nesnelere ait bilgilerin uydu görüntülerinden çıkarımı, şehir planlama, kartografik haritalama, arazi değerlendirme, afet yönetimi ve diğer birçok mekânsal bilginin elde edilmesi açısından çok önemlidir [1]. 3 boyutlu görselleştirmenin de öneminin artması ile uydu görüntülerinden çıkarılacak verilerin bu alanda kullanılması ve zenginleştirilmesi büyük önem taşımakta olup; güvenilir, hızlı ve güncel verilerin de akışında yer tutmaktadır.

Mekânsal verilerin 3 boyutlu gösteriminin popüler olması ile özellikle kent içi karar verme mekanizmalarının kullanıldığı 3 boyutlu kent modelleri de popüler hale gelmiştir. 3 boyutlu kent modelleri sayesinde mekânsal verilere farklı boyutlardan erişebilmekte, bu veriler üzerinden çeşitli yollarla analizleri yapılabilmektedir. 3 boyutlu kent modellerinin en belirgin ve en önemli özelliklerinden biri ise farklı verileri üç boyutlu modelleme sistemi içerisinde birleştirerek; bu verilerin aynı sistemde görülmesi ile analizlerin yapılmasını kolaylaştırmasıdır. 3 boyutlu modellerde farklı mekânsal bilgilerin yer alması, farklı disiplinlerin bu modelleri kullanmasına imkân sağlamaktadır [2] ve günümüzde, modellemede kullanılacak verilerin sağlıklı, hızlı ve güncel şekilde elde edilmesinin de yöntemlerinin ön plana çıkmasına neden olmuştur. Verilerin elde edilmesi için birçok yöntem mevcut olup, derin öğrenme yöntemleri son dönemlerde yaygın bir şekilde kullanılan, oldukça popüler yöntemlerdir. Görüntü işleme alanında sıklıkla kullanılan derin öğrenme yöntemleri, yapay sinir ağlarının sağladığı avantajlar ile daha hızlı ve sağlıklı veri elde edilmesi yönünden tercih edilen yöntemlerden olmuştur.

Bu tezde öncelikle yüksek çözünürlüklü uydu görüntülerinden derin öğrenme yöntemleriyle nesne ve detay çıkarımlarıyla ilgili önceki çalışmalar incelenmiştir.

Bu çalışmalarla bağlantılı olarak, çıkarılan detayların 3 boyutlu kent modellerine dönüştürülmesi hakkındaki çalışmalar da incelenmiştir.

Çalışma alanı olarak seçilen bölge, kullanılan uzaktan algılama verisi ve özellikleri, bina ayak izleri ve uydu görüntüleri ile karşılaştırılması, bina çatı sınıflarının belirlendiği derin öğrenme yönteminin detayları, bina yüksekliklerinin belirlenmesinde kullanılan sayısal yükseklik modeli gibi konular, 2. Bölümde ‘Materyal ve Yöntem’ başlığı altında ele alınmıştır. 3. bölümde elde edilen bulgular tartışılmıştır ve sonuçların iyileştirilmesine yönelik öneriler bu kısımda açıklanmıştır. Sonuçlar bölümü 4. bölümü oluşturmakta ve tez çalışması kapsamında karşılaşılan problemler, gelecek çalışmalar için öneriler verilmiştir.

1.1 Literatür Araştırması

Günümüz çalışmalarında uydu görüntüleriyle elde edilen verilerdeki doğruluk derecelerinin arttığı, bu verilerden elde edilen verilerin daha hızlı çözümler verdiği görülmektedir. Bu bölümde öncelikli olarak uydu görüntülerinden nesne/detay çıkarımına yönelik çalışmalar incelenmiş; daha sonrasında ise 3 boyutlu kent modellerinin elde edilmesinde kullanılan yöntemlere dair çalışmalar ele alınmıştır.

Derin öğrenme yöntemleri ile ilgili ortaya çıkan gelişmelerle beraber uydu görüntüleri ile derin öğrenme yöntemlerinin entegrasyonu çoğalmış ve nesnelerin özelliklerinin sınıflandırılmasında önemli bir yer tutmaya başlamıştır. Literatürde, uydu görüntülerinden nesne özelliklerinin belirlenmesine dair derin öğrenme yöntemleri kullanan birçok çalışma mevcuttur.

Derin öğrenme ile sınıflandırma işlemlerinde yüksek doğrulukta sonuçlar elde etmek mümkündür. Yüksek çözünürlüklü uydu görüntülerinden derin öğrenme mimarileri kullanılarak yapılan sınıflandırma işlemlerinde %92 üzerinde doğruluk derecesiyle 14 farklı sınıfın belirlendiği çalışmalara [3] ulaşabilmek mümkündür.

Bunun yanında, hiperspektral veri setlerini bir, iki ve üç boyutlu evrişimli sinir ağı mimarileri ile kullanarak geleneksel sınıflandırma yöntemlerinden %5-%9 oranında daha iyi sonuçlar elde edilebileceğini ortaya koyan farklı bir çalışma [4] da mevcuttur.

Bina çatı tiplerinin sınıflandırılmasında, küçük boyutlu çalışma alanlarında, önceden eğitilmiş derin öğrenme paketleri kullanılarak 7 ayrı çatı tipinde yüksek doğrulukta sonuçlar elde Münih şehri örneği [5], daha büyük çalışma alanlarında yapılacak araştırmalar için motivasyon oluşturmaktadır.

Bina ayak izlerinin, bina yüksekliklerinin ve çatı sınıflarının belirlenmesinde stereo (çift görüntüden 3 boyutlu değerlendirme ile) görüntülerin kullanılması yaygın bir yaklaşımdır. Bunun yanında, derin öğrenme yöntemleri, monoküler görüntü üzerinde binaların tespit edilmesini ve binaların çatı model geometrilerinin otomatik olarak tanımlanmasını %90 üzerinde bir doğrulukla mümkün kılabilir. Alidoost vd. (2018) [6] bir derin öğrenme algoritması olan CNN kullanarak, tek bir monoküler görüntü üzerinde %97 ile %92 oranında doğruluk değerlerine sahip bina çatı sınıflandırması sonuçları elde etmişlerdir. Bu çalışmada ilk olarak örnek eğitim veri seti kullanarak alandaki binaların, yolların ve ağaçların tanımlandığı veri seti ile çatı tiplerinin tanımlandığı iki adet veri seti kullanmıştır. Bir başka eğitim seti verisi olarak da normalize işlemlerinde kullandığı veri setini kullanarak VGG-F mimarisine dayalı bir CNN uygulamıştır. Bina algılama aşamasında eğitim alanları dışında bir test bölgesi seçilmiş ve grafik tabanlı segmentasyon yöntemi kullanarak; binaların, ağaçların ve yolların belirlenmesi sağlanmıştır. Daha sonrasında belirlenen bina alanlarında sınırlayıcı kutular kullanarak; ikinci bir ağı beslemiş ve bina çatılarının tanımlanmasını sağlamıştır.

Uydu görüntülerinin yanı sıra, diğer uzaktan algılanmış veriler de bina ve bina çatılarının modellenmesinde yaygın olarak kullanılmaktadır. Doğası gereği, diğer yöntemlere kıyasla daha yüksek doğruluklarla sonuçlanan yüksek çözünürlüklü LIDAR verileri ile binaları ve bina detaylarını 3 boyutlu ya da 2,5 boyutlu olarak modelleme imkânı vardır. Genellikle, maliyetleri ve sarfedilecek efor dikkate alındığında daha küçük çalışma bölgelerinde uygulanan bu yöntem, çatı tiplerinin belirlenmesi, gölge analizleri ya da bina modeli üzerinde yapılacak hassas analizler için kullanılmaktadır [7].

LIDAR nokta bulutlarından oluşturulan TIN ağlarının, bina ayak izlerini sınırlayıcı olarak kullanılmasıyla eğim parametresi olarak kullanılabilmesi ve bu parametrelerin, ortorektifiye edilmiş hava fotoğrafları ile analiz edilmesiyle çatı sınıflandırılmasının yapılabildiğini ortaya koyan çalışmalara da [8] ulaşılabilmektedir.

Bu gibi bir yaklaşımdaki ana problem yüksek eğimli çatıların sınıflandırılmasında elde edilen düşük doğruluktur. Düz, daha basit yapıya sahip çatılarda (eğimi %25 ve daha düşük) daha etkili sonuç verdiği ortaya konmuştur. Binaların genel çatı modellerinin düşük yoğunluklu verilerde daha iyi temsil edilebildiği sonucuna bu araştırmadan varılabilmektedir. Daha büyük çalışma alanlarında ve daha yüksek sayıdaki binaların ayak izi çıkarımı ya da çatı tipi sınıflandırmalarında, çok yüksek çözünürlüklü ($\geq 1m$) uydu görüntülerinin kullanılması yaygın yaklaşımdır. Sığ bir CNN mimarisi kullanılarak 6 farklı çatı tipi sınıfıyla 10.000 adet binanın sınıflandırılmasının yapıldığı çalışmalar da bulunmaktadır (bkz. [9]). Bu gibi çalışmalardaki ortak sonuç, eğitim verisinin doğruluğu ve sayısının çokluğu, sınıflandırma sonuçlarına etkisinin büyük olduğudur.

Bina ayak izlerinin çıkarımı ve bina çatılarının sınıflandırılması sürecinden sonra, 3 boyutlu kent modellerinin oluşturulmasında, bina modellerinin de ele alınması gerekmektedir. Modeller ile öznitelik verilerinin entegrasyonun artırılmasına yönelik ihtiyaçtan dolayı 3 boyutlu kent modelleme alanında literatürde birçok çalışmanın mevcut olduğu görülmektedir. Bu çalışmalar modelin kullanılacağı alan, elde edilecek verilerin kalitesi ve bu verilerden sağlanacak analizler doğrultusunda birçok farklı şekilde olup; farklı türde verilerin ve yöntemlerin kullanılması ve işlenmesi ile oluşturulmuştur. Modellerin oluşturulmasında, amaca yönelik olarak karmaşık süreçler ya da daha basit yöntemler kullanılabilir. Örneğin basit kadastral verilerin blok yapıda modellere dönüştürüldüğü sanal şehir uygulamaları sıklıkla karşılaşılan bir yaklaşımdır [10]. Bu uygulamalar navigasyon amaçlı 3 boyutlu haritalarda kullanılabilirdiği gibi afet ve acil yardım sistemi uygulamalarında da kullanabilecek özelliklere sahip modeller olabilmektedir [11].

3 boyutlu kent modelleri oluşturulurken kullanılan standart; OGC tarafından tanımlanmış olan CityGML standartlarıdır. 4 farklı ayrıntı temsil düzeyinin olduğu bu standartlar oluşturulacak 3 boyutlu modellerin kullanılacağı alanlara göre farklılık göstermektedir.

Genel olarak literatürde basit bina katı modellerinin kullanıldığı LOD1 seviyesi ve daha geliştirilmiş bina katı modellerinin olduğu LOD2 seviyesindeki modellere de rastlanmaktadır.

Kadhim vd. Cardiff kentinde yaptığı çalışmada yüksek çözünürlüklü uydu görüntülerini kullanmış; bu görüntülerden bina gölge analizlerini yapmış, bina ayak izlerini ve bina yüksekliklerini belirlemiştir. Uydu görüntülerinden elde ettiği yükseklik ve bina ayak izi verileri ile LOD1 seviyesinde 3 boyutlu kent modeli oluşturmuştur. Oluşturulan bu model ile binaların güneş enerjisi potansiyeli hakkında veriler elde etmiştir [12]. LOD2 seviyesindeki çalışmalar gerçek modellere LOD1 seviyesinden daha yakındır ancak oluşturulmaları emek ve zaman açısından daha maliyetlidir. Bu seviyedeki modeller genellikle hava fotoğrafları ve LIDAR verilerinin birlikte kullanılmasıyla oluşturulur [13]. Biljecki vd. (2019) bu seviyedeki modellerde göz ardı edilen konunun binaya ait çatı tipine çok fazla odaklanılıp, çatıların tematik tipinin ihmal edilmesi olduğunu belirtmişlerdir [13]. Bina modellerinin karmaşıklık düzeyi, amaca uygun olarak belirlenmektedir. Weiler vd. (2019); yenilenebilir ve sürdürülebilir kentlerin tasarımlarının yapılması amacıyla; CityGML LOD2 standartlarında oluşturulan şehir modeli ile her bir yapının çatı modellerini kullanarak, bina modelleri esas alınarak, simüle edilmiş ısı talebine dayalı olarak şehirler için yenilenebilir enerji kaynaklarını içeren iki simülasyon model üretmişlerdir [14].

Yapılan literatür araştırması sonucunda kent modellerinin basitten karmaşık seviyeye oluşturulma nedenleri ve bu modellerin büyük ve küçük çalışma alanlarında nasıl üretilebildikleri araştırılmıştır. İncelenen önceki çalışmalarda, analizler sonucu elde edilen doğruluk oranları ve bu doğrulukları etkileyen ana nedenler ortaya konmaya çalışılmıştır. Bulgular ve sonuçlar kısmında, bu tezde elde edilen doğruluk oranlarıyla karşılaştırılması yapıp nedenleri açıklanmaya çalışılmıştır.

Bölüm 2

Materyal ve Yöntem

2.1 Çalışma Alanı

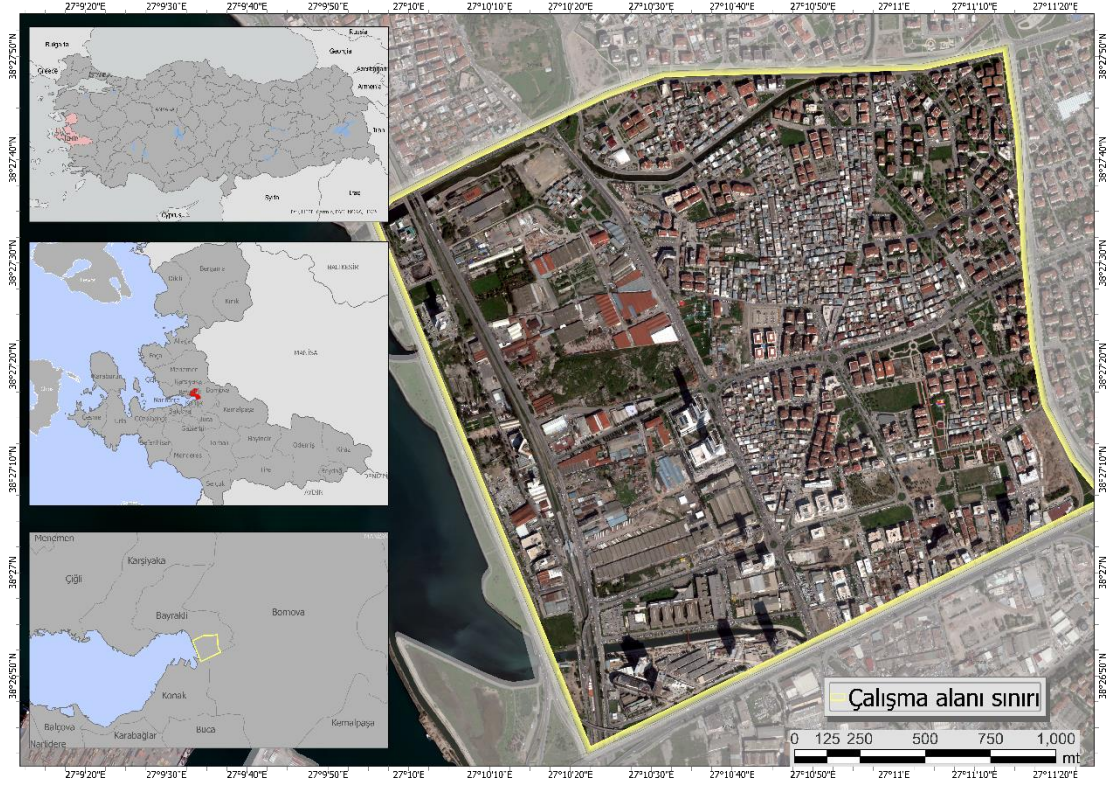
Çalışma alanı olarak İzmir ili Bayraklı ilçesi sınırları içerisinde bulunan, yapılaşmanın ve nüfusun yoğun olduğu bir alan olan Manavkuyu bölgesi seçilmiştir. Bu bölge yapılaşmanın yoğun olduğu, gecekondulara ve yüksek katlı binalara aynı anda eşlik eden bir bölgedir. Söz konusu bölgenin bir kısmı öncesinde Bornova ilçesi sınırları içerisinde bulunmakta olup; sonrasında ise Bayraklı ilçe sınırlarına katılmıştır. Ulaşım ağlarının ortasında, körfeze yakın, iş merkezlerinin yoğunluğundan dolayı yapılaşma hızının gün geçtikçe arttığı bölge 30 Ekim 2020 İzmir Depremi'nde de en çok hasar alan bölge niteliğini taşımaktadır (Şekil 2.1).

2.2 Kullanılan Veri ve Özellikleri

Çalışmada yapılan tüm uygulamalar ArcGIS Pro üzerinden gerçekleştirilmiştir. Yazılımın kullanıldığı donanım olan bilgisayarın özellikleri Tablo 2.1'de verilmektedir.

Tablo 2.1: Kullanılan bilgisayar özellikleri

İşlemci	Intel® Comet Lake Core™ i7-10750H 6C/12T; 12MB L3; 8GT/s; 2.6GHz > 5.0GHz; 45W; 14nm
Ekran	15,6" FHD 1920x1080 144Hz IPS Mat LED Ekran
Ekran Kartı	nVIDIA® GeForce® RTX2060 6GB GDDR6 192-Bit DX12 Refresh (2020 Sürümü)
Chipset	Mobile Intel® HM470 Chipset
Hafıza	512 GB



Şekil 2.1: Uygulama alan sınırı

Uydu görüntüleri olarak; WorldView-3 uydu sensöründen elde edilen 0,31 m çözünürlüğe sahip pankromatik ve 1.24 m çözünürlüğe sahip çok bantlı görüntüler kullanılmıştır. WorldView-3 Kaliforniya, Vandenberg Hava Üssü'nden 3 Ağustos 2014 tarihinde fırlatılmıştır. WorldView-3; pankromatik ve çok bantlı görüntülerin yanı sıra, sekiz bantlı kısa dalga kızılötesi (SWIR) ve 12 CAVIS bantlarına sahiptir. Yörünge yüksekliği 617 km olup; periyotunu 100 dakikada tamamlamaktadır [15]. Yörünge eğimi $97,9^{\circ}$ 'dir.

Çalışma alanında kullanılan sayısal yükseklik modeli Harita Genel Müdürlüğü'nden temin edilmiş olup 5 m çözünürlüğe sahiptir. Bina ayak izleri verileri ise İzmir Büyükşehir Belediyesi'nce onaylanmış hâlihazır harita paftalarının sayısallaştırılması ile elde edilmiş olan verileri içermektedir.

Halihazır haritalarda bina taban alanlarının sayısallaştırılması ile elde edilen veride bina taban alanı bilgileri bulunmakta olup; binaların çatı formlarına ait veri bulunmamaktadır.

Kullanılacak veriler için UTM koordinat sistemi ve WGS84 datumu referans olarak kullanılmıştır. Bina ayak izlerine ait verilerin TUREF'te üretilmiş olmasından dolayı tüm veri katmanları ilk önce ortak referans sistemine dönüştürülmüştür.

Multispektral uydu görüntüleri gibi birden fazla bant içeren görüntüleme sistemlerinde bantlar arasındaki kayıklıklar, uydunun yörüngesinden, yüksekliğinden, hızından kaynaklı ve dünyanın şekline bağlı olarak geometrik hatalar meydana gelmektedir [16]. Çalışma alanında da bina ayak izleri ve uydu görüntüleri arasında bu sebeplerden dolayı geometrik hatalar bulunmakta olup; söz konusu hatalar bina köşe noktaları referans alınarak manuel olarak düzeltilmiştir. Derin öğrenme modeli eğitilirken referans olarak çakıştırılmış bu veri kullanılmış olup; 3 boyutlu kent modeli oluşturulurken gerçek arazi verileri kullanılmıştır. Tablo 2.2'de kullanılan veri tipleri ve veri kaynakları özetlenmektedir.



a) Geometrik hatalar giderilmemiş bina örnekleri

b) Geometrik hatalar giderilmiş bina örnekleri

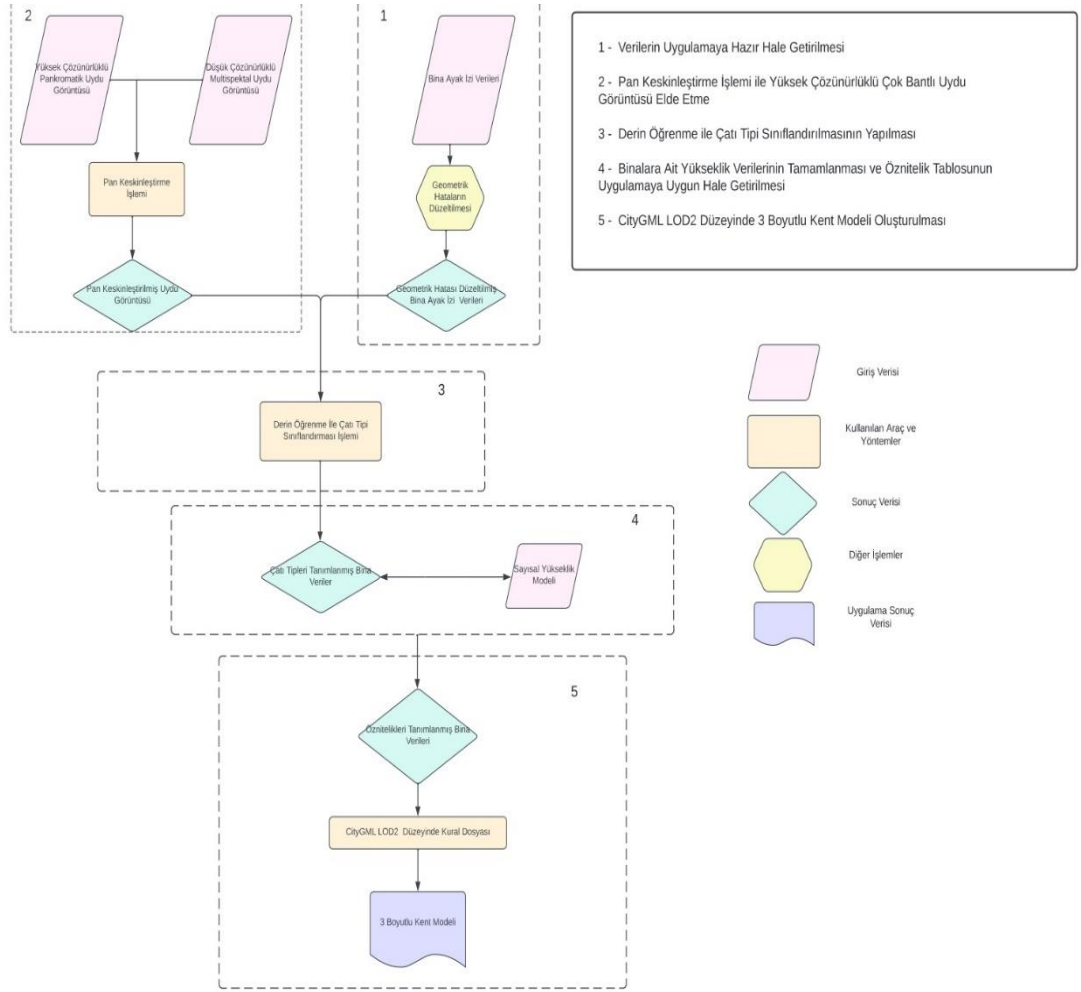
Şekil 2.2 Geometrik düzeltmeden önce ve sonra bina örnek görüntüleri

Tablo 2.2: Kullanılan veri tipleri ve kaynakları

Veri Tipi	Kaynak
WorldView-3 Uydu Görüntüsü	ESA
Bina Ayak İzi Verileri	İzmir Büyükşehir Belediyesi
Sayısal Yükseklik Modeli	Harita Genel Müdürlüğü
CityGML LOD2 Model Kural Dosyası	ArcGIS Pro

2.3 Yöntemler


3 boyutlu kent modelinin, belirlenen hedefler doğrultusunda yüksek çözünürlüklü uydu görüntülerinden derin öğrenme yöntemi ile oluşturulması aşamasında ilk olarak coğrafi veri tabanı oluşturulmuştur. Vektör ve raster yapıdaki veriler belirli ön işlemlere tabi tutularak analizler için hazır hale getirilmiştir. Bu ön işlemler arasında, mevcut uydu görüntüsünün çözünürlüğünün yükseltilmesi için pan-keskinleştirme işlemi, tüm veri katmanlarının ortak referans sistemine dönüştürülmesi, derin öğrenme ile çatı sınıflandırma işlemi için kullanılacak eğitim verisinin oluşturulup, sınıflandırma yapılması, sayısal yükseklik modelinden bina yüksekliklerinin atanması, sınıflandırılmış veriler ile bina ayak izlerinin ilişkilendirilmesi ve çatı tipi sınıflarına göre 3 boyutlu bina modellerinin oluşturulması, işlemlerini kapsamaktadır. Çalışmaya ait uygulama iş akış şeması Şekil 2.3'te verilmiştir.



Şekil 2.3: Uygulama iş akış şeması

2.3.1 Görüntü Keskinleştirme

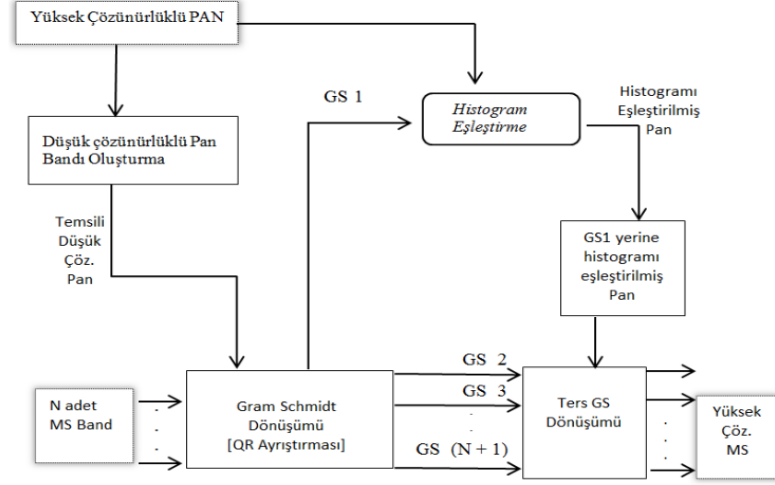
Görüntü keskinleştirme (pansharpening) işlemi, yüksek çözünürlüklü pankromatik görüntü ile düşük çözünürlüğe sahip olan çok bantlı görüntünün füzyon işlemine tabii tutularak yüksek çözünürlüğe sahip çok bantlı görüntü oluşturma işlemidir [17] (Şekil 2.4). Görüntü keskinleştirme işlemi sonucunda oluşturulan görüntüde; spektral ve radyometrik çözünürlük ile görüntü kalitesinin korunması önemlidir.



Şekil 2.4: Görüntü keskinleştirme işlemi konsepti [18]

Görüntü keskinleştirme işlemi yapılırken IHS, Brovey, Esri, Simple Mean, Gram-Schmidt algoritmaları ele alınmıştır. WorldView-3 görüntüleri ile yapılan çalışmalarda Gram-Schmidt algoritmasının; ağırlık kullanılan diğer yöntemlere göre daha iyi sonuçlar verdiği daha önce ortaya konmuştur [19]. Yapılan karşılaştırmalı değerlendirmeler sonucu Gram-Schmidt algoritmasının, WorldView-3 sensörünü tanıdığı ve diğer algoritmalara göre daha iyi sonuçlar verdiği gözlemlenmiştir.

Gram-Schmidt algoritması pankeskinleştirme işlemi için gram-schmidt keskinleştirme algoritmasını kullanmakta olup; vektör ortogonalizasyonuna dayalı genel bir algoritma içerir [20]. Algoritmanın 4 Ocak 2000 tarihinde Craig A. Laben ve Bernard V. Brower tarafından patenti alınmıştır [21]. Bu algoritmada işlemler aşağıda listelenen adımlar şeklinde ilerlemektedir ve işlem adımları Şekil 2.5'te özetlenmektedir.



Şekil 2.5: Gram-Schmidt algoritması [35].

- Düşük çözünürlüklü pankromatik görüntü; yüksek çözünürlüklü pankromatik görüntünün multispektral görüntü ile aynı ebatta bulanıklaştırılması ile oluşturulur.
- Algoritmanın temel olan ilk vektörün oluşturulması için; oluşturulan düşük çözünürlüklü görüntü orijinal ebatına getirilir; 2 boyutlu veri kümesinin bir boyutlu sütun vektörü olarak düzenlenir.
- Bir boyutlu sütun vektörüne dönüştürülen multispektral bantlar; Gram-Schmidt matrisine eklenir.
- Oluşturulan matriste vektör ortogonalizasyonu yapılır, Q matrisi kullanılarak R üst üçgen matrisi elde edilir.
- Yüksek çözünürlüğe sahip olan pankromatik görüntünün; algoritmanın ilk aşamasında oluşturulan düşük çözünürlüklü pankromatik görüntü temel alınarak histogramı eşleştirilir.
- Histogram eşleştirme işlemi ile oluşturulan pankromatik görüntü; modifiye işlemleri tamamlanmış olan Q matrisi, R üst üçgen matrisi ile çarpılır. Füzyon görüntü bandlarının sütun vektörler şeklinde elde edilmesi bu şekilde olur ve eski sütun ve satırlara döndürülür. Görüntü keskinleştirme işlemi böylece tamamlanmış olur [21].

Pankeskinleştirme işlemi yapılırken WorldView – 3 görüntüsünün yüksek çözünürlüklü pankromatik bandı ve görünür bölgedeki düşük çözünürlüklü multispektral bantlar kullanılmıştır. İşlem sonucunda pankeskinleştirilmiş yüksek çözünürlüklü multispektral uydu görüntüsü elde edilmiştir. Elde edilen görüntünün çözünürlüğü 0.31 m'dir. Kullanılacak olan görüntü bina ayak izlerinin çatı tiplerinin sınıflandırması için oluşturulacak modelin oluşturulmasında kullanılacak olan önemli bir veri kaynağıdır.


2.3.2 Derin Öğrenme ile Çatı Sınıflandırması

Yapay zekâ uygulamaları psikoloji, tıp, mühendislik hizmetleri gibi birçok alanda karşımıza çıkmaktadır. Makine öğrenmesi de yapay zekâ uygulamalarının kullanıldığı, makinelerin insan beyni gibi analizler yaparak sorunları belirleyip, karar mekanizmaları oluşturmasını kapsamaktadır. Endüstride çalışanların ve bilim insanların yapay zekâ teknolojilerini sıklıkla kullanarak, hayatımızı kolaylaştırması da bunun sebebidir. Görüntü işleme teknolojilerinde de sıklıkla kullanılmaya başlanan bir yapay zekâ kavramı olan derin öğrenme; genel bir tanımlama olarak verileri, seçilmiş özniteliklerini kullanarak tanımlamayı amaçlayan makine öğrenmesi uygulamalarını kapsar. Derin öğrenme yöntemleri ile ve ait belirlenmiş olan öznitelik bilgileri kullanılarak görüntü üzerinde sınıflandırma işlemi yapılmaktadır [22]. Görüntü işleme alanında sıklıkla kullanılan bir yöntem haline gelen derin öğrenme ile yapay zekadan faydalanılarak; operatör müdahalesinin en az olduğu, eğitilmiş piksel verilerinden sınıflandırma işlemi yapılmaktadır.

Derin öğrenme; yapay sinir ağlarının daha karmaşık bir hali gibi olup; nöronlara benzer yapılara sahiptir, bu yapılar birbirleri ile ilişki içerisinde bulunmaktadır. Derin öğrenme yöntemlerinde verilerin ayırt edici özelliklerinin sistemde yeri kadar eğitildiği, katmanlarla oluşturulan sınıflandırma birimleri ile veri işlemede bir hiyerarşi kurulur. Böylece kullanılacak veriler soyut durumlarından çıkarılarak; somut hale getirilmektedir [23].

Yapay sinir ağları beynin sinir sistemi düşünülerek geliştirilmiş olan yöntemleri içerir. Derin öğrenme yöntemlerinin temelini oluşturan yapay sinir ağları; beynin işleyiş biçimini ve yeni kurallar oluşturma yeteneğini taklit etmektedir [24].

Yapay sinir ağlarının eğitilmesi uygulama yapılan verilerden alınacak örneklerle sağlanmaktadır [22]. Tek katmanlı ağlar şeklinde geliştirilmeye başlanan yapay sinir ağları günümüzde çok katmanlı olarak kullanılmaktadır. Yapay sinir ağları beyin hücrelerinin çalışma şeklini gözeterek basit bir şekilde açıklanırsa; nöronlardaki verilerin sinapslar ile bağlantılarının sağlanması ve öğrenmenin bu bağlantılar yardımıyla ortaya çıkması şeklinde tanımlanabilmektedir (Şekil 2.6). Yapay sinir ağları doğrusal değildir. Doğrusal olmaması mimaride dağılmış olan verilerin de tanımlanmasında yardımcı olmaktadır.



Şekil 2.6: Yapay sinir ağları mimarisinin temel elemanları [25]

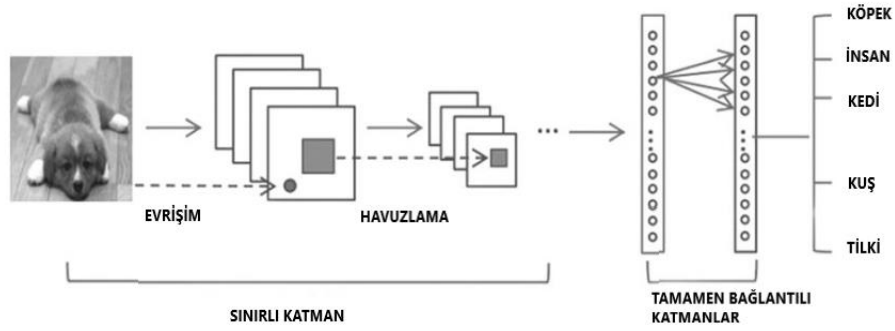
Derin öğrenme modellerinde kullanılan yapay sinir ağları çok katmanlı sinir ağları olup; her derin öğrenme modelinde yapay sinir ağları kullanılmadığı gibi her yapay sinir ağı da derin öğrenme modeli içermek zorunda değildir. Derin öğrenme modellerinde sıklıkla kullanılan yapay sinir ağlarından bazıları şunlardır: Evrişimli sinir ağları, Tekrarlayan sinir ağları ve Uzun kısa vadeli sinir ağları.

Evrişimli sinir ağları özellikle görüntü işleme alanında popüler olan ve sıklıkla kullanılan yapay sinir ağlarıdır. Bir dizi evrişim katmanına ek olarak yardımcı katmanlardan oluşur. Bu katmanın ana yapısı evrişim katmanıdır. Görüntünün derin öğrenme modellerinin temeli olarak varsayılmaktadır [26].

Tekrarlayan sinir ağları hafıza ile çalışan, girdi olarak kullanılan veriyi hatırlayarak bir sonraki adımda o veriden öğrendiği bilgileri kullanan sinir ağlarıdır. RNN dil işleme alanında sıklıkla 2. RNN'lerin dezavantajları girdi verilerin birikmesi sonucu hatırlamanın zor olması, işlemenin zayıf davranması olarak sayılabilir.

Uzun kısa vadeli sinir ağılar kısaca geliştirilmiş olan tekrarlayan sinir ağlarından meydana gelmektedir. LSTM'ler tekrarlayan sinir ağlarının hafıza problemlerinin çözülmesi ve uzun vadede oluşan hafıza problemlerine çözüm için geliştirilmiştir. Metin üretme, duygu analizi ve dil işlemede sıklıkla kullanılan başarılı bir yöntemdir.

Evrişimli sinir ağları görüntü işlemede sıklıkla kullanılmakta olan yapay sinir ağlarıdır. Şekil 2.7'de evrişimli sinir ağlarının temel mimarisini göstermektedir. Evrişimli sinir ağları; temel olarak evrişim katmanı, havuzlama katmanı ve tamamen bağlı katmanlardan oluşmaktadır.




Şekil 2.7: Temel bir evrişimli sinir ağı mimarisi gösterimi [27]

- Giriş Katmanı: İsminden de anlaşılacağı gibi ağı oluşturan verilerin ağı girişinin yapıldığı katmandır. Evrişimli sinir ağının ilk katmanıdır. Giriş katmanında kullanılacak verilerin sayısı, boyutu ve kalitesi modelin hızını ve kalitesini doğrudan etkilemektedir. Burada temel soru; oluşacak hangi veriye ve nasıl bir kalitede ihtiyaç olduğudur. Giriş katmanında kullanılan veriler dikkate alınarak; bu verileri işleyecek bir donanıma sahip olunmalıdır.
- Evrişim Katmanı: Bu katman girdi verileri ele alan ilk katmandır. Bu katmanda görüntünün yanı sıra görüntüye uygulanacak olan filtre de kullanılır. Filtreler görüntüler arasında bağlantı kurulmasını sağlamaktadır [22]. Şekil 2.8'de görüntü matrisi ve filtre matrisi örneği gösterilmektedir.



Şekil 2.8: Görüntü matrisi ve filtre matrisi örneği [22]

- Havuzlama Katmanı: Bu katman çıktı katmanı daha küçük bir boyuttaki resim boyutuna indirgemek için kullanılmaktadır.
- Tamamen Bağlantılı Katmanlar: Evrişim ve havuzlama katmanındaki girdi olarak kullanılan veriler burada birbirleriyle bağlanmakta olup; çıkış katmanında sonuç olarak ortaya çıkmaktadır [28]. Bu katmanda tüm bağlantılar modeli oluşturmak için bir araya gelirler (Şekil 2.9) [22].



Şekil 2.9: Tamamen bağlı katman örneği [22]

Şekil 2.9'da; x1, x2, x3, x4, x5 özellik matrisi olarak, y1 ve y2 de çıktı matrisi olarak düşünülmektedir.

Çatı tipi sınıflandırılması yapılırken; uygulamada ilk olarak eğitim verilerinin toplanması işlemi tamamlanmıştır.

Eđitim verileri oluřturulurken u temel atı tipi olan “Dz (Flat)”, “Beřik (Gable)” ve “Kırma (Hip)” atı tipleri tanımlanarak oluřturulmuřtur (Őekil 2.10). Oluřturulan eđitim verileri; bulguların karřılařtırılması iin her bir atı tipi iin 150 ve 300 adet olarak oluřturulmuřtur. Kullanılacak eđitim verileri nesnelere sınıflandırılması iin oluřturulacak modelin temelini oluřturmaktadır.

Evriřim ađlarının ilk modeli olarak kabul edilen LeNet 1990’lı yıllarda Yann LeChun ve arkadařları tarafından geliřtirilmiř evriřimli sinir ađıdır. Posta kodları, rakamları okumak iin kullanılmıř olan bu mimaride LeNet-5 mimarisi en yaygın kullanılanıdır. LeNet mimarisine benzeyen bir mimari olan AlexNet 2012 yılında SuperVision grubu tarafından tasarlanmıř olup, kendisinden nceki uygulamalardan daha bařarılı perfonmans sađlamıřtır. ZFNet mimarisi nral ađlardan en iyi hata oranlarına sahip bir mimari olup, AlexNet mimarisine benzemektedir. LeNet mimarisinden etkilenecek oluřturulan GoogleNet mimarisi 2014 tarihinde ILSVRC’nin kazanan mimarisi olmuř ve bu ađda parametre sayısı byk lde azaltılmıřtır. 2014 ILSVRC yarıřmasında bir bařka derece alan mimari olan VGGNet mimarisi zellik ıkarımında etkili bir mimaridir. 2015 yılına gelindiđinde ise ResNet olarak bilinen “Atık Sinir Ađları” mimarisi ortaya ıkarılmıřtır.



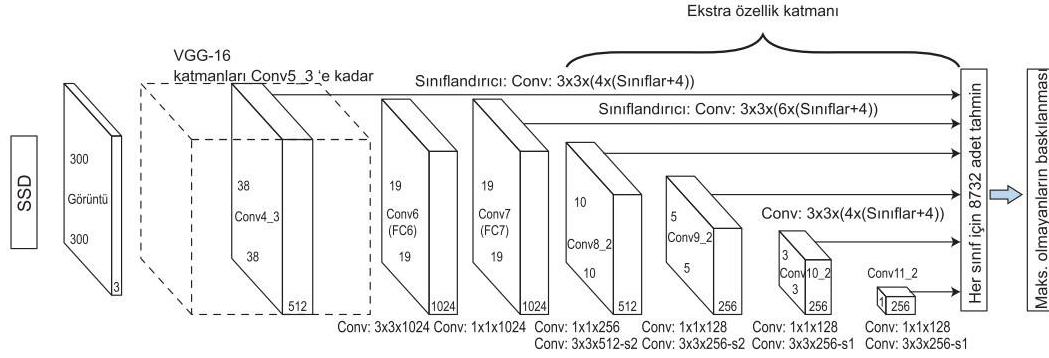
Şekil 2.10: Uygulama alanında bulunan çatı tipi örnekleri

Oluşturulan eğitim veriler örnekleri kullanılacak derin öğrenme modelinin eğitilmesi için temel veriler olarak belirlenmiştir. Nesnelerin sınıflandırılmasının işlemi için üretilen modelde SSD modeli ve Resnet34 mimarisi kullanılmıştır.

Nesnelerin sınıflandırılması ve algılanması için farklı derin öğrenme yöntemleri mevcut olup; YOLO, RCNN, SSD bu yöntemlerden birkaçıdır. RCNN uygulamaları bölge bazlı çalışmakta olup; geliştirilen diğer yöntemlere göre daha yavaş sonuçlar vermektedir. YOLO ilk olarak geliştirilen nesne tespit metodlarındandır. RCNN uygulamalarına göre daha hızlı ve doğru sonuçlar vermesinin yanı sıra küçük nesnelerin tespitinde verdiği sonuçlar tatmin edici sonuçlar değildir [29].

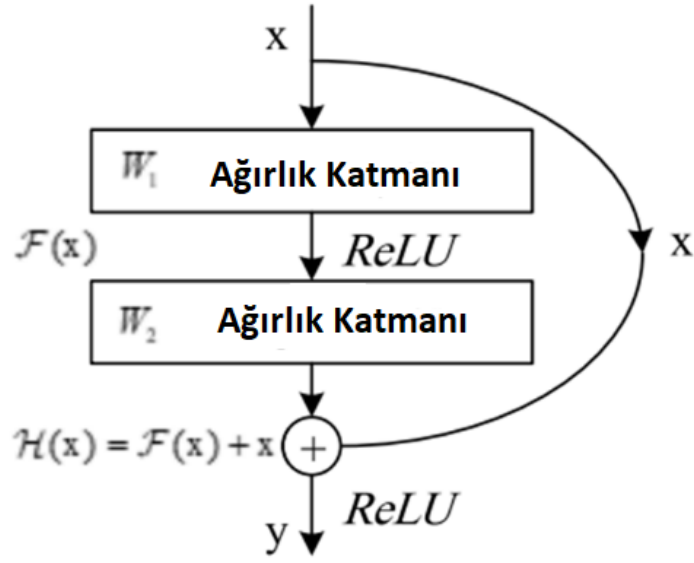
Uygulamada modelin oluşturulması için SSD yöntemi kullanılmıştır. SSD, modeli 2016 yılında Liu ve arkadaşları tarafından geliştirilmiş olan bir model olup; görüntüdeki nesnelerin algılanması için tek bir derin sinir ağı kullanılması ile geliştirilmiştir [30]. Temelinde VGG-16 mimarisi bulunmaktadır, fakat bu mimari sabit bir mimari olmamakla beraber, yöntemin kullanılacağı uygulamalarda farklı mimariler de geliştirilebilmektedir [29, 30].

SSD sınıflandırma ve tespit işlemlerinde sınırlayıcı kutuları kullanmakta olup; yeniden örnekleme aşamasında tüm işlemler tek bir derin sinir ağında tamamlamaktadır. Diğer yöntemlere göre daha hızlı ve başarılı bir yöntem olmak ile sistemlere entegrasyonu daha kolay bir yöntemdir.




Şekil 2.11: SSD mimarisi yapısı örneği [29, 30].

ResNet mimarisi kendisinden önce geliştirilmiş olan mimarilere göre daha başarılı bir yapıya sahiptir. Resnet mimarisinde hata oranı oldukça düşük olmakla beraber; en fazla 152 katman olmak üzere farklı derinliklerde (18 – 34 – 50 – 101) katmandan oluşabilmektedir [31]. Görüntü işleme uygulamalarında sıkça kullanılan ResNET mimarisi “Atık Sinir Ağları” mimarisi adı ile de literatürde yer alabilmektedir. Bu mimarinin en belirgin özelliği görüntüdeki belirli özellikleri alıp bu özellikler neticesinde sınıflandırma işlemini gerçekleştirmeleridir. ResNet kendisinden önce geliştirilen mimarilerin kaybolan- patlayan gradyan ve boyutsallık kayıplarını gidermek için geliştirilmiş olup, kullandığı atık ağlar ile olumlu sonuçlar vermiştir. Öğrenme sürecini iyileştiren bir etkisi bulunmaktadır [32]. ResNet mimarisini diğer mimarilerden farklı kılan özelliği; artık değerlerin kendinden sonraki katmanlara besleyen blokların modele ilave edilmesiyle oluşmasıdır (Şekil 2.11) [33].



Şekil 2.12: ResNET mimarisi [32]

Kullanılan katman sayısına göre farklı isimler alan ResNet mimarisinde sıklıkla kullanılan mimarilerden biri 34 katmandan oluşan ResNet34 mimarisidir (Şekil 2.12). ResNet34 mimarisi görüntü işlemede sıklıkla kullanılan bir ResNet modelidir.



Şekil 2.13: ResNet34 mimarisi [34]


Oluşturulan eğitim verileri 125 ve 250 epok sayıları ile ResNet34 mimarisi kullanılarak işlenmiştir. Kullanılan eğitim verileri ile derin öğrenme modeli oluşturularak; bu model sınıflandırma işlemi kullanılacak veri haline getirilmiştir. Bu aşamadaki epok sayısı; oluşturulan modelin eğitilmesinin tamamlanması için ağırlıkların kullanılarak yapılan yineleme işlemlerinin sayısını temsil eden bir kavramdır.

Oluşturulan model bina ayak izlerinin sınıflandırma işleminde kullanılmış ve böyle çatı tiplerinin sınıflandırılması işlemi ile nesne sınıflandırması işlemi tamamlanmıştır. Sınıflandırma işlemi uygulamanın en uzun süre devam eden işlemi olma özelliğini taşımaktadır.

2.3.3 Çatı Modellerinin Oluşturulması ve 3 Boyutlu Kent Modeli Oluşturulması

Çatı sınıflandırma işleminin tamamlanması bina ayak izlerine dair özniteliklerin tanımlanmasında önemli bir adımdır. Çalışma alanında modellemenin yapılabilmesi için bina ayak izlerine dair yükseklik verilerinin tanımlanması gerekmektedir. Burada Yükseklik verileri, bina ayak izlerinin öznitelik verilerindedir. Bina ayak izlerinin tanımlı olduğu veriler daha öncesinde geometrik hatalar düzeltilerek, çatı tiplerinin sınıflandırılması için uydu görüntüsü ile referanslandırılmıştır. Binalara ait yükseklikler tanımlanırken; sayısal yükseklik modelinde referans olarak kullanılacak veriler binalara ait ayak izi verilerinin halihazır haritalardan elde edilmiş gerçek koordinatlara sahip verileri olup, binaların çatı tipleri bu verilerin öznitelik tablosunda tanımlanmıştır. Bu alanda yükseklik tanımlama işlemi için Harita Genel Müdürlüğü'nden temin edilmiş olan 5 m çözünürlüğe sahip sayısal yükseklik modeli kullanılmıştır.

Bina ayak izleri ile yükseklik verilerini kapsayan öznitelik tablosu birleştirilmiştir. Bu birleştirme işlemi sonrasında bina ayak izlerine ait yükseklik verileri bina ayak izi alanı dikkate alınarak “Mean (Ortalama)” yöntemi ile tanımlanan yükseklikler olarak atanmıştır. Burada önemli noktalardan biri tanımlanan yüksekliklerin daha sonraki aşamada kullanılacak veriler ile uyumlu hale getirilmesi olup; öznitelik tablosuna bina yükseklikleri “BLDGHEIGHT” isimli yeni bir alan adıyla tanımlanmıştır. Bina yükseklik verilerinin yanında; binalara ait olan saçak ve mahya yüksekliklerinin tanımlanması işlemi de gerçekleştirilmiştir (Şekil 2.13). Bu işlem için İzmir ilinde uygulanan yasal çatı yüksekliklerinin, bina yüksekliklerinin ortalama %33'üne denk gelmesinden yararlanılmıştır. Mahya ve saçak yükseklikleri tanımlanırken öznitelik tablosuna “EAVEHEIGHT” ismiyle yeni bir sütun tanımlanarak modellemede kullanılacak olan veriler tamamlanmıştır.



Şekil 2.14: Binalara ait mahya ve saçak yükseklikleri gösterimi örneđi [35]

3 boyutlu kent modellerinin oluřma ařamaları temel olarak verilerin hazırlanması, verilerin 3 boyutlu hale getirilmesi, oluřan modeller üzerinden analizlerin yapılması ve görselleřtirme iřlemleri ile modelin sunumun yapılmasını ięerir.

Çalıřma alanında öznitelik verilerinin tanımlanması ile uygulamadaki veriler modellemeye hazır hale getirilmiřtir.

3 boyutlu modellerde kullanılan verilerin büyük olması, verilerin kullanılmalarının bir standardının olmaması çeřitli sorunlara neden olmuř olup; LOD kavramını ortaya çıkarmıřtır. LOD kavramı OGC CityGML standartlarına bađlı bir kavramdır. Modellemede sıklıkla kullanılan OGC CityGML standartları ile 3 boyutlu modeller oluřturulurken ortak kullanılan bir yapılandırma dili sayesinde verilerin analizi, birbirine dönüřtürülmesi durumları kolaylařtırılmaktadır.


CityGML standartı; kavramsal bir model standartı olup, 3 boyutlu modellerin oluřturulması için ortak bir dili ifade etmektedir. Modelleme yapılırken her bir cođrafi özelliđin tek tek belirlenip tanımlanması zordur. CityGML standartında her cođrafi özelliđin zorunlu özellikleri bulunmaktadır [36]. CityGML standartı ile 3 boyutlu kent modelleri için ortak bir dil belirlenip, verilerin bu dil aracılıđıyla birbirlerine dönüřümü, verilerden elde edilecek analizlerin yapılması kolaylařmıřtır. Bu da verilerin devamlılıđının sađlanmasına ve maliyet düřmesine öncülük etmiřtir.

CityGML, 3 boyutlu Őehir modellerini standart haline getirilen LOD seviyelerinde inceler [11]. CityGML ile XML tabanlı veri modeli oluřturulur. Bu açık kaynaklı bir veri modelidir. Söz konusu standartlar hem ię hem dıř mekânı kapsamaktadır.

CityGML standartları daha öncesinden 5 seviyede ayrıntı modeli tanımlanırken; son sürüm olan CityGML 3.0’da ayrıntı seviyeleri 4 olarak güncellenmiştir. Buradaki her seviye bir önceki seviyeden daha da fazla detay içermektedir.

CityGML kullanılarak 3 boyutlu kent modellerindeki tematik veriler rahatlıkla zenginleştirilebilmektedir. CityGML 3.0 ile her nesnenin ayrı bir kimliği olmakla beraber, nesnelerin tanımlanması ve ayırt edilmesi kolaylaştırılmıştır. CityGML ile nesnelerin ayırt edilmesi ve birbirleri ile ilişkilendirilmesi daha kolaydır [37].

CityGML standartları ile şehir modelleri oluşturulurken 4 ayrıntı düzeyi tanımlanmaktadır (Şekil 2.14).



Şekil 2.15: Aynı binanın CityGML ayrıntı düzeylerindeki gösterimi [38].

LOD0: Genelleştirilmiş bina modelini içerir. Binanın tabana alanını ve bina çatısının genelleştirilmiş modelini içermektedir.

LOD1: Binaya ait yükseklik kullanılarak, binanın katı modelinin oluşturulmasını içermektedir. Bu seviyede binanın taban alanı ve yüksekliği kullanılmaktadır. Blok modeli içermektedir.

LOD2: Binanın katı modeline ek olarak, binanın çatı elemanının da olduğu genelleştirilmiş modeli içermektedir. Gerçekçi bir modeldir fakat küçük ayrıntılar bu ayrıntı düzeyinde ihmal edilmektedir.

LOD3: Binaya ait en gerçekçi modeli içermektedir. Bu ayrıntı düzeyinde modele ait iç-dış mekân ayrıntılarına yer verilmektedir. Bina dış cephe giydirmesi de bu ayrıntı düzeyinde olmakta olup; en yüksek ayrıntı düzeyi LOD3 düzeyidir.

3 boyutlu kent modelleri oluşturulurken genel katı model kullanımı için LOD1 ayrıntı seviyesi kabul edilse dahi; LOD2 ayrıntı seviyesinin kullanılması kent modeli açısından yapılacak analizlere daha fazla imkân sağlamakta ve bilgi yeterliliği ve görsel açısında da daha çok avantaj sağlamaktadır.

Uygulama alanında 3 boyutlu kent modeli oluşturulurken prosedürel semboloji işlemleri için CityEngine kural paketleri kullanılmaktadır. Verilere ait özniteliklerin görselleştirilmesi için oluşturulan sembol katmanlarını kapsayan kural dosyaları hazır paketler halinde olduğu gibi; özel tanımlamalar istenmesi durumunda CityEngine üzerinde geliştirilerek; kullanıma hazır olan. rpk uzantılı dosyalar haline getirilebilmektedir. Uygulamanın bu aşamasında LOD2 seviyesinde model oluşturulması için yazılım içerisinde hazır halde bulunan kural dosyası tanımlanmıştır. Söz konusu kural dosyası ile bina ayak izlerinin öznitelik tablosu arasında ilişki model oluşturularak; basit bir 3 boyutlu kent modeli elde edilmiştir. Elde edilen modele ait görselleştirmenin zenginleştirilmesi kullanılacak modelin gerekliliği durumunda sağlanabilmektedir.

Bölüm 3

Bulgular

Yapılan çalışmada; 3 boyutlu kent modelleri oluşturulurken LOD2 seviyesindeki kent modellerinin yüksek çözünürlüklü uydu görüntülerinden elde edilen verilerle beraber yarı otomatik ve bütüncül bir şekilde elde edilmesi amaçlanmıştır.



Şekil 3.1: Uygulama sonucu oluşturulan 3 boyutlu modelden kesitler

Veriler değerlendirilirken çalışma alanının uydu görüntüleri dikkate alınmış ve yapılaşma durumları belirleyici seçenek tutularak 3 farklı alanda (Şekil 3.2) verilerin durumu incelenmiştir.

Her bir alan için daha öncesinde örnekleri toplanarak oluşturulan örnekler kullanılmıştır. Bu örnekler her bir çatı tipinden 150 ve 300 adet olarak toplanmış ve 125 ile 250 epok işlenerek oluşturulmuştur.



Şekil 3.2: Analiz yapılması için seçilen bölgelerin görüntüleri

Analiz yapılan 1.alanda “Ayrık Nizam”, 3.alanda “Bitişik Nizam” yapılaşma tipleri yağın olmakta olup; 2.alanda hem “Ayrık Nizam” hem de “Bitişik Nizam” yapılaşma tiplerinin beraber olduğu belirlenmiştir.

Tablo 3.1: Doğruluk analizi tablosu

EPOK SAYISI	ÖRNEK SAYISI	EN YÜKSEK BAŞARI ORANI	EN YÜKSEK BAŞARI ALANI	EN DOĞRU SINIFLANDIRMA TİPİ
125	150	70%	2.ALAN	FLAT
250	150	77%	2.ALAN	HİP
125	300	36%	3.ALAN	FLAT
250	300	81%	3.ALAN	GABLE

1.alandaki tüm çatıların “Kırma” çatı tipinde olduğu görülmüştür (Şekil 3.2). Bu alanda 125 epokla yapılan işlemlerde; doğrulukların daha düşük olduğu, alandaki “Düz” ve “Kırma” çatı tiplerinin ayırt edilmesinde sıkıntılar gözlemlenmiştir. Söz konusu alanda yapılan manuel kontrollerde bu durumun daha spesifik olarak tasarlanmış olan “Kırma” çatı tiplerinden görüldüğü belirlenmiştir.

250 epok kullanılarak yapılan işlemlerde, 300’şer adet eğitim verisi örneğinin kullanıldığından doğruluğun yaklaşık %80 civarında; 150’şer adet eğitim verisi örneği kullanıldığında ise %67 civarında olduğu belirlenmiştir.

Eđitim verilerinin sayısının artması sonuçların iyileřtirilmesi aısından önemli bir kıstas olarak karřımıza ıktığı grlmřtr.



řekil 3.3: 1. alan uydu grnts

2.alanda her  atı tipinden de yapıların bulunduđu ve sayılarının birbirilerine yakın olduđu grlmřtr (řekil 3.3). Sınıflandırma iřleminin gecekonduların mevcut olduđu alanlarda daha az dođruluđa sahip olduđu, bu alanlardaki uydu grntlerinden ayrıştırmanın zor olduđu manuel olarak da gzlemlenmiřtir. “Beřik” atı tipine sahip yapıların zelikle bitiřik nizam yapılařma kořullarında “Dz” ve “Kırma” atı tiplerinden ayrıştırılmasının dřk olduđu; sınıflandırma dođruluđunun bu alanlarda bu atı tipi iin dřk seyrettiđi grlmřtr.

150’řer adet eđitim verisi rneđi toplanılan uygulamada en dřk dođruluđun “Beřik” atı tipinde ıktığı belirlenmiřtir. 125 epok kullanıldıđında en yksek dođruluđun “Dz” atı tipinde grldđi ve %70 olduđu, “Kırma” atı tipinde ise dođruluđun %33’lerde kaldığı gzlemlenmiřtir.

Burada özellikle bitişik nizam yapılaşmaya sahip alanların manuel ayırt edilmesinin de zor olduğu alanlarda doğrulukların düşük olduğu gözlemlenmiştir. 250 epok kullanıldığında “Kırma” çatı tipinde %76 ile en yüksek doğruluğun olduğu, “Düz” çatı tipinde doğruluğun daha alt seviyelerde (%58 civarı) olduğu gözlemlenmiştir.



Şekil 3.4: 2.alan uydu görüntüsü

300'er adet eğitim verisi örneği 125 epokla işlendiğine doğrulukların “Düz” ve “Kırma” çatı tipinde %20'lerde kaldığı; “Beşik” çatı tipinin bu sefer ayırt edildiği fakat doğruluğun düşük olduğu gözlemlenmiştir. 250 epokluk uygulamada ise en yüksek doğruluğun %73 ile “Kırma” çatı tipinde, “Beşik” çatı tipinde ise doğruluğun artarak %63 civarından olduğu belirlenmiştir. “Düz” çatı tipinin burada en düşük doğruluğa sahip olduğu belirlenmiştir.

3.alanda en fazla “Düz” çatı tipinin olduğu, “Kırma” çatı tipinin en az yoğunluğa sahip olduğu ve alanda bitişik nizam yapılaşma koşulunun yaygın, yapılaşmaların standartları olmadığı görülmüştür (Şekil 3.4). Bu alanda “Beşik” ve “Düz” çatı tiplerinin birbirinden ayırt edilmesinde problemlerin mevcut olduğu tespit edilmiştir.



Şekil 3.5: 3.alan uydu görüntüsü

150’şer adet eğitim verisi örneği ile yapılan uygulamada en fazla “Düz” çatı tipinde doğruluğa sahip olduğu fakat bu doğruluğun derecesinin de yüksek olmadığı görülmüştür. Burada “Beşik” ve “Kırma” çatı tiplerinin birbirinden ayırt edilmesi ile ilgili problemlerin mevcut olduğu gözlemlenmiştir. Epok sayısının bu uygulamada doğruluk üzerinde çok fazla fark yaratmadığı belirlenmiştir.

Bölüm 4

Sonuç

Bu çalışmada yüksek çözünürlüklü uydu görüntülerinden derin öğrenme yöntemleri kullanılarak binalara ait çatı tipi sınıflandırılması yapılmış; sınıflandırma işleminden elde edilen veriler ile CityGML LOD2 standartında basit 3 boyutlu kent modelinin oluşturulması aşamaları gerçekleştirilmiştir.

Uygulama alanında yapılaşma koşullarının ve bina yüksekliklerini doğruluğa etkisi olduğu gözlemlenmiştir. Bitişik nizam yapılaşma koşullarının hâkim olduğu alanlarda çatı tiplerinin ayırt edilmesindeki doğruluk derecesinin düşük olduğu gözlenmektedir. Bitişik nizam yapılaşma koşullarına sahip alanlarda yapılaşma yükseklikleri arasındaki farkların özellikle belirgin olduğu alanlarda sınıflandırma doğruluklarının azaldığı görülmektedir. Ayrık nizam yapılaşma koşullarında ise özellikle bina yükseklikler koşullarının da benzer olduğu alanlarda sınıflandırma doğruluğunun daha yüksek olduğu ve oluşturulacak yarı otomatik 3 boyutlu kent modelinin gerçeğe daha yakın sonuçları verdiği görülmektedir. Plansız kentleşmenin yaygın olduğu alanlarda yapılan çalışmanın gerçeğe daha az yakın doğrulukta olduğu gözlemlenmektedir.

Yüksek sınıflandırma doğruluğu elde edilen alanlarda ortaya çıkan görünür sebebin; uydu görüntülerinden dahi ayırt edilmesi zor olan öz nitelikler üzerinde yoğunlaştığı görülmektedir. Gözle görünür şekilde ortaya çıkan bu durum da göstermektedir ki nesnelerin daha belirgin şekilde görüntülere sahip olması çıkacak doğruluğu doğrudan etkileyecektir.

Eđitim verisi 6rneklerinin sisteme daha fazla sayıda girilmesi ve sistem 6zerinde epok sayısı arttırılarak sistemde tanımlanması dođruluđu olumlu olarak etkileyen bir fakt6r olmakta olup; daha y6ksek dođrulukdaki sonu7ların elde edilmesi i7in sayısı arttırılmıř ve 7eřitlendirilmiř eđitim verinin daha fazla sayıda iřlem ile sisteme tanıtılıp; model oluřturulmasının dođruluđu dođrudan etkileyeceđi g6r6lmektedir. 6zellikle bu durumun 7atı tipi sınıflarının daha fazla olduđu alanlarda gerekli olduđu tespit edilmektedir.

Uygulama alanındaki 7atı tiplerinin standartlara uygun olarak yapılmamasından dolayı sınıflandırma dođruluđunun d6řt6đ6, oluřturulan modelin de bu y6zden ger7eđe yakınlıđının azaldıđı g6zlemlenmektedir. S6z konusu uygulamanın aynı veriler ile 7arpık kentleřmenin az olduđu, bina yapım ařamasında standartların uygulandıđı alanlarda daha y6ksek dođrulukta modellerin oluřmasında etkili olacađı g6zlemlenmektedir.

Kaynaklar

- [1] Chen, YH, Su W, Li, J, Sun ZP. Hierarchical object oriented classification using very high resolution imagery and LiDAR data over urban areas., *Adv Space Res* 2009; 43(7): 1101–1110.
- [2] Yücel MA, Selçuk M. Üç Boyutlu Kent Modellerinde Ayrıntı Düzeyi (LoD) Kavramı. *Jeodezi, Jeoinformasyon ve Arazi Yönetimi Dergisi* 2009; 2(101):3–9.
- [3] Doğan F, Türkoğlu İ. Derin Öğrenme ile Uydu Görüntülerinin Sınıflandırılması.8th International Advanced Technologies Symposium (2017); 9(569):2036-2043.
- [4] Ortaç G., Hiperspektral görüntülerde derin öğrenme yaklaşımının sınıflandırma başarımı üzerine etkisi (yüksek lisans tezi). Bursa: Bursa Uludağ Üniversitesi; 2019. <https://tez.yok.gov.tr/>
- [5] Partovi T, Fraundorfer F, Azimi S, Marmanis D, Reinartz P. Roof Type Selection Based on Patch-Based Classification Using Deep Learning for High Resolution Satellite Imagery. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives* (2017); 42(1W1): 653–57.
- [6] Alidoost F, Hossein Arefi H. A CNN-Based Approach for Automatic Building Detection and Recognition of Roof Types Using a Single Aerial Image. *PFG - Journal of Photogrammetry, Remote Sensing and Geoinformation Science* (2018); 86(5–6): 235–48.
- [7] Lindenthal T. Beauty in the Eye of the Home-Owner: Aesthetic Zoning and Residential Property Values. *Real Estate Economics* (2020); 48(2): 530–55.

- [8] Alexander C,Smith-Voysey S, Jarvis C, Tansey K. Integrating Building Footprints and LiDAR Elevation Data to Classify Roof Structures and Visualise Buildings.Computers, Environment and Urban Systems (2009); 33(4): 285–92.
- [9] Buyukdemircioglu M, Can R, S. Kocaman S. Deep Learning Based Roof Type Classification Using Very High Resolution Aerial Imagery. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences (2021); XLIII-B3-2(June): 55–60.
- [10] Oğuz C, Medeni E, Yılmaz T, GÜDÜKBAY U. Production and Visualitazion of 3D City Models From Building Allocation Plans. IEEE 14th Signal Processing and Communications Applications Conference 2006 April 17-18; Antalya, Türkiye. <https://ieeexplore.ieee.org/document/1659911>
- [11] Arasan G, İşçan L, Eker O. Bir 3B Şehir Uygulaması: AŞTİ. Harita Dergisi (2014); 151: 11 – 18.
- [12] Kadhim N, Mourshed M. A Shadow-Overlapping Algorithm for Estimating Building Heights from VHR Satellite Images. IEEE Geoscience and Remote Sensing Letters (2018); 15(1): 8 – 12
- [13] Biljecki F, Dehbi Y. Raise the Roof: Towards Generating LOD2 Models without Aerial Surveys Using Machine Learning. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* (2019); 4(4/W8): 27–34.
- [14] Weiler V, Stave J, Eicker U. Renewable Energy Generation Scenarios Using 3D Urban Modeling Tools—Methodology for Heat Pump and Co-Generation Systems with Case Study Application. *Energies* (2019); 12(3):403.
- [15] Uysal E. Uzak Fotogrametrisi.*Geomatik* (2016); 1(1): 24–38.
- [16] Küpcü, R. Rasat ve Göktürk-2 Uydu Görüntülerinin Uzaktan Algılama Yazılımları ile Farklı Referans Verileri Kullanarak Geometrik Düzeltme Doğruluğunun Araştırılması (yüksek lisans tezi). Eskişehir: Anadolu Üniversitesi; 2015. <https://tez.yok.gov.tr/>

- [17] Sümengen S, Şenaras Ç, Erdem A. Yüksek Çözünürlüklü Uydu Görüntüleri İçin Pankromatik Keskinleştirme Yöntemi. SAVTEK 2012 : Savunma Teknolojileri Kongresi, Ocak 2012; Ankara, Türkiye. <https://www.researchgate.net/publication/261037817>
- [18] TÜBİTAK Uzay Teknolojileri Araştırma Enstitüsü [İnternet].Ankara 2022 [erişim tarihi 05.01.2022] . <https://www.gezgin.gov.tr/pansharp/>
- [19] Belfiore OR, Meneghini C, Parente C, Santamaria R. Application of Different Pan-Sharpening Methods on Worldview-3 Images. ARPN Journal of Engineering and Applied Sciences (2016);11(1): 490–96
- [20] Esri. İzmir 2021 [erişim tarihi 20/06/2021]. <https://pro.arcgis.com/en/pro-app/latest/help/analysis/raster-functions/fundamentals-of-pan-sharpening-pro.htm>
- [21] Akoğuz, A. Uzaktan Algılamada Görüntü Birleştirme Algoritmalarının Karşılaştırılması (yüksek lisans tezi). İstanbul: İstanbul Teknik Üniversitesi; 2013. <https://tez.yok.gov.tr/>
- [22] Kutlu Ö. İnsansız Hava Aracı İle Elde Edilen Görüntülerin Derin Öğrenme Yöntemleri İle Analizi (yüksek lisans tezi). İstanbul: Marmara Üniversitesi; 2019. <https://tez.yok.gov.tr/>
- [23] Eker S, Karaküçük Y. Oftalmolojide Yapay Zeka ve Derin Öğrenme Uygulamaları. Journal of Yaşar University (2020); 1(1): 81–93.
- [24] Bingöl, K. Depreme Dayanıklı Mimari Tasarım Aşamasında Derin Öğrenme ve Görüntü Sınıflandırma Yöntemi ile Burulma Düzensizliği Tespiti (yüksek lisans tezi). Ankara : Çankaya Üniversitesi; 2020. <https://tez.yok.gov.tr/>
- [25] Yurtoğlu, H. Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler için Türkiye Örneği (uzmanlık tezi). 2005. <https://www.sbb.gov.tr/wp-content/uploads/2018/11/HasanYurtoglu.pdf>

- [26] Er MB. Öncede Eğitilmiş Derin Ağlar ile Göğüs Röntgeni Görüntüleri Kullanarak Pnömoni Sınıflandırılması. Konya Journal of Engineering Sciences (2021). 9(1): 193 – 204
- [27] Zhang Q, Bai C, Chen Z, Li P, Yu H. Deep Learning Models For Diagnosing Spleen And Stomach Diseases In Smart Chinese Medicine With Cloud Computing. Concurrency and Computation: Practice and Experience (2021); 33(4): e5252
- [28] Kurt, F. Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi (yüksek lisans tezi). Ankara: Hacettepe Üniversitesi;2018. <https://tez.yok.gov.tr/>
- [29] Başarır, B. Derin Öğrenme Tabanlı Nesne Takibi (yüksek lisans tezi). Bursa: Bursa Uludağ Üniversitesi; 2019. <https://tez.yok.gov.tr/>
- [30] Liu W, Anguelov D, Erhan D, Szegedy C, Redd S, Fu CY, Berg AC. Single Shot Multibox Detector. European conference on computer vision. Springer.
- [31] Ergün E, Kılıç K. Derin Öğrenme ile Artırılmış Görüntü Seti Üzerinden Cilt Kanseri Tespiti. Black Sea Journal of Engineering and Science (2021); 192-200.
- [32] Condori HC, De La Cruz JC, Mamani MacHaca W. ResNet Neural Network Hyperparameter Tuning for Rigid Pavement Failure Assessment. SACI 2021 - IEEE 15th International Symposium on Applied Computational Intelligence and Informatics (2021). 317–322.
- [33] Tan, Z. Derin Öğrenme Yardımıyla Araç Sınıflandırma (yüksek lisans tezi). Elazığ: Fırat Üniversitesi; 2019. <https://tez.yok.gov.tr/>
- [34] He KM, Zhang XY, Ren SQ, Sun J. BDeep Residual Learning for Image Recognition. 2016 Ieee Conference on Computer Vision and Pattern Recognition (2016); 770-778.
- [35] Markiewicz M. Determining Frankfurt's Suitability Potential For The Ontop Concept. EARSeL eProceedings, Special Issue: 34th EARSeL Symposium, 2014; 2014. 106 – 112.

- [36] Gröger G, Kolbe TH, Nagel C, Häfele KH. OpenGIS City Geography Markup Language (CityGML) Encoding Standard, OGC Document (2012)No.12-019:344 [Internet]. İzmir; 2022 [05.01.2022]. https://portal.opengeospatial.org/files/?artifact_id=47842
- [37] Kolbe T, Kutzner T, Smyth CS, Nagel C, ve diğ. OGC City Geography Markup Language (CityGML) Part 1: Conceptual Model Standard [Internet]. İzmir; 2021 [13.09.2021]. <https://docs.ogc.org/is/20-010/20-010.html#toc24>
- [38] Biljecki F, Ledoux H, Stoter J. An improved LOD specification for 3D building models. Computers, Environment, and Urban Systems (2016); 59: 25-37

Özgeçmiş

Adı Soyadı: Arzu Ece ATİLA

Eğitim:

2011–2016 Karadeniz Teknik Üniversitesi, Harita Mühendisliği Bölümü

İş Deneyimi

2017 – 2017 mimR Mimarlık İnşaat Restorasyon İç ve Dış Tic. Ltd. Şti

2019 – Halen Asrın Grup