**İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ**

# TELEKOMMÜNİKASYON SEKTÖRÜNDE KULLANILAN EK ODALARIN SOKAK DÜZEYİ GÖRÜNTÜLERİNDEN TESPİT EDİLMESİ

**YÜKSEK LİSANS TEZİ**

**Ahmet EĞRİ**

**Geomatik Mühendisliği Anabilim Dalı**

**Geomatik Mühendisliği Programı**

**HAZİRAN 2020**

**İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ**

# TELEKOMMÜNİKASYON SEKTÖRÜNDE KULLANILAN EK ODALARIN SOKAK DÜZEYİ GÖRÜNTÜLERİNDEN TESPİT EDİLMESİ

**YÜKSEK LİSANS TEZİ**

**Ahmet EĞRİ**
**(501131620)**

**Geomatik Mühendisliği Anabilim Dalı**

**Geomatik Mühendisliği Programı**

**Tez Danışmanı: Dr. Öğr. Üyesi Caner GÜNEY**

**HAZİRAN 2020**

İTÜ, Fen Bilimleri Enstitüsü'nün 501131620 numaralı Yüksek Lisans Öğrencisi Ahmet EĞRİ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "TELEKOMMÜNİKASYON SEKTÖRÜNDE KULLANILAN EK ODALARIN SOKAK DÜZEYİ GÖRÜNTÜLERİNDEN TESPİT EDİLMESİ" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

| | | |
|---|---|---|
| **Tez Danışmanı :** | **Dr. Öğr. Üyesi Caner GÜNEY**<br>İstanbul Teknik Üniversitesi | ..... |
| **Jüri Üyeleri :** | **Doç. Dr. Ahmet Özgür DOĞRU**<br>İstanbul Teknik Üniversitesi | ..... |
| | **Dr. Öğr. Üyesi Alper ŞEN**<br>Yıldız Teknik Üniversitesi | ..... |

**Teslim Tarihi : 4 Mayıs 2020**
**Savunma Tarihi : 5 Haziran 2020**

***Eşime,***

## ÖNSÖZ

Lisansüstü tez çalışmam süresince bana danışmanlık yapan, bilgilerini ve tecrübelerini paylaşan değerli tez danışmanım Dr. Öğr. Üyesi Caner GÜNEY'e desteklerinden dolayı çok teşekkür ederim.

Tez konumu belirlememde ve sonraki süreçte bana yol göstereci olan çok değerli hocalarım Doç. Dr. Ahmet Özgür DOĞRU ve Dr. Öğr. Üyesi Can Ünen'e çok teşekkür ederim.

Çalışmamın tamamlanabilmesi için ekipman ve veri desteğinde bulunan değerli dostum Abdullah Sait TÜRKSEVER'e çok teşekkür ederim.

Hayatımın her döneminde her zaman yanımda olan ve beni destekleyen değerli aileme ve çalışma süresince benimle birlikte emek sarf eden değerli eşime sonsuz teşekkürlerimi sunarım.

Mayıs 2020

Ahmet EĞRİ
Geomatik Mühendisi

**İÇİNDEKİLER**

**Sayfa**

**ÖNSÖZ……. vii**
**İÇİNDEKİLER ix**
**KISALTMALAR xi**
**ÇİZELGE LİSTESİ xiii**
**ŞEKİL LİSTESİ xv**
**ÖZET……. xvii**
**SUMMARY xix**
**1. GİRİŞ….. 1**
1.1 Tezin Amacı 3
1.2 Problem Tanımı 4
1.3 Çalışma Konusu 6
1.4 Hipotez 7
**2. LİTERATÜR ARAŞTIRMASI 9**
2.1 Bilgisayarlı Görü 10
2.2 Derin Öğrenme 11
2.2.1 Evrişimsel sinir ağlar 13
2.2.2 Bölge tabanlı evrişimsel sinir ağlar 14
2.3 Mapillary Platformunda Panoptik Bölütleme Yaklaşımı 19
2.3.1 Mapillary'e genel bakış 19
2.3.2 Panoptik bölütleme yaklaşımı 21
2.4 Kitle Kaynak 24
2.5 Hareket ile Nesne Oluşturma - Structure From Motion (SfM) 25
2.6 Telekommünikasyon Sektöründe Mekansal Uygulamalar 26
2.7 Veri Kümesi Değerlendirme Ölçütleri 28
**3. YÖNTEM 31**
3.1 Mekansal Verinin Elde Edilmesi 31
3.1.1 Jeodezik ölçme yöntemiyle mekansal veri üretimi 31
3.1.2 Araç üzerindeki kamera kullanılarak mekansal verinin elde edilmesi 32
3.1.3 Akıllı telefon kullanılarak mekansal veri üretimi 34
3.2 Mekansal Verinin Değerlendirilmesi 35
3.2.1 Geleneksel yöntemlerle verinin değerlendirilmesi 35
3.2.2 Yenilikçi yöntemle verinin değerlendirilmesi 35
3.3 Bulgular 37
3.3.1 Görüntülerden tespit edilen ek odası kapaklarının konum kestirimi açısından değerlendirilmesi 37
3.3.2 Yenilikçi yöntemin sınıflandırma başarımının değerlendirilmesi 48
3.3.3 Yenilikçi yöntemde kullanılan iki farklı tekniğin karşılaştırılması 56
3.3.4 Geleneksel ve yenilikçi yöntemlerinlerin maliyet ve zaman yönünden değerlendirilmesi 57
**4. SONUÇ VE ÖNERİLER 59**

**KAYNAKLAR..... 61**
**ÖZGEÇMİŞ..... 65**

## KISALTMALAR

**CBS** **:** Coğrafi Bilgi Sistemleri
**CNN** **:** Convolution Neural Network
**FPN** **:** Feature Pyramid Network
**GIS** **:** Geographic Information System
**OSM** **:** OpenStreetMap
**R-CNN** **:** Region Based Convolution Neural Network
**RPN** **:** Region Proposal Network
**SFM** **:** Structure from Motion
**VGI** **:** Volunteered Geographical Information

## ÇİZELGE LİSTESİ

**Sayfa**

**Çizelge 2.1 :** Bilgisayarlı görü ile görüntü işleme arasındaki farklar... ……..**10**
**Çizelge 2.2 :** En çok tercih edilen Python kütüphaneleri..... **12**
**Çizelge 2.3 :** Karışıklık matrisi örneği.....Hata! Yer işareti tanımlanmamış.
**Çizelge 3.1 :** Geleneksel yöntemin uygulanış bilgileri..... **31**
**Çizelge 3.2 :** Araç kamerası özellikleri.....Hata! Yer işareti tanımlanmamış.
**Çizelge 3.3.a:** Feneryolu mahallesi koordinat listesi Hata! Yer işareti tanımlanmamış.
**Çizelge 3.3.b:** Küçükbakkalköy mahallesi koordinat listesi .....Hata! Yer işareti tanımlanmamış.
**Çizelge 3.3.c:** Yeni Mahalle koordinat listesi.....Hata! Yer işareti tanımlanmamış.
**Çizelge 3.4 :** Üç çalışma bölgesine ait koordinat farklarının kalite bilgileri Hata! Yer işareti tanımlanmamış.**6**
**Çizelge 3.5 :** Üç çalışma bölgesine ait karışıklık matrisleri ..... **389**
**Çizelge 3.6 :** Yapay öğrenme modeli tanımlama başarısı kullanılan ölçütler..... **54**
**Çizelge 3.7 :** Görüntü elde etme araçlarının sonuçlara etkisi ..... **40**
**Çizelge 3.8 :** Geleneksel ve yenilikçi yöntemlerin maliyet bilgileri ..... **41**

## ŞEKİL LİSTESİ

**Sayfa**

**Şekil 1.1 :** Ek odası (manhole) örneği. ..... **5**
**Şekil 1.2 :** Geleneksel ve yenilikçi yöntemin karşılaştırılması. ..... **7**
**Şekil 2.1 :** Evrişimsel Sinir Ağında katmanların uygulanması. ..... **14**
**Şekil 2.2 :** R-CNN Modeli Akış Şeması ..... **15**
**Şekil 2.3 :** Hızlı R-CNN. ..... **16**
**Şekil 2.4 :** Daha Hızlı R-CNN ..... **16**
**Şekil 2.5 :** Maske R-CNN ..... **17**
**Şekil 2.6 :** Özellik Piramidi Ağı (FPN) ..... **18**
**Şekil 2.7 :** Daha Hızlı R-CNN Modelinde FPN omurgası kullanımı ..... **19**
**Şekil 2.8 :** Sol: Ayrışık Model Sağ: Mapillary Panoptik Bölütleme Modeli ..... **22**
**Şekil 2.9 :** Üst: Anlamsal Bölütleme aşamaları Alt: MiniDL mimarisi ..... **23**
**Şekil 2.10:** Mapillary'de SFM algoritmasının uygulaması ..... **26**
**Şekil 2.11:** Şebeke Bilgi Sistemi'nde Ek odası-Tranşe İlişkisi ..... **27**
**Şekil 2.12:** Ek odası kapağı örnekleri ..... **27**
**Şekil 2.13:** Şebeke arıza yönetimi mimarisi. ..... **28**
**Şekil 3.1 :** Geleneksel yöntemle veri üretimi ..... **32**
**Şekil 3.2 :** Blackvue marka kameranın araç içinden görüntüsü. ..... **33**
**Şekil 3.3 :** Mapillary kontrol panelinde sürüş planlaması ..... **34**
**Şekil 3.4 :** Mapillary Mobil uygulaması ve görüntü kaydetme ekranı. ..... **35**
**Şekil 3.5 :** Mapillary nesne doğrulama sayfası. ..... **36**
**Şekil 3.6 :** Doğrulama çalışması sonuçları. ..... **36**
**Şekil 3.7 :** Feneryolu veri kümesine ait normal dağılım tablosu. ..... **44**
**Şekil 3.8 :** Küçükbakkalköy veri kümesine ait normal dağılım tablosu. ..... **45**
**Şekil 3.9 :** Yeni mahalle veri kümesine ait normal dağılım tablosu. ..... **46**
**Şekil 3.10:** Feneryolu Mahallesi çalışma alanına ait tematik harita. ..... **50**
**Şekil 3.11:** Küçükbakkalköy çalışma bölgesindeki metriklerin dağılımı. ..... **51**
**Şekil 3.12:** Yeni Mahalle çalışma bölgesindeki metriklerin dağılımı. ..... **52**
**Şekil 3.13:** Asfalt yamasının ek odası olarak algılanması. ..... **53**
**Şekil 3.14:** Ağaç gölgesinin ek odası olarak algılanması. ..... **53**
**Şekil 3.15:** Rögar kapağının ek odası olarak algılanması. ..... **54**
**Şekil 3.16:** Türkiye'de kullanılan ek odası kapak örnekleri. ..... **56**

# TELEKOMMÜNİKASYON SEKTÖRÜNDE KULLANILAN EK ODALARIN SOKAK DÜZEYİ GÖRÜNTÜLERİNDEN TESPİT EDİLMESİ

## ÖZET

Günümüzde veri ekonomisi zihin dünyamızın yeniden şekillenmesini sağlamaktadır. Alışılagelmişin dışında yöntemler ile veri üretmenin ve analiz etmenin yolları sürekli bir şekilde çeşitlenmektedir. Geomatik mühendisliği alanındaki veri elde etme yöntemleri de klasik haritalar yerine web tabanlı haritaların ve coğrafi bilgi sistemlerinin kullanımının yaygınlaşmasıyla büyük bir değişim yaşamıştır. Harita bilgileri kimi zaman belirli bir bütçe harcanarak üretildiği gibi kimi zaman da OpenStreetMap (OSM) gibi kitle kaynak kullanımı ile üretilebilmektedir.

Son yıllarda kalabalık toplulukların dahil olduğu konuma dayalı veri üretiminde büyük bir artış gözlemlenmektedir. Giderek artan sayıdaki kitle kaynaklı coğrafi veri tabanı servisleri özel ve tüzel kişilerin bu platformlara veri hizmeti katkısı sunmalarına ya da buradaki verileri kullanmalarına olanak sağlamıştır. Bu gelişmeler, Gönüllü Coğrafi Bilgi (Volunteered Geographic Information, VGI) kavramının hayatımızda yer edinmesini sağlamıştır.

Mekansal Veri Altyapılarının (Spatial Data Infrastructure, SDI) ve geoportalların etkin olarak kullanıldığı geçtiğimiz çeyrek yüzyılda mekansal verinin yönetişiminde daha etkin yollar aranmakta ve ayrıca makinelerin/etmenlerin bu yönetişimin bir parçası olması sağlanmaya çalışılmaktadır. Özellikle büyük kitleler tarafından mobil platformlar aracılığıyla üretilen verilerin değerlendirilerek karar-destek süreçlerine dahil edilmesi konusunda büyük çaba harcanmaktadır. Bu amaçla kullanıma sunulan yapay öğrenme modellerinin yükselen algılama başarımı, mekansal veri üretiminde endüstriyel bir araç olarak bu yöntemlerin kullanılmasının önünü açmaktadır.

Bu gelişmeler sonrasında, günümüzde harita verisi üretimindeki fazla zamana ihtiyaç duyulan ve emek yoğun iş süreçlerine sahip geleneksel yöntemler yerini derin öğrenme tabanlı bilgisayarlı görü tekniklerini içeren yenilikçi çözümlere bırakmaktadır. Bu konuda hazırlanan çok sayıda akademik çalışmanın yanı sıra benzer amaçlarda farklı firmaların geliştirdiği farklı ticari çözümler de bulunmaktadır.

Mapillary platformu kitle kaynak yöntemiyle kullanıcılardan sokak düzeyi (street-level) görüntüleri toplayıp, bu görüntülerden derin öğrenme yöntemiyle harita bilgilerinin üretildiği bir girişim (startup) çözümüdür. Mapillary, bilgisayarlı görü (computer vision) ve derin öğrenme (deep learning) teknikleri ile değerlendirme yaparak kullanıcıların yüklediği görüntülerden mekansal bilgiler üretmektedir. Bu bilgiler arasında vektör veri yapısında ilgi noktası (Point of Interest) özellikli trafik ışıkları, trafik levhaları, ek odalar (manhole), rögar kapakları gibi nesneler bulunmaktadır. Mapillary görüntülerde tespit ettiği bu nesnelerin konumlarını özniteliklerine/nesne sınıflarına bağlı olarak harita üzerinde gösterebilmektedir.

Mapillary'nin 2014 yılında açık lisans ile hayata geçmesinden sonra OSM kullanıcıları uydu görüntüleri ya da hava fotoğrafları ile elde edilemeyen ve saha çalışması

gerektiren verileri bu platform üzerinden toplamaya başlamışlardır. Mapillary platformu Openstreetmap'in "ID Editör" ve "JOSM" çizim aracıyla entegre olup sokak seviyesi görüntüler bu platformda açılabilmektedir. Mapillary'nin bu özelliği açık kaynak kodlu harita geliştirilmesine katkı sunan topluluklar tarafından benimsenmesini ve dünya genelinde çok sayıda sokak düzeyi görüntünün platforma yüklenmesini sağlamıştır. Bugüne kadar, Mapillary platformuna dünyanın farklı bölgelerinden 800 milyondan fazla sokak düzeyi görüntü kaydedilmiştir.

Bu tez çalışması kapsamında, bilgisayarlı görü (computer vision), derin öğrenme (deep learning), anlamsal bölütleme (semantic segmentation) gibi kavramlar Mapillary ile ilişkilendirilerek incelenmektedir.

Bu çalışmada; Mapillary platformunda bir sınıf olarak kabul edilen ek odaların (manhole) sokak düzeyi görüntüler üzerinden bilgisayarlı görü yaklaşımıyla tespit edilmesi ve tespit edilen ek odaların belirlenen konum bilgileriyle, telekomünikasyon sektöründe halihazırda kullanılan jeodezik ölçme yöntemleriyle belirlenmiş olan konum bilgilerinin karşılaştırılması ve değerlendirilmesi yapılmaktır. Bu sayede, yenilikçi olarak nitelendirilen yöntemle mekansal veri üretiminin halihazırda kullanılmakta olan geleneksel ölçme yöntemlerinin yerini alıp alamayacağı araştırılmaktadır. Çalışma alanı olarak İstanbul'da üç farklı yol ağı (arter) farklı kategorilerde analiz yapılabilecek biçimde belirlenmiştir. Çalışma alanlarında cep telefonu ve GPS'li araç kamerasının kullanıldığı iki farklı teknikle sokak düzeyi görüntüler elde edilmekte ve elde edilen görüntüler Mapillary platformuna aktarılmaktadır. Böylelikle, görüntü elde etme araçlarının sokak düzeyi görüntülerinden harita verilerinin üretildiği yenilikçi yöntemin çıktılarına ne şekilde etki ettiği de ortaya konmaktadır.

Elde edilen bulgular ışığında yenilikçi yöntemin mevcut durumda doğruluk başarımı özelinde geleneksel yöntemin yerini alamayacağı ve birlikte kullanılmaları durumunda telekomünikasyon sektöründeki uygulamalarda verimliliğin artacağı sonucuna ulaşılmıştır. Bu türden bir yenilikçi yöntemin kullanıldığı varlık tanımlama ve varlıkların koordinatlarını belirleme çözümlerinde, çalışma kapsamında yapılan önerilerin dikkate alınması durumunda yakın gelecekte yenilikçi yöntemin, geleneksel yöntemin yerine geçeceği öngörülmektedir.

## DETECTION OF MANHOLES FROM STREET-LEVEL IMAGERY IN TELECOMMUNICATION BUSINESS

## SUMMARY

Nowadays, the data economy provides the reshaping of our world. The ways of producing and analyzing data with the usual methods are constantly diversified. Data acquisition methods in the field of geomatics engineering have also undergone a major change with the widespread use of web-based maps and geographic information systems instead of classical maps. Map data is sometimes produced by spending a certain budget and sometimes by crowdsourcing such as OpenStreetMap (OSM).

In recent years, there has been a huge increase in location-based data production, including communities. An increasing number of crowd-sourced geographical database services have enabled individuals and legal entities to provide data services to these platforms or to use the data there. These developments have enabled the concept of Volunteered Geographic Information (VGI) to take place in our lives.

In the past quarter century, where spatial data infrastructures (spatial data infrastructures, SDI) and geoportals are used effectively, more effective ways of governance of spatial data are being sought and also efforts are made to ensure that machines / factors are a part of this governance. Particularly, great efforts are made to evaluate the data produced by large masses via mobile platforms and to include them in decision-support processes. The increasing perception of artificial learning models introduced for this purpose paves the way to use these methods as an industrial tool in the production of spatial data.

In artificial learning, neural networks that provide data production are trained instead of directly coding to produce data. For example, when a cat is wanted to be detected with the help of a neural network; There is no need to code for mustache and ear search. You have to show thousands of tagged cat images to the algorithm, and as a result, the algorithm can automatically find other cats. If foxes are classified incorrectly as cats, there is no need to re-code. To eliminate detection errors, only more tagged cat images are shown to the algorithm.

Artificial learning methods are frequently used in the solution of many problems such as object detection and semantic segmentation in the computer vision field. In recent years, spatial data production using street level images with the help of artificial learning methods has become one of the important focal points of both academic studies and commercial applications.

After these developments, traditional methods with much time spent in map data production and labor-intensive business processes are replaced by solutions including deep learning based computer vision techniques. In addition to numerous academic studies on this title, there are also different commercial solutions developed by different companies for similar purposes.

In recent years, the success of classification models in object detection has been carried to a very high level with the use of neural networks and artificial learning power in computer vision approach. Computers can detect objects in videos and images obtained by real-time evaluation, thus enabling driverless vehicles, augmented reality, etc. It is observed that the studies have also accelerated. By integrating the object creation (Sturucture from Motion, SfM) technique into the detection algorithms, it is possible to produce spatial data from street-level images by integrating the spatial data of multiple objects containing the same object into the detection algorithms.

Mapillary is a start-up solution that collects street-level images from users with crowdsourcing method and generates map information with deep learning method from these images. Mapillary generates spatial information from images uploaded by users by evaluating with computer vision and deep learning techniques. This information includes objects such as traffic lights with point of interest in the vector data structure, traffic signs, manhole covers. Mapillary can display the locations of these objects detected on the images, depending on their attributes / object classes.

After Mapillary was launched with an open license in 2014, OSM users started to collect data that cannot be obtained with satellite images or aerial photographs and require field work on this platform. Mapillary platform is integrated with Openstreetmap's “ID Editor” and “JOSM” drawing tool and street level images can be opened on this platform. This feature has enabled Mapillary to be adopted by communities that contribute to the development of open source maps, and many street-level images are uploaded to the platform. To date, over 800 million street-level images from different parts of the world have been recorded on the Mapillary.

Within the scope of this thesis, concepts such as computer vision, deep learning, semantic segmentation are analyzed in relation to Mapillary.

On the other hand, like all companies that build and operate infrastructure, telecommunications companies need spatial data infrastructure to operate their communication networks. Spatial data of the equipment needed to provide communication services are stored in the companies' information systems. Some of these equipment may be aboveground assets such as base stations or field cabinets that people can easily see in their environment, while others are components of infrastructure systems buried underground, such as pipes or cables.

In order to ensure the continuity of the services of telecommunication companies; assets in network systems need to be able to accurately produce location information, they can update their location information after changes to infrastructure systems, and they can produce and integrate the location information of new assets added to the expanding system due to newly added service ends. Although infrastructure companies make significant investments in GIS-based asset management systems, significant or missing data can be found in their databases. Inventory data in constant change and improvement are missing or inaccurate; it may lead to incorrect results of the planning, new field measurements and delay in meeting the demands of the customers.

Telecommunications companies; is in search of a solution that will ensure the flow of data and information between field studies and office environment in spatial data production, which is less dependent on human factor, faster, lower cost and higher data quality. Thus, telecommunication companies will be able to reduce time and cost expenses, provide higher quality services to their end users and stand out in the competition of providing successful services over fiber optic infrastructure.

It is aimed to detect the manholes accepted as a class in the Mapillary platform with a computer vision approach on the street level images, and to compare and evaluate the location information of the manholes identified with the geodetic measurement methods currently used in the telecommunication sector. In this way, it is explored whether the spatial data production with the method described as innovative can replace the traditional measurement methods currently in use. As a study area, three different road networks (arteries) in Istanbul have been determined in such a way that analysis can be made in different categories. Street-level images are obtained with two different techniques using mobile phones and GPS embeded vehicle cameras in the work areas and the images are imported to the Mapillary platform. Thus, it is revealed how the image capture tools affect the outputs of the innovative method by which map data is produced from street-level images.

In addition, it will be investigated how the image acquisition tools to be used within the scope of this study affect the outputs of the innovative method in which map data is produced from street-level images. For this purpose, street level images will be obtained by using the vehicle camera with GPS and mobile phone. The position information produced from the images obtained by both methods will be compared using metrics such as accuracy, precision, sensitivity.

In the light of the obtained findings, it has been concluded that the innovative method cannot replace the traditional method in terms of accuracy achievement in the current situation, and if used together, efficiency will increase in applications in the telecommunications sector. It is predicted that in the near future, the innovative method will replace the traditional method, if the suggestions made within the scope of the study are taken into consideration.

It is considered that the proposed method can be used in order to compare the coordinates with known points, as they need information about whether additional rooms can maintain their presence within the scope of maintenance and repair activities carried out by telecommunication companies. In the case of an additional room cover that is not found in the GIS environment and spatial database but has been identified with an innovative method, the traditional method can be used to produce higher accuracy location information of the relevant point. Thus, the innovative method can be used to optimize the performance of the traditional method.

Telecommunications companies can take advantage of an innovative method to speed up their exploration in the relevant regions before investing in new regions. Thus, they can provide an overview of investment decision-support for the relevant region at a lower cost and less time. If more detailed study is preferred according to these results, traditional method can be used.

Within the scope of local government studies, many vehicles are constantly on track to serve the city for different purposes. Garbage trucks, city buses, municipal vehicles, etc. The cameras with GNSS receiver integrated on the vehicle can record continuously while performing many vehicle works. The recorded images can be evaluated in artificial learning models similar to the computer vision deep learning model used in this study, and hundreds of city objects can be detected on images and associated with the Urban Information Systems. In these days when “Smart” Cities are discussed extensively, such spatial intelligence practices will contribute to local governments to manage cities more effectively. At the same time, the acquired and tagged image datasets will provide the formation of a tagged spatial data education set infrastructure for different spatial intelligence applications.

# 1. GİRİŞ

Günümüzde veri ekonomisi zihin dünyamızın yeniden şekillenmesini sağlamaktadır. Alışılagelmişin dışında yöntemler ile veri üretmenin ve analiz etmenin yolları sürekli bir şekilde çeşitlenmektedir. Geomatik mühendisliği alanındaki veri elde etme yöntemleri de klasik haritalardan web tabanlı haritaların ve coğrafi bilgi sistemlerinin kullanımının yaygınlaşmasıyla büyük bir değişim yaşamıştır. Harita bilgileri kimi zaman belirli bir bütçe harcanarak üretildiği gibi kimi zaman da OpenStreetMap (OSM) gibi kitle kaynak kullanımı ile üretilebilmektedir.

Son yıllarda kitlelerin dahil olduğu konuma dayalı veri üretiminde büyük bir artış gözlemlenmektedir. Giderek artan sayıdaki kitle kaynaklı coğrafi veri tabanı servisleri özel ve tüzel kişilerin bu platformlara veri hizmeti katkısı sunmalarına ya da buradaki verileri kullanmalarına olanak sağlamıştır. Bu tür ve benzeri gelişmeler Gönüllü Coğrafi Bilgi (Volunteered Geographic Information, VGI) kavramının hayatımızda yer edinmesini sağlamıştır (Goodchild, 2007).

Veri üretimi ve sonrasında üretilen bu verilerin değerlendirilerek amaca uygun bilgi, harita bilgisi ve harita üretim işlerinin tamamen insan tarafından manüel olarak gerçekleştirilmesi oldukça uzun bir zaman almaktadır. Dünyanın önde gelen teknoloji şirketleri bilgi işlem konusunda agresif bir değişime yol açacak yapay öğrenme alanında yatırımlarını giderek artırmaktadır. Bill Gates bu konudaki çalışmaları "*Makine Öğrenmesinde bir atılım on Microsoft'a değer*" ifadesiyle özetlemiştir (Barnes, 2015).

Mekansal Veri Altyapılarının (Spatial Data Infrastructure, SDI) ve geoportalların etkin olarak kullanıldığı geçtiğimiz çeyrek yüzyılda mekansal verinin yönetişiminde daha etkin yollar aranmakta ve ayrıca makinelerin/etmenlerin bu yönetişimin bir parçası olması sağlanmaya çalışılmaktadır (Güney, 2015). Günümüzde, özellikle mobil platformlar sayesinde kitlelerin ürettiği verileri değerlendirerek karar-destek süreçlerine dahil olmasını sağlayan bir çok uygulama geliştirilmektedir. Bu amaçla

kullanıma sunulan yapay öğrenme algoritmalarının algılama başarımındaki artış, veri üretiminde endüstriyel bir araç olarak bu yöntemlerin kullanımının önünü açmaktadır.

Yapay öğrenmede, veri üretimi yapmak amacıyla doğrudan kodlama yapmak yerine veri üretimini sağlayan sinir ağları eğitilmektedir. Örneğin, bir kedi bir sinir ağı yardımıyla algılanmak istendiğinde; bıyık ve kulak aramaya yönelik kodlama yapılmasına gerek yoktur. Algoritmaya binlerce etiketli kedi görüntüsü gösterilmekte ve bunun sonucunda algoritma diğer kedileri otomatik olarak bulabilmektedir. Tilkilerin kedi olarak yanlış sınıflandırılması halinde yeniden kodlama yapmaya ihtiyaç duyulmamaktadır. Algılama hatalarının giderilmesi için yalnızca daha fazla etiketlenmiş kedi görüntüsü algoritmaya gösterilmektedir (Tanz, 2016).

Yapay öğrenme yöntemleri bilgisayarlı görü alanındaki nesne algılama ve anlamsal bölütleme gibi birçok problemin çözümünde sıkça kullanılmaktadır. Son yıllarda, yapay öğrenme yöntemleri yardımıyla sokak düzeyi görüntüler kullanılarak mekansal veri üretimi yapmak, gerek akademik çalışmaların gerekse ticari uygulamalarım önemli odak noktalarından biri haline gelmiştir.

Mapillary, kitle kaynak yöntemiyle gönüllü kullanıcıların sokak düzeyi görüntü (street-level) paylaşabildiği bir harita platformudur (URL-1). Mapillary, kullanıcılara gönüllülerin ürettiği sokak seviyesi görüntüleri sunmanın yanı sıra, Bilgisayarlı Görü (computer vision) ve Derin Öğrenme (Deep Learning) teknikleri ile değerlendirme yaparak kullanıcıların yüklediği bu görüntülerden anlamlı bilgiler üretmektedir. Bu tür mekansal bilgilere nokta katmanında tutulan trafik ışıkları, trafik levhaları, ek odalar (manhole), rögar kapakları, vb. gibi şehre ilişkin nesneler örnek olarak verilebilir (URL-2). Bu nesneler, ulaşım ağları boyunca uzanan ve mekansal veri altyapılarına kaydedilmesi gereken önemli yol varlıklarıdır.

Altyapı inşa eden ve işleten tüm firmalar gibi telekommünikasyon firmaları da sahip oldukları haberleşme şebekelerini işletebilmek için mekansal veri altyapısına ihtiyaç duymaktadır. Haberleşme hizmetinin sunulmasında gereksinim duyulan ekipmanlara ait mekansal veriler firmaların bilgi sistemlerinde depolanmaktadır. Bu ekipmanlardan bazıları insanların çevrelerinde rahatlıkla görebildiği baz istasyonları veya saha dolapları gibi yer üstü varlıklar olabilirken bazıları ise boru ya da kablolar gibi yer altında gömülü olan altyapı sistemlerinin bileşenleridir.

Rekabetin oldukça yüksek olduğu bu sektörde telekommünikasyon firmaları yatırım yaptıkları şebeke sistemlerinden maksimum verim elde etmek ve müşterilerine kesintisiz hizmet sunmak istemektedir (Hussain ve diğ. 2017). Bu amaçla kurulan CBS-Telekom uygulamaları tarafından karşılanması beklenen ana gereksinimlerden bazıları şunlardır:

- Şebeke genişlemesinin planlaması ve tasarımı,
- Port seviyesine kadar bina içi ya da bina dışı şebekenin modellenmesi,
- Tranşe, kablo, boru ve ekipmanların tanımlanması,
- Ekipman atamasını içeren ekipman yönetimi,
- İş sonu projelerinin ve ölçme verilerinin depolanması,
- Operasyon Destek Sistemleri (Operational Support System, OSS) ya da İş Destek Sistemleri (Business Supoort System, BSS) için şebeke verisi sunma,
- Servis aktivasyonu ya da hizmet verme öncesi sorgulamalarının gerçekleştirilmesi,
- Kablo hatalarının (kopma, hasar, vb.) tespit edilmesi,
- Birçok satış, pazarlama ve hizmet verilmesi ile ilişkili fonksiyonlar (Deshpande, 2009).

Kısaca ifade edilen bu yaklaşımların ve iş süreçlerinin başarılı biçimde uygulanabilmesi için öncelikle şebekelere ait varlıkların doğru, güvenilir ve düşük maliyetli yöntemlerle mekansal veri kümelerinin üretilmesi gerekmektedir.

### 1.1 Tezin Amacı

Bu tez çalışmasının temel amacı telekomünikasyon sektöründe kullanılan ek odası kapaklarının yapay öğrenme yöntemi ve bilgisayarlı görü teknikleri kullanılarak sokak düzeyi görüntülerinden tespit edilmesi ve konum bilgilerinin üretilmesidir. Yenilikçi olarak nitelendirilen bu yöntemin başarımı, halihazırda telekomünikasyon sektöründe kullanılmakta olan geleneksel ölçme yöntemleriyle elde edilen sonuçlarla kıyaslanarak değerlendirilecektir. Bu kapsamda, her iki yöntemle veri üretimi için ihtiyaç duyulan kaynak ve zaman farklılıkları da ortaya konacaktır. Elde edilecek bulgular doğrultusunda, telekomünikasyon sektöründeki mekansal veri üretimi sürecinde

yenilikçi yöntemin geleneksel ölçme yöntemlerinin yerini alıp alamayacağı sorusuna cevap aranacaktır.

Ayrıca, bu çalışma kapsamında kullanılacak görüntü elde etme araçlarının sokak düzeyi görüntülerinden harita verilerinin üretildiği yenilikçi yöntemin çıktılarına ne şekilde etki ettiği de araştırılacaktır. Bu amaçla, GPS'li araç kamerası ve cep telefonu kullanılarak sokak düzeyi görüntüler elde edilecektir. Her iki yöntemle elde edilen görüntülerden üretilen konum bilgileri doğruluk, hassasiyet, duyarlılık gibi metrikler kullanılarak kıyaslanacaktır.

## 1.2 Problem Tanımı

Telekomünikasyon firmaları hizmetlerinin sürekliliğini sağlayabilmek için; şebeke sistemlerinde bulunan varlıkların konum bilgilerini doğru bir şekilde üretebilmeleri, altyapı sistemlerinde gerçekleştirilen değişikliklerden sonra bu varlıkların konum bilgilerini güncelleyebilmeleri ve yeni eklenen servis uçları nedeniyle genişleyen sisteme eklenen yeni varlıkların konum bilgilerini üretip mevcut sistemle bütünleştirebilmeleri gerekmektedir. Altyapı şirketleri CBS tabanlı varlık yönetim sistemlerine önemli yatırımlar yapıyor olsalar da veritabanlarında önemli oranlarda eksik ya da yanlış veriler bulunabilmektedir. Sürekli değişim ve gelişim içinde bulunan envanter verilerinin eksik ya da hatalı olması; planlamaların hatalı sonuçlar vermesine, yeni saha ölçmelerine gereksinim duyulmasına ve müşterilerin taleplerinin karşılanmasında gecikme yaşanmasına neden olabilmektedir (Hebbalaguppe ve diğ. 2017).

Halihazırda mekansal verinin üretilmesinde geleneksel ölçme yöntemleri kullanılmaktadır. Şekil 1.1'de gösterilen ek odaların öncelikle saha personeli tarafından ölçme işlemi yapılmaktadır. Ardından, ölçüsü yapılan malzeme ya da ekipmana ilişkin öznitelik verileri kayıt edilmektedir. Son olarak, ofis ortamında konum bilgisi ve öznitelik verileri bütünleştirilerek CBS ortamında mekansal model oluşturulmaktadır (Hebbalaguppe ve diğ. 2017).

Bu işlemler şebeke altyapısının genişlemesi ya da bakım ve yenileme kapsamında şebekeye yeni ekipman eklendiği her durumda tekrarlanmaktadır. Ölçme işlemi, mümkünse 'Global Uydu Navigasyon Sistemi (Global Navigation Satellite System, GNSS)' kullanılarak yapılmaktadır. Uydudan gelen sinyallerin sağlıklı bir şekilde

alınamadığı yerlerde (sık ve yüksek yapılaşmanın yoğun olduğu bölgelerde) yersel ölçme yöntemleri kullanılmaktadır.




**Şekil 1.1 :** Ek odası (manhole) örneği.

Şebeke genişleme ve bakım faaliyetleriyle, yol ağları boyunca uzanan onbinlerce kilometrelik altyapı sistemlerinde yaşanan değişikliklere paralel olarak geleneksel ölçme yöntemleri varlık yönetim sistemlerinin güncellenmesi ihtiyacına yeterince hızlı cevap verememektedir. Bilgi sistemlerinin güncellemesinde yaşanan bu gecikmeler, abonelere daha geç ulaşılmasına sebep olmaktadır. Telekomünikasyon firmaları haftalarca sürebilen bu gecikmelerden ötürü önemli ölçüde maddi kayıp yaşamaktadır.

Ayrıca, telekomünikasyon firmaları varlık yönetim sistemlerindeki verilerini güncellemek ve doğrulamak amacıyla periyodik olarak (genellikle yıllık) saha çalışmaları gerçekleştirmektedir. Söz konusu çalışmalarda, görevli personel şebeke bilgi sisteminde yer alan ve sahada gözlemlenen ekipmanları genellikle bir mobil uygulama aracılığıyla doğrulamaktadır. Şebeke elemanlarında bir değişiklik gözlemlenmesi halinde ise bilgi sisteminde uyuşmazlık olduğu geri bildiriminde bulunulmaktadır. Aylarca sürebilen bu arazi çalışmalarıyla güncellenen veriler, çalışma süresinin uzun olması nedeniyle aslında çalışma sonunda güncelliğini yitirmiş veriler haline gelmektedir. Tamamen insan tarafından gerçekleşen bu güncelleme ve doğrulama faaliyetinin doğruluğu da kontrol edilememektedir.

Bunların yanı sıra, telekomünikasyon firmaları fiber optik altyapı yatırım planlaması yaparken yüksek müşteri potansiyeline sahip bölgeleri tespit edebilmek için diğer firmalara ait altyapı verisine ihtiyaç duymaktadır. Bir bölge hakkında yatırım kararı alınabilmesi için ilgili bölgede diğer firmalara ait altyapının olmaması karar verme aşamasında en önemli parametrelerden biri olmaktadır. Bu problemin çözümünde,

belirlenen bölgelere yönlendirilen saha ekiplerinin yaptığı keşif çalışmaları kullanılmaktadır. Fakat bu çalışmalar, metropollerin bütününün incelenerek doğru bölgelerin tespit edilmesinde yetersiz kalmakla birlikte firmalara önemli bir maddi yük getirmektedir.

Yukarıda ifade edilen tüm bu ve benzeri nedenlerden ötürü telekomünikasyon firmaları; arazi çalışmalarıyla büro ortamı arasındaki veri ve bilgi akışını insan faktörüne daha az bağımlı, daha hızlı, daha düşük maliyetle ve daha yüksek veri kalitesiyle sağlayacak bir çözüm arayışı içeresindedir. Böylece telekomünikasyon firmaları zaman ve maliyet giderlerini azaltacak, son kullanıcılarına daha yüksek kalitede hizmet verebilecek ve fiber optik altyapı üzerinden başarılı hizmet sunma rekabetinde öne çıkabilecektir.

### 1.3 Çalışma Konusu

Son yıllarda sinir ağlarıyla yapay öğrenme gücünün bilgisayarlı görü yaklaşımında kullanılmasıyla sınıflandırma modellerinin nesne algılamadaki başarısı oldukça üst seviyelere taşınmıştır. Bilgisayarların gerçek zamanlı (real time) değerlendirmeyle elde edilen video ve görüntülerdeki nesneleri algılayabildiği ve bu sayede sürücüsüz araç, artırılmış gerçeklik, vb. çalışmaların da hızlandığı görülmektedir. Aynı nesneyi içeren birden fazla görüntüden nesneye ait mekansal verinin üretilebildiği hareket ile nesne oluşturma (Sturucture from Motion, SfM) tekniğinin de algılama algoritmalarına entegre edilmesiyle sokak düzeyi görüntülerinden nesnelere ait mekansal veri üretmek mümkün hale gelmiştir.

Haberleşme/telekomünikasyon sektörü, teknolojik gelişmeler ve tüketicilerden artan talep ve beklentilerle birlikte günden güne gelişim göstermektedir. Bu tez çalışması kapsamında, fiber optik haberleşme şebekelerinin en önemli düğüm noktalarından olan ek odaların konumlarının sokak seviyesi görüntüleri kullanılarak tespit edilmesi ele alınacaktır. Telekomünikasyon firmalarının bilgi sistemleriyle entegre olarak çalışabilecek ve aralarındaki altyapı rekabetinde kendilerini ön plana çıkarabilecek bu yeni yöntemin performansı çeşitli başarı ölçütleri kullanılarak değerlendirilecektir.

## 1.4 Hipotez

Bu tez çalışması kapsamında, telekommünikasyon sektöründe kullanılan ek odalar, gelişmiş bir bilgisayarlı görü algoritması yardımıyla sokak düzeyi görüntülerinden otomatik olarak algılanacaktır. Seçilen çalışma alanlarında GPS'li araç kamerası ve cep telefonu kullanılarak sokak düzeyi görüntüler elde edilecek ve bu görüntülerden ek odalara ait mekansal veri üretilecektir. Geleneksel ölçme yöntemiyle üretilen verilerin kontol verisi (ground truth) olarak kullanılacağı çalışmada ilk olarak, yenilikçi olarak nitelendirilen yöntemin geleneksel ölçme yöntemlerinin yerini alıp alamayacağı araştırılacaktır. Yenilikçi yöntemin, halihazırda geleneksel ölçme yapılarak üretilmiş şebeke verilerinin kontrol edilmesine katkı sağlayacak bir araç olarak kullanıp kullanılamayacağı bu çalışmada cevabı aranacak bir diğer başlık olacaktır. Ayrıca yenilikçi yöntemde GPS'li araç kamerasıyla ve cep telefonuyla elde edilen görüntülerden üretilmiş mekansal veriler duyarlılık (recall) ve kesinlik (precision) gibi metrikler kullanılarak karşılaştırılacaktır. Şekil 1.2'de belirtilen her iki yöntemle veri üretiminin zaman ve maliyet açısından güçlü ve zayıf yönleri hakkında kıyaslama yapılacaktır.




**Şekil 1.2 :** Geleneksel ve yenilikçi yöntemin karşılaştırılması.

## 2. LİTERATÜR ARAŞTIRMASI

Son yıllarda sokak düzeyi görüntülerini kullanarak harita bilgisi üretmeyi amaçlayan çok sayıda çalışma ortaya konmuştur. Krylov ve diğ. (2018) yaptıkları çalışmada sunduğu algoritma ile *'Google Street View'* platformundaki görüntüleri kullanarak trafik ışıklarının ve telgraf direklerinin mekansal verilerini üretmiştir. Bu mekansal veriler, bir güzergah üzerinde art arda elde edilen görüntülerle kurulan üçgenleme (triangulation) yöntemiyle hesaplanan derinlik mesafesinin görüntülerin elde edildiği konum bilgilerine eklenmesiyle hesaplanmıştır. Hebbalagubbe ve diğ. (2017) de yaptıkları çalışmada benzer bir iş akışıyla sokak düzeyi görüntülerini kullanarak telekommünikasyon sektöründe kullanılan ek oda, saha dolabı ve baz istasyonu kulesi gibi nesnelerin konum bilgilerini üretmişlerdir.

Nesne algılama problemlerinin çözümüne yönelik akademik araştırmalarla ortaya konan yöntemlerin yanı sıra ticari işletmelerin geliştirdiği uygulamalar da bu alandaki gelişmelere ivme kazandırmaktadır. 2009 yılında '*OpenStreetView*' adıyla başlayan, 2016 yılında Telenav firması, 2019 yılında Grab firması tarafından satın alınan ve '*OpenStreetCam*' olarak yeniden isimlendirilen açık lisansa (CC-BY-SA) sahip projeyle sokak düzeyi görüntülerden nesne tanımlama yaklaşımı kullanılarak trafik işaretleri ve trafik ışıkları tespit edilebilmektedir. Facebook tarafından geliştirilen RetinaNet isimli geliştirme kütüphanesini kullanarak nesneleri tespit edebilen uygulamanın temel amacı navigasyon uygulamalarında ihtiyaç duyulan hız limitleri ve dönüş kısıtlamalarına yönelik harita bilgilerinin sokak düzeyi görüntüler kullanılarak üretilmesidir. Ülkemizde de Dece Yazılım firmasının sunmuş olduğu TrafficPro uygulaması araç kamerası ya da cep telefonuyla elde edilen görüntülerden trafik işaretleri ve rögar kapakları gibi nesnelere ait mekansal verileri üretmektedir.

Bu tez çalışması kapsamında sokak düzeyi görüntüler kullanılarak ek odaların tespit edilmesi ve mekansal verilerinin üretilmesi için İsveç'te hayata geçen bir girişim şirketi (startup) olan Mapillary tercih edilmiştir. Telekomünikasyon sektöründeki envanter yönetim probleminin çözümüne yönelik Github'da varolan nesne algılama algoritmalarının basit birer entegrasyonunu kullanmak yerine veritabanında bulanan

milyonlarca görüntüyle algılama algoritmasını eğiterek günden güne gelişmekte olan Mapillary tercih edilmiştir. Ayrıca, Mapillary mekansal verinin üretiminde bugüne kadar kullanılan tüm yöntemlerden farklı olarak görüntülerden oluşturduğu 3 boyutlu nokta bulutunu kullanmaktadır. Mapillary'nin sahip olduğu nesne algılama algoritması ve birinci bölümde açıklanan problemin çözümünde bu algoritmanın kullanımı tez çalışmasının literatür araştırması bölümünde detaylı olarak anlatılacaktır.

## 2.1 Bilgisayarlı Görü

Bilgisayarlı görü, bir görüntü içindeki nesnelerin ve/veya nesne sınıflarının ayırt edilmesini sağlamak için görüntülerden özellik çıkarma işlemi olarak tanımlanmaktadır (Lee, 2015). Bu süreç, pek çok soyutlama aşamasından oluşur. İşlemlerin ilk adımı, her bir görüntü hakkında genel tahmini bir bilgi elde etmek için görüntüleri sınıflandırmakla (classification) başlamaktadır. Daha sonra görüntülerin içindeki nesneleri algılama (object detection) ve onları kategorilerine göre ayırarak sınırlayıcı kutular içine alma ile devam etmektedir. Son olarak, anlamsal bölütleme (semantic segmentation) ve örnek bölütlemesi (instance segmentation) ile her bir kategorideki pikselin ait olduğu sınıf tanımlanarak hassas bir görüntü tanımlama işlemi yapılmış olur (Neuhold ve diğ. 2017).

Son yirmi yıla kadar geleneksel bilgisayarlı görü uygulamaları, görüntü işleme (image processing) tekniklerinin imkan verdiği ölçüde tarif edilmeye çalışılmıştır. Bu tekniklerin her birinin arkasındaki fikir, görüntü içindeki çeşitli özelliklerin (köşeler, renk kimyasalları, görüntünün dokusu, vb.) varlığını kodlayarak görüntüyü temsil etmenin bir yolunu formüle etmektir (Lee, 2015).

Çizelge 2.1 'de görüldüğü gibi bilgisayarlı görüde görüntü işleme gibi görüntüleri girdi olarak almaktadır. Görüntü işlemede elde edilen çıktı yine başka bir görüntü iken bilgisayarlı görüde çıktı renk, boyut veya sayı olabilmektedir (URL-3).

**Çizelge 2.1 :** Bilgisayarlı görü ile görüntü işleme arasındaki farklar.

| İşlem | Girdi | Çıktı |
|---|---|---|
| **Görüntü İşleme** | Görüntü | Görüntü |
| **Bilgisayarlı Görü** | Görüntü/Video | Nicel ya da nitel bilgi |
| **Makine Öğrenmesi** | Görüntü, Video, Sinyal | Nicel ya da nitel bilgi |

Son yirmi yılda bilgisayarlı görü alanında yapılan çalışmalarda ise ‘Yapay Sinir Ağları (Artificial Neural Networks, ANNs)’nın yeteneklerinden ve ‘Görüntü İşleme Birimi (Graphical Processing Unit, GPU)’ teknolojisindeki gelişmelerden faydalanılarak önemli ölçüde ilerleme kaydedilmştir.

## 2.2 Derin Öğrenme

Derin öğrenme; çoklu katmanlar ya da doğrusal olmayan bilgi işlem aşamalarından oluşan modellerden ve ard arda daha yüksek, daha soyut katmanlarda denetimli ya da denetimsiz özellik saptama yöntemlerinden oluşan bir makine öğrenmesi alt sınıfıdır (Deng ve Yu, 2013). Derin öğrenme, büyük ölçüde insan beyninin işleyişinden esinlenilen bir bilgisayar paradigması olan Yapay Sinir Ağlarına (Artificial Neural Networks, ANNs) dayanır. İnsan beyni gibi, her biri basit bir işlem yapan ve bir karar vermek için birbirleriyle etkileşen birçok bilgi işlem hücresinden veya nöronlardan oluşur (O’Mahony ve diğ, 2016). Farklı tip yapay sinir ağlarının değerlendirilmesi ya da birleştirilmesi ile büyük veri üzerinde anlamlı sonuçlara ulaşmak için yaygın olarak kullanılan bir yöntemdir (Deng ve Yu, 2013).

Makine öğrenmesi ya da derin öğrenme alanında yapılan çalışmalarda Python, R, Java gibi birçok farklı programlama dili kullanılmaktadır. Python, geliştiricilere sunmuş olduğu esneklik ve özelliklerle bu programlama dilleri arasında ön plana çıkmaktadır. Python dilini makine öğrenmesi, derin öğrenme ve yapay zeka alanında en iyi programlama dilleri arasına yerleştiren özellikler aşağıdaki şekilde özetlenebilir:

- Özgür ve açık kaynak kodlu olma özelliği topluluk tarafından tercih edilmesini ve uzun vadede gelişmesini sağlamaktadır
- Kapsamlı kütüphaneler, mevcut her sorun için bir çözüm bulma olanağı sunmaktadır (Geliştiriciler tarafından en çok tercih edilen kütüphaneler ve genel özellikleri Çizelge 2.2’de belirtilmiştir) (Anirudh, 2020).
- Sorunsuz uygulama ve entegrasyon, farklı beceri seviyesine sahip kişiler için erişilebilir olmasını sağlamaktadır
- Kodlama ve hata ayıklama süresini azaltarak üretkenliği artırmaktadır
- Esnek hesaplama ve doğal dil işleme içinde kullanılabilmektedir
- C ve C++ modülleriyle sorunsuz çalışmaktadır (Claire, 2020).

**Çizelge 2.2 :** En çok tercih edilen Python kütüphaneleri.

| | |
|---|---|
| TensorFlow | Google tarafından kendi makine öğrenmesi ihtiyaçlarını karşılamak üzere geliştirilmiştir. Açık kaynak kodlu hale gelmesiyle kullanıcılar tarafından en çok tercih edilen kütüphane olmuştur. Airbnb, Snapchat, Uber gibi dünya devi şirketlerde kendi uygulmalarında bu algoritmayı kullanmaktadır. |
| PyTorch | Açık kaynak kodlu Torch makine öğrenmesi kütüphanesine dayanır ve Python entegrasyonu sayesinde ek işlevselliğe sahiptir. Bir veri kümesi üzerinde n boyutlu dizi oluşturarak süreçler arasında daha fazla kontrol etme imkanı sunar. Salesforce, Standford Üniversitesi ve Udacity gibi kuruluşlar makine öğrenmesi çözümlerinde kullanırlar. |
| Keras | Kullanıcı dostu arayüzü ve CPU'lar ve GPU'lar arasında paralelleştirme için sorunsuz bir destek sunmasından dolayı en çok tercih edilen kütüphanelerdendir. Ayrıca kütüphane yineleme konusunda sunduğu modüler yaklaşım sonsuz bir şekilde özelleştirilebilir ve yeni bir derin öğrenme çözümü oluşturmak için herhangi bir sırayla birbirine bağlanabilirdir. |
| Scikit-learn | NumPy ve SciPy gibi güçlü kütüphaneler üzerine inşa edilmiştir. Veri sınıflandırması ve yapılandırması gibi işlevselliklerin yanı sıra regresyon, kümeleme, boyutsal küçültme ve model seçimi gibi fonksiyonlar sunmaktadır. Scikit-learn, GitHub'daki projelerin %40'ında kullanılmaktadır ve J.P.Morgan, Spotify gibi şirketler tarafından da tercih edilmektedir. |
| NumPy | Tensorflow ya da diğer kütüphaneler bile tensörler üzerinde birden fazla işlem yapmak için dâhili olarak Numpy kullanır. Kullanıcıların verilerini içine koymaları için N boyutlu bir dizi nesnesi oluşturur. Bu özelliği diğer vertabanlarına uyarlanabilme ve veri dönüşmleri için avantaj sağlamaktadır. |

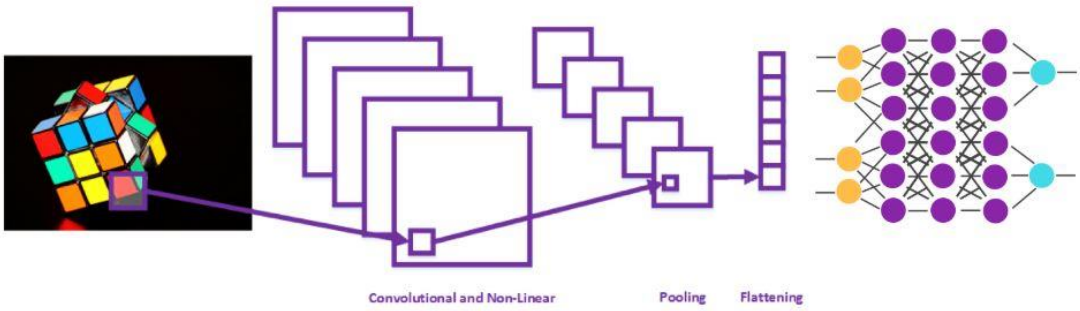
### 2.2.1 Evrişimsel sinir ağlar

Evrişimsel Sinir Ağları (Convolutional Neural Networks, CNNs) genellikle görüntülerin değerlendirilmesinde kullanılan derin öğrenme algoritmaları için özelleştirilmiş çeşitli katmanlardan oluşan derin sinir ağları alt sınıfıdır. Derinlikleri ve genişlikleri değiştirilerek kapasitelerinin artırılabildiği bu ağlar kullanılarak, görüntülerdeki pikseller hakkında yüksek doğrulukla bilgi elde etmek mümkündür. Benzer boyutlu katmanlara sahip standart ileri beslemeli sinir ağlarına kıyasla, CNN'lerin çok daha az bağlantısı ve parametresi olmasından dolayı eğitilmesi daha kolaydır (Krizhevsky ve diğ, 2012).

Evrişimsel sinir ağlarının verimli mimari yapıları ve bu yapıların işletilmesini destekleyen güçlü GPU'ların geliştirilmesi sayesinde derin öğrenme alanındaki çalışmalar da ivme kazanmıştır. Evrişimsel sinir ağları, sınıflandırma ve algılama görevini yapabilmek için görüntüleri çeşitli katmanlarda kullanarak değerlendirmektedir. Şekil 2.1'de ana hatlarıyla görselleştirilmiş iş akışında yer alan bu katmanları genel olarak aşağıdaki gibi tanımlamak mümkündür:

- **Evrimşimsel Katmanı (Convolutional Layer):** Görüntüye birden fazla filtre uygulayarak, görüntü içindeki özelliklerin çıkarılmasını sağlayan katmandır. Görüntü sınıflandırmasının en temel aşaması olan özellik haritası (Feature Map) bu katmanın uygulanması sonucunda üretilmektedir.
- **Doğrusallığı Bozma Katmanı (Non-Linearity Layer):** Yapay sinir ağları, gerçek dünyaya ait doğrusal olmayan algılama problemlerinin çözümünde kullanılmaktadır. Sinir ağının öğrenme gücünü kaybetmemesi ve doğrusal bağlanım (linear regression) gibi davranmaması amacıyla her uygulama fonksiyonu sonrasında doğrusallığı bozma katmanı (Non-Linearity Layer) uygulanır.
- **Havuzlama Katmanı (Pooling Layer):** Ağdaki parametre ve hesaplama yükünü azaltmak amacıyla kendinden önce gelen katmana ait çıktının (özellik haritası, öneri bölge, vb.) mekânsal büyüklüğünü azaltmak amacıyla kullanılmaktadır.
- **Düzleştirme Katmanı (Flatenning Layer):** Evrim ve havuzlama katmanlarından gelen çıktıyı tam bağlantı katmanına iletmek üzere tek boyutlu diziye dönüştüren katmandır.

**Tam Bağlantı Katmanı (Fully Connected Layer):** Düzleştirme katmanından aldığı verilerden sinir ağı yoluyla öğrenme işleminin gerçekleştiği katmandır. Bu katmanın uygulanmasının ardından piksellere ilişkin sınıflandırma işlemi tamamlanmış olmaktadır (URL-4).




**Şekil 2.1 :** Evrişimsel Sinir Ağı'nda katmanların uygulanması (URL-4).

### 2.2.2 Bölge tabanlı evrişimsel sinir ağlar

Nesne algılama (object detection) algoritmalarında en iyi performans gösteren yöntemler, genellikle birden çok alt seviye görüntü özelliğini yüksek seviyede içerikle birleştiren karmaşık uyumlu sistemlerdir. Bu sistemler arasında görüntüleri parçalar halinde değerlendiren ve zamanla geliştiriciler tarafından doğruluk ve işlem süresi kapasiteleri açısından önemli iyileştirmelerinin yapıldığı bölge bazlı algılama yöntemleri ön plana çıkmıştır. Bu tezin konusu olan çalışmadaki öneminden dolayı bölge tabanlı algılama yöntemleri hakkında kapsamlı bir inceleme sunulacaktır.

İlk olarak, Girshick ve diğ. (2014) yaptığı çalışmada **Bölge Tabanlı Evrişimsel Sinir Ağı (Region Based Convolution Neural Network, R-CNN)** modelini ortaya koymuştur. Bu yaklaşım, o döneme kadar bilinmekte olan iki bilgiyi kullanarak inşa edilmiştir: Birinci bilgi: Nesnelerin görüntü içindeki konumlarını belirlemek ve sınıflara ayırmak için görüntüye evrişimsel sinir ağı uygulanabilmektedir. İkinci bilgi ise etiketli eğitim verileri az olduğunda, yardımcı bir görev olarak denetimli bir ön eğitim yapmak, sinir ağlarının performanısnda bir artış sağlayacağıdır. Görüntü bölütlemesi (image segmentation) çalışmalarında önemli bir eşik olan ve ortaya konulduktan sonra bir çok araştırmacı tarafından performansı geliştirilen R-CNN modeli üç temel aşamadan oluşturmaktadır:

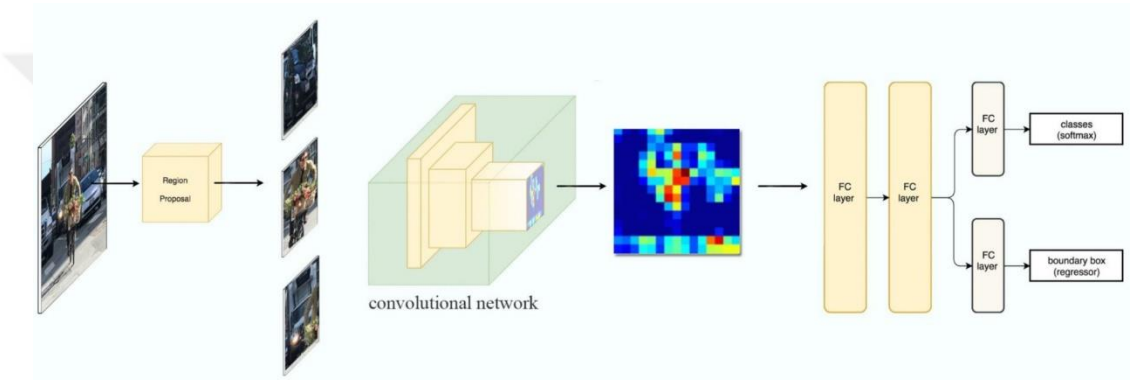
1- Görüntü içinde benzer özellikler gösteren alanlardan Destek Vektör Makinesi (Support Vector Machine, SVM) (Tang, 2015) kullanılarak eşit büyüklükte

aday bölge önerileri oluşturulur (bir görüntü için yaklaşık 2000 bölge önerisi üretilmektedir).

2- Her bir aday aday bölgeyi içeren görüntü parçası ayrı ayrı Evrişimsel Sinir Ağında (ConvNet) değerlendirilir.

3- Son olarak, Tam Bağlantı Katmanında (Fully Connected Layer) nesne sınıflandırması yapılır ve nesnelere ait sınırlayıcı kutular oluşturulur (Girshick ve diğ, 2014).

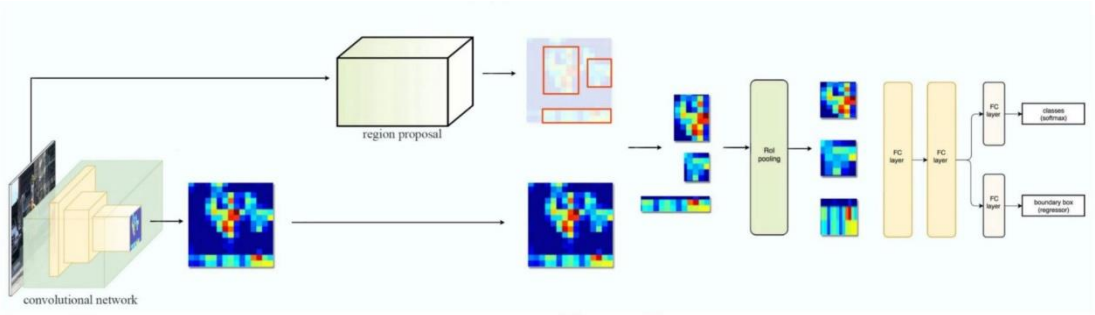
Şekil 2.2'de Bölge Tabanlı Evrişimsel Sinir Ağına ilişkin işlem aşamaları görselleştitirilmiştir.




**Şekil 2.2 :** R-CNN modeli akış şeması (Hui,2018).

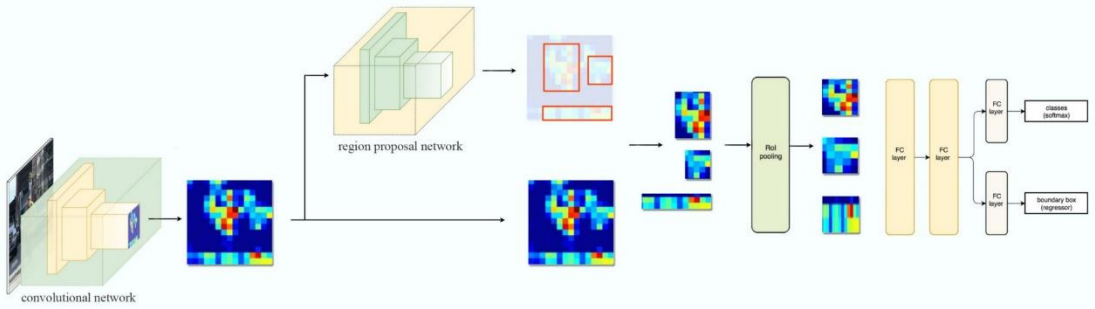
Bu çalışmadan yaklaşık bir sene sonra Microsoft Derin Öğrenme ekibinden Girshick (2015) kendi nesne algılama modelini, test etme ve eğitme hızı açısından bir üst seviyeye taşıyarak **Hızlı-Bölge Tabanlı Evrişimsel Sinir Ağı (Fast R-CNN)** modelini ortaya koymuştur. Şekil-4'te işlem aşamalarının görülebildiği bu yöntem, R-CNN'den farklı olarak ilk aşamada görüntüden bölgeler kırpmak yerine tüm görüntüyü CNN'de değerlendirerek özellik haritası çıkarmayı amaçlamıştır. Ayrıca, bu modelde harici bir işlemle bölge önerileri içeren sınırlayıcı kutular çizdirilmiş, bu sınırlayıcı kutular özellik haritası üzerine oturtulmuş ve ilgili bölgeler (Regions of Interest, RoIs) özellik haritasından çıkarılmıştır. Bu sayede, R-CNN yöntemindeki öneri görüntü parçalarının yeniden depolanma ihtiyacı ortadan kaldırılmış ve depolama alanında yüzlerce gigabit tasarruf sağlanmıştır. Ayrıca, özellik haritası ve bölge önerilerinin birleşmesiyle oluşan farklı boyuta sahip ilgili bölgeler (RoIs) havuzlama katmanıyla aynı boyuta getirilerek sınıflandırmanın yapılacağı tam bağlantı katmanına girdi olarak sokulmuşlardır. İşlem adımlarındaki bu değişimle

Hızlı R-CNN modelinde R-CNN'e göre eğitim süresi (yaklaşık 9 saat) 9 kat ve test süresi (görüntü başına 2,3 saniye) 7 kat hızlanmıştır (Girshick, 2015).




**Şekil 2.3 :** Hızlı R-CNN (Hui, 2018).

Hızlı R-CNN modeli, Şekil 2.3'te görüldüğü gibi harici bir işlemle bölge önerisi üretme adımını içinde barındırmaktadır. Bu yöntemle, ağın test aşamasında bölge önerilerini üretme işlemi görüntü başına 2,3 saniye sürmesi anlamına gelmektedir ve hala yavaştır. Ren ve diğ. (2016) Hızlı R-CNN algoritmasına ekledikleri bölge teklif ağı (Region Proposal Network, RPN) ile Şekil 2.4'de belirtilen **Daha Hızlı R-CNN (Faster R-CNN)** algoritmasını inşa etmiştir. İki yöntem arasındaki tek farklılık, ilgili bölge (RoI) teklifini harici bir işlemle yapmak yerine özellik haritasına Bölge Teklif Ağı (Region Propasal Network, RPN) adı verilen dahili bir evrişimsel ağ uygulanarak yapılmasıdır. Bu gelişmeyle, ağdaki işlem sayısı azalmış ve modelin uçtan uca (end-to-end) eğitilmesi mümkün hale gelimiştir. Daha Hızlı R-CNN'lerde ilgili bölge (RoI) oluşturma işlemi görüntü başına 10 milisaniyeye kadar düşmüştür (Ren ve diğ, 2016).

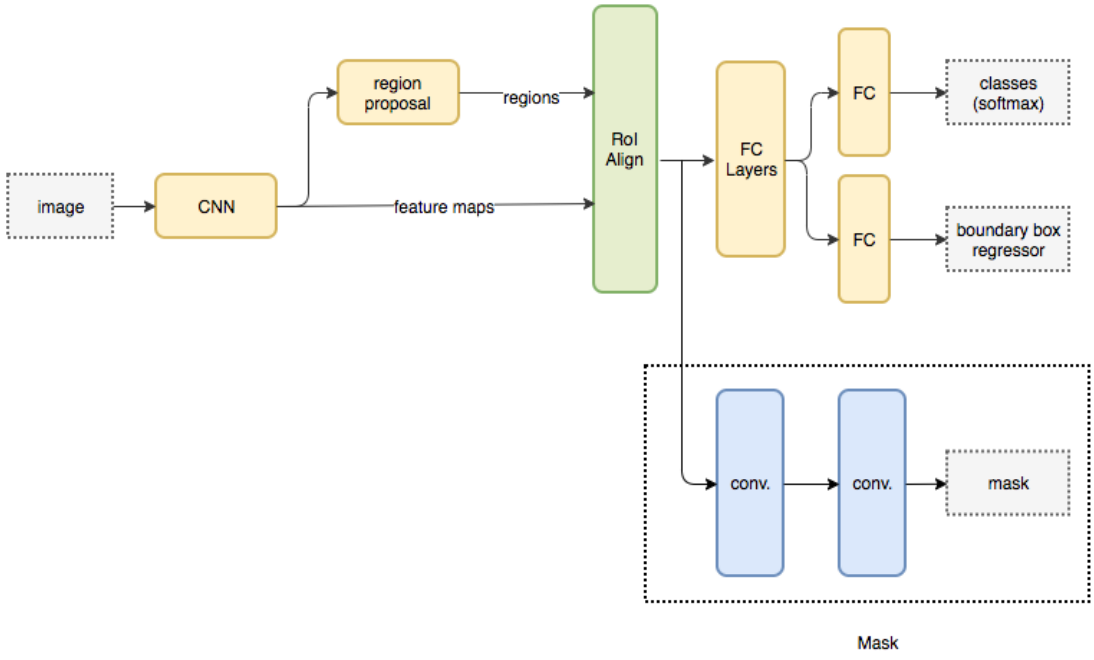



**Şekil 2.4 :** Daha Hızlı R-CNN (Hui, 2018)

Daha Hızlı R-CNN yönteminin çıktısı, nesnelerin ait olduğu sınıf türleri ve bu sınıf türlerine göre üretilmiş sınırlayıcı kutulardır. Fakat, iç içe geçmiş çok sayıda nesneyi içeren görüntülerin değerlendirilmesinde sınırlayıcı kutuları içeren çıktılar görüntü bölütlemesi için tek başına yeterli değildir. Daha hassas görüntü bölütlemesi yapabilmek amacıyla He ve diğ. (2017) yaptığı çalışmada **Maske R-CNN (Mask R-**

**CNN)** modelini ortaya koymuştur. Bu model, Daha Hızlı R-CNN yönteminin iki çıktısı olan nesne sınıfları ve sınırlayıcı kutulara üçüncü bir çıktı olarak nesne maskesini eklemiştir. Şekil 2.5'de görüldüğü gibi, öneri bölgeler iki yeni evrişimsel ağ üzerinde değerlendirilmektedir. Bu ağlarda, ilgili bölge içinde kalan piksellerin nesneye ait olduğu yerlerde 1 ve ait olmadığı yerlerde 0 değerini alan bir matris oluşturulur. Bu sayede nesnelere ilişkin piksel bazlı bir bölütleme yapılmış olur.

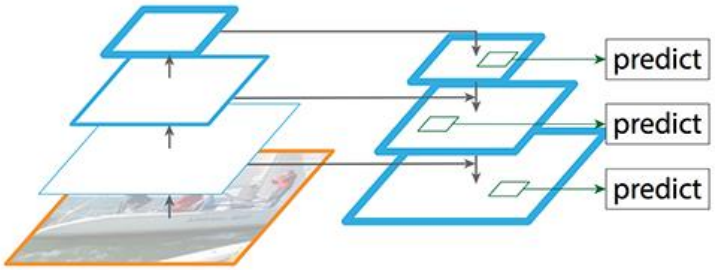
Maske R-CNN yöntemiyle elde edilen bir diğer gelişme ise **Bölge Hizalama (RoI Align)** özelliğidir. Daha önceki yöntemlerde **Bölge Havuzlama (RoI Pooling)** katmanıyla derlenen özellik haritasındaki bölgelerin gerçek görüntüye göre konumlarında sapmalar olduğu tespit edilmiştir. Bunun sebebi farklı boyutlarda ve farklı nesneleri temsil eden özellik haritaları tek bir özellik haritasında birleştirilmek istendiğinde sınır piksellerin birbiriyle tam olarak örtüşmemesidir. Bölge sınırlarındaki eğriliğin dijitalleşmesiyle gelen bu sorunun çözümü için Bölge Hizalama yöntemi üst üste gelemeyen sınır piksellerine enterpolasyon uygulayarak yeni değerler üretmektedir. Bu yeni katman özellik haritalarının üretiminde %10'a kadar daha iyi konum doğruluğu elde edilmesini sağlamıştır (He ve diğ, 2017).




**Şekil 2.5 :** Maske R-CNN

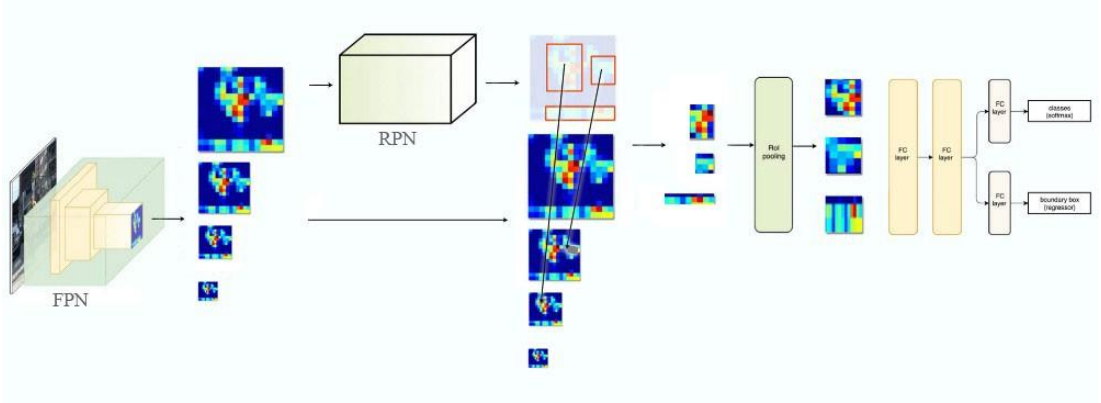
Bu aşamaya kadar anlatılan R-CNN, Hızlı R-CNN ve Daha Hızlı R-CNN nesne algılama yöntemlerinde özellik haritaları tek bir ConvNet kullanılarak üretilmekteydi. Görüntüye ait tek bir ölçekten özellik çıkarmak görüntüdeki özellikle küçük nesnelerin

algılanamaması problemini de beraberinde getirir. Aynı görüntüyü farklı ölçeklerde üreterek evrişimsel ağların girdisi olarak sunmak ise üretilen görüntülerin getireceği fazladan depolama alanı ihtiyacı ve işlem yükü nedeniyle etkili bir çözüm olamamaktadır. Bu problemin çözümünde **Özellik Piramidi Ağı (Feature Pyramid Network, FPN)** adı verilen algılama yöntemi kullanılarak çok ölçekli özellik haritaları üretmek, doğruluk ve işlem hızı açısından en verimli yöntem olarak karşımıza çıkmaktadır. FPN yöntemi, Şekil 2.6'da görülebildiği gibi aşağıdan yukarıya ve yukarıdan aşağıya olmak üzere iki aşamadan oluşmaktadır. Aşağıdan yukarı doğru çıkıldıkça mekansal çözünürlük düşerken anlamsal değer artmaktadır. Geleneksel ConvNet yapısında aşağıdan yukarıya doğru özellik haritaları oluşturulur fakat işlem hızında avantaj sağlamak amacıyla alt katmanlarda nesne algılama yapılmamaktadır. Yalnızca çözünürlüğün düşük olduğu üst katmanlarda nesne algılama yapmak özellikle küçük nesneler için doğruluk oranının düşmesine yol açmaktadır.




**Şekil 2.6 :** Özellik Piramidi Ağı (FPN)

FPN yöntemi çözünürlüğün düşük, anlamsal değerin yüksek olduğu üst katmandan aşağıya doğru bir yol oluşturur (5 adet katman). Her ölçekte piksel değerlerine ilişkin tahminler kaydedilirken nesnelerin konumunda bir kayıp yaşanmaması amacıyla alt katmanlara geçişte nesnelerin konumlarını doğrulayan yanal bağlantılar kullanmaktadır. Nesne tahminleri piramidin 4 katmanında (conv2, conv3, conv4, conv5) gerçekleştirilir. En altta oluşturulan ve çözünürlüğü en yüksek olan ilk katmandan çok fazla işlem yükü getirmesi sebebiyle tahminde bulunulmaz. Ayrıca, FPN algoritması tek başına nesne algılaması modeli değildir ve diğer algılama yöntemlerinde özellik çıkartma modülü olarak yer almaktadır. Şekil 2.7'de Daha Hızlı R-CNN yönteminde Özellik Piramidi (FPN) uygulaması görülmektedir (Lin ve diğ, 2017).




**Şekil 2.7 :** Daha Hızlı R-CNN modelinde FPN omurgası kullanımı.

## 2.3 Mapillary Platformunda Panoptik Bölütleme Yaklaşımı

### 2.3.1 Mapillary'e genel bakış

Mapillary, bireylerin ve kuruluşların dünyayı daha iyi anlamalarına yardımcı olan sokak seviyesi görüntü paylaşım platformudur. 2014 yılında açık lisans ile kurulan bu platformun misyonu; geleceğin haritalarını oluşturmak, akıllı şehirlerin kurulabilmesi ve sürücüsüz araçlara giden yolun açılması için harita verilerini ve sokak seviyesi görüntülerini daha erişilebilir hale getirmektir. Kameralar, akıllı telefonlar ve diğer basit araçları kullanarak ilgi duyan herkes Mapillary'nin sokak seviyesi görüntü havuzuna katkı sunabilmektedir. Mapillary tarafından sunulan servisler, dünya genelinde birçok otomotiv şirketi, mekânsal veri hizmeti sunan şirketlerle kamu kurumları ve belediyeler tarafından kullanılmaktadır (URL-5).

Mapillary 2014 yılının başlarında kurulduğunda, sokak seviyesi görüntülerine erişimin birçok harita üretim talebinden yalnız biri olduğu ortaya çıkmıştır. Belediyeler, hizmet sektöründe faaliyet gösteren firmalar ve otomobil şirketleri gibi kuruluşlar elektrik direği veya trafik işareti envanteri gibi konularda görüntülerden veri almak için Mapillary'e başvurmuştur. Şirketin kurucu ortaklarında Jan Erik Solem bu konuyu şu şekilde açıklamaktadır: "*Burada büyük bir pazar vardı. Sokak seviyesi görüntülerini otomatik ve doğru bir şekilde analiz etmek için bilgisayarları güçlendirerek, çeşitli haritalama taleplerini düşük maliyetlerle karşılayabilirdik. Bizim için önemli olan anahtar parça teknolojiyi bulmaktı. Neyse ki hızlı bir şekilde çalışmak için dünyanın dört bir yanından veri seti aldık.*"

2016 yılında Mapillary'deki bilgisayarlı görü uzmanları, yol işaretlerinden çukurlara ve elektrik direklerine kadar görüntülerdeki birçok şeyi tespit etmek için PyTorch

kütüphanesinde geliştirilen yapay öğrenme modelleri oluşturmaya başlamıştır. PyTorch kütüphanesi kullanılarak algoritmaların kolay geliştirilebilir olması, kütüphanenin esnek yapısı, büyük veri görüntü kümeleri üzerinden hızlı çalışabilmesi (Eric, 2019) vb. nedenlerle Mapillary derin öğrenme modellerini PyTorch kütüphanesini kullanarak geliştirmiştir.

Bu arada, dinamik hesaplama grafiklerinin kullanılması nesne algılama ve panoptik bölütleme ağları ile çalışmayı çok daha kolay hale getirmiştir. Bu ağlar, dinamik hesaplamayı desteklemeyen (Tensorflow gibi) diğer derin öğrenme kütüphaneleri kullanılarak da yapılabilmektedir. Ancak PyTorch'ta yapılması çok daha kolay ve genellikle hesaplama açısından daha etkili olduğu Mapillary tarafından çeşitli ortamlarda ifade edilmiştir.

PyTorch'ta inşa edilen Mapillary modelleri, bir sokak düzeyi görüntüsündeki birçok şeyi tespit ederek etiketleyebilmektedir. Görüntü bölütlemesinin yanı sıra Mapillary modelleri, görüntülerden üretilen üç boyutlu nokta bulutunu kullanarak nesne sınıflarının coğrafi konumlarını da işaretlemektedir. Mapillary'nin farklı türde görsel işaretlemeyle sunmuş olduğu bu harita verilerine, kullanıcılar ihtiyaç duydukları kategorileri filtreleyerek erişim sağlayabilmektedir. Tüm paydaşların aynı görüntülerden ihtiyaç duydukları farklı verileri alabilmeleri harita üretiminde ölçeklenebilirliği tamamen yeni bir seviyeye taşımaktadır (Mahon, 2017).

Görüntü içinde algılanan nesnelerin coğrafi konumlarının belirlenip haritaya işaretlenmesiyle ilgili olarak Solem: "*Nesneleri harita üzerinde işaretlemek için yalnızca görüntü üzerinde tespit etmenin dışında birlikte çalışan farklı bir yöntem bulmamız gerekiyordu. Bu kez, nesneleri bağımsız bir harita özelliği olarak işaretlemeden önce aynı nesneyi farklı görüntülerde algılayarak coğrafi konumunu tespit edecek bir algoritmaya ihtiyacımız vardı. Bunu yapmak için birçok kullanıcıdan gelen görüntülerle kurduğumuz bağlantı sayesinde üretilen 3 boyutlu modeller kullanıyoruz. Söz konusu 3 boyutlu modeller, PyTorch'ta geliştirdiğimiz algoritmadan elde edilen bölütleme sonuçları kullanılarak geliştiriliyor ve bu sayede gökyüzü, ağaçlar, hareket eden nesneler gibi rahatsız edici alanları ortadan kaldırabiliyoruz.*" ifadelerini kullanmıştır (URL-6).

Derin Öğrenme modellerinin eğitilmesi için önemli miktarda etiketli (annotated) veriye ihtiyaç duyulmaktadır. ImageNet (Russakovsky ve diğ, 2015), PASCAL VOC

(Everingham ve diğ, 2014), Microsoft COCO (Lin ve diğ, 2015) gibi veri setleri hem ticari hem de bilimsel araştırma toplulukları tarafından oluşturulmuş önemli eğitim veri setleridir. Ancak, sokak seviyesi görüntüleri değerlendirmek üzere kurgulanan algoritmaların eğitilmesi için geniş çerçevelere sahip veri setlerinin yerine sokak seviyesi görüntülerine özel hazırlanmış veri setine ihtiyaç duyulmaktadır. Mapillary geliştiricileri, gelecekte sürücüsüz araçların da gerçek zamanlı anlamsal değerlendirme yapabilmesine yönelik trafiğin paydaşlarının sokak seviyesi görüntülerdeki birbirleriyle olan etkileşimlerini daha iyi anlamlandırabilecek bir veri seti çalışması başlatmıştır. Mapillary geliştircileri bu amaçla; 18,000 eğitim, 2,000 doğrulama ve 5,000 test görüntüsü olmak üzere dünyanın farklı bölgelerinden elde edilmiş toplam 25,000 yüksek çözünürlüklü sokak seviyesi görüntüsünden 152 adet nesne kategorisinde ve 100 adet örneğe özgü kategoriden oluşan Mapillary Vistas verisetini oluşturmuştur (Neuhold ve diğ, 2017). Platforma yüklenen her yeni görüntü derin ağlarda değerlendirilerek Mapillary Vistas veri setine göre kategorilere ayrılmaktadır. Mapillary'de şu anda 700 milyondan fazla sokak seviyesi görüntüsü mevcuttur ve platforma her gün yaklaşık iki milyon yeni görüntü eklenmektedir.

### 2.3.2 Panoptik bölütleme yaklaşımı

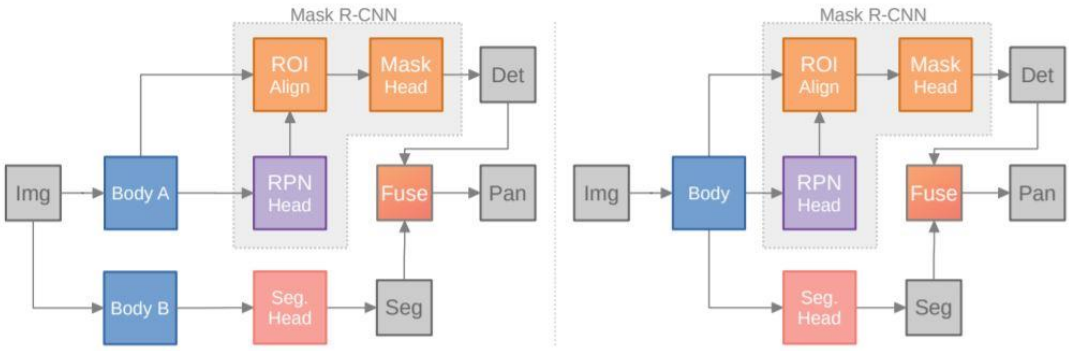
Bilgisayarlı görünün ilk uygulamaları insanlar, hayvanlar ya da araçlar gibi sayılabilen nesneler (things) üzerine odaklanmıştır . Son yirmi yılda ise gökyüzü, yol, toprak gibi şekilsiz ve sayılamayan nesnelerin (stuff) algılanması üzerine çalışmalar yürütülmeye başlanmıştır.

Sayılamayan nesnelerin görüntü üzerinde tespit edilmesi genellikle anlamsal bölütleme (semantic segmentation) olarak adlandırılır ve uygulama prensibi her bir piksele bir sınıf etiketlemesi yapmak şeklindedir. Buna karşılık, sayılabilen nesnelerin tespit edilmesi nesne algılama (object detection) ya da örnek bölütlemesi (instance segmentation) olarak adlandırılır. Bu çalışmalarda ise her bir nesnenin sınırlayıcı kutular ve anlamsal maskeler kullanılarak tespit edilmesi amaçlanmaktadır.

Milyonlarca sokak seviyesi görüntüsü içindeki her türlü nesnenin tespiti için modellerin ayrı ayrı uygulanması gereğinden fazla hesaplama yükü getireceği açıktır. Ayrıca modellerin birbirleriyle etkileşim içinde olmaması etiketleme tutarlılığının kontrolü ve güçlendirilmesinin önüne geçmektedir.

Kirillov ve diğ. (2018) yaptıkları çalışmada Panoptik ifadesinin kelime anlamını "tek bir bakışta her şey dahil görme" olarak ifade etmiştir. Panoptik bölütlemede her piksele bir anlamsal etiket ve bir örnek kimliği atanır. Anlamsal etiket nesnenin ait olduğu kategoriyi gösterirken, örnek kimliği ise aynı kategorideki farklı nesnelerin ayrıştırılmasını sağlamaktadır. Aynı etikete ve örnek kimliğine sahip piksellerin aynı nesneye ait olduğu anlaşılmaktadır. Ayrıca sayılamayan nesnelere ilişkin örnek kimliği gözardı edilmektedir (Krillov ve diğ, 2018).

Mapillary araştırma ekibinden Porzi ve diğ. (2019) Bilgisayarlı Görme ve Örüntü Tanıma (Computer Vision and Pattern Recognition, CVPR) Konferası'nda yayınladıkları makaleyle Mapillary'deki Panoptik Bölütleme modelini tanıtmışlardır. Söz konusu Panoptik Bölütleme modeli, Şekil 2.8'de görüldüğü gibi özellik çıkarıcı görevi gören bir ana omurga (backbone) ve iki bölütleme aşamasından (anlamsal bölütleme ve örnek bölütlemesi) oluşmaktadır. Mapillary'e ait tüm modellerde olduğu gibi bu model de Mapillary Vistas Veriseti (MVD) kullanılarak eğitilmiştir.




**Şekil 2.8 :** Sol: Ayrışık model Sağ: Mapillary Panoptik Bölütleme Modeli.

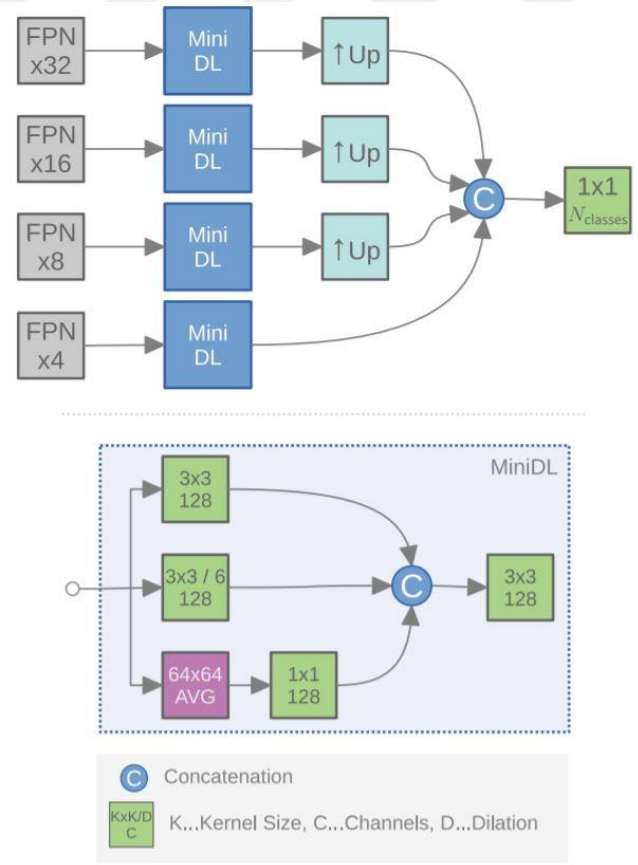
Panoptik Bölütlemede kulanılan ana omurga, ResNet-50 (He ve diğ, 2016) ağının daha önce detaylı olarak açıklanan Özellik Piramidi Ağı (Feature Pyramid Network, FPN) (Lin ve diğ, 2016) ile özelleştirilmiş şeklidir. Örnek Bölütlemesinin Maske R-CNN (Bölüm 2.2.2) mimarisine dayanarak yapıldığı ilk aşamada, Özellik Piramidinin dört katmanına (conv2, conv3, conv4, conv5) ait çıktılar Bölge Öneri Ağına (Region Proposal Network, RPN) girdi olarak aktarılmaktadır. Burada çapa (anchor) adı verilen sınırlayıcı kutular kullanılarak özellik haritasından gelen girdilerden bölge önerileri hazırlanmaktadır. Daha sonra bölge önerilerine RoIAlign katmanı uygulanarak piksel hizalamaları yapılır ve bölge önerileri tek bir mekânsal çözünürlüğe getirilerek sonuçlar iki paralel alt bölüme yönlendirilir. Bu bölümlerden

birincisinde sınıf etiketlemesi yapılırken diğerinde ise sınıf türüne göre maske bölütlemesi yapılmaktadır.

Anlamsal Bölütleme (Semantic Segmentation) aşaması da Özellik Piramidi Ağının dört katmanını girdi olarak almaktadır. Şekil 2.9'da görüldüğü gibi farklı boyutlara sahip özellik haritası katmanına MiniDL adı verilen ve DeepLabV3'e (Chen ve diğ, 2017) benzeyen örnekleme işlemi uygulanmaktadır.

MiniDL mimarisi üç alt daldan oluşmaktadır: İlk iki parça sırasıyla 1 ve 6 genişlemeli 128 çıktı kanallı 3x3 mekansal büyüklüklere sahiptir. Üçüncü parçada ise 64x64 boyutunda havuzlama (pooling) aşamasının ardından 1x1 boyutlarına sahip 128 kanallı filtre uygulanır. MiniDL ağında uygulanan her bir ölçekteki katmanlar 3x3 boyutuna sahip 128 kanallı çıktılar halinde birleştirilmektedir.

Elde edilen tüm akışlar birleştirilir ve 1x1 boyutlu $N_{classes}$ kanallı son bir evrişim katmanına beslenir. Burada her bir pikselin ait olduğu sınıfı tahmin eden softmax katmanı bölütleme işlemini tamamlamış olur.




**Şekil 2.9 :** Üst: Anlamsal Bölütleme aşamaları Alt: MiniDL mimarisi.

Son olarak iki algılama (anlamsal bölütleme ve örnek bölütlemesi) aşamalarının birleştirme (fusion) işlemi Krillov ve diğ. (2018) yaptığı çalışmada ortaya koyduğu haliyle gerçekleştirilir. Öngörülen örnekler (instances) için sınıflandırma skor sırasına göre örnek tahmninleri yinelenmektedir. Her bir örnek için, son çıktıdaki pikselleri kendisine ait ve hala atanmamış olan pikseller işaretlenir. Atanmamış pikseller, eğer sayılabilen bir nesneye aitse (things) bölütleme başlığı (segmentation head) tahminine göre en olası sınıfa alınır. Bu pikseller, eğer sayılamayan bir nesneye (stuff) aitse gözardı edilmektedir. Böylece görüntüdeki tüm piksellerin ait olduğu sınıf atamaları gerçekleştirilmiş olmaktadır (Porzi ve diğ, 2019).

## 2.4 Kitle Kaynak

Kitle kaynak (crowdsourcing), bir şirket veya kurumun daha önce maaşlı çalışanlarla yapılan bir işi yaptırmak için önceden tanımlanmamış kalabalık bir insan topluluğuna çağrıya çıkmasıdır (Howe, 2006). Amerikan gazeteci Jeff Howe 2006 yılında bu tanımı yaptığında kitle kaynak kullanılarak veri üretimi günümüze kıyasla oldukça düşük bir oranda bulunmaktaydı. Kitle kaynak ile veri üretimi konusu 2007 yılında Goodchild tarafından ortaya konan 'Gönüllü Coğrafi Bilgi (Volunteered Geographic Information, VGI)' kavramıyla birleşerek mekansal bilgi sektöründe yeni bakış açılarının ortaya çıkmasını sağlamıştır. Günümüzde; belirli bir işi gönüllü kitleler ile yapmanın, belirli bir bütçe ayırarak yapmaya oranla daha başarılı sonuçlar verdiği düşüncesi giderek yayılmaktadır.

İngiltere'de 2004 yılında hayata geçen OpenStreetMap (OSM) projesi mekansal bilgi sektöründeki en büyük ve en fazla kullanılan kitle kaynak platformudur. OSM, uzaktan algılama görüntülerinin potansiyelini kullanması ve esnek CBS tabanlı olmasıyla kitleleri belirli amaçlar için bir araya getirebilmektedir. HOT OSM (Humanitarian Openstreetmap Team) doğal afetlerin yaşandığı yerler için deprem sonrası harita üretimini dünya genelindeki kullanıcıların desteğiyle insani yardım hizmeti olarak sunmaktadır (Westrope ve diğ. 2014).

Kullanıcıların kendi sokaklarını, evlerini web tabanlı harita üzerinde gösterimine olanak sağlayan platform bugün birçok projeye altlık oluşturmuştur. Açık veri ekosisteminde OpenStreetMap, yeni girişimlere de ilham kaynağı olmuştur. Mapillary'nin 2014 yılında açık lisans (open licance) ile hayata geçmesiyle birlikte OSM gönüllüleri Mapillary platformuna da sokak seviyesi görüntüsü verisi sunmaya

başlamıştır. Mapillary'nin zaman içerisinde kitle kaynak ile büyümesi OSM'in gelişmesine ivme kazandırmıştır. 2014 yılı ekim ayından beri Mapillary'deki sokak seviyesi görüntüler OSM ID Editör içinde de açılabilir hale gelmiştir. Bu sayede kullanıcılar uydu görüntüsünden anlaşılamayan trafik levhası, engelli rampası gibi detayları sokak seviyesi görüntülerine bakarak OSM'ye kaydetme imkanı bulmuşlardır (Juhasz ve Hochmair, 2016).

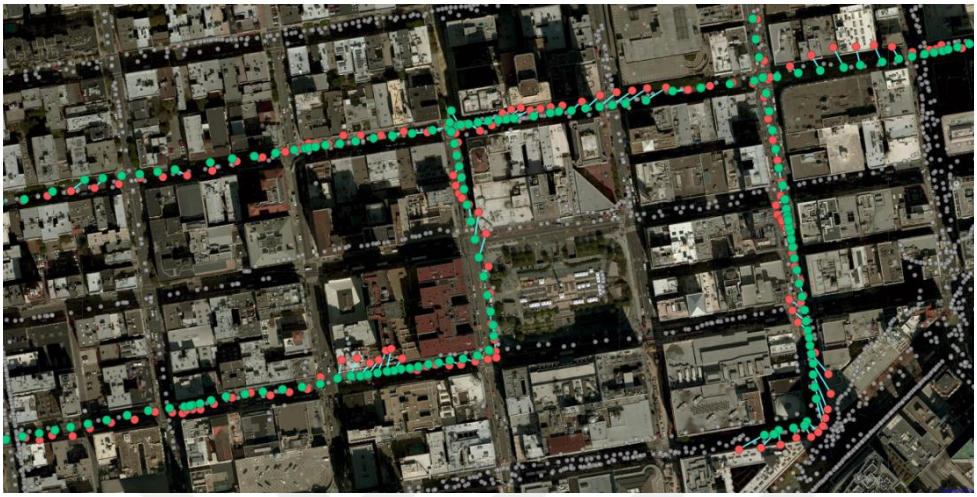
## 2.5 Hareket ile Nesne Oluşturma - Structure From Motion (SfM)

Hareket ile nesne oluşturma (Structure from Motion, SfM), farklı noktalardan elde edilen görüntü dizilerinden 3 boyutlu model elde etme imkanı sunan bir yöntemdir. Geleneksel fotogrametrik yöntemlere göre çok daha düşük maliyet ve daha az uzmanlık gerektirir. Geleneksel yöntemler 3 boyutlu (3D) model oluşturabilmek için yer kontrol noktaları, kameranın konumu ve dönüklük parametrelerine ihtiyaç duyarken hareket ile nesne oluşturma yönteminde birbirleri ardına gelen görüntülerde eşleşen noktalar referans alınarak anlık ve otomatik olarak çözümleme yapılır (Westoby ve diğ. 2012).

İnsansız Hava Aracı (İHA) fotogrametrisinde, nokta bulutu ve dijital yükseklik modelinin (Digital Elevation Model, DEM) üretilmesinde sağladığı avantajlar nedeniyle SfM yöntemi son yıllarda yaygın olarak kullanılmaktadır. Zhang ve diğ. 2019'da yaptığı çalışmalarında iki farklı insansız hava aracı ve kamera çifti (DSLR kamera ve aksiyon kamerası) kullanarak aynı uçuş planıyla yaptıkları çalışmada hareket ile nesne oluşturma yöntemi kullanarak ürettikleri dijital yüzey modelinde santimetre hassasiyetinde sonuçlar elde etmiştir. SfM iş akışı süreciyle insansız hava aracı görüntülerinden yeniden oluşturulmuş nokta bulutuna ulaşılabilmektedir (Bianco ve diğ. 2018).

Mapillary tarafından tespit edilen nesnelerin harita üzerindeki konumları, görüntünün çekildiği cihazın konumuyla doğrudan ilişkilidir. Cep telefonu ya da araç kamerasındaki GNSS verileri özellikle binaların yoğun olduğu yerleşim yerlerinde sapmalara uğramaktadır. Mapillary, görüntülerin kayıt edildiği konumuna ilişkin sapmaların düzeltilmesi için Structre from Motion (SFM) algoritmasını kullanır. Bu algoritma bir biri ardına gelen görüntü sekansları arasında yanlış hizalanmış olanları doğru konuma getirilmesine yardımcı olur. Şekil 2.10'da görüldüğü gibi kırmızı noktalar GNSS'den elde edilen konumları, yeşil noktalar ise Mapillary'de SFM

algortiması çalıştırılarak mevcut yol ağına doğru yönlendirilmiş noktaları ifade eder. Bu yöntemle görüntülerden bilgisayarlı görü ile elde edilen nesnelerin harita üzerindeki konumları daha yüksek doğruluğa ulaşması sağlanabilmektedir (Juhasz, 2016).



**Şekil 2.10 :** Mapillary'de SFM algoritmasının uygulaması.

## 2.6 Telekommünikasyon Sektöründe Mekansal Uygulamalar

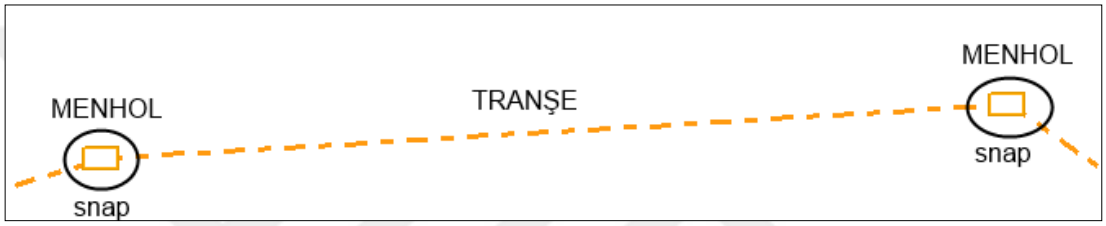
Son yirmi yılda teknolojik gelişmelere paralel olarak sabit genişbant internet erişimine olan ihtiyacın artması telekomünikasyon şirketlerini fiber optik altyapı yatırımına yönlendirmektedir. Daha önce bakır kablolarla internet hizmeti veren şirketler bakır kablolarını fiber optik kablolar ile değiştirirken altyapıya sahip olmayan şirketler de kazı sürecinden başlayarak fiber optik altyapı inşa etmektedir (Alarcon ve diğ. 2008).

Fiber optik altyapı, yerin altına inşa edilen borular, boruların içinden geçen kablolar, kabloların birbirleri ile bağlandığı ek yerleri, ek odaları, vb. gibi bileşenlerden oluşmaktadır. Telekomünikasyon firmaları, altyapılara ilişkin mekânsal bilgileri, altyapıların en verimli şekilde yönetimi ve yeni altyapıların planlanması için CBS tabanlı platformlara kaydetmek zorundadır. Altyapı haritaları telekommünikasyon şirketlerinde birçok planlama ve görüntüleme yazılımında altlık olarak kullanılmaktadır.

Fiber optik altyapılarda ek odalar haricinde diğer bileşenler yer altında gömülü halde bulunmaktadır. Altyapıdan yeni kablo çekilmesi, bakım çalışmaları ve arızalara müdahele edilme işlemleri ek odalar kullanılarak yapılmaktadır.

Ayrıca, şebeke bilgi sistemleri için mekânsal veri üretimi de ekoların konumlarının ölçülmesi yardımıyla gerçekleşmektedir. Konum bilgisi üretilen ek odalar aşağıdaki standartlarda üretilen şekil ve öznitelik bilgilerini içerecek şekilde bilgi sistemine kaydedilir:

- Ek odaların geometri tipi nokta (POINT) olmalıdır.
- Ek oda nesnesi, tranşe katmanı ile kesiştirilmelidir (Şekil 2.11).
- Tüm ek oda noktalarında tranşe çizgisi de kırılmalıdır.
- Öznitelik tablolarında asgari olarak ek oda tipi, ek oda şekli, ek odanın ait olduğu firma, güzergah ve inşa tarihi bilgileri tutulmalıdır.



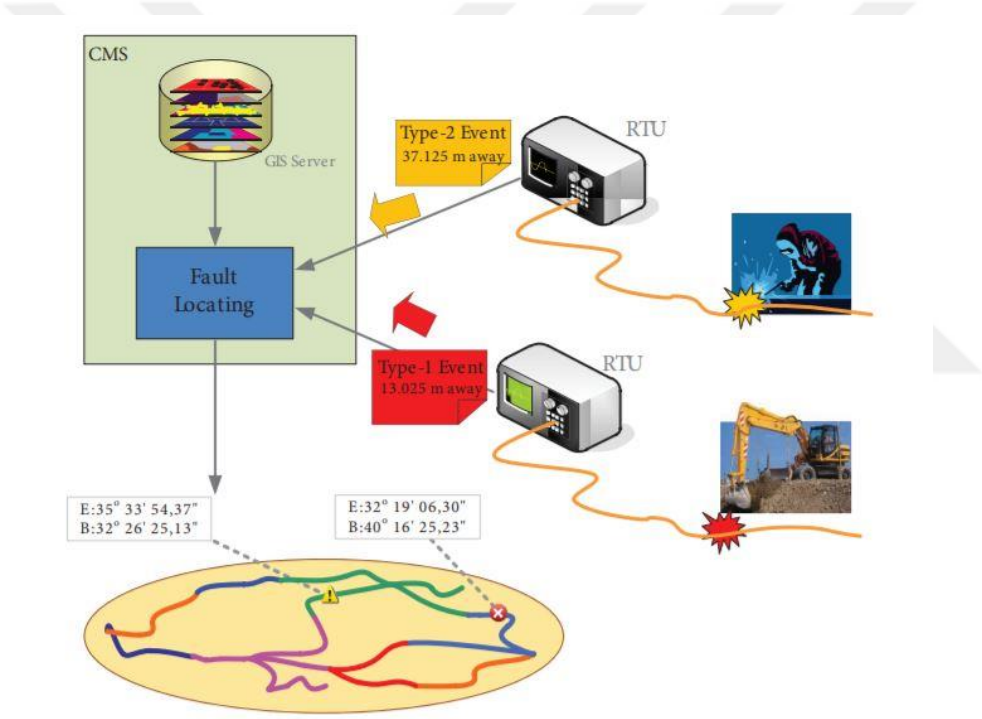

**Şekil 2.11 :** Şebeke Bilgi Sistemi'nde Ek oda-Tranşe ilişkisi.

Ülkemizde ve dünyada farklı telekomünikasyon şirketlerine ait farklı şekil, renk ve büyüklüklerde ek odalar kullanılmaktadır. Şekil 2.12'de görüldüğü ek odaların kapakları genellikle daire ya da dikdörtgen şeklindedir. Ek oda kapakları geçmişte demir döküm malzemeden üretilmekte iken günümüzde daha ekonomik ve hafif olan kompozit malzeme tercih edilmektedir.




**Şekil 2.12 :** Ek Odası kapağı örnekleri.

Şebeke Bilgi Sistemleri'nin telekomünikasyon sektöründe kullanılan başka yazılımlarla birlikte kullanılmasına yönelik Akdemir ve diğ. (2016) yaptığı çalışmada Şekil 2.13'deki iş akışında görüleceği gibi arıza takip platformu kurulmuştur. Fiber optik kablolara fiziksel bir müdahele olması halinde belirli aralıklarla sahada tesis edilmiş olan aktif cihazlar, kesinti sinyali üretmektedir. Bu kesinti sinyalleri aktif cihazdan ne kadar uzaklıkta bir hata alındığını CBS sunucusuna iletmektedir. Kesintinin yaşandığı noktanın aktif cihaza uzaklığına göre harita üzerinde hata alınan noktanın koordinatları tespit edilmektedir. Bu sayede kesintiler anlık olarak merkezde gözlenmektedir (monitoring) ve kesintinin çözümü için saha ekipleri ilgili konuma yönlendirilebilmektedir. Telekomünikasyon firmaları bu ve benzeri mimari yapıdaki arıza takip platformlarını sıkça kullanmaktadır.




**Şekil 2.13 :** Şebeke arıza yönetimi mimarisi.

## 2.7 Veri Kümesi Değerlendirme Ölçütleri

Yapay öğrenme yöntemleriyle gerçekleştirilen sınıflandırma işlemlerinde kurgulanan modelin performansını yalnızca doğruluk (accuracy) ölçütü ile değerlendirmek yeterli değildir. Doğruluk ölçütünün yanısıra, gerçek değerlerle (actual values) tahmin edilen değerler (predicted values) arasındaki ilişkiyi gösteren 'Doğru Pozitif (True Positive, TP)', 'Doğru Negatif (True Negative, TN)', 'Yanlış Pozitif (False Positive, FP)', 'Yanlış Negatif (False Negative, FN)' metriklerinden oluşan bir karışıklık matrisi

(confusion matrix) oluşturulmaktadır. Bu tez çalışması kapsamında elde edilen veriler kullanılarak Çizelge 2.3'de örneği gösterilen bir karışıklık matrisi hazırlanacaktır.

**Çizelge 2.3 :** Karışılık Matrisi örneği.

| | | Actual Values | |
|---|---|---|---|
| | | Positive | Negative |
| Predicted Values | Positive | TP | FP |
| | Negative | FN | TN |

Bu tez çalışması kapsamında elde edilen ek odalara ait veri kümesi göz önünde bulundurularak değerlendirme ölçütlerini aşağıdaki gibi tanımlamak mümkündür (Tharwat, 2018):

**TP (Doğru Pozitif - True Positive) :** Ek oda olan nesnelerin 'ek oda' etiketiyle tespit edilmesidir.

**TN (Doğru Negatif - True Negative) :** Ek oda olmayan nesnelerin 'ek oda değil' etiketiyle tespit edilmesidir.

**FP (Yanlış Pozitif - False Pozitive) :** Ek oda olmayan nesneleri 'ek oda' etiketiyle tespit edilmesidir.

**FN (Yanlış Negatif – False Negative) :** Ek oda olan nesnelerin 'ek oda değil' etiketiyle tespit edilmesidir.

**Doğruluk (Accuracy) :** Yapay öğrenme modelinin sınıflandırıcısının ne kadar başarılı çalıştığını gösterir.

$$Doğruluk = \frac{TP + TN}{TP + FP + TN + FN}$$

**Duyarlılık (Recall) :** Tüm pozitif sınıflardan ne kadar doğru tahmin yapıldığını ifade etmektedir.

$$Recall = \frac{TP}{TP + FN}$$

**Hassasiyet (Precision) :** Tüm sınıflardan ne kadar doğru tahmin yapıldığını ifade etmektedir.

$$Precision = \frac{TP}{TP + FP}$$

**Tahmin Hatası (Prediction Error) :** Tahminlerdeki hata miktarını göstermektedir.

$$Tahmin\ Hatası = \frac{FP + FN}{TP + FP + TN + FN}$$

Alıcı İşletim Karakteristik Eğrisi **(Receiver Operating Characteristic Curve, ROC Curve)**; doğru pozitif oranı **(True Positive Rate, TPR)** ve yanlış pozitif oranını **(False Positive Rate, FPR)** metriklerinin X ve Y eksenlerine yerleştirildiğinde eğrinin altında kalan alanın hesaplanması ile elde edilmektedir. Eğrinin altında kalan alan ne kadar büyükse yapay öğrenme modelinin başarı oranı da o kadar y"üksek demektir (Powers, 2011).

$$Doğru\ Pozitif\ Oranı = \frac{TP}{TP + FN}$$

$$Yanlış\ Pozitif\ Oranı\ = \frac{FP}{FP + TN}$$

# 3. YÖNTEM

## 3.1 Mekansal Verinin Elde Edilmesi

### 3.1.1 Jeodezik ölçme yöntemiyle mekansal veri üretimi

İstanbul'da Kadıköy, Ataşehir ve Silivri ilçeleri sınırlarında yer alan Feneryolu, Küçükbakkalköy ve Yeni Mahalle mahallelerinde gerçekleştirilen jeodezik ölçülerle ekodalarının konum bilgileri üretilmiştir. Yer kontrol noktası (ground truth) olarak kullanılan noktaların 3B konum bilgileri sürekli gözlem yapan GNSS istasyonlarından (Continuously Operating Reference Stations, CORS) oluşan 'İstanbul Su ve Kanalizasyon İdaresi Uydularla Konum Belirleme Sistemi (İSKİ-UKBS)'ne bağlı olarak 'Gerçek Zamanlı Kinematik (Real-Time Kinematic)' ölçme tekniği uygulanarak üretilmiştir. Gezici GNSS alıcısı olarak Şekil 3.1'de görülen Trimble firmasının çift frekanslı R6 alıcısı kullanılmıştır. Uydudan gelen sinyallerin sağlıklı bir şekilde alınamadığı sık ve yüksek yapılaşmanın yoğun olduğu bölgelerde yersel ölçme teknikleri kullanılmaktadır.

Feneryolu ve Küçükbakkalköy mahallelerinde gerçek zamanlı GNSS gözlemleri 2019 yılının Ağustos ayında, Yeni Mahalle'de ise 2020 yılının Mayıs ayında gerçekleştirilmiştir. Çizelge 3.1'de görüldüğü üzere çalışma kapsamındaki toplam 178 ek odası 9 günde toplam 70 saatlik bir çalışma süresiyle ölçülmüştür. GNSS gözlemleriyle gerçek zamanlı olarak elde edilen ek odası kapaklarının orta noktalarının koordinat değerleri CBS ortamına aktarılarak nokta veri yapısına dönüştürülmüştür.

**Çizelge 3.1 :** Geleneksel yöntemin uygulanış bilgileri.

| Çalışma Bölgesi | GNSS Gözlem Tarihi | GNSS Tekniği ile Ölçülen Ek Odası Sayısı | GNSS Gözlem Süresi | Arazideki Ölçme Operatörü Sayısı | Ölçme Maliyeti |
|---|---|---|---|---|---|
| **Feneryolu** | Ağustos 2019 | 58 | 3 gün (25 saat) | 2 | 5,000.00 TL |
| **Küçükbakkalköy** | Ağustos 2019 | 45 | 2 gün (15 saat) | 1 | 4,000.00 TL |
| **Yeni Mahalle** | Mayıs 2020 | 75 | 4 gün (30 saat) | 1 | 7,000.00 TL |
| ***Toplam*** | | *178* | *9 gün (70 saat)* | | *16,000.00 TL* |



**Şekil 3.1 :** Geleneksel yöntemle veri üretimi.

### 3.1.2 Araç üzerindeki kamera kullanılarak mekansal verinin elde edilmesi

Sokak seviyesi görüntülerinin elde edilmesi için araç kamerası olarak Çizelge 3.2'de teknik özellikleri belirtilen ve Şekil 3.2'de görülen Blackvue markasının DR900M modeli kullanılmıştır (URL-7). Mapillary ve Blackvue kameralarının üreticisi Pittasoft firmaları arasında yapılan anlaşma gereğince Mapillary firmasına özel olarak üretilmiş olan bu kamerada; görüntüleri elde edildikleri andaki koordinat bilgisi ile ilişkilendiren özel bir yazılım bulunmaktadır. Bu sayede görüntü dosyaları masaüstü uygulaması olan Mapillary Uploader kullanılarak Mapillary platformuna oldukça kolay biçimde yüklenebilmektedir (URL-8).

**Çizelge 3.2 :** Araç kamerası özellikleri.

| | |
|---|---|
| **Kamera** | 8 megapiksel CMOS Sensör |
| **Görüş Açısı** | Diyagonal 162º, Yatay 136º, Dikey 77º |
| **Çözünürlük** | 4K Full HD (3840 x 2160) |
| **Görüntü Kalitesi** | En yüksek: 25 + 10 Mbps |
| **GPS** | Gömülü |

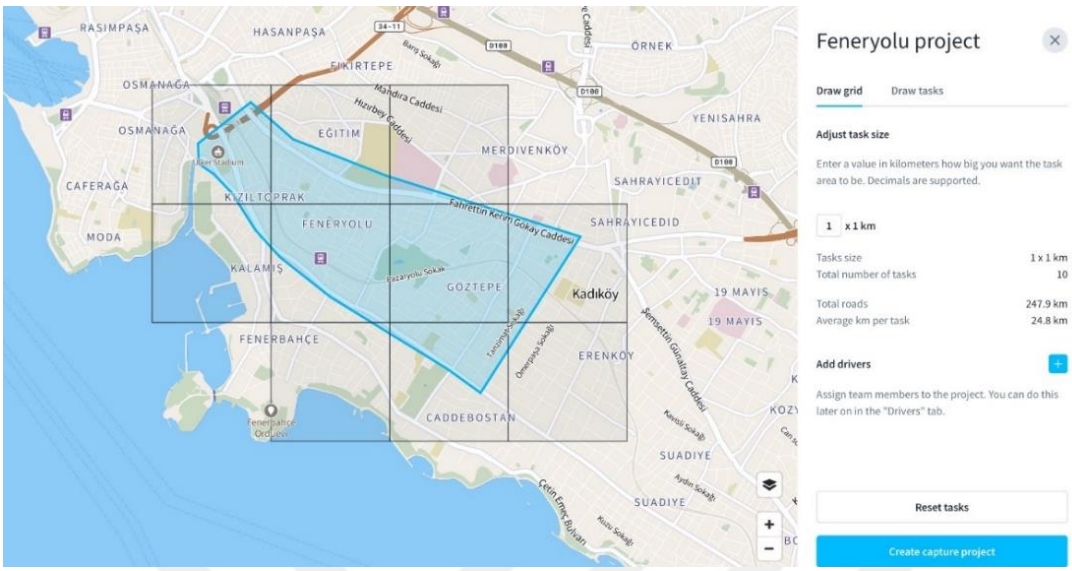
Masaüstü uygulaması araç kamerasının kaydettiği video görüntülerini GPS verilerinden yararlanarak belirli aralıklarda görüntü karelerine dönüştürmektedir. Araç hareket etmediğinde elde edilmiş görüntüler uygulamanın ürettiği 'stationary' klasöründe toplanmaktadır. Uygulama GPS sinyali alınamadan elde edilen görüntüleri de yine bir başka klasörde toplanmaktadır. Son olarak Mapillary'e yüklenen görüntü dizileri 'uploaded' klasöründe toplanmakta ve istenildiği zaman 'history' sekmesinden daha önce yüklenmiş görüntü dizileri görüntülenebilmektedir (URL-9).




**Şekil 3.2 :** Blackvue Marka Kameranın Araç İçinden Görüntüsü.

Sokak seviyesi görüntülerinin araç kamerasıyla çekimlerini planlamak amacıyla Mapillary web platformunun Şekil 3.3'de görülen kontrol paneli (dashboard) yardımıyla çalışma alanının sınırları çizilmiştir. Daha sonra, Feneryolu mahallesi için üretilen bu çalışma alanı, MapillaryDriver mobil uygulamasında görüntülenerek çekimler esnasında hareket edilen ve çekimi yapılan güzergahlar geride bırakılan GPS izleriyle takip edilmiştir. MapillaryDriver uygulaması; Android ya da İOS tabanlı cihazlarda erişilebilen görüntü çekimi yapmayı planlayanların görevlerini yerine getirmek için kullandıkları, görevlerini kabul etmelerine, her görevde nerelerin haritasının üretilmesinin gerektiğini görmelerine ve görev tamamlandığında sonuçları göndermelerine olanak sağlayan bir mobil uygulamadır. Bu uygulama sayesinde birden fazla kullanıcıyı içeren takımlar oluşturulabilmekte, her takım üyesine farklı

bölgelerde sürüş görevi atanabilmekte ve bu sayede toplulukların dahil olduğu görüntü kaydetme süreçleri yönetilebilmektedir (URL-10).

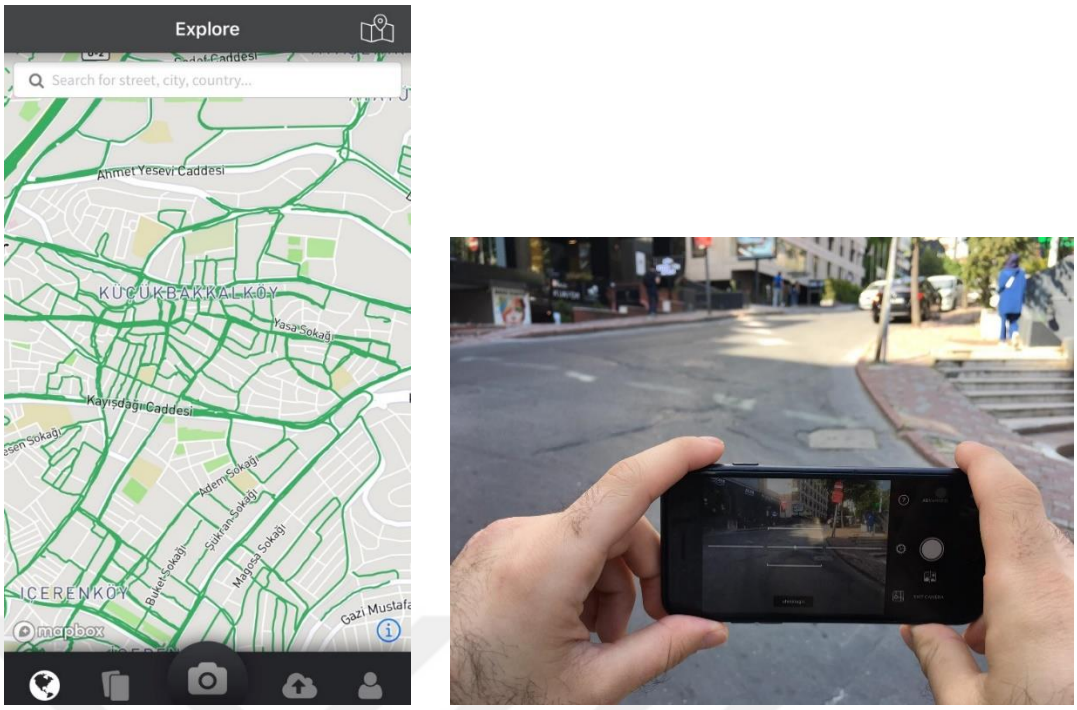



**Şekil 3.3 :** Mapillary kontrol panelinde sürüş planlaması.

### 3.1.3 Akıllı telefon kullanılarak mekansal veri üretimi

Mapillary kullanıcıları araç kamerası ile veri üretiminin dışında Android ya da IOS tabanlı cihazlarda erişilebilen 'Mapillary' mobil uygulamasıyla da platform için görüntü elde edilebilmektedir. Uygulama anlık olarak veritabanına görüntü yüklemenin yanı sıra çevrimdışı dahili hafızaya görüntüleri kaydederek ofis ortamında verilerin yüklenmesine de izin vermektedir. Kullanıcıların profil bilgileriyle giriş yapabildiği uygulamada kişilerin kendi yükledikleri görüntü adedi, kat edilen mesafe, vb. gibi bilgilerin yanı sıra diğer kullanıcıların yüklediği görüntüler de görüntülenebilmektedir.

Bu tez çalışması kapsamında Ataşehir ilçesi Küçükbakkalköy mahallesinde belirlenen yaklaşık 5 kilometrelik güzergahta Xiaomi markasının Redmi 5 Plus modeli akıllı telefonu kullanılarak sokak düzeyi görüntüler kayıt edilmiştir. Xiaomi Redmi 5 Plus akıllı telefonunda bulunan kameranın çözünürlüğü 12MP olup 4K kalitesinde (2160p @ 30 fps) görüntü kaydedebilmektedir. Şekil 3.4'de Ataşehir ilçesi Küçükbakkalköy Mahallesi'nde 'Mapillary Mobile' uygulamasının kullanımına ilişkin ekran görüntü görülmektedir.




**Şekil 3.4 :** Mapillary Mobil uygulaması ve görüntü kaydetme ekranı.

## 3.2 Mekansal Verinin Değerlendirilmesi

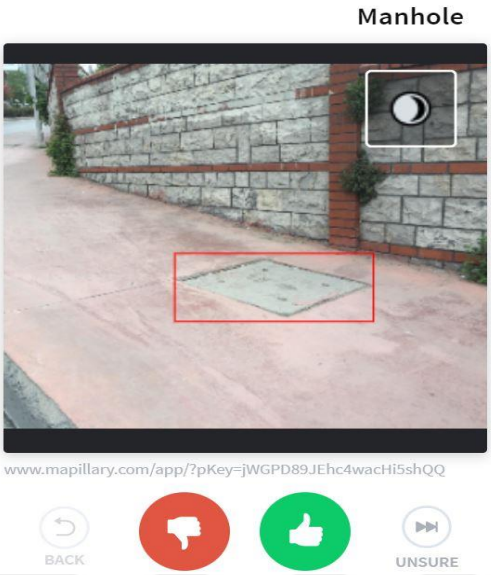
### 3.2.1 Geleneksel yöntemlerle verinin değerlendirilmesi

GNSS uydularına dayalı olarak sahadan elde edilen konum bilgilerinin 'Bilgisayar Destekli Tasarım (Computer Aided Design, CAD)' yazılımları kullanılarak ön değerlendirmesi gerçekleştirilmektedir. Daha sonra ESRI firmasının ArcGIS yazılımı kullanılarak sahada üretilen konum bilgileri nokta detay sınıfına dönüştürülmektedir. Ölçme ile elde edilen noktalar ile öznitelik verilerinin tutulduğu referans noktaları eşleştirilerek ek oda numalaralandırmaları yapılmaktadır. Bu işlemler şebeke altyapısının genişlemesi ya da bakım ve yenileme kapsamında şebekeye yeni varlıkların eklenmesi durumunda tekrarlanmaktadır.

### 3.2.2 Yenilikçi yöntemle verinin değerlendirilmesi

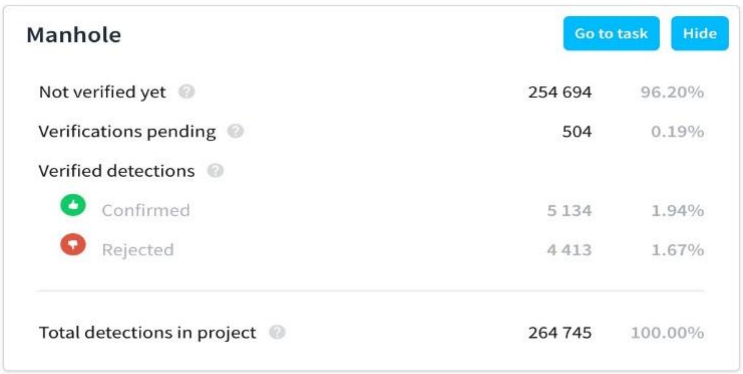
İki farklı yaklaşımla elde edilen sokak düzeyi görüntüleri Mapillary platformuna aktarıldıktan sonra Mapillary tarafından geliştirilmiş olan yapay öğrenme algoritmasının ek odaları tahmin etme doğruluğunun arttırılması için doğrulama (verification) çalışması Mapillary firması tarafından başlatılmıştır. Tüm dünyadan ilgi gösteren herkesin katılımına açık olan doğrulama çalışması, derin öğrenme modelinin özellikle ek odası kapaklarını tanıma başarımının arttırılması için modelin eğitimine

katkıda bulunulmasına olanak sağlamaktadır. Şekil 3.5'de gösterildiği üzere uygulama; doğrulama çalışmasına katılan kullanıcılara, derin öğrenme sınıflandırıcısının ek odası olarak tanımladığı (recognition) nesneleri kare içerisine alarak doğru tahmin yapılıp yapılmadığını sormaktadır.




**Şekil 3.5 :** Mapillary nesne doğrulama sayfası.

Bu çalışma kapsamında üretilmiş olan görüntülerin de içinde bulunduğu tüm İstanbul'a ait veri kümesine ilişkin olarak algoritma tarafından içinde ek odası olma ihtimali bulunan 254.694 görüntü tespit edilmiştir. Şekil 3.6'da görüldüğü üzere 25 farklı gönüllü kullanıcının 'Mapillary Verifier Tool' arayüzü üzerinden katıldığı veri doğrulama sürecinde, gönüllü kullanıcılar tarafından 254.694 görüntü arasından 5134 adet görüntüde ek odası kapaklarının doğru tespit edildiği ve 4413 görüntüde ise ek odası kapağı bulunmadığı belirlenmiştir (URL-11). Bu çalışma sonucunda bilgisayarlı görü algoritmasının ek oda tespitindeki başarım oranının artırılması hedeflenmiştir.




**Şekil 3.6 :** Doğrulama çalışması sonuçları.

## 3.3 Bulgular

Bu bölümde, üç farklı bölgede iki farklı yöntemle gerçekleştirilen çalışmalarla yenilikçi yöntem olarak nitelendirilen yöntemin başarım değerlendirmesi konum doğruluğu, veri değerlendirme süresi, üretim maliyeti gibi farklı açılardan karşılaştırılmalar yaparak gerçekleştirilmiştir.

### 3.3.1 Görüntülerden tespit edilen ek odası kapaklarının konum kestirimi açısından değerlendirilmesi

Üç ayrı çalışma alanında bulunan tüm ek odası kapaklarının iki boyutlu koordinat değerleri 'Uluslararası Yersel Referans Sistemi (*International Terrestrial Reference Frame 2005* (ITRF05)' datumunda 2005.0 epoğunda 30° dilim orta meridyeni 3° dilim genişlikli Gauss-Krüger projeksiyonunda sağa ve yukarı koordinat çifti olarak hesaplanmıştır. GNSS uydu tekniğiyle ölçülen ek odaların 2B koordinat değerleri daha güvenilir ve yüksek doğrulukta olduğundan referans veri kümesi (*ground truth data set*) olarak kabul edilmiştir. Sokak düzeyi görüntülerinden tespit edilmiş olan ek odası kapaklarının '*World Geodetic System* (WGS-84)' datumunda ve ölçü epoğundaki koordinat değerleri doğruluk analizinde test noktası olarak alınmıştır.

Feneryolu Mahallesi'nde yapılan çalışmalarda Çizelge 3.1'de görüleceği üzere 58 tane ek odası kapağının konumları GNSS gözlemleri ile belirlenmiştir. Çizelge 3.3'de verilen konum bilgilerinde görüleceği üzere Feneryolu Mahallesi'nde sokak düzeyi görüntülerinden Mapillary platformu derin öğrenme yaklaşımı ile 16 adet doğru pozitif (True Pozitive, TP) ek odası tespit etmiştir.

Küçükbakkalköy Mahallesinde yapılan çalışmalarda 45 tane ek odasının koordinatları GNSS gözlemleri ile belirlenmiştir. Küçükbakkalköy Mahallesi'nde sokak düzeyi görüntülerinden Çizelge 3.3'de konum bilgileri görülen 24 adet doğru pozitif (True Pozitive, TP) ek odası tespit etmiştir.

Yeni Mahalle'de GNSS tekniği kullanılarak koordinatları belirlenen ek odası sayısı 75'tir. Yeni Mahalle'de görüntüler üzerinden tespit edilen ve Çizelge 3.3'de konum bilgileri görülen doğru pozitif sayısı da 16'dır. Farklı yöntemlerle üretilen her iki veri kümesinde eşleşen ortak noktalar doğru pozitif noktalardır. Bu durumda Feneryolu Mahallesi'nde 16, Küçükbakkalköy Mahallesi'nde 25 ve Yeni Mahalle'de 16 nokta üzerinden yenilikçi yöntemle elde edilen koordinat değerlerinin, geleneksel yöntemle

üretilmiş referans koordinat değerlerinden olan farklılıkları ve standart sapmaları hesaplanmıştır. Üç farklı bölge için sağa ve yukarı koordinat bileşenlerinde ayrı ayrı koordinat farkları Şekil 3.7, Şekil 3.8 ve Şekil 3.9'daki gösterilen grafikler üzerinden incelendiğinde farkların normal dağılımda olduğu görülmüştür.

**Çizelge 3.3.a :** Feneryolu Mahallesi koordinat listesi.

| **Test Noktalarının ITRF05 Datumunda 2005.0 Epoğunda 30° dilim orta meridyeni 3° dilim genişlikli Gauss Krüger Projeksiyon Koordinatları** | | | | | | | |
|---|---|---|---|---|---|---|---|
| **Feneryolu Mahallesinde Araç Kamerasıyla Kaydedilen Görüntüler üzerinden Tespit Edilen Ek Odaların Koordinat Değerleri** | | | | | **Feneryolu Mahallesinde GNSS Uydu Tekniğiyle Ölçülen Ek Odaların Koordinat Değerleri (*Ground Truth Data Set*)** | | |
| **Sıra No** | **NN** | **Sağa (m)** | **Yukarı (m)** | **Durum** | **NN** | **Sağa (m)** | **Yukarı (m)** |
| **8** | **22202** | 419619,41 | 4539320,42 | TP | **22202** | 419595,51 | 4539325,58 |
| **76** | **25519** | 420447,53 | 4539072,68 | TP | **25519** | 420451,34 | 4539084,36 |
| **135** | **25525** | 420686,75 | 4539041,14 | TP | **25525** | 420703,67 | 4539013,11 |
| **94** | **25552** | 420510,64 | 4538990,86 | TP | **25552** | 420513,02 | 4538995,11 |
| **128** | **25553** | 420442,35 | 4539012,78 | TP | **25553** | 420443,89 | 4539018,54 |
| **131** | **25554** | 420443,76 | 4539011,75 | TP | **25554** | 420445,90 | 4539021,91 |
| **134** | **25583** | 420462,75 | 4539182,21 | TP | **25583** | 420468,15 | 4539176,14 |
| **132** | **25584** | 420459,61 | 4539186,50 | TP | **25584** | 420454,97 | 4539187,50 |
| **65** | **214062** | 419765,50 | 4539112,37 | TP | **214062** | 419764,00 | 4539107,54 |
| **67** | **214087** | 419983,48 | 4539061,25 | TP | **214087** | 419988,41 | 4539053,96 |
| **110** | **214167** | 419920,28 | 4538848,80 | TP | **214167** | 419917,73 | 4538844,39 |
| **53** | **214168** | 419909,11 | 4538861,01 | TP | **214168** | 419902,64 | 4538844,83 |
| **78** | **214177** | 420069,58 | 4539013,06 | TP | **214177** | 420074,62 | 4539000,87 |
| **26** | **214284** | 419957,09 | 4539173,58 | TP | **214284** | 419945,09 | 4539184,17 |
| **34** | **214286** | 420323,04 | 4539224,16 | TP | **214286** | 420318,29 | 4539226,46 |
| **36** | **319527** | 420545,13 | 4539057,32 | TP | **319527** | 420546,75 | 4539062,25 |
| **1** | | 420072,81 | 4539019,73 | FP | | | |
| **2** | | 420066,13 | 4539052,39 | FP | | | |
| **3** | | 420017,68 | 4538893,21 | FP | | | |
| **4** | | 419978,52 | 4539043,68 | FN | | | |
| **5** | | 420091,21 | 4539250,55 | FP | | | |
| **6** | | 420087,80 | 4539099,91 | FP | | | |
| **7** | | 420068,51 | 4539106,27 | FP | | | |

**Çizelge 3.3.a (devam) :** Feneryolu Mahallesi koordinat listesi.

| | | | | |
|---|---|---|---|---|
| **9** | | 419758,17 | 4539107,95 | FP |
| **10** | | 419753,60 | 4539279,13 | FP |
| **11** | | 420166,12 | 4538694,93 | FP |
| **12** | | 420193,13 | 4538769,12 | FP |
| **13** | | 420277,76 | 4539112,13 | FP |
| **14** | | 419536,85 | 4539347,34 | FP |
| **15** | | 420572,40 | 4538871,43 | FP |
| **16** | | 420373,75 | 4539207,08 | FP |
| **17** | | 420024,20 | 4539128,52 | FP |
| **18** | | 419669,61 | 4539315,53 | FP |
| **19** | | 419632,32 | 4539329,83 | FN |
| **20** | | 420251,52 | 4539045,99 | FP |
| **21** | | 420225,55 | 4538984,36 | FP |
| **22** | | 420128,18 | 4538995,02 | FP |
| **23** | | 420229,29 | 4538743,28 | FP |
| **24** | | 420258,53 | 4538643,77 | FP |
| **25** | | 420280,71 | 4538713,85 | FP |
| **27** | | 420067,45 | 4539207,52 | FP |
| **28** | | 420102,13 | 4539245,05 | FP |
| **29** | | 420145,64 | 4539027,10 | FP |
| **30** | | 420136,54 | 4538712,46 | FP |
| **31** | | 420196,58 | 4538923,73 | FP |
| **32** | | 420502,29 | 4538916,75 | FP |
| **33** | | 420601,14 | 4538870,69 | FP |
| **35** | | 420543,45 | 4539058,48 | FP |
| **37** | | 420614,34 | 4538882,27 | FP |
| **38** | | 420579,83 | 4539056,97 | FP |
| **39** | | 420298,78 | 4539163,63 | FP |
| **41** | | 420047,52 | 4538920,15 | FP |
| **42** | | 420022,02 | 4539036,47 | FP |
| **43** | | 419495,00 | 4539355,76 | FN |
| **44** | | 420734,78 | 4539077,87 | FP |
| **45** | | 420399,32 | 4539200,30 | FP |
| **46** | | 420691,17 | 4538988,21 | FP |
| **47** | | 420636,33 | 4538902,77 | FP |
| **48** | | 420502,17 | 4538911,33 | FP |
| **49** | | 420593,68 | 4538873,23 | FP |
| **50** | | 420495,85 | 4538935,33 | FP |

**Çizelge 3.3.a (devam) :** Feneryolu Mahallesi koordinat listesi.

| | | | | |
|---|---|---|---|---|
| **51** | | 420045,60 | 4538920,26 | FP |
| **52** | | 420060,44 | 4538989,21 | FP |
| **54** | | 419955,12 | 4538824,56 | FP |
| **55** | | 419672,62 | 4539316,54 | FP |
| **56** | | 419775,16 | 4539135,01 | FP |
| **57** | | 419841,62 | 4539258,38 | FP |
| **58** | | 420276,50 | 4539115,00 | FP |
| **59** | | 420164,71 | 4538867,85 | FP |
| **60** | | 419550,41 | 4539341,02 | FN |
| **61** | | 420287,26 | 4539137,57 | FP |
| **62** | | 419789,80 | 4539173,81 | FP |
| **63** | | 419761,12 | 4539107,56 | FP |
| **64** | | 419789,31 | 4539175,63 | FP |
| **66** | | 419766,22 | 4539124,03 | FP |
| **68** | | 420101,72 | 4538933,11 | FP |
| **69** | | 419955,08 | 4538955,51 | FP |
| **70** | | 420048,86 | 4538917,86 | FP |
| **71** | | 420721,57 | 4539022,96 | FP |
| **72** | | 420661,59 | 4539040,04 | FP |
| **73** | | 420379,44 | 4538966,69 | FP |
| **74** | | 420665,24 | 4538925,91 | FP |
| **75** | | 420425,96 | 4538956,23 | FP |
| **77** | | 420064,93 | 4538993,01 | FP |
| **79** | | 420038,74 | 4538937,05 | FN |
| **80** | | 420426,28 | 4539193,05 | FP |
| **81** | | 420576,66 | 4539055,01 | FP |
| **82** | | 420560,76 | 4539122,62 | FP |
| **83** | | 420452,40 | 4538940,65 | FP |
| **84** | | 420503,29 | 4538974,15 | FP |
| **85** | | 420387,81 | 4539207,05 | FP |
| **86** | | 419759,95 | 4539112,07 | FP |
| **87** | | 419830,93 | 4539237,90 | FP |
| **88** | | 420040,77 | 4538938,31 | FN |
| **89** | | 419914,27 | 4538850,37 | FP |
| **90** | | 419952,39 | 4538829,11 | FP |
| **91** | | 420091,46 | 4539243,09 | FP |
| **92** | | 420492,27 | 4538931,26 | FP |
| **93** | | 420513,21 | 4539169,32 | FP |
| **95** | | 420002,31 | 4538794,88 | FP |
| **96** | | 420166,99 | 4539064,48 | FP |
| **97** | | 420262,52 | 4539082,91 | FP |
| **98** | | 420227,15 | 4538987,21 | FP |
| **99** | | 420278,50 | 4539114,98 | FN |

**Çizelge 3.3.a (devam) :** Feneryolu Mahallesi koordinat listesi.

| | | | | |
|---|---|---|---|---|
| **100** | | 420096,09 | 4538739,36 | FP |
| **101** | | 419745,22 | 4539280,79 | FN |
| **102** | | 420261,31 | 4539020,34 | FP |
| **103** | | 420265,65 | 4539016,81 | FP |
| **104** | | 420209,96 | 4539044,88 | FP |
| **105** | | 420208,50 | 4538670,25 | FN |
| **106** | | 419724,16 | 4539302,16 | FP |
| **107** | | 420034,98 | 4539125,22 | FP |
| **108** | | 419970,50 | 4539009,07 | FP |
| **109** | | 420085,86 | 4538919,02 | FP |
| **111** | | 420020,54 | 4538893,52 | FP |
| **112** | | 419981,73 | 4538806,25 | FP |
| **113** | | 419978,40 | 4538816,48 | FN |
| **114** | | 419982,05 | 4538806,34 | FP |
| **115** | | 419980,07 | 4538806,93 | FP |
| **116** | | 420123,85 | 4539293,12 | FP |
| **117** | | 419888,61 | 4539004,66 | FP |
| **118** | | 419938,94 | 4538909,55 | FP |
| **119** | | 419966,63 | 4539004,75 | FP |
| **120** | | 420019,77 | 4538895,02 | FP |
| **122** | | 420133,51 | 4538713,54 | FN |
| **123** | | 420037,70 | 4539145,57 | FP |
| **124** | | 420058,79 | 4538881,77 | FP |
| **125** | | 420060,21 | 4538883,41 | FP |
| **126** | | 420492,39 | 4538923,26 | FP |
| **127** | | 420503,16 | 4538908,73 | FP |
| **129** | | 420695,29 | 4539037,80 | FP |
| **130** | | 420560,05 | 4539056,88 | FP |
| **133** | | 420589,22 | 4538865,14 | FP |
| **136** | | 420158,86 | 4539067,94 | FP |
| **137** | | 420155,25 | 4539051,23 | FP |
| **138** | | 420132,48 | 4539000,90 | FN |
| **139** | | 419633,00 | 4539332,30 | FP |
| **140** | | 419985,20 | 4538813,90 | FP |
| **141** | | 419461,64 | 4539361,91 | FP |
| **142** | | 420111,86 | 4538950,75 | FP |
| **143** | | 420117,93 | 4538971,51 | FP |

**Çizelge 3.3.b :** Küçükbakkalköy Mahallesi koordinat listesi.

| Test Noktalarının ITRF05 Datumunda 2005.0 Epoğunda 30° dilim orta meridyeni 3° dilim genişlikli Gauss Krüger Projeksiyon Koordinatları | | | | | | | |
|---|---|---|---|---|---|---|---|
| Küçükbakkalköy Mahallesinde Cep Telefonu Kamerasıyla Kaydedilen Görüntüler üzerinden Tespit Edilen Ek Odaların Koordinat Değerleri | | | | | Küçükbakkalköy Mahallesinde GNSS Uydu Tekniğiyle Ölçülen Ek Odaların Koordinat Değerleri (Ground Truth) | | |
| Sıra No | NN | Sağa (m) | Yukarı (m) | Durum | NN | Sağa (m) | Yukarı (m) |
| **30** | **23656** | 425572,40 | 4539049,46 | TP | **23656** | 425575,21 | 4539049,51 |
| **25** | **23687** | 426134,81 | 4539050,24 | TP | **23687** | 426138,25 | 4539050,79 |
| **36** | **23747** | 425494,92 | 4538931,57 | TP | **23747** | 425490,78 | 4538930,73 |
| **8** | **24499** | 426092,78 | 4538937,90 | TP | **24499** | 426090,16 | 4538937,84 |
| **21** | **24501** | 426223,87 | 4538899,98 | TP | **24501** | 426219,10 | 4538900,68 |
| **22** | **24502** | 426266,85 | 4538890,32 | TP | **24502** | 426269,17 | 4538887,08 |
| **20** | **24503** | 426398,11 | 4538863,77 | TP | **24503** | 426396,89 | 4538865,80 |
| **19** | **24510** | 426412,72 | 4538821,85 | TP | **24510** | 426412,35 | 4538820,52 |
| **6** | **24522** | 426213,02 | 4539035,88 | TP | **24522** | 426216,99 | 4539033,30 |
| **9** | **24532** | 426005,56 | 4538971,28 | TP | **24532** | 426003,85 | 4538970,89 |
| **1** | **25020** | 425699,73 | 4538955,63 | TP | **25020** | 425700,35 | 4538958,95 |
| **28** | **25021** | 425851,30 | 4539040,77 | TP | **25021** | 425846,36 | 4539040,50 |
| **34** | **25026** | 425363,55 | 4538949,68 | TP | **25026** | 425360,18 | 4538956,77 |
| **15** | **25035** | 425962,73 | 4538681,45 | TP | **25035** | 425963,25 | 4538677,58 |
| **14** | **25037** | 425990,45 | 4538711,94 | TP | **25037** | 425990,36 | 4538714,62 |
| **24** | **25043** | 426145,12 | 4538785,17 | TP | **25043** | 426148,56 | 4538787,15 |
| **26** | **25044** | 426133,33 | 4538846,74 | TP | **25044** | 426131,70 | 4538855,94 |
| **32** | **25189** | 425601,40 | 4538936,77 | TP | **25189** | 425599,54 | 4538944,16 |
| **11** | **25192** | 425606,07 | 4538760,93 | TP | **25192** | 425608,09 | 4538763,12 |
| **3** | **25243** | 426290,48 | 4538753,27 | TP | **25243** | 426289,27 | 4538752,95 |
| **40** | **26157** | 425720,84 | 4539040,99 | TP | **26157** | 425721,47 | 4539040,28 |
| **33** | **26202** | 425449,88 | 4538930,40 | TP | **26202** | 425445,96 | 4538934,66 |
| **13** | **26231** | 426495,12 | 4538851,25 | TP | **26231** | 426495,23 | 4538852,61 |
| **5** | **26232** | 426485,72 | 4538792,41 | TP | **26232** | 426487,75 | 4538791,06 |
| **2** | | 425719,16 | 4539036,75 | FP | | | |
| **4** | | 426146,22 | 4539055,26 | FP | | | |
| **7** | | 426148,83 | 4539056,43 | FP | | | |
| **10** | | 426019,24 | 4538750,36 | FP | | | |
| **12** | | 426001,81 | 4538969,21 | FP | | | |
| **16** | | 425592,74 | 4538729,20 | FP | | | |
| **17** | | 426016,48 | 4538741,73 | FP | | | |
| **18** | | 426066,35 | 4539045,08 | FP | | | |
| **23** | | 426403,10 | 4538797,71 | FP | | | |
| **27** | | 426183,98 | 4538780,80 | FP | | | |
| **29** | | 425895,69 | 4539044,63 | FP | | | |
| **31** | | 425701,54 | 4538952,35 | FP | | | |
| **35** | | 425624,46 | 4538813,11 | FP | | | |
| **37** | | 425715,57 | 4539014,88 | FP | | | |
| **38** | | 425718,65 | 4539038,16 | FP | | | |
| **39** | | 426000,14 | 4539045,51 | FP | | | |
| **41** | | 426033,29 | 4539046,83 | FP | | | |

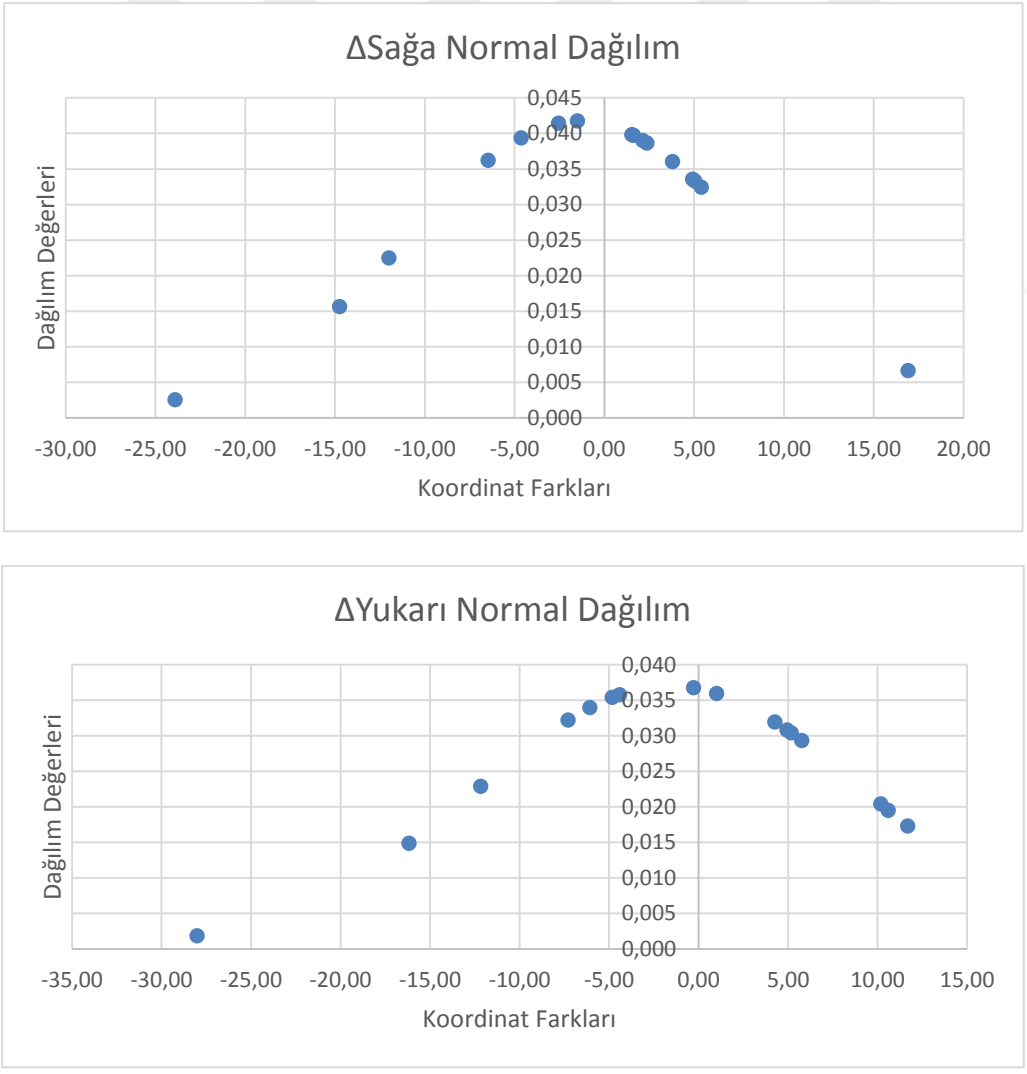
**Çizelge 3.3.c :** Yeni Mahalle koordinat listesi.

| **Test Noktalarının ITRF05 Datumunda 2005.0 Epoğunda 30° dilim orta meridyeni 3° dilim genişlikli Gauss Krüger Projeksiyon Koordinatları** | | | | | | | |
|---|---|---|---|---|---|---|---|
| **Yeni Mahallede Araç Kamerasıyla Kaydedilen Görüntüler üzerinden Tespit Edilen Ek Odaların Koordinat Değerleri** | | | | | **Yeni Mahallede GNSS Uydu Tekniğiyle Ölçülen Ek Odaların Koordinat Değerleri (*Ground Truth Data Set*)** | | |
| **Sıra No** | **NN** | **Sağa (m)** | **Yukarı (m)** | **Durum** | **NN** | **Sağa (m)** | **Yukarı (m)** |
| **70** | **196** | 352712,29 | 4551470,09 | TP | **196** | 352708,74 | 4551468,95 |
| **25** | **191** | 353141,74 | 4551584,81 | TP | **191** | 353142,76 | 4551581,03 |
| **71** | **190** | 352929,94 | 4551782,87 | TP | **190** | 352930,04 | 4551781,52 |
| **37** | **183** | 353487,10 | 4551475,10 | TP | **183** | 353486,76 | 4551471,91 |
| **62** | **174** | 353955,95 | 4552210,46 | TP | **174** | 353955,78 | 4552209,33 |
| **9** | **138** | 352607,79 | 4551138,18 | TP | **138** | 352608,18 | 4551135,97 |
| **34** | **118** | 353419,39 | 4551756,70 | TP | **118** | 353419,29 | 4551761,95 |
| **17** | **109** | 352613,43 | 4551228,53 | TP | **109** | 352612,88 | 4551227,11 |
| **47** | **107** | 352941,88 | 4551320,49 | TP | **107** | 352949,14 | 4551325,57 |
| **67** | **104** | 353009,78 | 4551432,90 | TP | **104** | 353013,87 | 4551437,47 |
| **33** | **101** | 353338,45 | 4551568,44 | TP | **101** | 353339,88 | 4551568,92 |
| **36** | **100** | 353279,44 | 4551474,15 | TP | **100** | 353278,09 | 4551473,54 |
| **51** | **99** | 352912,49 | 4551524,62 | TP | **99** | 352914,52 | 4551526,16 |
| **50** | **97** | 352955,00 | 4551611,47 | TP | **97** | 352955,07 | 4551613,05 |
| **32** | **75** | 353249,07 | 4551435,79 | TP | **75** | 353246,27 | 4551435,16 |
| **54** | **25** | 354033,91 | 4551207,84 | TP | **25** | 354031,14 | 4551206,24 |
| 39 | | 353442,89 | 4551739,62 | FN | | | |
| 44 | | 352839,00 | 4551677,30 | FN | | | |
| 58 | | 352984,27 | 4551743,66 | FN | | | |
| 65 | | 352970,04 | 4551750,62 | FN | | | |
| 69 | | 353476,48 | 4551446,99 | FN | | | |
| 10 | | 352613,12 | 4551186,20 | FP | | | |
| 12 | | 352617,88 | 4551206,40 | FP | | | |
| 13 | | 352623,14 | 4551232,71 | FP | | | |
| 23 | | 353773,74 | 4551893,69 | FP | | | |
| 24 | | 353109,75 | 4551618,90 | FP | | | |
| 26 | | 353998,23 | 4551247,08 | FP | | | |
| 28 | | 353691,56 | 4551760,64 | FP | | | |
| 29 | | 353016,30 | 4551443,06 | FP | | | |
| 30 | | 353552,98 | 4551872,61 | FP | | | |
| 38 | | 353108,65 | 4551613,15 | FP | | | |
| 41 | | 352892,30 | 4551824,69 | FP | | | |
| 42 | | 353283,01 | 4551473,30 | FP | | | |
| 45 | | 353181,16 | 4551562,21 | FP | | | |
| 46 | | 352939,29 | 4551316,54 | FP | | | |
| 48 | | 352676,24 | 4551388,86 | FP | | | |

**Çizelge 3.3.c (devam) :** Yeni Mahalle koordinat listesi.

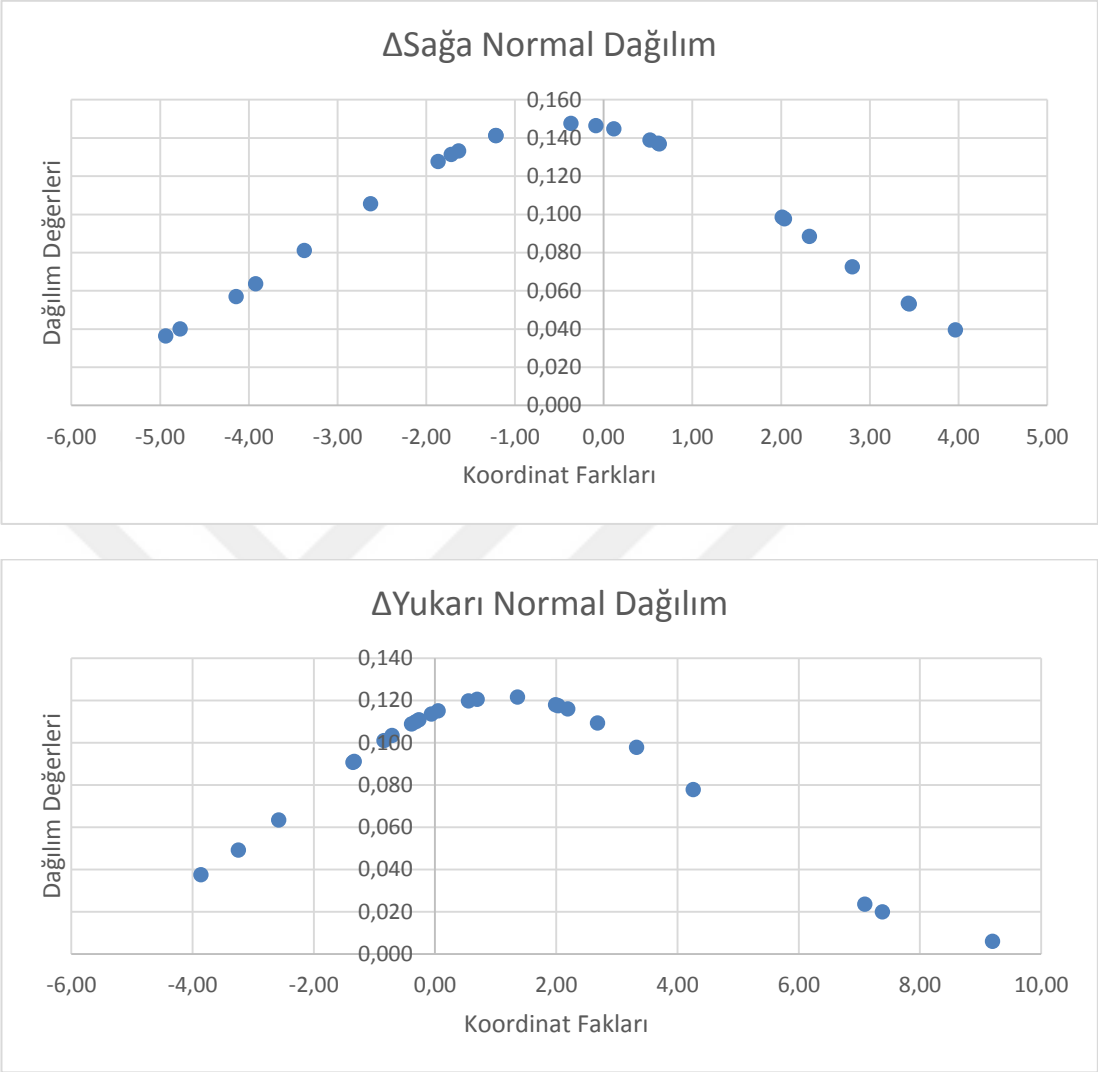
| | | | | |
|---|---|---|---|---|
| 49 | | 352968,12 | 4551748,33 | FP |
| 52 | | 353876,89 | 4552065,46 | FP |
| 53 | | 353481,84 | 4551910,25 | FP |
| 55 | | 352732,25 | 4551494,18 | FP |
| 56 | | 352635,97 | 4551273,13 | FP |
| 57 | | 353951,41 | 4552170,46 | FP |
| 59 | | 352902,65 | 4551817,16 | FP |
| 60 | | 352645,47 | 4551317,22 | FP |
| 64 | | 352942,70 | 4551308,75 | FP |
| 66 | | 353743,23 | 4551845,01 | FP |
| 73 | | 353006,32 | 4551712,21 | FP |

Feneryolu veri kümesi için algoritma tarafından tespit edilen ek odaların konumlarıyla referans ek odalar (ground truth) arasındaki koordinat farklarından üretilmiş sağa ve yukarı normal dağılım tablosu Şekil 3.7'de verilmiştir.



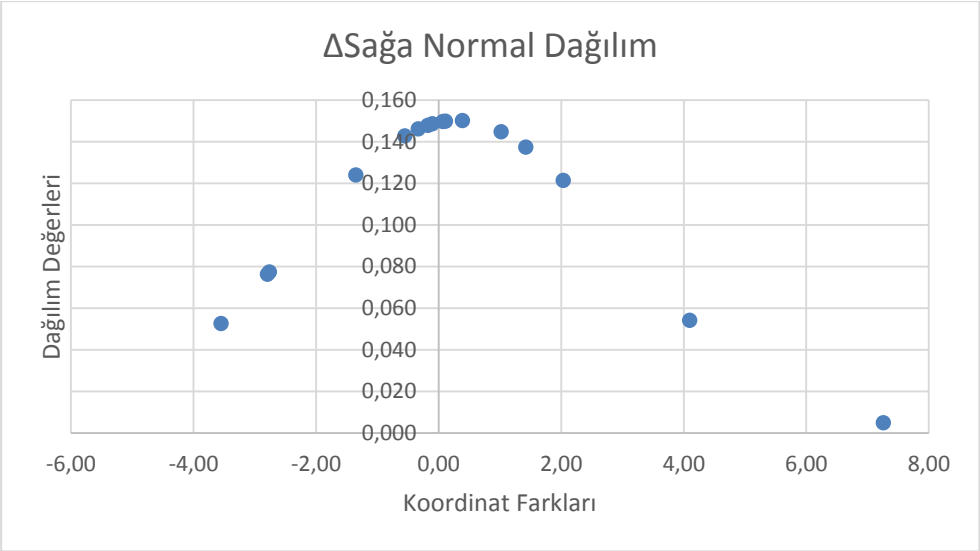

**Şekil 3.7 :** Feneryolu veri kümesine ait Normal Dağılım tablosu.

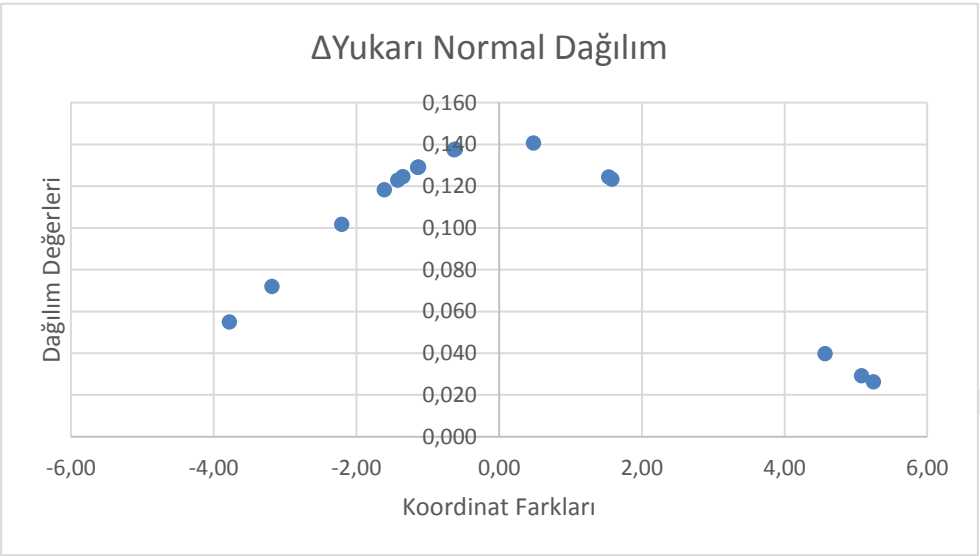
Küçükbakkalköy veri kümesi için Şekil 3.8'de algoritma tarafından tespit edilen ek odaların konumlarıyla referans ek odalar (ground truth) arasındaki koordinat farklarından üretilmiş sağa ve yukarı normal dağılım tablosu verilmiştir.




**Şekil 3.8 :** Küçükbakkalköy veri kümesine ait Normal Dağılım tablosu.

Yeni Mahalle veri kümesi için algoritma tarafından tespit edilen ek odaların konumlarıyla referans ek odalar (ground truth) arasındaki koordinat farklarından üretilmiş sağa ve yukarı normal dağılım tablosu Şekil 3.9'de verilmiştir. Çizelge 3.4'de üç çalışma bölgesi için ayrı ayrı referans ve test noktalarının koordinat farklarına ilişkin en küçük ve en büyük koordinat farkları ile standart sapma gibi kalite bilgileri verilmiştir.




**Şekil 3.9 :** Yeni mahalle veri kümesine ait normal dağılım tablosu.

**Çizelge 3.4 :** Üç çalışma bölgesine ait koordinat farklarının kalite bilgileri.

| Çalışma Bölgesi | Feneryolu | | Küçükbakkalköy | | Yeni Mahalle | |
|---|---|---|---|---|---|---|
| Koordinat Bileşeni | ΔSağa (m) | ΔYukarı (m) | ΔSağa (m) | ΔYukarı (m) | ΔSağa (m) | ΔYukarı (m) |
| Ortalama (μ) (m) | -1.38 | -1.61 | -0.42 | 1.16 | 0.30 | 0.09 |
| En Büyük Fark (+) (m) | 16.92 | 11.68 | 3.97 | 9.20 | 7.26 | 5.24 |
| En Büyük Fark (-) (m) | -23.90 | -28.03 | -4.94 | -3.86 | -3.55 | -3.78 |
| Standart Sapma ($\sigma$) (m) | 9.55 | 10.78 | 2.70 | 3.27 | 2.65 | 2.81 |
| Standart Hata ($m_\sigma$) (m) | 2.39 | 2.69 | 0.55 | 0.67 | 0.66 | 0.70 |

Çizelge 3.4 incelendiğinde Feneryolu Mahallesi'nde GNSS tekniğiyle elde edilen koordinat değerleri ile yenilikçi yöntemle elde edilen koordinat değerleri farklarının ortalama 1.5 m dolayında olduğu görülmesine karşın en büyük farkların 20 m'yi

geçtiği görülmektedir. Bu durum standart sapma değerlerine de yansımış ve standart sapma yaklaşık 10 m olarak hesaplanmıştır. Feneryolu Mahallesi gibi yoğun yerleşimin, yüksek yapılaşmanın, dar sokakların olduğu yerlerde koordinat farklarının ve dolayısıyla konum belirleme hatalarının yüksek olduğu, Yeni Mahalle gibi daha kırsal alanda bulunan yerlerde farkların ve hataların görece daha düşük olduğu görülmektedir.

Sokak düzeyi görüntülerin elde edildiği kameraların bütünleşik olarak çalıştığı tek frekanslı gömülü GNSS çipleri mutlak konum belirleme (*absolute positioning*) yöntemini kullanmaktadır. Literatürde bu yöntemin konum belirleme doğruluğu yaklaşık 5 m dolayındadır. Diğer taraftan geleneksel yöntemde jeodezik ölçme amaçlı geliştirilen çift frekanslı bir GNSS alıcısı bağıl konum belirleme (*relative positioning*) yöntemiyle gerçek zamanlı kinematik konum belirleme tekniğini kullanarak desimetre altı doğrulukta konum bilgisi üretmektedir. Her ne kadar Mapillary platformu GNSS tabanlı konum bilgilerini SfM algoritması ile birlikte kullanarak ek odası kapaklarının konum bilgilerini üretiyor olsa da, yenilikçi yöntemle üretilen konum bilgisi kalitesi geleneksel yönteme göre çok düşük düzeyde kalmaktadır.

Buradan hareketle çalışma kapsamındaki yenilikçi yöntemin yaklaşık olarak metre altı doğruluk gerektiren şebeke bilgi sistemlerinin oluşturulması için gerekli konum doğruluğunu sağlayamadığı görülmüştür.

Yenilikçi yöntemin konum belirleme kalitesinin iyileştirilebilmesi için kameraların görüntü elde etme anındaki konumları aşağıdaki yaklaşımlarla desteklenebilir:

- Kamera konumunu belirlemek için hem araçtaki kamerayla bütünleşik çalışan hem de akıllı telefonda gömülü olarak bulunan GNSS kartları, L1 ve L2 gibi çift frekansta GPS sinyali alabilen özellikte seçilebilir. Ayrıca hem araç tarafında hem de akıllı telefonda yalnız gerçek zamanlı konum bilgisi üreten özellikte GNSS çipleri değil aynı zamanda ham veri kaydı yapabilen ve dolaysıyla daha sonra GNSS gözlemlerinin değerlendirilebilmesine (*post-process*) olanak veren türde GNSS donanımları tercih edilebilir.
- Kamera konumunu belirlemek için mutlak konum belirleme tekniklerinden olan ‘Presizyonlu Konum Belirleme (*Precise Point Positioning*, PPP)’ tekniği kullanılarak konum kalitesi iyileştirilebilir. Bu tür bir tekniğin kullanılması, mevcutta kullanılan mutlak konum belirleme tekniğinden farklı olarak hassas

uydu yörünge ve saat bilgilerinin konum belirleme sürecine dahil edilmesiyle daha yüksek doğrulukta konum bilgisinin üretilmesini sağlayacaktır. Bunun için de öncelikle araçta ve akıllı telefon tarafından çift frekanslı GPS sinyali alabilen bir alıcıya gereksinim bulunmaktadır.

- Kamera konumunun belirlenmesinde bağıl konum belirleme yöntemi geleneksel yöntemdekine benzer biçimde gerçek zamanlı kinematik konum belirleme tekniği yaklaşımıyla kullanılabilir. Örneğin İstanbul'da İSKİ UKBS gibi sürekli hizmet veren ağlardan destek alınarak kamera konum bilgisi daha yüksek doğrulukta üretilebilir. Yine burada da çift frekanslı bir alıcının kullanılması durumunda konum doğruluğu desimetre altında elde edilebilirken, tek frekanslı bir alıcı ile DGPS tekniğinin kullanılması durumunda ise metre altında bir doğruluk elde edilebilecektir.
- Görüntüler Mapillary platformuna yüklenmeden önce görüntülerin elde edildiği noktalar, yüksek çözünürlüklü uydu görüntüsü kullanılarak sürükle-bırak yöntemiyle yol ağına göre hizalanabilir. Yapılacak olan bu manüel düzeltmeyle platfomun üreteceği nesnelere ait konum bilgilerindeki kaba hatalar azaltılabilecektir.

### 3.3.2 Yenilikçi yöntemin sınıflandırma başarımının değerlendirilmesi

Sınıflar arasındaki dağılımın yakın olmaması nedeniyle çalışma kapsamında kullanılan yapay öğrenme modelinin başarımını yalnız doğruluk (*accuracy*) ölçütü ile değerlendirmek yeterli olmayacaktır. Bu nedenle doğruluk ölçütünün yanı sıra, hassasiyet (*presicion*) ve duyarlılık (*recall*) gibi diğer ölçütler de başarımı değerlendirmek için dikkate alınmıştır. Bunun için öncelikle yapay öğrenmede sınıflandırma problemlerinde kullanılan, gerçek değerlerle (*actual values*) tahmin edilen değerler (*predictive values*) arasındaki ilişkileri gösteren 'Doğru Pozitif (*True Positive*, TP)', 'Yanlış Pozitif (*True Negative*, TN)', 'Doğru Negatif (*True Negative*, TN)', 'Yanlış Negatif (*False Negative,* FN)' metriklerinden oluşan bir 'karışıklık matrisi (*confusion matrix*)' oluşturulmuştur. Karışıklık matrisi, gerçek ve tahmin edilen değerlerle oluşturulan 4 farklı kombinasyonlu bir tablodur. Geleneksel yöntem sonuçlarının referans veri alınarak, yenilikçi yöntemle üretilen sonuçların referans kümesiyle olan ilişkilerine göre sözü edilen metriklerin değerleri CBS ortamında belirlenmiştir. Şekil 3.10, Şekil 3.11 ve Şekil 3.12'de ise her üç bölge için CBS

ortamında yapılan çalışmaların sonucu, diğer bir ifadeyle yenilikçi yöntemle tahmin edilmiş olan ek odaların sözü edilen dört metriğe göre sınıflandırılmasını gösteren tematik haritalar bulunmaktadır. Çizelge 3.5'de her üç çalışma bölgesine ait örnekleme veri kümeleri için oluşturulmuş karışıklık matrisleri verilmektedir.

**Çizelge 3.5 :** Üç çalışma bölgesine ait karışıklık matrisleri.

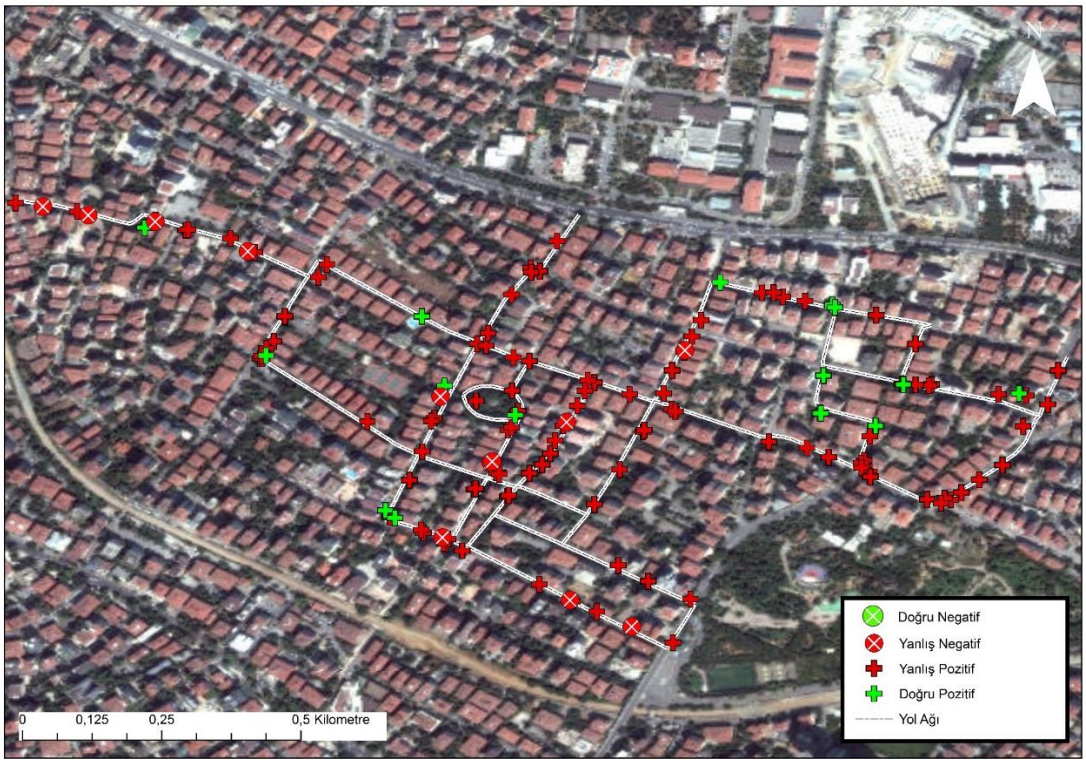
| | | Feneryolu | | Küçükbakkalköy | | Yeni Mahalle | |
|---|---|---|---|---|---|---|---|
| | | Gerçek Değerler | | Gerçek Değerler | | Gerçek Değerler | |
| | | Pozitif | Negatif | Pozitif | Negatif | Pozitif | Negatif |
| Tahmin Edilen Değerler | Pozitif | TP=16 | FP=113 | TP=24 | FP=17 | TP=16 | FP=26 |
| | Negatif | FN=12 | TN=0 | FN=0 | TN=0 | FN=5 | TN=0 |

Çizelge 3.5'deki değerler topluca ele alındığında araç kamerası ile elde edilen görüntülerde ek odası kapakları, derin öğrenme modeli tarafından başarılı biçimde tahmin edilip sınıflandırılamadığı görülmektedir. Diğer taraftan akıllı telefon kamerasıyla elde edilen görüntülerin başarımı araç kamerası ile elde edilen veri kümesine göre daha yüksek çıkmaktadır. Bunun nedeni akıllı telefon kamerasıyla elde edilen görüntülerin daha yakın mesafeden ve daha dik açıyla elde edilmiş olmasıdır. Ayrıca araç kamerasıyla görüntü elde edilirken araç camından yansıyan ışığın görüntülerde karanlık bölge oluşturmasından ötürü de yanlış algılama sonuçları ortaya çıkabilmektedir.

Çizelge 3.5'deki metriklere bakıldığında yanlış pozitif olarak etiketlenen yani gerçekte ek oda olmayan ancak model tarafından ek oda olarak kabul edilen örneklerin sayısının, gerçekten ek oda olup ek oda olarak etiketlenen örnek sayısından oldukça yüksek olduğu görülmektedir. Algılama başarımının düşük çıkmasına sebep olan bu durumun en önemli sebebi görüntülerin elde edildiği güzergahlarda çok sayıda yağmur suyu ve atık su şebekesine ait rögar kapağının bulunmasıdır. Her ne kadar Mapillary platformunda bu kapaklar "manhole" etiketiyle sınıflandırılsa da telekommünikasyon sektöründen oldukça farklı sektörlere ait olan bu şebeke elemanları bu tez çalışması kapsamında "ek oda" olarak kabul edilmemiştir. Bu problemin çözümü için Mapillary'nin ek oda sınıfında sektörel bazda (telekomünikasyon, atık su, içme suyu, vb.) alt sınıflar oluşturarak algoritmayı eğitmesi gerektiği bu tez çalışması sonucunda ulaşılan bulgulardan bir tanesidir.

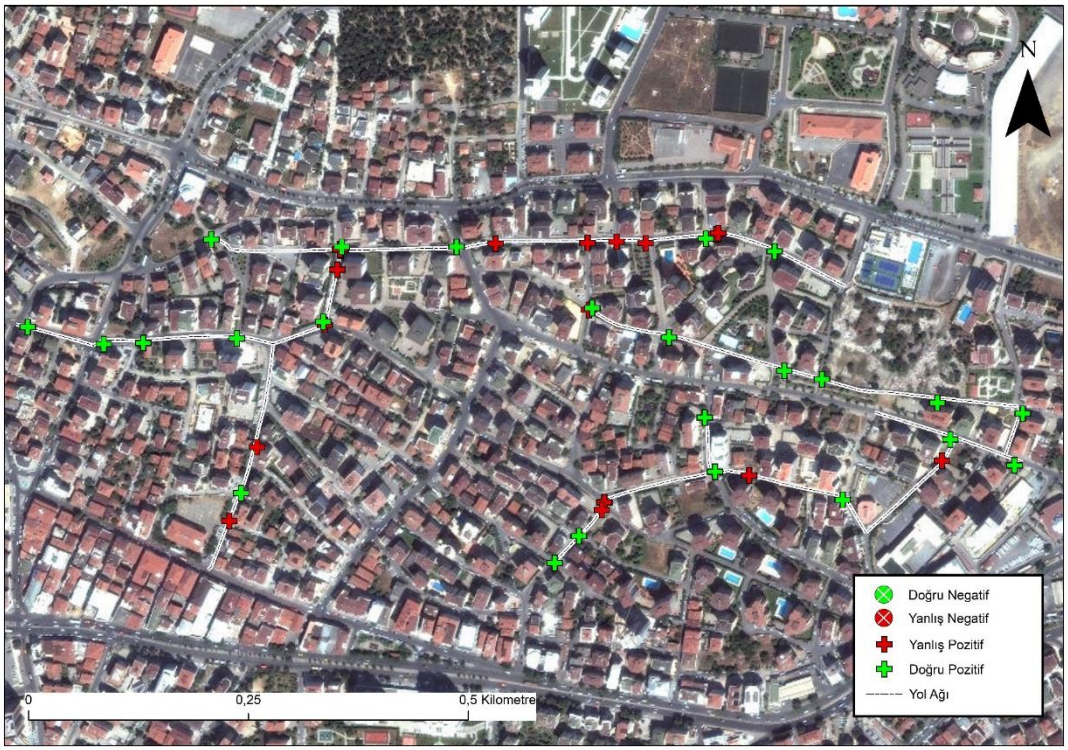
Çizelge 3.5'deki değerler üç çalışma bölgesi için ayrı ayrı aşağıdaki biçimde açıklanmıştır:

- Feneryolu Mahallesi için Mapillary platformunda kullanılan derin öğrenme modeli araç kamerasıyla kaydedilen sokak düzeyi görüntülerinden 141 noktayı ek odası olarak tahmin etmiştir. Belirlenen 141 noktanın 16 tanesi doğru pozitif, 113 tanesi de yanlış pozitif ve 12 tanesi de yanlış negatif olarak etiketlenmiştir. Aynı bölgede akılı telefon kamerasıyla elde edilen görüntülerden ek oda tespit edilememiştir.
- Küçükbakkalköy Mahallesi için derin öğrenme modeli akıllı telefon kamerasıyla kaydedilen sokak düzeyi görüntülerden 41 noktayı ek odası olarak tahmin etmiştir. Belirlenen 41 noktanın 24 tanesi doğru pozitif, 17 tanesi de yanlış pozitif olarak etiketlenmiştir. Aynı bölgede Mapillary platformunda kullanılan yapay öğrenme modeli araç kamerasıyla elde edilen görüntülerden 8 noktayı ek oda olarak tahmin etmiş olmasına rağmen, bu noktaların tümü gerçekte ek oda olmayıp yanlış pozitif olarak etiketlenmiştir.
- Yeni Mahalle için Mapillary platformunda kullanılan derin öğrenme modeli araç kamerasıyla kaydedilen sokak düzeyi görüntülerinden 47 noktayı ek odası olarak tahmin etmiştir. Belirlenen 47 noktanın 16 tanesi doğru pozitif, 26 tanesi de yanlış pozitif ve 5 tanesi de yanlış negatif olarak etiketlenmiştir.



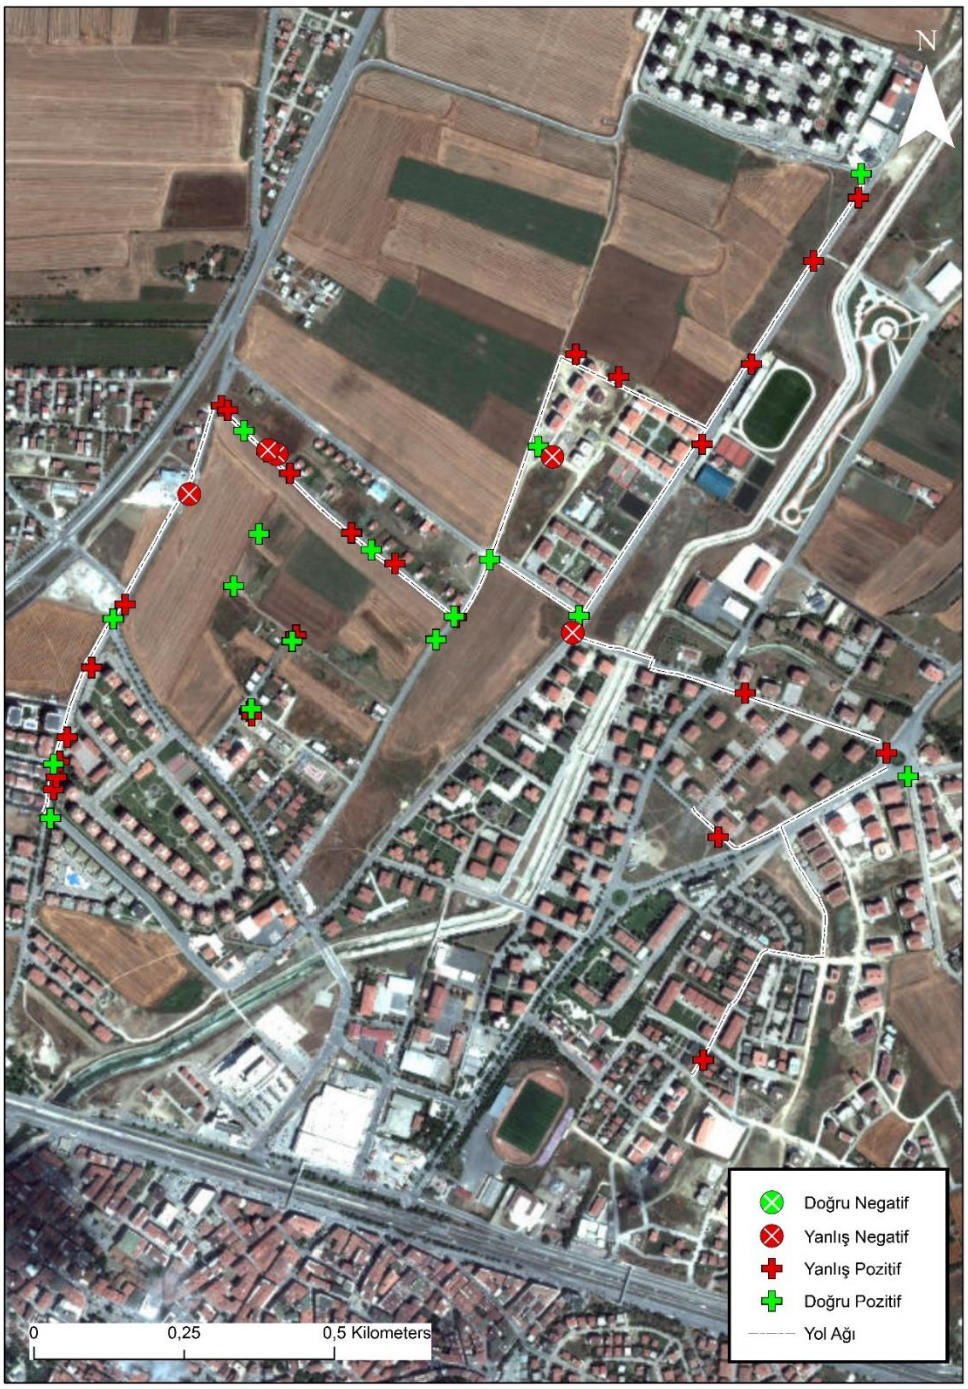

**Şekil 3.10 :** Feneryolu Mahallesi çalışma alanına ait tematik harita.

Derin öğrenme modelinin başarımı Küçükbakkalköy Mahallesi'nde elde edilen görüntüler için Feneryolu Mahellesi sonuçlarına göre görece daha yüksektir. Bununla birlikte, Küçükbakkalköy veri kümesi sonuçlarının akıllı telefon kamerasıyla elde edildiği, Feneryolu veri kümesi sonuçlarının ise araç kamerasıyla kaydedilen görüntülerden elde edilen sonuçlar olduğu unutulmamalıdır. Bu nedenle her iki veri kümesini birbirleriyle karşılaştırmak anlamlı olmayacaktır. Her ne kadar aynı derin öğrenme algoritması kullanılmış olsa da farklı görüntüleme donanımlarının ve tekniğinin kullanılmış olması girdi veri kümesine etki edeceğinden, her örnekleme bölgesinin kendi içinde değerlendirilmesi daha anlamlı bir yaklaşım olacaktır.




**Şekil 3.11 :** Küçükbakkalköy çalışma bölgesindeki metriklerin dağılımı.

Şekil 3.12'de görülen Yeni Mahalle'ye ilişkin veri kümesi araç kamerasıyla elde edilen görüntülerden oluşmaktadır. Feneryolu örneklemesinde olduğu gibi Yeni Mahalle örneklemesinde de yanlış pozitiflerin sayısı doğru pozitiflerden daha fazladır. Ancak bu kez aradaki oran daha azdır. Benzer olarak veri kümesi içerisinde yanlış negatif örnekler bulunmaktadır. Bu durumda Yeni Mahalle veri kümesi için de derin öğrenme algoritmasının sınıflandırma başarımı düşük kalmıştır. Bunula birlikte Feneryolu ve Yeni Mahalle veri kümeleri karışıklık matrisinde bulunan metrikler üzerinden karşılaştırıldığında Yeni Mahalle örneklemesinin daha başarılı sonuç verdiği ifade edilebilir.




**Şekil 3.12 :** Yeni Mahalle çalışma bölgesindeki metriklerin dağılımı.

Şekil 3.13 ve Şekil 3.14'de çalışma kapsamında karşılaşılan ilginç yanlış negatif örnekleri gösterilmektedir. Şekil 3.13'de görülen yol üzerindeki asfalt yaması ve Şekil 3.14'de görülen ağaç gölgesi derin öğrenme modeli tarafından ek odası olarak tahmin edilmiştir. Bu hatalı tahminler, daha fazla doğrulama (verification) çalışması yaparak azaltılabilmektedir. Şekil 3.15'de ise derin öğrenme modeli yağmur suyu kapağını, ek

odası kapağı olarak etiketlemiştir. Bu etiketleme her ne kadar Mapillary platformu için doğru bir sonuç gibi görünse de telekomünikasyon sektöründe kullanılan ek odaların tespit edilmesi çalışması için yanlış üretilmiş bir sonuçtur.




**Şekil 3.13 :** Asfalt yamasının ek oda olarak algılanması.



**Şekil 3.14 :** Ağaç gölgesinin ek oda olarak algılanması.




**Şekil 3.15 :** Rögar kapağının ek oda olarak algılanması.

Çalışma kapsamında, görüntüler üzerinden ek odası kapağı tanımlama başarımının daha iyi analiz edilebilmesi için karışıklık matrisinde yer alan metrikleri kullanan doğruluk, hassasiyet, duyarlılık gibi başkaca ölçütlerden yararlanılmıştır.

Çizelge 3.5'de verilen matris üzerindeki metrikler kullanılarak her üç mahallenin veri kümelerine ilişkin yapay öğrenme algoritmasının sınıflandırıcısının başarım ölçütleri Çizelge 3.6'da verilmiştir.

**Çizelge 3.6 :** Yapay öğrenme modelinin tanımlama başarısı için kullanılan ölçütler.

| Çalışma Bölgesi | Feneryolu | | Küçükbakkalköy | | Yeni Mahalle | |
|---|---|---|---|---|---|---|
| Doğruluk (*accuracy*) | 0.11 | 11% | 0.59 | 59% | 0.34 | 34% |
| Tahmin Hatası (*prediction error*) | 0.89 | 89% | 0.41 | 41% | 0.66 | 66% |
| Hassasiyet (*precision*) | 0.12 | 12% | 0.59 | 59% | 0.38 | 38% |
| Duyarlılık (*recall*) | 0.57 | 57% | 1.00 | 100% | 0.76 | 76% |
| F1-ölçüsü (*F1-score*) | 0.20 | 20% | 0.74 | 74% | 0.51 | 51% |
| Özgüllük (*specificity*) | 0.00 | 0% | 0.00 | 0% | 0.00 | 0% |
| Doğru Pozitif Oranı (*True Positive Rate*, TPR) | 0.57 | 57% | 1.00 | 100% | 0.76 | 76% |
| Yanlış Pozitif Oranı (*False Positive Rate*, FPR) | 1.00 | 100% | 1.00 | 100% | 1.00 | 100% |

Çizelge 3.6 incelendiğinde çalışma bölgeleri arasında başarımı en yüksek olan veri kümesinin Küçükbakkalköy örneklemesi olduğu görülmektedir. Bunun temel nedeni Küçükbakkalköy çalışma bölgesinde akıllı telefon kamerasının kullanılmış olmasıdır.

Küçükbakkalköy Mahallesi'nde elde edilen görüntülerin Mapillary platformunda kullanılan derin öğrenme modelinde sınıflandırılması sonucunda model doğruluğu

%59 düzeyinde olup üç mahalle arasında doğruluğu en yüksek çalışma bölgesidir. Bir diğer ifadeyle sınıflandırıcı görüntülerde bulunan 100 nesnenin yalnızca 59 tanesini doğru sınıflandırabilmiştir. Her ne kadar üç çalışma bölgesi arasında en yüksek doğruluk değeri olsa da gerçek uygulamalarda kullanmak için yeterli doğrulukta değildir. En yüksek hassasiyet değeri de Küçükbakkalköy veri kümesi için hesaplanmış ve doğruluk ölçütü ile aynı değer elde edilmiştir. Başka bir ifadeyle model, ek odası kapağı olarak tahmin ettiği nesnelerin yalnızca %59'u gerçekten ek odası kapağıdır. Küçükbakkalköy veri kümesinde sahte negatif bulunmadığı için duyarlılık metriği otomatik olarak 1 çıkmaktadır.

Çizelge 3.6'daki başarım ölçütleri karşılaştırıldığında araç kamerasıyla görüntü elde edilen iki çalışma bölgesi arasında daha yüksek başarım sağlanan bölge Yeni Mahalle olmuştur. Yeni Mahalle veri kümesi için doğruluk %34, hassasiyet %38 ve duyarlılık %76 olarak hesaplanmıştır. Diğer bir ifadeyle, görüntülerde bulunan 100 nesneden 34 tanesi doğru tespit edilmiştir. Görüntüler üzerinde ek odası olarak tahmin edilen nesnelerin %38'i gerçek pozitif yani gerçekten ek odasıdır. Derin öğrenme modeli gerçekte ek odası olan nesnelerin ancak %76'sını gerçek pozitif olarak tespit edebilmektedir.

Çalışma kapsamındaki veri kümeleri içerisinde doğru negatif etiketlenmesi örneği hiç bulunmadığından yanlış pozitif oran ölçütleri 1 olarak hesaplanmıştır. Bu nedenle ROC eğrileri anlamlı olmamaktadır. Özgüllük ölçütü görüntülerde ek odası olmadığı durumda yani gerçek negatif sınıflarda ek odası tespit edilme olasılığını göstermektedir. Ancak çalışma kapsamındaki örneklemelerde doğru negatif etiketlemesi olmadığı için özgüllük değerleri 0 çıkmaktadır.

Yenilikçi yöntemle ek odası kapaklarının tanıma başarımının iyileştirilebilmesi için öncelikle modelin kullandığı eğitim veri kümesindeki doğrulama çalışmalarının sayısal olarak arttırılması gerekmektedir. Bölüm 3.2'de ifade edilen ve Şekil 3.6'da gösterilen gönüllü kullanıcıların gerçekleştirdiği doğrulama çalışmaları kapsamında, gönüllüler tarafından incelenen görüntü sayısının toplam görüntü sayısına oranı yaklaşık %3.7 düzeyindedir. Bir gözetimli öğrenme (*supervised learning*) süreci için bu oranın yükseltilmesi, en azından %10 düzeyine çıkarılması gerekmektedir.

Bu savı destekleyecek olan konulardan biri de dünyada ve Türkiye'de farklı telekomünikasyon firmalarının Şekil 3.16'da görüldüğü üzere farklı şekil, renk ve

büyüklükte ek odası kapakları kullanmalarıdır. Başka bir ifadeyle ek odası kapağı için şekil, büyüklük ve renk açısından belirlenmiş bir standart bulunmamakta ve bu durumda ek odası kapağının sokak düzeyi görüntüler üzerinden tanımlanma başarımını etkilemektedir. Genelde daire veya dikdörtgen şeklinde olan ek odası kapakları geçmişte demir döküm malzemeden üretilmekteyken bugün daha ekonomik ve hafif olan kompozit malzeme kullanılmaktadır. Çalışma kapsamında yapay öğrenme algoritması sınıflandırıcısının Şekil 3.15'de gösterilen yağmur suyu kapakları Şekil 3.16'da gösterilen ek odası kapaklarını ayırmadaki düşük başarımı yanlış pozitif örneklemelerin artmasına neden olmuştur.




**Şekil 3.16 :** Türkiye'de kullanılan ek odası kapak örnekleri.

### 3.3.3 Yenilikçi yöntemde kullanılan iki farklı tekniğin karşılaştırılması

Görüntü elde etme araçlarının algılama başarımına olan etkisini değerlendirmek amacıyla çalışma kapsamında kullanılan iki farklı tekniğin olumlu ve olumsuz yanları karşılaştırılmıştır. Çalışma kapsamında elde edilen deneyimlere dayanılarak Çizelge 3.7'de ifade edilen değerlendirmeler ortaya çıkarılmıştır.

**Çizelge 3.7 :** Görüntü elde etme araçlarının sonuçlara etkisi.

| **Araç Kamerasıyla Görüntü Elde Etme** | **Cep Telefonuyla Görüntü Elde Etme** |
|---|---|
| **Olumlu Yönleri:**<br>• Görüntü elde etme süresi oldukça hızlıdır.<br>• Batarya kısıtı yoktur.<br>• Geniş açılı görüntü elde etme imkanı bulunmktadır.<br>• Araç kullanırken farklı bir işlem gerektirmemektedir.<br>**Olumsuz Yönleri:**<br>• Yol ekseninin ortasında bulunan İSKİ yağmur suyu ve rögar kapakları "menhol" olarak etiketlenmektedir.<br>• Kaldırımdaki ek odalar yol kenarındaki park etmiş araçlardan dolayı kamerada görünmemektedir.<br>• Araç camından yansıyan nesneler yanlış algılamaya sebep olabilmektedir. | **Olumlu Yönleri:**<br>• Görüntüler kaldırımdan elde edildiği için yağmur suyu, rögar kapağı, vb. gibi algılama sorunu yaratacak nesneler yoktur.<br>• Araçların yol kenarına park etmesi engel oluşturmuyor<br>• Işığın yansıma problemi yoktur.<br>**Olumsuz Yönleri:**<br>• Görüntü elde etme hızı düşüktür.<br>• Daha dar açılı görüntüler elde edilmektedir.<br>• Batarya kısıtı vardır. |

### 3.3.4 Geleneksel ve yenilikçi yöntemlerinlerin maliyet ve zaman yönünden değerlendirilmesi

Çizelge 3.8 incelendiğinde çalışma kapsamındaki üç çalışma bölgesi için yenilikçi yöntemle harita bilgisi üretme işinin maliyet, zaman ve emek açısından geleneksel yöntemle karşılaştırıldığında çok daha üstün durumda bulunduğu görülmektedir. Yalnız bu açılardan değerlendirildiğinde yenilikçi yöntem, telekomünikasyon sektörünün beklentilerini geleneksel yönteme göre daha çok sağlamaktadır. Bu

durumda yenilikçi yöntemin doğruluk açısından başarımının yükselmesi durumunda geleneksel yöntemin yerini hızlıca alacağını göstermektedir.

**Çizelge 3.8 :** Geleneksel ve yenilikçi yöntemlerin maliyet bilgileri.

| Çalışma Bölgesi | GNSS Gözlem Tarihi | GNSS Tekniği ile Ölçülen Ek Odası Sayısı | GNSS Gözlem Süresi | Arazideki Ölçme Operatörü Sayısı | Ölçme Maliyeti |
|---|---|---|---|---|---|
| **Feneryolu** | Ağustos 2019 | 58 | 3 gün (25 saat) | 2 | 5,000.00 TL |
| **Küçükbakkalköy** | Ağustos 2019 | 45 | 2 gün (15 saat) | 1 | 4,000.00 TL |
| **Yeni Mahalle** | Mayıs 2020 | 75 | 4 gün (30 saat) | 1 | 7,000.00 TL |
| ***Toplam*** | | *178* | *9 gün (70 saat)* | | *16,000.00 TL* |

| Çalışma Bölgesi | Görüntülerin Elde Edildiği Tarih | Görüntülerden Elde Edilen Ek Odası Sayısı | Görüntü Kayıt Süresi | Operatör Sayısı | Ölçme Maliyeti | Araç Güzergahının Uzunluğu |
|---|---|---|---|---|---|---|
| **Feneryolu** | Ağustos 2019 | Araçla 16/141 | Araçla 1 gün (1.5 saat) | 1 | 300.00 TL | 4 km |
| **Küçükbakkalköy** | Ağustos 2019 | Araçla 0/8<br>Telefonla 24/41 | Araçla 1 gün (1 saat)<br>Telefonla 1 gün (3 saat) | 1 | 300.00 TL | 5 km |
| **Yeni Mahalle** | Mayıs 2020 | Araçla 16/47 | Araçla 1 gün (1 saat) | 1 | 200.00 TL | 6 km |
| ***Toplam*** | | *56/237* | *3gün (6.5 saat)* | *1* | *800.00 TL* | *15 km* |

Sokak düzeyi görüntülerinin elde edilmesinde bu çalışma kapsamındaki yenilikçi yöntemden farklı olarak 'Gezgin Harita Sistemleri (*Mobile Mapping Systems*, MMS)' de kullanılmaktadır. Gezgin harita sistemleri de bu çalışmada kullanılan tekniklere benzer biçimde hem birçok farklı tür alıcıyı barındıran hareketli platformlar hem de sırt çantası özelinde tasarlanan ve operatörün yürürken ortamı ölçen sistemler olarak kullanılabilmektedir. Bu tür sistemlerin kullanılarak geliştirilmiş çözümlere örnek olarak '*Google Street View*' gösterilebilir.

Çalışma kapsamında kullanılan yenilikçi yöntemle, profesyonel bir çözüm olarak geliştirilen gezgin harita üretim sistemleri arasında maliyet açısından büyük farklar bulunmaktadır. Gezgin harita üretim sistemleri yüksek doğruluklu GNSS alıcıları, çoklu kameralı optik görüntüleme sistemleri, çoklu tarayıcılı lazer tarama sistemleri, navigasyon sistemleri gibi üst düzey ve yüksek maliyetli donanımlar kullanmakta ve farklı yapıdaki veri kümelerinin bütünleştirilmesi için de yüksek maliyetli veri değerlendirme süreçlerini gerektirmektedir. Ayrıca, yüksek veri üretim ve değerlendirme maliyetleri aynı bölgeye ait verinin elde edilme sıklığını da azaltmaktadır. Oysaki çalışmada yararlanılan yenilikçi yöntem son derece düşük maliyetli ve hızlı sonuç üreten bir çözüm olup istenilen sıklıkta gerçekleştirilmesi yüksek bir maliyet oluşturmamaktadır.

# 4. SONUÇ VE ÖNERİLER

Çalışma kapsamında telekomünikasyon sektöründe kullanılan ek odaların yenilikçi yöntem olarak nitelendirilen çözümle tespit etme ve konumlarını belirleme başarımı, telekomünikasyon sektöründe halihazırda kullanılan geleneksel yöntemle farklı açılardan karşılaştırılmıştır. Genel olarak yenilikçi yöntemin, ek odası kapaklarını otomatik tanıma başarımının düşük düzeyde kaldığı görülmüştür. Yenilikçi yöntemle tespit edilen ek odası kapaklarının belirlenen konum bilgileri de geleneksel yöntemle belirlenmiş olan konum bilgilerine göre oldukça farklı olduğu görülmüştür. Konum ve tanıma doğruluklarıyla ilgili başarım sonuçları göz önüne alındığında yenilikçi yöntemin geleneksel yöntemin tamamen yerini alması bu çalışma kapsamındaki sonuçlarla olası görülmemektedir. Ancak değerlendirmeye konu sokak düzeyi görüntülerinin kalitesinin artması, görüntüleri değerlendiren derin öğrenme modelinin gelişmesiyle zaten daha az kaynak, zaman ve iş gücü gerektiren yenilikçi yöntemin geleneksel yöntemin yerini alacağı açıktır. Benzer durum derin öğrenme ile yüz tanıma modellerinde yaşanmış, önceleri başarımı düşük olan yapay öğrenme modelleri bugün gelinen noktada yüz tanıma konusunda insanın yüz tanıma başarımını geçmiştir. Bu benzeşimden yola çıkarak yenilikçi yöntemin, geleneksel yöntemin başarımını yakalamasının uzun sürmeyeceği söylenebilir.

Telekomünikasyon firmaları tarafından gerçekleştirilen bakım onarım faaliyetleri kapsamında ek odaların varlığını koruyup koruyamadığı bilgisine gereksinim duymaları nedeniyle koordinatları bilinen noktalarla karşılaştırmak için çalışma kapsamında önerilen yöntemin kullanılabileceği düşünülmektedir. CBS ortamında ve mekansal veritabanında olmayıp yenilikçi yöntemle tespit edilmiş ek odası kapağı olması durumunda, ilgili noktanın daha yüksek doğrulukta konum bilgisinin üretilmesi için geleneksel yönteme başvurulabilir. Böylece yenilikçi yöntem, geleneksel yöntemin başarımını eniyilemek için kullanılabilir.

Telekomünikasyon firmaları, yeni bölgelerde yatırım yapmadan önce ilgili bölgelerde gerçekleştirdikleri keşif çalışmalarını hızlandırmak için yenilikçi yöntemden yararlanabilir. Böylece ilgili bölge hakkında daha düşük maliyetle ve daha az zaman

harcayarak yatırım karar-desteği için genel bir bakış açısı sağlayabilirler. Bu sonuçlara göre daha ayrıntılı çalışma yapılması tercih edilirse geleneksel yöntem kullanılabilir.

Yerel yönetim çalışmaları kapsamında farklı amaçlarla çokça araç kente hizmet etmek için sürekli seyir halindedir. Çöp kamyonları, belediye otobüsleri, zabıta araçları vb. birçok araç işlerini yerine getirirken araç üzerinde bulunan GNSS alıcı entegreli kameralar sürekli görüntü kaydedebilirler. Kaydedilen görüntüler bu çalışma kapsamında yararlanılan bilgisayar görü amaçlı derin öğrenme modeline benzer yapay öğrenme modellerinde değerlendirilerek yüzlerce şehir nesnesi görüntüler üzerinden tespit edilip Kent Bilgi Sistemleri ile ilişkilendirilebilir. "Akıllı" Şehirlerin yoğun olarak tartışıldığı bu günlerde bu tür mekansal zeka uygulamaları yerel yönetimlerin şehirleri daha etkin yönetmesine katkı sağlayacaktır. Aynı zamanda elde edilen ve etiketlenen görüntü veri kümeleri farklı mekansal zeka uygulamaları için etiketli mekansal veri eğitim kümesi altyapısının oluşmasını sağlayacaktır.

## KAYNAKLAR


**Akdemir, Ö. K., Dursun, T., Arslan, S., Benzer, R., Akcayol, M. A.** (2016). A GIS-based novel active monitoring system for fiber networks, *Turkish Journal of Electrical Engineering and Computer Sciences*, 24 : 247 - 261.

**Alarcon, M. J., Zorzano, F. J., Jevtic, A., Andina, D.** (2008). Telecommunications Network Planning and Maintenance, *2th World Multi-Conference on Systemics, Cybernetics and Informatics,* (8) pp. 64-68.

**Anirudh, V., K.** (2020). Top 10 Libraries for Machine Learning. Retrieved October 10, 2019, from https://it.toolbox.com/tech-101/top-python-libraries-for-machine-learning.

**Barnes, J.** (2015). *Azure Machine Learning Microsoft Azure Essentials*. Redmond, Washington: Microsoft Press.

**Bianco, S., Ciocca, G., & Marelli, D.** (2018). Evaluating the Performane of Structure from Motion Pipelines, *Journal of Imaging, 2018* (4), 98.

**Chen, L. C, Papandreou, G., Schroff, F. & Adam, H.** (2017). Rethinking Atrous Convolution for Semantic Image Segmentation, *ArXiv: 1706.05587.*

**Claire, D.** (2020). Best Python Libraries for Machine Learning and Deep Learning. *Towards Data Science*. Retrieved October 10, 2019, from https://towardsdatascience.com/best-python-libraries-for-machine-learning-and-deep-learning-b0bd40c7e8c

**Deng, L. & Yu, D.** (2013). Deep Learning: Methods and Apllications, *Foundations and Trends in Signal Processing*, (pp.197-387).

**Deshpande, M.** (2009). Telecom GIS: An Integrated Approach. *geospatialworld*. Retrieved October 10, 2019, from *https://www.geospatialworld.net/article/telecom-gis-an-integrated-approach/*

**Eric, V.** (2019). Recent Developments in Chemical Vapour Deposition. *spar3d*. Retrieved October 10, 2019, from *https://www.spar3d.com/news/software/mapillary-maps-objects-detected-in-imagery-using-deep-learning-in-3d.*

**Everingham, M., Eslami, S., M., A., Gool, L., V., & Williams, C., K., I.** (2014). The Pascal Visual Object Classes Challenge: A Retrospective, *International Journal of Computer Vision*, pp.98-136.

**Girshick, R.** (2015). Fast R-CNN, *2015 IEEE International Conference on Computer Vision (ICCV)*, Santiago, ABD, pp.1440-1448.

**Girshick, R., Donahue, J., Darrell, T., & Malik, J.** (2014). Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation, *2014 IEEE*

*Conference on Computer Vision and Pattern Recognition*, Columbus, ABD, pp.580-587.

**Goodchild, M. F.** (2007). Citizens as voluntary sensors: Spatial data infrastructure in the world of web 2.0, *International Journal of Basic and Applied Sciences*, (2) pp. 24-32.

**Güney, C.** (2015). Mekansal Bilgi Sistemlerinde Yapay Zeka, *TMMOB Harita ve Kadastro Mühendisleri Odası 15. Türkiye Harita Bilimsel ve Teknik Kurultayı.*

**He, K., Gkioxari, G., Dollar, P., & Girshick, R.** (2017). Mask R-CNN, *2017 IEEE International Conference on Computer Vision (ICCV)*, Venedik, İtalya, pp.2980-2988.

**Hebbalaguppe, R., Garg G., Hassan E., Ghosh H. & Verma, A.** (2017). Telecom inventory management via object recognition and localization on google street view images, *2017 IEEE Winter Conference on Applications of Computer Vision*, 725-733. doi: 10.1109/WACV.2017.86.

**Howe, J.** (2006, June 1). The Rise of Crowdsourcing. *The Wired.* Retrieved from https://www.wired.com/.

**Hui, J.** (2018). Image Segmentation with Mask R-CNN. *Medium.* Retrieved from https://medium.com/@jonathan_hui/image-segmentation-with-mask-r-cnn-ebe6d793272.

**Hussain, A., Kazmi J. & Arsalan, M. H.** (2017). Integration of telecom databases with geodatabase model for the effective telecom network management through geo-informatics, *International Journal of Basic and Applied Sciences*, pp. 272-280.

**Juhasz, L.,** (2016). How accurate is Mapillary and how to improve?. *blog.mapillary*.com, Retrieved October 11,2019, from *https://blog.mapillary.com/update/2016/08/19/mapillary-accuracy.html*

**Juhasz, L., Hochmair, H.** (2016). User Contribution Patterns and Completeness Evaluation of Mapillary, a Crowdsourced Street Level Photo Service, *Transactions in GIS*, 20 (6) 925-947.

**Karpathy, A., & Fei, L. F.** (2015). Deep Visual-Semantic Alignments for Generating Image Descriptions, *IEEE Transactions on Pattern Analysis and Machne Intellingence* (2), 664-676.

**Kirillov, A., He T., Girshick, R., Rother, C., & Dollar, P.** (2019). Panoptic Segmentation, *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, CA, USA, pp. 9396-9405.

**Krizhevsky, A., Sutskever, I., & Hinton, G., E.** (2012). ImageNet Classification with Deep Convolutional Neural Networks, *NIPS'12: Proceedings of the 25th International Conference on Neural Information Processing Systems,* Red Hook, NY, ABD, 2012.

**Krylov, V., A., Kenny, E., & Dahyot, R.** (2018). Automatic Discovery and Geotagging of Objects from Street View Imagery, *Remote Sensing Journal*, 10 (5): 661.

**Lee, A.** (2015). Comparing Deep Neural Networks and Traditional Vision Algorithms in Mobile Robotics, *Swartmore University,*

**Lin, T., Dollar, R., Girshick R., He, K., Hariharan B., & Belongie, S.** (2017). Feature Pyramid Networks for Object Detection, *2017 IEEE Conference on Computer Vision and Pattern Recognition*, Honululu, ABD, pp.936-944.

**Lin, T., Dollar, R., Girshick R., He, K., Hariharan B., & Belongie, S.** (2017). Feature Pyramid Networks for Object Detection, *2017 IEEE Conference on Computer Vision and Pattern Recognition*, Honululu, ABD, pp.936-944

**Lin, T., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., ….. Dollar, P.** (2015). Microsoft COCO: Common Object in Context, *arXiv: 1405.0312v3.*

**Mahon, A.** (2017). Visualizing Al Detections for Improved Map Editing. *blog.mapillary*.com, Retrieved October 11,2019, from *https://blog.mapillary.com/product/2017/08/08/visualizing-ai-detections-for-improved-map-editing.html*.

**Neuhold, G., Ollmann T., Bulo S. R. & Kontschieder, P.** (2017). The Mapillary Vistas Dataset for Semantic Understanding of Street Scenes, *2017 IEEE International Conference on Computer Vision*, (pp.145-154). Italy : Venice, October 22-29.

**O'Mahony, N., Murphy, T., Panduru, K., Riordan, D., & Walsh, J.** (2016). Adaptive process control and sensor fusion for process analytical technology, *27th Irish Signals and Systems Conference 2016 (ISSC),* IEEE, (pp. 1–6).

**Porzi, L., Bulo, S., R., Colovic, A., & Kontschieder, P.** (2019). Seamless Scene Segmentation, *2019 IEEE Conference on Computer Vision and Pattern Recognition,* Long Beach, ABD, pp.8277-8286.

**Powers, D., M., W.** (2011). Evaluation: From Precision, Recall And F-Measure To ROC, Informedness, Markedness & Correlation, *Journal of Machine Learning Technologies,* ISSN: 2229-3981 & ISSN: 2229-399X, Volume 2, Issue 1, 2011, pp-37-63.

**Ren, S., He, K., Girshick, R., & Sun, J.** (2016). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, *IEEE Transactions on Pattern Analysis and Machine Intelligence,* pp.1137-1149.

**Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., …… Fei, L., F.** (2015). The ImageNet Large Scale Visual Recognition Challenge, *International Journal of Computer Vision,* pp.211-252.

**Tang, Y.** (2015). Deep Learning Using Linear Support Vector Machines, *arXiv:1306.0239.*

**Tanz, J.** (2016). Soon We Won't Program Computers. We'll Train Them Like Dogs. *wired.com*. Retrieved October 11, 2019, from *https://www.wired.com/2016/05/the-end-of-code/*.

**Tharwat, A.** (2018). Classification Assessment Methods, *Applied Computing and Informatics*. Doi: https://doi.org/10.1016/j.eswa.2020.113391.

**Westoby, M. J., Brasington, J., Glasser, N.F., Hambrey, M. J. & Reynolds, J. M.** (2012). Sturcture from Motion Photogrammetry in Physical Geography, *Geomorphology 179*, pp.300-314.

**Westrope, C., Banick R. & Levine, M.** (2014). Groundtruthing Openstreetmap Building Damage Assessment, *Humanitarian Technology: Science, Systems and Global Impact 2014*, 29–39.

**Url-1** <*https://www.mapillary.com/app/* >, erişim tarihi 1.11.2019.

**Url-2** <*https://help.mapillary.com/hc/en-us/articles/115000967191-Object-detections*>, erişim tarihi 06.10.2019.

**Url-3** < *https://www.rsipvision.com/defining-borders/*>, erişim tarihi 12.11.2019.

**Url-4** < *https:// rubikscode.net/2018/02/26/introduction-to-convolutional-neural-networks*>, erişim tarihi 06.10.2019.

**Url-5** <*blog.mapillary.com*>, erişim tarihi 06.10.2019.

**Url-6** <*https://medium.com/pytorch/filling-in-the-gaps-how-mapillary-uses-pytorch-to-improve-maps-everywhere-and-for-everyone-9190a96c35*>, erişim tarihi 06.10.2019.

**Url-7** < *https://blackvue.com/product/dr900s-2ch*/ >, erişim tarihi 06.10.2019.

**Url-8** < *https://blog.mapillary.com/update/2019/06/04/customized-mapillary-dashcam-for-effortless-mapping.html* >, erişim tarihi 06.10.2019.

**Url-9** < *https://help.mapillary.com/hc/en-us/articles/360020825811-Desktop-uploader* >, erişim tarihi 06.10.2019.

**Url-10** <*https://help.mapillary.com/hc/en-us/articles/360022768092-Capture-projects*>, erişim tarihi 06.10.2019.

**Url-11** <*https://www.mapillary.com/project/verification/t9qFVfNh3ltDtiDO2fb2mr*>, erişim tarihi 12.11.2019.

## ÖZGEÇMİŞ



**Ad-Soyad** **:** AHMET EĞRİ

**Doğum Tarihi ve Yeri** **:** 06.10.1990 SİVAS

**E-posta** **:** egri.ahmet@gmail.com

### ÖĞRENİM DURUMU:

- **Lisans** **:** 2014, İTÜ, İnşaat Fakültesi, Geomatik Müh. Bölümü

### MESLEKİ DENEYİM VE ÖDÜLLER:

- 2014-2015 yılları arasında İSBAK'ta ulaşım planlama üzerine çalıştı.
- 2015 yılından günümüze İSTELLKOM'da fiber optik altyapıların planlaması üzerine çalışıyor.