

Harita Dergisi



Temmuz 2021
Sayı:166

ISSN 1300-5790
E-ISSN 2667-4084

Kavzoğlu, T., Çölkese, İ., Seferci, U.G., Öztürk, M.Y.: **Marmara Denizi'ndeki Müsilaj Oluşumlarının Çok Zamanlı Optik ve Termal Uydu Görüntülerinden Makine Öğrenme Algoritması ile Tespiti ve Analizi** (Detection and Analysis of Marine Mucilage Bloom in the Sea of Marmara by a Machine Learning Algorithm from Multi-Temporal Optical and Thermal Satellite Images)

Simav, M., Akpınar, İ., Akdoğan, Y.A., Yıldız, H.: **Türkiye'de Güncel Yersel Gravimetri Çalışmaları** (Recent Terrestrial Gravimetry Studies in Turkey)

Yılmaz, E.Ö., Kavzoğlu, T.: **Derin Öğrenmenin Temel Prensipleri ve Uzaktan Algılama Alanındaki Uygulamaları** (Basic Principles of Deep Learning and Its Applications in Remote Sensing)



HARİTA DERGİSİ

Temmuz 2021

Yıl: 87 Sayı: 166

ALTI AYDA BİR YAYIMLANIR.
HAKEMLİ DERGİDİR.
YEREL SÜRELİ YAYINDIR.
YAZI DİLİ TÜRKÇE, İNGİLİZCE'DİR.

Sahibi

Harita Genel Müdürlüğü Adına
Tuğgeneral Hurşit AĞIRCAN

Sorumlu Müdür

Harita Yük.Tek.Ok.K.İği Adına
Doç.Dr.Müh.Alb. Hasan YILDIZ

Editör

Yük.Müh.Alb. Selçuk CEYLAN

Yönetim Kurulu

Doç.Dr.Müh.Alb. Hasan YILDIZ (Bşk.)
Dr.Müh.Alb. İbrahim NALCI
Dr.Müh.Alb. Osman Atıla AKABALI
Yük.Müh.Alb. Selçuk CEYLAN
Doç.Dr.Müh.Yb. Mehmet SİMAV

Yönetim Yeri Adresi

Harita Genel Müdürlüğü
Harita Dergisi Yönetim Kurulu
Başkanlığı
06590 Cebeci / ANKARA

Tel: (312) 595 21 22

Faks: (312) 320 14 95

web: www.harita.gov.tr/harita-dergisi

e-posta: haritadergisi@harita.gov.tr

Basım Yeri

Harita Genel Müdürlüğü Matbaası
ANKARA

ISSN 1300 – 5790

E-ISSN 2667 – 4084

Bu dergide yayımlanan makaleler,
yazarlarının özel fikirlerini yansıtır.

TÜBİTAK-ULAKBİM Mühendislik ve
Temel Bilimler Veri Tabanında
(TÜBİTAK MTBVT) taranmaktadır.

İ Ç İ N D E K İ L E R

ARAŞTIRMA MAKALELERİ

Marmara Denizi'ndeki Müsilaj Oluşumlarının Çok Zamanlı Optik ve Termal Uydu Görüntülerinden Makine Öğrenme Algoritması ile Tespiti ve Analizi (Detection and Analysis of Marine Mucilage Bloom in the Sea of Marmara by a Machine Learning Algorithm from Multi-Temporal Optical and Thermal Satellite Images)

Taşkın KAVZOĞLU, İsmail ÇÖLKESEN,
Umut Güneş SEFERCİK, Muhammed Yusuf ÖZTÜRK 1 – 9

Türkiye'de Güncel Yersel Gravimetri Çalışmaları (Recent Terrestrial Gravimetry Studies in Turkey)

Mehmet SİMAV, İlyas AKPINAR,
Yunus Aytaç AKDOĞAN, Hasan YILDIZ 10 – 24

DERLEME MAKALESİ

Derin Öğrenmenin Temel Prensipleri ve Uzaktan Algılama Alanındaki Uygulamaları (Basic Principles of Deep Learning and Its Applications in Remote Sensing)


Elif Özlem YILMAZ, Taşkın KAVZOĞLU 25 – 43

Bilim Kurulu

Dr.Tuğg. Osman ALP (KKK)
Prof.Dr. Bahadır AKTUĞ (AÜ)
Prof.Dr. Ali Melih BAŞARANER (YTÜ)
Prof.Dr. Ahmet Tuğrul BAŞOKUR (AÜ)
Prof.Dr. İbrahim Öztuğ BİLDİRİCİ (KTÜN)
Prof.Dr. Çetin CÖMERT (KTÜ)
Prof.Dr. Rahmi Nurhan ÇELİK (İTÜ)
Prof.Dr. Hande DEMİREL (İTÜ)
Prof.Dr. Uğur DOĞAN (YTÜ)
Prof.Dr. Semih ERGİNTAV (BÜ)
Prof.Dr. Oğuz GÜNGÖR (AÜ)
Prof.Dr. Cevat İNAL (KTÜN)
Prof.Dr. Hakan KARABÖRK (KTÜN)
Prof.Dr. Fevzi KARSLI (KTÜ)
Prof.Dr. Taşkın KAVZOĞLU (GTÜ)
Prof.Dr. Şenol Hakan KUTOĞLU (BEÜ)
Prof.Dr. Nebiye MUSAOĞLU (İTÜ)
Prof.Dr. Haluk ÖZENER (BÜ)
Prof.Dr. Ayşe Filiz SUNAR (İTÜ)
Prof.Dr. Uğur ŞANLI (YTÜ)
Prof.Dr. Dursun Zafer ŞEKER (İTÜ)
Prof.Dr. Mustafa TÜRKER (HÜ)
Prof.Dr. Nesibe Necla ULUĞTEKİN (İTÜ)
Prof.Dr. Aydın ÜSTÜN (HÜ)
Prof.Dr. Naci YASTIKLI (YTÜ)
Prof.Dr. Ferruh YILDIZ (KTÜN)
Prof.Dr. Cemal Özer YİĞİT (GTÜ)
Prof.Dr. Orhan ALTAN
Prof.Dr. Fatmagül KILIÇ GÜL
Prof.Dr. Şerif HEKİMOĞLU
Prof.Dr. Mahmut Onur KARSLIOĞLU
Prof.Dr. Ahmet KAYA
Prof.Dr. Ali KOÇYİĞİT
Prof.Dr. Sıtkı KÜLÜR
Prof.Dr. Cankut ÖRMECİ
Prof.Dr. Fatma Gönül TOZ
Doç.Dr. Onur LENK (İÜ)
Doç.Dr. Hakan MARAŞ (ÇÜ)
Doç.Dr. Mustafa Tevfik ÖZLÜDEMİR (İTÜ)
Doç.Dr.Müh.Alb. Hasan YILDIZ (HGM)
Doç.Dr. Ali KILIÇOĞLU
Dr. Hakan AKÇIN (ZBEÜ)
Dr. Mustafa KURT (OÜ)
Dr.Müh.Alb. Yavuz Selim ŞENGÜN (HGM)
Dr.Müh.Alb. Altan YILMAZ (HGM)
Dr. Mustafa ATA
Dr. Coşkun DEMİR
Dr. Oktay EKER
Dr. Mustafa ERDOĞAN

Harita Dergisi'nin 166. Sayısında Makalelerin Değerlendirilmesinde Hakemlik Yapan Akademisyenler

Prof.Dr. Mehmet ALKAN (YTÜ)
Prof.Dr. Cüneyt AYDIN (YTÜ)
Prof.Dr. Bülent BAYRAM (YTÜ)
Prof.Dr. Oğuz GÜNGÖR (AÜ)
Prof.Dr. Fevzi KARSLI (KTÜ)
Prof.Dr. Elif SERTEL (İTÜ)
Prof.Dr. Mustafa TÜRKER (HÜ)
Doç.Dr. Uğur AVDAN (ESTÜ)
Doç.Dr. İsmail ÇÖLKESEN (GTÜ)
Doç.Dr. Ali KILIÇOĞLU
Dr. Hakan AKÇIN (ZBEÜ)
Dr. Coşkun DEMİR



Walters Deniz Atlası XVI. yüzyıl. Yunanistan, Adalar Denizi, Anadolu Haritası. (K. Özdemir, Osmanlı Deniz Haritaları'ndan alınmıştır.)

WALTERS DENİZ ATLASI

Walters Deniz Atlası, 16. yüzyıl Osmanlı haritacılığının gösterişli örneklerindendir. Atlas, Amerika Birleşik Devletleri'nde, Baltimore, Maryland'da Walters Art Gallery'de bulunmaktadır. Adını da bulunduğu yerden almıştır. İlk bakışta Atlas'ın Osmanlı Sarayı için hazırlandığı apaçık görülmektedir. Sayfalarını çevirince deniz haritalarıyla Türk minyatür sanatının iç içe olduğu göze çarpar. Saray nakkahanesinde üretilen güzel bir eserle karşı karşıya olduğumuzu söyleyebiliriz. Ali Macar Reis Atlası'nın sarayda çok beğenilip, benzerlerinin yapıldığı düşüncesindeyiz. Bunlardan iki tanesi bugün elimizdedir ve *Walters Deniz Atlası* bunlardan biridir.

Atlasta yer alan haritalar, *Ali Macar Reis Atlası'nda* olduğu gibi çift sayfaya çizilmiştir; boyutları 45x30,1 cm'dir. Haritalar Venedik kaynaklı parşömen üzerine sekiz renkli olarak hazırlanmıştır. Siyah, kırmızı, altın yıldız, yeşil, sarı, mavi, eflatun, açık yeşil gibi canlı ve göz alıcı renkler kullanılmıştır. 16. yüzyılda Osmanlıların Venedik'ten ithal ettiği mallar arasında kâğıt ve parşömen, ipekli kumaştan hemen sonra gelmekte idi. Yine bu yıllarda Türk tüccarlar Venedik'te Caneregio semtinde bir evde kalmaktaydılar. Rialto'da da ticarethane ve mağazaları bulunmaktaydı. Atlasta Venedik'te imal edilen parşömenin kullanılması, bazı batılı araştırmacıların haritaların İtalya'da yapıldığı gibi varsayımlar üretmelerine yol açmıştır. Gerçekte atlas, Osmanlı Sarayı'ndaki hünerli ellerin eşsiz bir eseridir.

Atlasta yer alan haritaların ortak özelliği, dünya haritası dışındakilerin birer deniz haritası olmasıdır. Hepsinde 17 adet rüzgârgülü bulunmakta ve bu rüzgârgüllerinden çıkan yön çizgileri tüm harita yüzeyini kaplamaktadır. Haritalarda ikisi tam, ikisi yarım dört rüzgârgülü büyük ve süslüdür.

Atlas'ta sekiz harita yer alır:

1. Karadeniz Haritası
2. Ege ve Doğu Akdeniz Haritası
3. Orta Akdeniz ve İtalya Haritası
4. Batı Akdeniz ve İspanya Haritası
5. İngiliz Adaları, Fransa ve Baltık Denizi Haritası
6. Avrupa, Akdeniz ve Kuzey Afrika Haritası
7. Güney Asya ve Hint Okyanusu Haritası
8. Dünya Haritası

Kaynak: Özdemir, K. (2008, s. 110-111). *Osmanlı Haritaları*. İstanbul: Avea

Marmara Denizi'ndeki Müsilaj Oluşumlarının Çok Zamanlı Optik ve Termal Uydu Görüntülerinden Makine Öğrenme Algoritması ile Tespiti ve Analizi

(Detection and Analysis of Marine Mucilage Bloom in the Sea of Marmara by a Machine Learning Algorithm from Multi-Temporal Optical and Thermal Satellite Images)

Taşkın KAVZOĞLU¹, İsmail ÇÖLKESEN¹, Umut Güneş SEFERCİK¹, Muhammed Yusuf ÖZTÜRK¹

Gebze Teknik Üniversitesi, Harita Mühendisliği Bölümü, Gebze, Kocaeli
kavzoglu@gtu.edu.tr

Geliş Tarihi (Received): 11.06.2021

Kabul Tarihi (Accepted): 30.06.2021

ÖZ

Küresel ısınmanın karasal alanların yanında denizel alanlarda da doğal dengeyi bozan etkileri bulunmaktadır. Bu bozucu etkilerden biri olan müsilaj ya da deniz salyası, iç deniz ve körfezlerde ortaya çıkan doğal felaketlerden biridir. Müsilaj, Marmara Denizi'nde 2021 yılının Mayıs ayından itibaren hızlı bir şekilde yayılarak akıntı ve rüzgâr etkisiyle Gemlik ve İzmit körfezleriyle İstanbul'un kıyı bölgelerinde etkili olmuştur. Bu çalışmada, Sentinel-2 ve Landsat-8 uydu görüntüleri yardımıyla müsilajın Marmara Denizi'nin İstanbul, Kocaeli, Yalova ve Bursa illerine ait sahilleri kapsayan yaklaşık 4000 km²'lik alanda başlangıçtan itibaren yayılımı, kapladığı alan ve deniz yüzeyinde müsilaj yoğunluğuna bağlı olarak oluşan ısıl değişimler detaylı şekilde analiz edilmiştir. Analizler için 14, 19 ve 24 Mayıs 2021 tarihlerinde çekilen Sentinel-2A görüntüleri ile 17 Mayıs tarihli Landsat-8 görüntüsünün termal bandı kullanılmıştır. Görüntü işleme teknikleri ve popüler makine öğrenme algoritması olan rastgele orman ile deniz yüzeyi müsilaj oluşumları %99 doğrulukla tespit edilmiştir. Müsilaj kaplı alan büyüklüğü, 14 Mayıs 2021 tarihinde 49,71 km² olarak hesaplanırken 24 Mayıs 2021 tarihinde 70,37 km² olarak hesaplanmıştır. Bu sonuç, 10 günlük süreçte %41'lik bir artışı işaret ederek durumun ciddiyetini ortaya koymuştur. Diğer taraftan, deniz suyu sıcaklığı kıyılardan uzak müsilaj olmayan alanlarda ortalama 14,5°C iken müsilajın yoğun olduğu bölgelerde 17°C'nin üzerinde tespit edilmiştir. Tüm bu sonuçlar Marmara Denizi'nde 2007 yılında ilk kez görülen müsilaj olgusunun yılın özellikle bahar dönemlerinde ani sıcaklık artışları ve diğer etkenlerle birlikte kendini göstermeye devam edeceğini işaret etmektedir.

Anahtar Kelimeler: Müsilaj, Rastgele Orman, Sentinel-2A, Landsat-8, Termal bant

ABSTRACT

Global warming has effects that disrupt the natural balance in marine areas as well as terrestrial areas. One of these disruptive effects, mucilage, or sea saliva, is one of the natural disasters in the inland seas and bays. Mucilage has been spreading rapidly in the Sea of Marmara since May 2021 and has been effective in the Gemlik and İzmit Bays, and the coastal areas of İstanbul with the effects of currents and wind. In this study, the distribution of mucilage in an area of approximately 4000 km² covering the coasts of the Sea of Marmara,

Istanbul, Kocaeli, Yalova and Bursa. With the help of Sentinel-2 and Landsat-8 satellite images, the area covered and the thermal changes caused by the density of mucilage on the sea surface were analyzed in detail from the beginning of the phenomenon. In the analysis, May 14, 19 and 24, 2021 Sentinel-2A images and May 17, 2021 Landsat-8 thermal image were employed. With digital image processing techniques and random forest, a popular machine learning algorithm, sea surface mucilage formations were estimated with 99% accuracy. Whilst the size of the mucilage covered area was calculated as 49.71 km² on May 14, 2021, it was calculated as 70.37 km² on May 24. This result marked a 41% increase in the 10-day period, indicating the severity of the situation. On the other hand, the sea water temperature was found to be 14.5°C on average in areas without mucilage far from shore, while it was over 17°C in areas where mucilage was dense. All these results indicate that the mucilage phenomenon, first observed in the Marmara Sea in 2007, will continue to manifest itself together with sudden temperature increases and other factors, especially in the spring periods of the year.

Keywords: Mucilage, Random Forest, Sentinel-2A, Landsat-8, Thermal band

1. GİRİŞ

Marmara Denizi, İstanbul ve Çanakkale Boğazlarının bağlı olduğu ve çevresinde çok sayıda endüstriyel bölgeyi barındıran yoğun deniz trafiğinin olduğu önemli bir iç denizdir. 2021 yılı ilkbaharı ortalarında Marmara Denizi'nde ortaya çıkan müsilaj zamanla ciddi bir tehdit boyutuna ulaşmıştır. Uzunluğu kilometrelere ulaşabilen müsilaj, literatürdeki diğer adlarıyla "deniz sümüğü" ya da "deniz salyası" olgusunun yapısı jelatinimsi agregalar bütünü olarak tanımlanmaktadır. Müsilaj, denizel alanlarda biyolojik üretimin önemli parçası olan bitkisel planktonun (fitoplankton) çevresel faktörlerin tetiklemesi sonucu aşırı çoğalmasıyla suya salgıladıkları organik maddedir. Bakteri ve virüs muhtevası barındıran müsilaj, uzun süre etkili olması durumunda özellikle endüstriyel balıkçılık ve turizm sektörleri için ciddi boyutlarda problem oluşturmaktadır (Azam ve diğerleri, 1999). Müsilajın devamlılığında ise ani sıcaklık

değişimleri, rüzgâr hızı ve aşırı yağışların etkili olduğu ifade edilmektedir (Yentur ve diğerleri, 2013). Müsilajın dünya üzerinde en etkili olduğu ve son iki yüz yıldır takip edildiği Adriyatik Denizi'yle ilgili bilimsel çalışmalar mevcuttur (Funari ve Ade, 1999; Giani ve diğerleri, 2005; Kraus ve Supić, 2015). Akdeniz ve Karadeniz'den gelen farklı ısı ve tuzluluk oranlarına sahip suların geçiş bölgesi olan Marmara Denizinde ise ilk müsilaj oluşumu 2007 yılı yaz aylarında gözlemlenmiş ve müsilaj alanlarının ortalama sıcaklığı $18,4 \pm 1,0^\circ\text{C}$ olarak ölçülmüştür (Aktan ve diğerleri, 2008, Tüfekçi ve diğerleri, 2010; Tas ve diğerleri, 2020). Benzer şekilde Çanakkale Boğazı ve yakın çevresinde Ekim 2008'den Ağustos 2009'a kadarki süreçte müsilaj varlığı gözlemlenmiştir (Yentur ve diğerleri, 2013). Ülkemizde son müsilaj varlığı ise Çanakkale Boğazı'nda 2020 Aralık ayında Özalp (2021) tarafından rapor edilmiştir.

Avrupa Uzay Ajansı (ESA)'nın 2014 yılından itibaren 5 günlük periyotta ve 10 metre konumsal çözünürlükte sunduğu ücretsiz uydu görüntüleriyle ABD'nin benzer şekilde ücretsiz sunduğu Landsat-8 termal bant uydu görüntüleri ile artık belirli zaman periyotlarında ortaya çıkan doğal olayların izlenmesi ve birçok analizin yapılması mümkün hale gelmiştir. Bu çalışmada, 2021 yılı Mayıs ayında Marmara Denizi'nde ortaya çıkan müsilaj oluşumlarının, ciddi tehdit boyutlarına ulaştığı İstanbul, Kocaeli, Yalova ve Bursa illerine ait sahilleri içine alan bölgede, denizdeki hareketleri ve alansal dağılımlarına ilişkin bilgilerin çok zamanlı optik ve termal uydu görüntüleri temelinde analiz edilmesi hedeflenmiştir. Bu hedef doğrultusunda, bulutluluk oranı analize uygun olan Sentinel-2 ve Landsat-8 uydu görüntüleri üzerinde makine öğrenme algoritmaları kullanılarak müsilajın otomatik sınıflandırması gerçekleştirilmiştir. Sınıflandırma sonucu müsilajın alansal büyüklüğü, deniz suyu içerisinde kapladığı alanın yüzde bazındaki zamansal değişimi, deniz suyu ile arasındaki ısı farkı gibi konularda kantitatif hesaplamalar gerçekleştirilmiş ve önemli bulgulara ulaşılmıştır. Denizlerindeki müsilaj oluşumunun ve hareketlerinin uzaktan algılama teknolojisiyle izlenmesi, zamansal ve konumsal tespitlerin yapılması konularında dünyada çok sınırlı sayıda çalışma bulunmakta olup (Zambianchi, 1992; Tassan, 1993; Gigliotti, 2013) ülkemizde yapılmış herhangi bir bilimsel çalışmaya rastlanmamıştır. Bu durum çalışmanın özgün değerini ortaya koymaktadır.

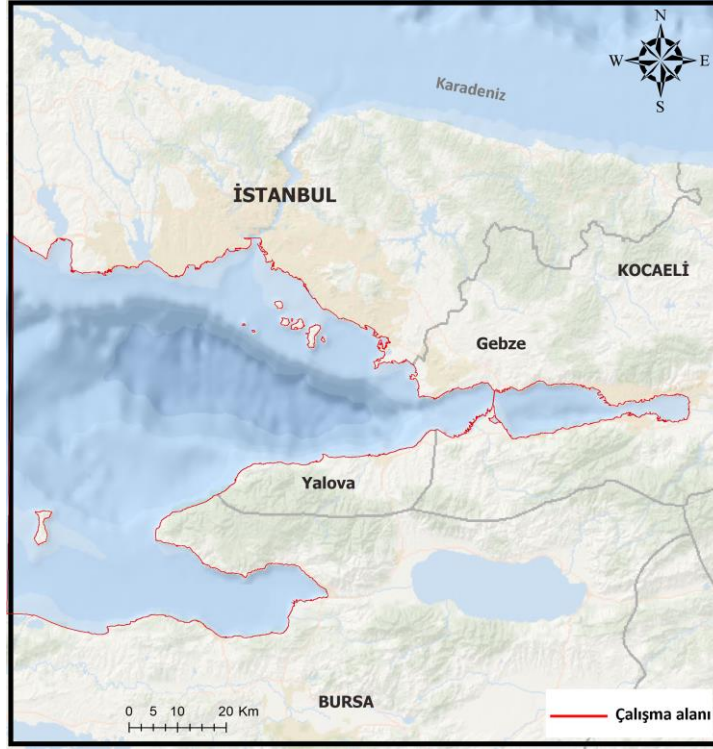
2. ÇALIŞMA ALANI VE VERİ SETİ

Bu çalışmada Marmara Denizi'nde meydana gelen müsilaj oluşumlarının çok zamanlı uydu

görüntüleri ile izlenmesi amaçlanmıştır. Bu amaç doğrultusunda çalışma alanı olarak Marmara Denizi'nin doğu, kuzeydoğu ve güneydoğu kesimlerini kapsayan çözünmüş oksijen miktarının en az seviyede olduğu ve müsilaj oluşumunun en yoğun olarak gözlemlendiği yaklaşık 4000 km²'lik bir alan tespit edilmiştir (Şekil 1). Çalışma alanı kuzeyinde İstanbul, doğusunda Kocaeli ile Yalova ve güneyinde Bursa illerinin Marmara Denizi'ne komşu olan kıyı kesimlerini içermektedir. Çalışma alanına kıyısı olan şehirler Türkiye İstatistik Kurumu (TÜİK) 2020 nüfus istatistiklerine göre Türkiye nüfusunun yaklaşık %25'ini bünyesinde barındırmaktadır. Bölge içerisinde ulusal ve uluslararası deniz ticaretine katkı sağlayan limanlar yer alırken, deniz mahsulü açısından başta balıkçılık olmak üzere ülke ekonomisine önemli katkılar sağlamaktadır. Diğer taraftan, çalışma alanı kıyı kesimlerinde yer alan sahil rekreasyon alanları ve plajlar turizm sektörü açısından önemli cazibe merkezleridir.

Çalışma alanı olarak tespit edilen Marmara Denizi'nin yaklaşık 4000 km²'lik alanı özelinde müsilaj oluşumlarının çok zamanlı izlenmesi, tespiti ve haritalanması amacıyla ESA tarafından ücretsiz olarak servis edilen Sentinel-2 uydu görüntüleri kullanılmıştır. Sentinel-2 uydusu, Kopernik programı kapsamında geliştirilen ve 10 m, 20 m ve 60 m konumsal çözünürlüğe sahip 13 spektral bantlı görüntüler sunan Yer gözlem uydularından biridir. 60 m konumsal çözünürlüğe sahip 3 bant genellikle atmosferik düzeltme ve sIRRus bulutlarının taranmasında kullanıldığı için literatürde genellikle 10 m ve 20 m konumsal çözünürlüğe sahip 10 spektral bant kullanılmaktadır. Mevcut konumsal ve spektral özelliklerinin yanında, zamansal çözünürlük noktasında 5 günlük periyotlarda görüntülerin kullanıcılara sunulması Sentinel-2A görüntülerinin birçok bilimsel çalışmada temel veri seti olarak kullanımını ortaya çıkarmıştır.

Uygulama kapsamında Sentinel-2 görüntülerinin temin edilmesinde öncelikle çalışma alanını kapsayan ve müsilaj tespiti noktasında özellikle deniz alanı üzerinde bulut etkisinin olmadığı görüntüler araştırılmıştır. Bu kapsamda, geometrik ve radyometrik düzeltmeleri yapılan; 14 Mayıs 2021, 19 Mayıs 2021 ve 24 Mayıs 2021 tarihlerinde çekilen Sentinel-2A görüntüleri kullanılmıştır (Copernicus Open Access, 2021). Bununla birlikte deniz suyu ve deniz yüzeyindeki müsilaj oluşumlarının yüzey sıcaklıklarının tespit edilmesi amacıyla, 17 Mayıs 2021 tarihinde Landsat-8 uydu görüntüsünün 10,60-11,19 µm dalga boyu aralığında kaydedilen 100 m konumsal çözünürlüğe sahip termal bantı da değerlendirilmiştir (EarthExplorer, 2021).



Şekil 1. Çalışma alanının konumu.

3. MATERYAL VE YÖNTEM

Bu çalışmada Marmara Denizi'nde etkili olan müsilaj oluşumlarının tespit edilmesi, zamansal değişimlerinin belirlenmesi ve haritalanması amacıyla çok zamanlı Sentinel-2 uydu görüntülerinden yararlanılmıştır. Çalışmada görüntü ön işleme, görüntü sınıflandırma ve Yer yüzeyi sıcaklığının hesaplanması şeklinde üç temel işlem adımı ile gerçekleştirilmiştir (Şekil 2).

a. Veri Temini ve Ön İşleme

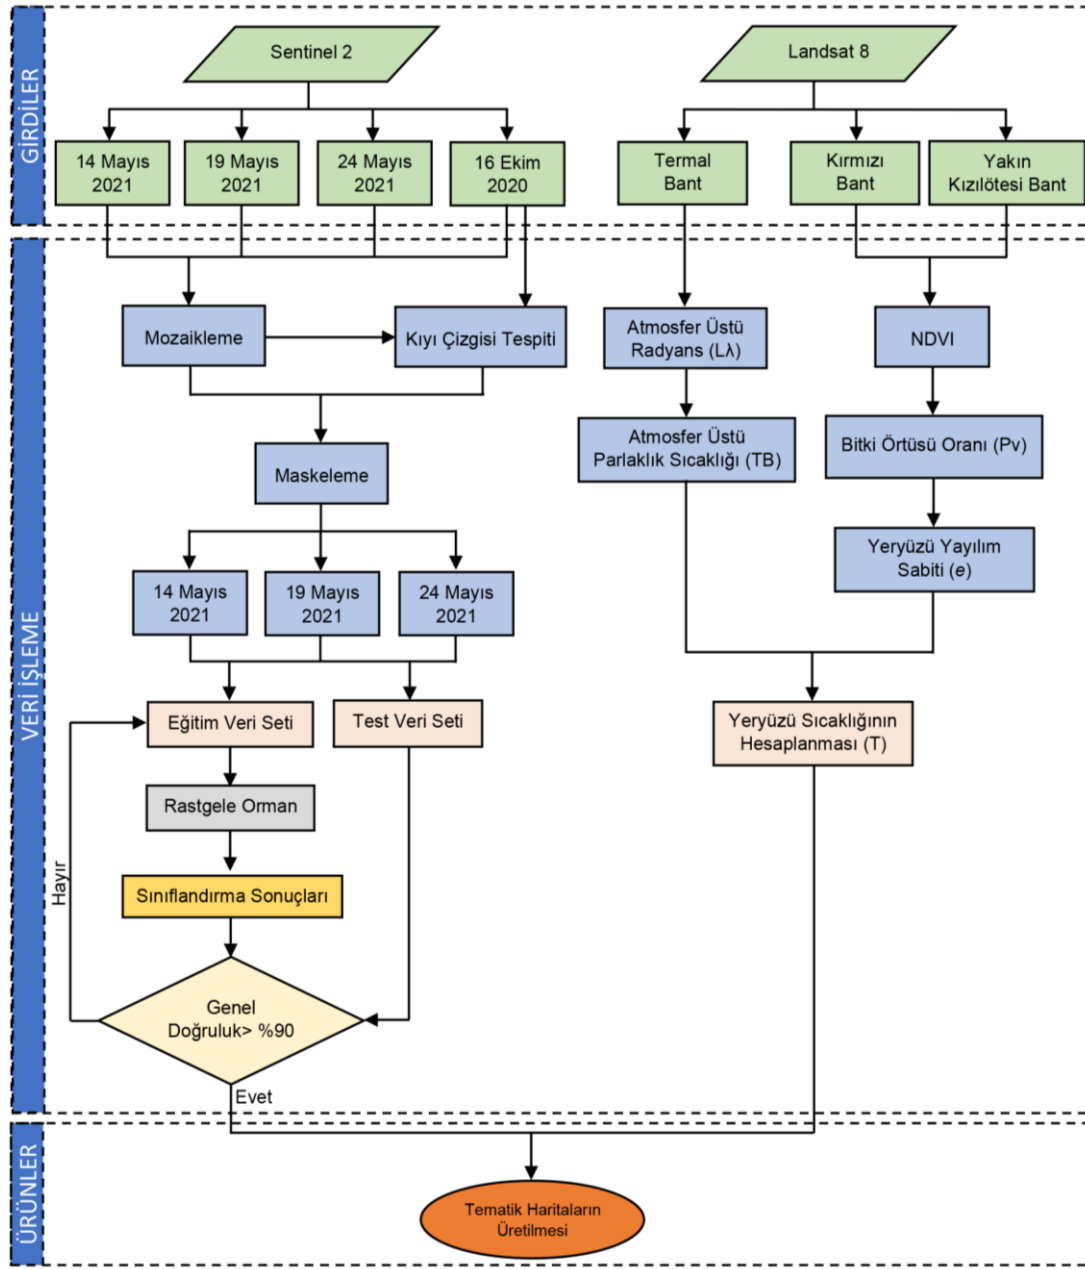
Çalışma kapsamında müsilaj oluşumlarının çok zamanlı uydu görüntüleri yardımıyla tespiti amacıyla 14, 19 ve 24 Mayıs 2021 tarihlerinde elde edilen Sentinel-2 uydu görüntülerinden yararlanılmıştır. Çalışma alanı olarak belirlenen yaklaşık 4000 km²'lik deniz alanı tek bir görüntü çerçevesine sığmamasından dolayı, aynı tarihte bindirmeli olarak çekilen ve Marmara Denizi'nin İstanbul ve Yalova illeri arasını, Kocaeli ve Bursa kesimlerini kapsayan üç görüntü çerçevesinden yararlanılmıştır (Tablo 1).

Görüntü ön işleme adımı öncelikli olarak Sentinel Application Platform (SNAP) yazılımı (SNAP, 2021) yardımıyla görüntülerin 60 m bantları dışındaki tüm spektral bantları 10 m konumsal çözünürlüğe yeniden örneklendirilmiştir.

Tablo 1. Çalışmada kullanılan uydu görüntülerine ilişkin bilgiler.

Uydu Görüntüsü	Görüntü Tarihi	Pencere No	Kullanım Amacı
Sentinel-2	14.05.2021	T35TPF	Müsilaj alanlarının tespiti
		T35TQF	
		T35TPE	
	19.05.2021	T35TPF	
		T35TQF	
		T35TPE	
24.05.2021	T35TPF	Kıyı çizgisi çıkarımı	
	T35TQF		
	T35TPE		
16.10.2020	T35TPF	Yüzey sıcaklık haritası üretimi	
	T35TQF		
	T35TPE		
Landsat-8	17.05.2021	Path:180 Row:032	

Bu adımdan aynı tarihli üç görüntüye mozaiklenme işlemi R yazılımında gerçekleştirilmiştir. Mozaikleme işleminde; çakışan görüntülerden ilkindeki piksel değerlerinin esas alındığı yaklaşım kullanılmıştır (Jensen, 2015).



Şekil 2. Çalışmada kullanılan iş akış diyagramı.

Mozaikleme işleminin ardından oluşan görüntü üzerinden Marmara Denizi'ni kapsayan alanların çıkarılması ve kara alanlarının maskelenmesi amacıyla kıyı çizgisi tespiti işlemi yapılmıştır. Bu amaç doğrultusunda müsilaj oluşumlarının deniz yüzeyinde ve kıyı kesimlerinde gözlemlenmediği 16 Ekim 2020 tarihli Sentinel-2 uydu görüntüsü orta kızılötesi (SWIR) kıyı çizgisinin tespit edilmesinde Marmara Denizi'nin yüzeyinin en net görülebildiği 16 Ekim 2020 tarihli Sentinel-2 görüntüsü kullanılmıştır. Kıyı çizgisinin otomatik olarak tespitinde söz konusu uydu görüntüsünün 1,565-1,655 μm dalga boyu aralığında görüntülenen orta kızılötesi bandı (B11)

kullanılmıştır. Deniz ve su yüzeylerinin spektral karakteristikleri gereği SWIR bölgede hemen hemen hiç yansımaya vermemektedir. Bu özellikten yararlanarak Sentinel-2 görüntüsünün SWIR bandına ilişkin histogram dağılımı üzerinden deniz ve kara ayrımı yapılarak, 16 Ekim 2020 tarihinde çalışma alanına ilişkin kıyı çizgisi otomatik olarak tespit edilmiştir. Oluşturulan vektör formatındaki kıyı çizgisi yüksek çözünürlüklü uydu görüntüleri ile ilişkilendirilerek doğrulaması yapılmış ve tespit edilen hatalar manuel olarak düzeltilmiştir. Oluşturulan sonuç kıyı çizgisi Marmara Denizi'nde 4000 km^2 lik bir alanı ve yaklaşık 840 km uzunluğundaki bir sahil şeridini kapsamaktadır.

Görüntü işleme aşamasının son adımında mozaikleme işlemi ile oluşturulan 14, 19 ve 24 Mayıs 2021 tarihli ham görüntüler üzerinden vektör olarak oluşturulan Ekim 2020 tarihli kıyı çizgisi yardımıyla maskeleme işlemi yapılarak sadece çalışmaya konu olan deniz alanlarını içeren görüntüler elde edilmiştir.

b. Görüntü Sınıflandırma

Çalışma alanı olarak belirlenen ve ön işlemler sonucu elde edilen üç farklı tarihli uydu görüntüsü üzerinden müsilaaj alanlarının tespiti ve haritalanması amacıyla piksel tabanlı kontrollü sınıflandırma yaklaşımı kullanılmıştır. Bu amaç doğrultusunda üç farklı tarih için çalışma alanındaki müsilaaj oluşumları, deniz yüzeyi ve gemileri temsil eden örnekleme noktaları ayrı ayrı belirlenmiştir. Söz konusu örnekleme noktalarının yaklaşık %70'i eğitim verisi olarak etiketlenirken, eğitim verisinde yer almayan %30'luk kısmı test verisi olarak değerlendirmeye alınmıştır.

Sınıflandırma işlemin gerçekleştirilmesinde popüler makine öğrenme algoritmalarından rastgele orman (RO) algoritması kullanılmıştır. RO algoritması, görüntü sınıflandırma aşamasında gösterdiği etkili, hızlı ve güçlü performansından dolayı literatürde birçok görüntü sınıflandırma çalışmasında temel sınıflandırıcı olarak kullanılmaktadır (Immitzer ve diğerleri, 2012; Fu ve diğerleri, 2017; Colkesen ve Kavzoglu, 2017; Sheykhmousa ve diğerleri, 2020). RO, sınıflandırma modelini kurmak için birçok karar ağacını kullanmakta ve bu ağaçların bir araya gelmesiyle oluşan yapıya ise karar ormanı olarak adlandırılmaktadır (Breiman, 2001). Karar ormanı içindeki ağaçların eğitilmesi için orijinal eğitim veri seti alt kümelerle bölünür. Bu kümelerin 2/3'ü sınıflandırma modelini kurmak için, kalan 1/3'ü ise oluşturulan sınıflandırma modelinin doğruluğunu test etmek için kullanılmaktadır (Kavzoglu, 2017). Sınıflandırma işlemi sırasında sınıf etiketi belli olmayan bir piksel ormandaki karar ağaçlarından tek tek geçirilir ve sınıf etiketinin tahmini için bir oy alır. Son aşamada tüm oylardan en fazla orana sahip olan sınıf etiketi o örneğin sınıfı olarak atanır.

c. Yeryüzü Sıcaklık Haritasının Üretilmesi

Çalışma alanı içerisinde kalan müsilaaj ve deniz suyunun sıcaklık değerlerinin analizini yapmak amacıyla Landsat 8 uydusu tarafından 17 Mayıs 2021 tarihinde çekilen ve 30 m konumsal çözünürlüğe yeniden örnekleme yapılarak sunulan termal görüntü (Bant 10) kullanılmıştır. Çalışma bölgesinde kalan termal bant yardımıyla yüzey

sıcaklık değerinin hesaplanmasında Suresh ve diğerleri, (2016) tarafından önerilen işlem adımları takip edilmiştir (Şekil 2).

Yüzey sıcaklık değerlerinin hesaplanmasında, ilk adım termal görüntü için Eşitlik (1) yardımıyla atmosfer üstü radyans değerleri hesaplanmıştır. Eşitlikte L_{λ} atmosfer üstü radyans değerini, M_L termal görüntüye ait çarpımsal yeniden ölçeklendirme faktörünü, Q_{cal} görüntü piksel değerlerini ve A_L termal görüntüye ait katkı yeniden örnekleme faktörünü ifade etmektedir.

$$L_{\lambda} = M_L Q_{cal} + A_L \quad (1)$$

Elde edilen radyans değerleri ikinci adımda, atmosfer üstü parlaklık sıcaklığına dönüştürülmüştür. Eşitlik (2)'den görüleceği üzere Kelvin (K) olarak elde edilen parlaklık sıcaklığının santigrat ($^{\circ}\text{C}$) birimine dönüştürmek için elde edilen parlaklık değerinden 273.15 çıkarılmıştır.

$$BT = K_2 / \ln(K_1 / L_{\lambda} + 1) - 273.15 \quad (2)$$

Eşitlikte, BT : Atmosfer üstü parlaklık sıcaklık değeri ($^{\circ}\text{C}$), K_1 , K_2 : Görüntüye ait termal dönüşüm sabitlerini ifade etmektedir.

Yeryüzü sıcaklığının doğru belirlenebilmesi için gerekli olan en önemli parametrelerden birisi yeryüzü yayılım değeridir. Yeryüzü yayılım değeri, yüzeyin ısı enerjisini radyan enerjiye dönüştürebilme yeteneği olarak tanımlanabilir (Sekertekin ve Bonafoni, 2020). Yeryüzü yayılım değeri, bitki örtüsü oranı değerine bağlı olarak değişmektedir. Bitki örtüsünün oranına ait değer ise arazideki bitki örtüsü kondisyonunu gösteren normalize edilmiş fark bitki örtüsü indisi (NDVI) değerlerinden elde edilmektedir (Avdan ve Jovanovska, 2016). NDVI değerleri Landsat 8 uydusundan elde edilen kırmızı ve yakın kızıl ötesi bantlar kullanılarak Eşitlik (3) yardımıyla hesaplanmıştır.

$$NDVI = \frac{\text{Yakın Kızılötesi} - \text{Kırmızı}}{\text{Yakın Kızılötesi} + \text{Kırmızı}} \quad (3)$$

Elde edilen NDVI değerleri yardımıyla Eşitlik (4)'teki bağıntı kullanarak bitki örtüsü oranı sabiti (P_v) hesaplanmıştır.

$$P_v = \left(\frac{NDVI - NDVI_{\min}}{NDVI_{\max} - NDVI_{\min}} \right)^2 \quad (4)$$

NDVI ve P_v değerleri daha sonra Eşitlik (5)'de verilen yüzey yayılım değerinin (e) hesabında kullanılmaktadır.

$$e = 0.004 \times P_v + 0.986 \quad (5)$$

Son işlem adımında termal görüntüdeki piksel değerleri Eşitlik (6) yardımıyla atmosferik etkilerden arındırılmış gerçek yüzey sıcaklık değerlerine dönüştürülmüştür. Bu eşitlikte λ termal görüntünün ortalama dalga boyunu ve c ışık hızıdır.

$$T = \frac{BT}{1 + \left(\frac{\lambda x BT}{c^2} \right) \times \ln(e)} \quad (6)$$

4. UYGULAMA

Çalışma kapsamında çok zamanlı Sentinel-2 uydu görüntülerinin sınıflandırılması amacıyla her bir tarih için tespit edilen eğitim veri setleri kullanılarak ayrı ayrı RO tahmin modelleri oluşturulmuştur. RO ile tahmin modeli oluşumunda ağaç sayısı 500 ve her bir düğümdeki örnek sayısı $\sqrt{10 \text{ bant}} \cong 3$ olarak alınmıştır. Oluşturulan RO tahmin modelleri öncelikle test veri setlerine uygulanmış ve test veri setleri için müsilaj sınıfına ilişkin F-skor (Hellden's ölçütü) değerleri %99'un üzerindedir. Sonuç modeller üç farklı tarihli veri setlerine uygulanarak müsilaj oluşumları tespit edilmiştir. Şekil 3'te 14, 19 ve 24 Mayıs 2021 tarihleri arasında tespit edilen müsilaj oluşumları ve çalışma alanındaki dağılımları gösterilmiştir. Yapılan analizler sonucunda yaklaşık 4000km²'lik çalışma alanı içerisinde müsilaj oluşumlarının 14 Mayıs 2021 tarihinde yaklaşık 50 km²'lik bir alanda etkili olduğu, bu oluşumların çalışma alanının %1,24'ne denk geldiği görülmüştür (Tablo 2). 19 Mayıs 2021 tarihinde ise çalışma alanındaki müsilaj yoğunluğunun alansal açıdan %15 artarak 57 km²'ye yükseldiği görülmektedir. Diğer bir ifadeyle, ilk görüntüden beş gün sonrasında çalışma alanındaki müsilaj yoğunluğu %1,42'ye yükselmiştir. Diğer taraftan, çalışmada değerlendirmeye alınan 24 Mayıs tarihli son görüntünün sınıflandırma sonuçları incelendiğinde müsilaj yoğunluğunun çalışma alanında 70km²'lik bir alanda etkili olduğu belirlenmiştir. Bu, elde edilen miktar değerlendirmeye alınan görüntüler içerisinde müsilaj miktarının en yoğun tespit edildiği dönem olmuştur. Nitekim müsilaj miktarındaki artış oranı 14 Mayıs tarihine göre %41, 19 Mayıs tarihine göre %22 artmıştır.

Bununla birlikte 4000 km²'lik deniz alanının %1,75'inde müsilaj oluşumu tespit edilmiştir.

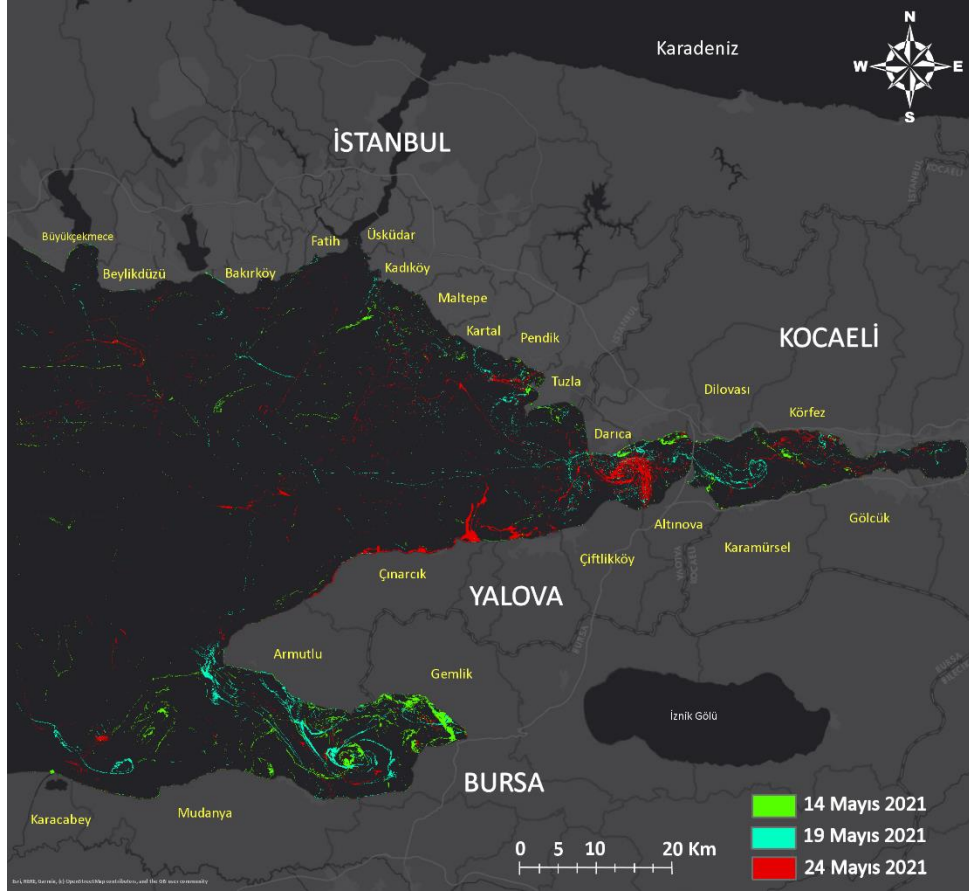
Tablo 2. Çalışma bölgesinde, zamansal olarak belirlenen Müsilaj yoğunluk oranlarına ilişkin değerler.

Tarih	Müsilaj kaplı alan	
	Alansal (km ²)	Oransal (%)
24.05.2021	70,37 km ²	% 1,75
19.05.2021	57,32 km ²	% 1,42
14.05.2021	49,71 km ²	% 1,24

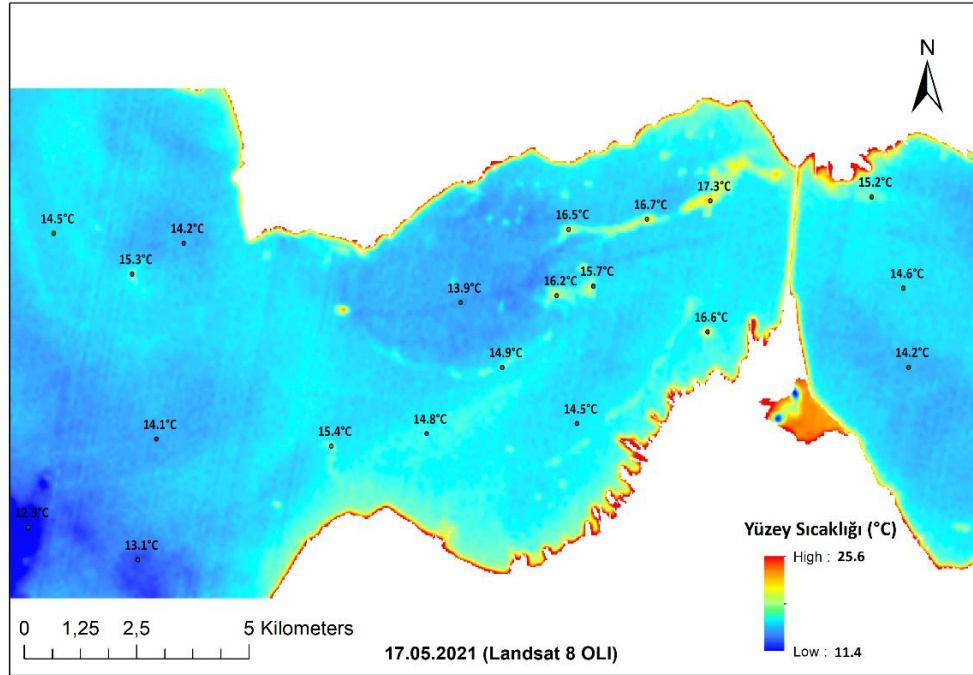
Çalışma alanı içerisinde tespit edilen müsilaj oluşumlarının konumsal dağılımları incelendiğinde, 14 Mayıs 2021 tarihinde özellikle Yalova ve Bursa illerinin Armutlu-Gemlik-Mudanya kesiminde yoğunlaştığı görülmektedir. Bu tarihte Kocaeli/Darıca kıyı kesiminde ve İstanbul/Kadıköy, Kartal, Pendik ve Tuzla sahil kesimlerinde sınırlı miktarda müsilaj oluşumları gözlenmiştir. 19 Mayıs 2021 tarihinde ise müsilaj oluşumlarının Gemlik Körfezi'nden uzaklaşarak Marmara Denizi açıklarına doğru hareketlendiği, bu sırada Armutlu ve Karacabey kıyı kesimlerinde yoğunlaşmaların arttığı izlenmiştir. Diğer taraftan müsilaj oluşumları İstanbul/Kadıköy-Tuzla sahil kesimi boyunca ve devamında Kocaeli Darıca-Körfez sahil kesimine kadar etkili olduğu görülmektedir.

24 Mayıs tarihi itibarıyla ise müsilaj oluşumlarının Marmara Denizi'nin genelinde yoğunlaştığı, özellikle Yalova/Çınarcık-Altınova sahil kesimlerinde ve Altınova-Darıca kıyıları arasında kalan bölgele önemli miktarlarda müsilaj kümelenmelerinin olduğu açıkça görülmektedir. İstanbul kesiminde ise özellikle sahil kenarlarında ve Pendik-Tuzla kıyı şeridinde yoğunlaşmaların olduğu tespit edilmiştir.

Çalışma alanında deniz yüzeyi sıcaklığı ve müsilaj oluşumlarının yüzey sıcaklığının incelenmesi amacıyla, 17 Mayıs 2021 tarihli Landsat-8 görüntüsünün termal bandı yardımıyla oluşturulan yüzey sıcaklığı haritası Şekil 4'te verilmiştir. Yüzey sıcaklığı haritası üzerinde temiz deniz yüzeyi ve müsilaj oluşumları üzerinde bazı noktalarda tespit edilen yüzey sıcaklık değerleri de gösterilmiştir. Şekilden de görüleceği üzere temiz deniz yüzeyinde 17 Mayıs 2021 tarihinde ortalama yüzey sıcaklığı yaklaşık 14,5°C iken, müsilaj oluşumlarının yoğun olarak gözlemlendiği alanlarda genel olarak 3°C'lik artışlar belirlenmiş olup, deniz yüzey sıcaklığının 17,3°C değerine kadar da yükselmiş olduğu tespit edilmiştir.



Şekil 3. Tespit edilen müsilaj oluşumları ve çalışma alanındaki dağılımları.



Şekil 4. Çalışma alanındaki yüzey sıcaklığı haritası.


5. SONUÇ VE ÖNERİLER


Uzaktan algılama teknolojileri yeryüzünde meydana gelen zamana bağlı doğal ve yapay değişimlerin izlenmesi ve tespiti noktasında önemli bir veri kaynağı durumundadır. Bu çalışmada, Marmara Denizi'nin büyük bölümünde deniz yüzeyinde oluşan müsilaj Sentinel-2A ve Landsat-8 görüntüleri kullanımıyla zamansal olarak haritalanmıştır. Ayrıca, yüzey sıcaklıklarının analizi gerçekleştirilmiştir. Elde edilen sonuçlar Mayıs ayı ortasından itibaren Gemlik ve İzmit Körfezlerinde yoğun tabakaların rüzgâr ve akıntıyla hareketleri gözlemlenmiştir. Müsilaj oluşumunun 14 Mayıs 2021 tarihinden itibaren 10 günlük zaman diliminde %41'lik bir artış göstererek yaklaşık 70 km²lik bir alanda etkili olduğu tespit edilmiştir. Elde edilen bu bulgu, müsilaj oluşumunun çok hızlı bir şekilde artış gösterdiğini ortaya koymuştur. Termal görüntü yardımıyla elde edilen yüzey sıcaklık değerleri analiz edildiğinde, müsilaj oluşumlarının yüzey sıcaklığı yoğunluğa bağlı olarak temiz deniz yüzeyine göre yaklaşık 3°C fazla olduğu ve ortalama 17±1°C seviyesine kadar ulaştığı görülmüştür. Bu bulgu, 2008 yılında İstanbul Boğazı ve İzmit Körfezinde yaşanan müsilaj oluşumları üzerine yapılan çalışmaları doğrular niteliktedir (Aktan ve diğerleri, 2008). Marmara Denizi'nde çözünmüş oksijenin azaldığı ve partikül organik maddelerin artış gösterdiği, dalga hareketinin ve akıntının olmadığı bölgelerde yüzey sıcaklığının artış gösterdiği değerlendirilmektedir. Optik ve termal görüntülerde bulutluluk oranının bahar döneminde yüksek olması nedeniyle tüm Marmara Denizi değerlendirmeye tabi tutulamamış ve Haziran ayı başlangıcı için değerlendirme gerçekleştirilememiştir. Devam eden çalışmalarla, yaz döneminde müsilaj hareketliliğinin beş gün aralıklarla periyodik olarak takibi yapılabilecek ve müsilaj yoğunluğu ile sıcaklık ilişkisi modellenebilecektir.

ORCID

Taşkın KAVZOĞLU  <https://orcid.org/0000-0002-9779-3443>

İsmail ÇÖLKESEN  <https://orcid.org/0000-0001-9670-3023>

Umut Güneş SEFERCİK  <https://orcid.org/0000-0003-2403-5956>

Muhammed Yusuf ÖZTÜRK  <https://orcid.org/0000-0001-6459-9356>

KAYNAKLAR

- Avdan, U. ve Jovanovska, G. (2016). Algorithm for automated mapping of land surface temperature using LANDSAT 8 satellite data. *Journal of Sensors*, 2016, 1–8. doi: 10.1155/2016/1480307
- Aktan, Y., Isinibilir, M., Topaloğlu, B., Dede, A. ve Çardak, M. (2008). Mucilage event associated with diatoms and dinoflagellates from the Marmara Sea, Turkey. *Harmful Algae News*, May 2008, 36, 1-7.
- Azam F., Fonda-Umani S. ve Funari E. (1999). Significance of bacteria in the mucilage phenomenon in the northern Adriatic Sea. *Ann Ist Super Sanita*, 35(3), 411-9. PMID: 10721207.
- Breiman, L. (2001). Random Forests. In *Machine Learning* (pp. 5–32). Chapman and Hall/CRC.
- Colkesen, I. ve Kavzoglu, T. (2017). Ensemble-based canonical correlation forest (CCF) for land use and land cover classification using sentinel-2 and Landsat OLI imagery, *Remote Sensing Letters*, 8(11), 1082-1091. doi: 10.1080/2150704X.2017.1354262
- Copernicus Open Access (Sentinel uydu görüntülerine erişim), (2021, 25 Mayıs). Erişim adresi: <https://scihub.copernicus.eu>.
- Danovaro, R., Fonda-Umani, S. ve Pusceddu, A. (2009). Climate change and the potential spreading of marine mucilage and microbial pathogens in the Mediterranean Sea. *PLoS one*. 4. e7006. doi: 10.1371/journal.pone.0007006
- EarthExplorer (Landsat uydu görüntülerine erişim), (2021, 20 Mayıs) <http://earthexplorer.usgs.gov/>.
- Fu, B., Wang, Y., Campbell, A., Li, Y., Zhang, B., Yin, S., Xing, Z. ve Jin, X. (2017). Comparison of object-based and pixel-based Random Forest algorithm for wetland vegetation mapping using high spatial resolution GF-1 and SAR data. *Ecological Indicators*, 73, 105–117. doi: 10.1016/j.ecolind.2016.09.029
- Funari E. ve Ade P. (1999). Human health implications associated with mucilage in the northern Adriatic Sea. *Ann Ist Super Sanita*, 35(3), 421-5. PMID: 10721208.

- Giani, M., Savelli, F., Berto, D., Zangrando, V., Cosović, B. ve Vojvodić, V. (2005). Temporal dynamics of dissolved and particulate organic carbon in the northern Adriatic Sea in relation to the mucilage events. *Science of The Total Environment*, 353(1-3), 126-38. doi: 10.1016/j.scitotenv.2005.09.062
- Gigliotti, A. (2013). Extracting temporal and spatial distributions information about marine mucilage phenomenon based on Modis satellite images; a case study of the Tyrrhenian and the Adriatic Sea, 2010-2012. *Master of Science in Geospatial Technologies*, <https://run.unl.pt/bitstream/10362/9205/1/TGE00095.pdf>
- Immitzer, M., Atzberger, C. ve Koukal, T. (2012). Tree species classification with random forest using very high spatial resolution 8-band WorldView-2 Satellite data. *Remote Sensing*, 4(9), 2661–2693. doi: 10.3390/rs4092661
- Jensen, J. R. (2015). Introductory digital image processing: A remote sensing perspective (4th. ed.). Prentice Hall Press, USA.
- Kavzoglu, T. (2017). Object-oriented random forest for high resolution land cover mapping using Quickbird-2 Imagery. *Handbook of Neural Computation*, 2017, 607-619.
- Kraus, R. ve Supić, N. (2015). Sea Dynamics impacts on the macroaggregates: A case study of the 1997 mucilage event in the northern Adriatic. *Progress in Ocenaography*, 138, 249-267. doi: 10.1016/j.pocean.2015.06.005
- Mecozzi, M., Acquistucci, R., Noto, V., Pietrantonio, E., Amici, M. ve Cardarilli, Demetria. (2001). Characterization of mucilage aggregates in Adriatic and Tyrrhenian Sea: Structure similarities between mucilage samples and the insoluble fractions of marine humic substance. *Chemosphere*, 44, 709-20. doi: 10.1016/S0045-6535(00)00375-1
- Özalp, H.B. (2021). First massive mucilage event observed in deep waters of Çanakkale Strait (Dardanelles), Turkey. *Journal of the Black Sea/Mediterranean Environment*, 27(1), 49-66.
- Sekertekin, A. ve Bonafoni, S. (2020). Land surface temperature retrieval from Landsat 5, 7, and 8 over rural areas: Assessment of different retrieval algorithms and emissivity models and toolbox implementation. *Remote Sensing*, 12(2), 294. doi: 10.3390/rs12020294
- Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P. ve Homayouni, S. (2020). Support vector machine versus random forest for remote sensing image classification: A Meta-analysis and systematic review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308–6325. doi: 10.1109/JSTARS.2020.3026724
- SNAP (Sentinel Application Platform), (2021, 24 Haziran), <https://step.esa.int/main/download/snap-download>.
- Suresh, S., Ajay Suresh, V. ve Mani, K. (2016). Estimation of land surface temperature of high range mountain landscape of Devikulam Taluk using LANDSAT 8 data. *International Journal of Research in Engineering and Technology*, 05(01), 92–96.
- Tas, S., Kus, D. ve Yılmaz, I. N. (2020). Temporal variations in phytoplankton composition in the north-eastern Sea of Marmara: potentially toxic species and mucilage event. *Mediterranean Marine Science*, 21(3), 668-683. doi: 10.12681/mms.22562
- Tassan, S. (1993). An algorithm for the detection of the white-tide ("mucilage") phenomenon in the adriatic sea using AVHRR data. *Remote Sensing of Environment*, 45(1), 29-42. doi: 10.1016/0034-4257(93)90079-D
- Tüfekçi, V., Balkıs, N., Beken Polat, Ç., Ediger, D. ve Mantıkçı, M. (2010). Phytoplankton composition and environmental conditions of a mucilage event in the Sea of Marmara. *Turkish Journal of Biology*, 34, 199-210. doi: 10.3906/biy-0812-1
- Yentur, R.E., Buyuates, Y., Ozen, O. ve Altın, A. (2013). The environmental and socio-economical effects of a biologic problem: Mucilage. *Marine Science and Technology Bulletin*, 2(2), 13-15.
- Zambianchi, E., Calvitti, C., Cecamore, P., D'Amico, F., Ferulano, E. ve Lanciano, P. (1992). The mucilage phenomenon in the Northern Adriatic Sea, summer 1989: a study carried out with remote sensing techniques. *Marine Coastal Eutrophication*, 126, 581-598. doi: 10.1016/B978-0-444-89990-3.50053-5

Türkiye’de Güncel Yersel Gravimetri Çalışmaları (Recent Terrestrial Gravimetry Studies in Turkey)

Mehmet SİMAV*^{ID}, İlyas AKPINAR^{ID}, Yunus Aytaç AKDOĞAN^{ID}, Hasan YILDIZ^{ID}

Harita Genel Müdürlüğü, Ankara

*Sorumlu yazar: mehmet.simav@harita.gov.tr

Geliş Tarihi (Received): 22.03.2021

Kabul Tarihi (Accepted): 27.05.2021

ÖZ

Harita Genel Müdürlüğü koordinatörlüğünde gerçekleştirilen “Türkiye Yükseklik Sisteminin Modernizasyonu ve Gravite Altyapısının İyileştirilmesi (2015-2020)” projesinin temel hedeflerinden biri, yersel ve hava gravimetrisi yöntemleriyle ulusal gravite veri tabanını geliştirmek ve Türkiye bölgesel gravite alanı modelini iyileştirmektir. Proje kapsamında 2016 yılından itibaren, beş ulusal kurumun iş birliğiyle ülke genelinde yoğun yersel gravimetri çalışmaları gerçekleştirilmiştir. Çalışmaların başında, Ankara ili içerisinde yaklaşık 20 km’lik bir mesafede 210 mGal gravite farkı olan iki noktalı bir kalibrasyon bazı tesis edilmiştir. Çalışmalarda kullanılan bağıl gravimetrelerin kalibrasyon katsayıları bu bazda yapılan ölçümlerle güncellenmiştir. Doğal, çevresel ve insan kaynaklı gürültülerden olabildiğince arındırılmış bir laboratuvar (TRGrav-Lab) kurulmuştur. Bağıl gravimetrelerin gürültü karakteristikleri ve sürüklenme katsayıları bu laboratuvar da düzenli aralıklarla izlenmiştir. TRGrav-Web veri portalı kurulmuş, ham ölçüler ve meta verileri ölçü ekipleri tarafından gün sonunda portala düzenli olarak yüklenmiştir. 100 tanesi mutlak gravimetri noktası olmak üzere 11783 noktadan oluşan yaklaşık 5’x5’ konumsal çözünürlüğe sahip yeni bir ulusal gravite standardizasyon ağı (TRGrav-Net) oluşturulmuştur. Çevresel ve aletsel etkilerden arındırılmış gravite gözlemlerinin ağırlıklı en küçük kareler dengesi sonunda TRGrav-Net noktalarında ortalama hata 35 µGal olarak belirlenmiştir. TRGrav-Net kurulum çalışmaları devam ederken İstanbul, Ankara, Tekirdağ illeri ile Kırıkkale-Çorum hava gravimetrisi test alanı, Marmara Denizi’nde 1.5 km²’den daha büyük adaların tamamı, Gökçeada ve Bozcaada ile Kuzey Kıbrıs Türk Cumhuriyeti genelinde birkaç kilometre konumsal çözünürlükte gravite sıklaştırma çalışmaları yapılmıştır. Son olarak, ülke genelinde jeoit modeli kontrolü için farklı bölgelerde tesis edilen 7 farklı nivelman hattına ait 1757 noktada yersel gravimetri çalışmaları gerçekleştirilmiştir. Bu çalışmalar sonucunda elde edilen yeni yersel gravite verileri, tarihsel gravite verilerinin kalite kontrolünde kullanılmış ve tarihsel verilerdeki kaba hata ve tutarsızlıkların giderilmesini sağlamıştır. Kırıkkale-Çorum bölgesindeki sıklaştırma verilerinin yukarı yönlü uzanımı, hava gravimetrisi testlerinde referans veri seti olarak kullanılmıştır. 2020 yılı sonuna kadar toplanan güncel yersel gravite verileri, kalite kontrolü yapılmış tarihsel gravite verileri ile birlikte yüksek çözünürlüklü ve doğruluklu Türkiye Jeoit Modeli-2020 hesaplamalarının temel girdisi olarak kullanılmıştır.

Anahtar Kelimeler: Yersel Gravimetri, TRGrav-Net, TRGrav-Lab, TRGrav-Web, Yükseklik Sistemi Modernizasyonu.

ABSTRACT

One of the major objectives of the “Turkish Height System Modernization and Gravity Recovery (2015-2020)” project coordinated by the General Directorate of Mapping is to recover the national gravity database and improve the Turkish regional gravity field model from terrestrial and airborne gravimetry. Intensive terrestrial gravimetry campaigns have been conducted throughout the country since 2016 by the collaborative works of five national institutions within the project. In the beginning of the fieldworks, a new calibration baseline consisting of two absolute gravity sites with average distance of 20 km apart and gravity ranges up to 210 mGal was constructed in Ankara city. The calibration constants of the relative gravimeters used in the project were updated based upon the observations on the calibration base. A laboratory (TRGrav-Lab), decontaminated from the natural, environmental, and man-made noises, was built. The noise characteristics and the drifts of the gravimeters were monitored at regular intervals in this laboratory. TRGrav-Web portal was set up for the survey teams to upload the daily raw observations along with their metadata at the end of the survey day. A national gravity standardization network (TRGrav-Net) consisting of 11783 sites, 100 of which are absolute points, with a spatial resolution of about 5’x5’ were established. The weighed constrained least squares adjustment of the gravity observations reduced for the environmental and instrumental effects resulted in a mean formal error of 35 µGal at TRGrav-Net sites. Gravity densifications at a few kilometers’ spatial resolution over İstanbul, Ankara, Tekirdağ cities and Kırıkkale-Çorum airborne gravimetry test region, islands larger than 1.5 km² in the Sea of Marmara, Gökçeada, Bozcaada and Turkish Republic of Northern Cyprus have also been completed during the TRGrav-Net establishment. Lastly, terrestrial gravimetry was performed at the 1757 levelling benchmarks over 7 discrete levelling profiles constructed at different regions in the country for the geoid model validation. The recent terrestrial gravity data have been used for the quality control of the historical data and they have provided to remove the gross errors and discrepancies in the historical gravity datasets. The upward-continuation of the densified data in Kırıkkale-Çorum region have been utilized as reference dataset for the airborne gravimetry test studies. The recent terrestrial gravity data acquired until the end of 2020 along with

the quality controlled historical gravity data have been used as the major input for the computation of high resolution and accurate Turkish Geoid Model-2020.

Keywords: Terrestrial Gravimetry, TRGrav-Net, TRGrav-Lab, TRGrav-Web, Height System Modernization.

1. GİRİŞ

Maupertuis, Bouguer, Condamine, Cassini gibi bilim insanları tarafından 18'inci yüzyılda sarkaç aparatları ile başlayan yersel gravimetri, jeodezi biliminin sacayaklarından biri olan Yer gravite alanının ölçülmesi ve modellenmesinde 300 yıla yakın bir zamandır kullanılan bir yöntemdir. Günümüzde yersel gravimetri çalışmaları, yaylı bağıl gravimetreler ve lazer interferometrik serbest düşme ilkesine dayalı mutlak gravimetreler ile μGal mertebesinde yüksek doğruluk ve duyarlıkla gerçekleştirilmektedir (Torge, 1989). Yersel gravimetride gözlemler yeryüzünde yapıldığından, çekim kaynağına yakınlık nedeniyle bu gözlemlerinin gravite alanını çözme gücü diğer gravimetri yöntemlerine göre daha yüksektir. Yersel gravite gözlemleri, Yer gravite alanının uzun, orta ve kısa dalga boylu sinyallerinin tamamını içermektedir. Ölçümler bir nokta üzerinde durağan biçimde yapılmaktadır. Bu nedenle, hava ve deniz gravimetrisindeki gibi hareketten kaynaklanabilecek bozucu etkilere maruz kalınmadığından, ölçü doğruluğu ve duyarlığı önemli ölçüde artmaktadır. Yersel gravimetri; düşey koordinat sistemlerinin gerçekleştirimi (jeoit belirleme ve nivelman ağları), hassas konumlama ve navigasyon, yapay uydu yörüngelerinin belirlenmesi, maden/petrol/doğalgaz/jeotermal aramaları, fizik ve metroloji, deniz seviyesi değişimleri/buzul erimeleri/iklim değişimlerinin izlenmesi, volkanoloji, tektonik yapıların belirlenmesi ve kabuk/manto modellenmesi gibi yer ve uzay bilimlerinin hemen hemen tüm alanlarında kullanılmaktadır.

Ülkemizde yersel gravimetri çalışmaları 1950'li yıllarda Türkiye Temel Gravite Ağı (TTGA-56) kurulum çalışmaları ile başlamıştır (Ayhan ve diğerleri, 1992). Bu tarihten sonra, jeodezik, jeofizik ve jeolojik amaçlarla, Harita Genel Müdürlüğü, Maden Tetkik ve Arama Genel Müdürlüğü (MTA) ve Türkiye Petrolleri Anonim Ortaklığı (TPAO) tarafından ülke genelinde yersel gravimetri çalışmaları gerçekleştirilmiştir. Bunun yanında daha küçük alanlarda çeşitli üniversite ve araştırma kurumlarınca da yersel gravite ölçüleri yapılmaktadır. MTA ve TPAO envanterinden derlenen yersel gravite verileri, Harita Genel Müdürlüğü tarafından Türkiye Jeoit Modeli

hesaplamalarında kullanılmıştır. Ancak, ülkemizde yersel gravimetri ve meta veri saklama konusunda kurumlar arası standartların henüz sağlanmamış olması sebebiyle, derlenen veriler arasında birtakım sistematik ve kaba hatalardan kaynaklanan tutarsızlıklara rastlanılmıştır (Simav ve diğerleri, 2012). Söz konusu veriler, ayrıntılı kalite kontrolden geçirilerek gravimetrik jeoit modeli hesaplamalarında kullanılmıştır (Kılıçoğlu ve diğerleri, 2006; Kılıçoğlu ve diğerleri, 2011; Yıldız ve diğerleri, 2021).

Ülke yükseklik sisteminin, bilimsel ve teknolojik gelişmeler ışığında ve dünyadaki yeni yaklaşımlarla modernize edilmesi amacıyla, Harita Genel Müdürlüğü koordinatörlüğünde, MTA, TPAO, TÜBİTAK MAM ve TÜBİTAK UME iş birliğiyle 2015 yılında "Türkiye Yükseklik Sisteminin Modernizasyonu ve Gravite Altyapısının İyileştirilmesi (2015-2020)" projesi başlatılmıştır (Simav ve diğerleri, 2015). T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı destekli projenin temel hedeflerinden biri, yersel ve hava gravimetrisi yöntemleriyle ulusal gravite veri altyapısını geliştirmek ve Türkiye bölgesel gravite alanı modelini iyileştirmektir. Projenin nihai hedefi ise 1-3 km konumsal çözünürlükte 1-3 cm doğrulukla Türkiye Jeoit Modelini hesaplamaktır. Projenin 2015 yılı yatırım programında yayımlanmasını müteakip, ölçü ekipmanlarının tedariki ile başlayan yersel gravimetri çalışmalarına 2020 yılı sonuna kadar devam edilmiştir. Arazi çalışmaları öncesinde, yersel gravimetri ölçü ve değerlendirme standartları oluşturulmuş, eğitim, test ve kalibrasyon çalışmaları gerçekleştirilmiştir. Nisan 2016'dan sonra yeni ulusal gravite standardizasyon ağının (TRGrav-Net) kurulumuna ve bu ağa dayalı sıklaştırma çalışmalarına başlanmıştır.

Simav ve Yıldız (2019) tarafından yersel gravimetri ölçü ve değerlendirme standartları ayrıntılı bir şekilde ele alınmış, TRGrav-Net'in 26°E-31°E ve 36°N-40°N arasında kalan bölümüne ilişkin sonuçlar yayımlanmıştır. Bu çalışmada ise, 2020 yılı sonu itibarıyla ülke genelini kapsayan ölçülerin tamamlanması sonrası, TRGrav-Net'in tamamına ilişkin sonuçlar verilmektedir. Bunun yanında; TRGrav-Lab gravimetri laboratuvarı ve TRGrav-Web veri portalı tanıtılmakta, TRGrav-Net'e dayalı yersel gravimetri sıklaştırma çalışmaları anlatılmaktadır. Yeni yersel gravimetri verileri ile gerçekleştirilen uygulamaların sonuçları sunulmakta ve gelecekte yapılması planlanan çalışmalar hakkında bilgi verilmektedir.

2. YERSEL GRAVİMETRİ STANDARTLARI

Gravimetrik yöntemlerde ulusal/uluslararası standartlara ulaşabilmek için aynı gravite alanına ilişkin ölçülerin, değişkenlerin, modellerin, büyüklüklerin ve yaklaşımların ortak bir anlayış ile değerlendirilmesi ve anlaşılması gerekmektedir (Kılıçoğlu ve diğerleri, 2010). Ülkemizde yersel gravimetri çalışmaları farklı amaçlara yönelik olarak değişik kurum ve kuruluşlar tarafından yapılmaktadır. Ancak ölçme ve değerlendirmede ulusal düzeyde bir standart olmadığından, kurumlardan derlenen veriler arasında tutarsızlıklar ortaya çıkmaktadır. Veriler arasındaki tutarsızlığa; (i) Nokta konumlandırma farklı referans sistemlerinin kullanımı, (ii) Düşük doğruluklu nokta konumlandırma teknikleri ve iyi kalibre edilmemiş gravimetrelerin kullanımı, (iii) Sistematik hataları giderecek uygun ölçü yöntemlerinin uygulanmaması, (iv) Gravite ölçülerine uygun indirgemelerin (düzeltmelerin) getirilmemesi gibi nedenleri sıralamak mümkündür. Simav ve diğerleri (2012) tarafından önerildiği şekilde, proje kapsamında 2016 yılında yersel gravimetri ölçülerine başlanmadan önce nokta yeri seçiminden, konumlamaya, mutlak ve bağıl gravimetri ölçü yöntemlerinden veri işlem aşamasına kadar standartlar belirlenmiş ve titizlikle uygulanmıştır.

a. Nokta Yeri Seçimi

TRGrav-Net ve yersel gravimetri sıklaştırma noktalarının yaklaşık konumları arazi çalışmaları öncesinde topoğrafik haritalar ve yüksek çözünürlüklü ortogörüntüler üzerinden belirlenmiştir. Gravite gözlemlerinin mikrosismisiteden etkilenmemesi için yer seçiminde noktaların su havzaları, ana yol, demir yolu, maden sahaları ve bataklık alanlardan uzak olmasına özen gösterilmiştir. Noktaların kesin yerleri arazide keşif çalışması ile belirlenmiş, TRGrav-Net noktaları yaklaşık 10 mm çapında demir çubukla yere işaretlenmiştir. Tesis edilen noktaların uzun süre kalıcılığının sağlanması ve tahrip olmaması için yerleşim yerleri içerisinde cami, okul, kamu binaları ve anıtsal yapılar, yerleşim yerleri dışında ise araçla ulaşımın mümkün olduğu sabit yerli kayalar nokta yeri olarak seçilmiştir. Örnek nokta fotoğrafları Şekil 1'de gösterilmektedir.

b. Konum Belirleme

Yer gravite alanı ölçmelerinde konum doğruluğu, en az gravimetrik ölçümlerin doğruluğu kadar önemlidir. Konum belirlemede kullanılan koordinat referans çerçevesi Yer merkezli ve

global olmalıdır. Çünkü teorik olarak bütün tanımlar ve modeller Yer'in tamamı için ve Yer merkezli bir koordinat sistemine göre yapılmaktadır. TRGrav-Net ve yersel gravimetri sıklaştırma noktalarının 3 boyutlu koordinatları çoğunlukla TUSAGA-Aktif sisteminden yararlanarak TUREF referans çerçevesinde (Aktuğ, 2005) belirlenmiştir. Konum belirlemede standardizasyonu sağlamak için tüm ölçü ekipleri aynı özelliklere sahip benzer anten/alıcı sistemini kullanmıştır. Alıcının nokta üzerinde sabitlenip gerekli düzeltmeleri almasını müteakip, 10 epok okuma toplanmış ve okumaların ortalaması ile bulunan 3 boyutlu koordinatlar esas alınmıştır. Sabitlenme problemi ile karşılaşılması durumunda, en az 45 dakika statik gözlem yapılarak çözümleme yapılmıştır. Yersel gravimetri noktalarının yatay koordinatları birkaç cm, elipsoit yüksekliği ise 1 dm'den daha iyi duyarlıkta belirlenmiştir.



Şekil 1. Örnek nokta tesisleri ve konum belirleme.

c. Mutlak Gravimetri

TRGrav-Net ve kalibrasyon bazı mutlak gravimetri noktalarında A10 (#044) mutlak gravimetresi kullanılarak, kuzey ve güney yönlü olmak üzere iki farklı oturum gerçekleştirilmiştir. Her bir oturumda 8 set gözlem yapılmıştır. Bir set

1 saniye aralıklı 120 serbest düşmeden oluşmaktadır. Birinci oturumda mutlak gravimetre kuzey, ikinci oturumda ise sökülüp tekrar kurularak güney doğrultusuna yönlendirilmektedir. Böylece kurulum ve düzeçlemeden kaynaklanabilecek kaba hataların önüne geçilmektedir. İki oturum arasındaki farkın 10 μGal 'i geçmesi durumunda ilave üçüncü ya da dördüncü oturum yapılmaktadır (Akdoğan ve diğerleri, 2019). Mutlak gravimetre ve elektronik üniteleri, içerisinde kesintisiz güç kaynağı olan özel olarak tasarlanmış bir araç ile taşınmaktadır. Mutlak gravite okumalarının, cihazın efektif (referans) yüksekliğinden nokta yüzeyine indirgenmesi amacıyla, her bir mutlak gravite noktasında bağıl gravimetre ile düşey gravite gradyenti ölçüleri yapılmaktadır. Efektif yükseklik, mutlak gravimetrenin serbest düşüş yolu üzerinde yer alan ve sonuç gravite değerinin, kullanılan düşey gradyent değerinden bağımsız olduğu referans yüksekliği olarak tanımlanmaktadır (Timmen, 2003).



Şekil 2. Düşey gravite gradyenti ve mutlak gravite ölçümleri.

Bunun için yerden yüksekliği 25-95-150 cm olan üç farklı yüksekliğe sahip özel bir platform tasarlanmıştır. Bağıl gravite okumaları; A-O-Ü-O-A-Ü-A-O-Ü (A: alt, O: orta, U: üst) sıralamasıyla,

her seviyede 60 saniye süreli ve 3 okuma olacak şekilde yapılarak, hem serbestlik derecesi artırılmış hem de gradyent kestiriminde doğrusal olmayan terim de belirlenebilmiştir (Akdoğan ve diğerleri, 2019). Bir mutlak gravimetri noktası üzerinde gerçekleştirilen düşey gravite gradyent ve mutlak gravite ölçülerine ilişkin görseller Şekil 2'de sunulmuştur.

ç. Bağıl Gravimetri

Bağıl gravimetri ölçmelerinde Scintrex CG-5 ve CG-6 gravimetreleri kullanılmıştır. Gravimetrelerin günlük sürüklenme (drift) değerlerini belirleyebilmek amacıyla, A-B-C-D-E-C-B-A ölçü sıralamasına sahip profil yöntemi uygulanmıştır. Gravimetreler, noktalar arasında standart taşıma çantaları içerisinde ve arazi araçlarıyla taşınmıştır. Rüzgâr ve direkt güneş ışınlarından korumak için rüzgâr koruyucu veya şemsiye kullanılmıştır.



Şekil 3. Bağıl gravimetri çalışmaları.

Gravimetreler nokta üzerinde yerleştirildiğinde pusula yardımıyla kuzeye yönlendirilmiş, düzeçleme sonrasında iç sıcaklığın ve sensörün durağan hale gelmesi için en az 10 dakika bekletilmiştir. 6 Hz örneklem aralıklı gözlemlerin ortalamasından oluşan 60 saniye süreli en az 5 okuma gerçekleştirilmiştir. Son 5 okuma arasında

5 μGal 'den daha az bir değişim olması ve okumalarda yukarı/aşağı yönlü bir eğilim görülmemesi durumunda ölçüm tamamlanmıştır. Düzeltme kaymaları 5 yay saniyesinden ve standart sapması 0.3 mGal'den yüksek okumalar değerlendirme dışında bırakılmıştır. Her bir gravite okuması sonrası atmosferik basınç ve sıcaklık değerleri kaydedilmiştir. Ölçümler sırasında gravimetreye özgü iç düzeltmeler (gelgit düzeltmesi vb.) ve filtreler (sürekli düzeç eğimi düzeltmesi, sismik filtre vb.) aktif hale getirilmiştir. Bağlı gravimetri çalışmalarına ilişkin görseller Şekil 3'te sunulmuştur.

d. Veri İşlem

(1) Mutlak Gravimetri

Mutlak gravite ölçümleri, Micro-g LaCoste tarafından sağlanan g9 yazılımı (Micro-g LaCoste, 2012) ile işlenmiştir. Vakumlu ortamda ilk hızı v_0 , başlangıç konumu x_0 ve düşey gravite gradyent değeri γ bilenen bir test kütesinin serbest düşüşü sırasında, lazer interferometre ile hassas bir şekilde izlenmekte, konum x_i ve zaman ölçümleri t_i yapılmaktadır. (1) eşitliği ile verilen gözlem eşitliğinin en küçük karelerle çözümü ile mutlak gravite değeri g_0 hesaplanabilmektedir (Micro-g LaCoste, 2012).

$$x_i = x_0 + v_0 \tilde{t}_i + \frac{g_0 \tilde{t}_i^2}{2} + \frac{\gamma x_0 \tilde{t}_i^2}{2} + \frac{\gamma v_0 \tilde{t}_i^3}{6} + \frac{\gamma g_0 \tilde{t}_i^4}{24}$$

$$\tilde{t}_i = t_i - \frac{(x_i - x_0)}{c} \quad (1)$$

Çevresel etkilerden kaynaklanan gravite indirgemeleri yazılım tarafından hesaplanmakta ve ham ölçülere uygulanmaktadır. Katı Yer gelgitleri için ETGTAB programı (Wenzel H-G, 1996), 1200 dalgalı Tamura (1987) gelgit potansiyeli kataloğuyla birlikte kullanılmıştır. Okyanus yüklemesi etkisi FES2004 okyanus gelgiti modeli (Lyard ve diğerleri, 2006) kullanılarak belirlenmiştir. Kutup gezinmesi düzeltmesi için IERS Bülten B'de verilen günlük kutup koordinatları ve 1.16 genlik faktörü kullanılmıştır. Atmosferik kütle değişimlerimden kaynaklı gravite indirgemeleri için 0.3 $\mu\text{Gal} \cdot \text{hPa}^{-1}$ deneysel katsayı uygulanmıştır. Mutlak gravite değerleri, cihazın efektif yükseklik noktasında belirlenmiştir. A10 (#044) mutlak gravimetresi efektif yüksekliği, yapılan denemeler sonucunda fabrika alet yüksekliğinin 3.74 cm altında bulunmuştur (Simav ve Yıldız, 2019). Sistem ve set dağılım belirsizliklerini de içerecek şekilde bugüne kadar tesis edilen 100 adet mutlak gravimetri noktasında toplam belirsizlik 10 μGal seviyesindedir.

Efektif yükseklikteki gravite değerinin farklı bir yükseklikteki karşılığını bulmak için düşey gravite gradyent değerleri $\gamma(h_i)$, gereklidir. Bu değerler, 2.c bölümünde açıklanan farklı yüksekliklerdeki $R^c(h)$ indirgenmiş bağlı gravite okumalarına, (2) eşitliğindeki kuadratik fonksiyonun uydurulması ve elde edilen a ve b polinom katsayılarının (3) eşitliğinde kullanılmasıyla hesaplanmıştır. (3) eşitliğindeki h_i terimi efektif yüksekliği ifade etmektedir ve A10 (#044) gravimetresi için 68.26 cm'dir (Simav ve Yıldız, 2019).

$$R^c(h) = a \cdot h^2 + b \cdot h + c \quad (2)$$

$$\gamma(h_i) = a \cdot h_i + b \quad (3)$$

100 adet mutlak gravimetri noktasında efektif yükseklikte kestirilen $\gamma(h_i)$ değerleri 0.2392-0.4125 mGal/m arasında değişkenlik göstermekte olup, konumsal dağılımı Şekil 4(a)'da, nokta yüksekliğine göre değişimi ise Şekil 4(b)'de sunulmuştur.

(2) Bağlı Gravimetri

Ham bağlı gravimetri okumaları; katı Yer ve okyanus gelgitleri, atmosferik kütle hareketleri, kutup gezinmesi, yeraltı suyu ve toprak nemi değişimleri ve aletsel sürüklenme gibi ham ölçülere düzeltme olarak getirilmesi gereken çeşitli çevresel ve aletsel sistematik etkileri içermektedir (Torge, 1989; Timmen, 2010). Scintrex CG-5 ve CG-6 gravimetreleri, gravite okumalarına gerçek zamanlı olarak Yer gelgiti, uzun dönemli sürüklenme, düzeç sapması ve sıcaklık düzeltmesi uygulayabilmektedir (Scintrex, 2009; Scintrex, 2018). Ancak, gravimetre işlemcisi tarafından hesaplanan bu düzeltmeler basit birinci-derece modellere dayalı olduğundan yaklaşık sonuçlar sağlar. Ayrıca gravimetreler basınç, kutup gezinmesi ve okyanus yüklemesi gibi toplamda 10-20 μGal 'e erişebilen düzeltmeleri ise gerçek zamanlı olarak uygulayamaz (Cattin ve diğerleri, 2015). Literatürdeki çalışmalarla da uyumlu olacak şekilde ön-işlem aşamasında Scintrex gravimetrelerinin gerçek-zamanlı düzeltmeleri gravite okumalarından çıkarılır ve bunların yerine daha doğru/tam düzeltmeler hesaplanarak gravite okumalarına eklenir (Jousset ve diğerleri, 1995; Bonvalot ve diğerleri, 1998; Gabalda ve diğerleri, 2003; Lederer, 2009; Hector ve Hinderer, 2016).

R^R ham gravite okuması, Δg^T , Δg^A , Δg^P , Δg^O , Δg^H , Δg^D sırasıyla katı Yer gelgiti, atmosferik basınç, kutup gezinmesi, okyanus yüklemesi, gravimetre yükseklik değişimi ve sürüklenme

düzeltilmesi, k ise kalibrasyonla bulunan ölçek katsayısı olmak üzere bir t anında düzeltilmiş/indirgenmiş gravite okumaları R^c aşağıdaki şekilde yazılabilmektedir:

$$R^c(t) = (R^R(t) + \Delta g^T(t) + \Delta g^A(t) + \Delta g^P(t) + \Delta g^O(t) + \Delta g^H(t) + \Delta g^D(t)) \times k \quad (4)$$

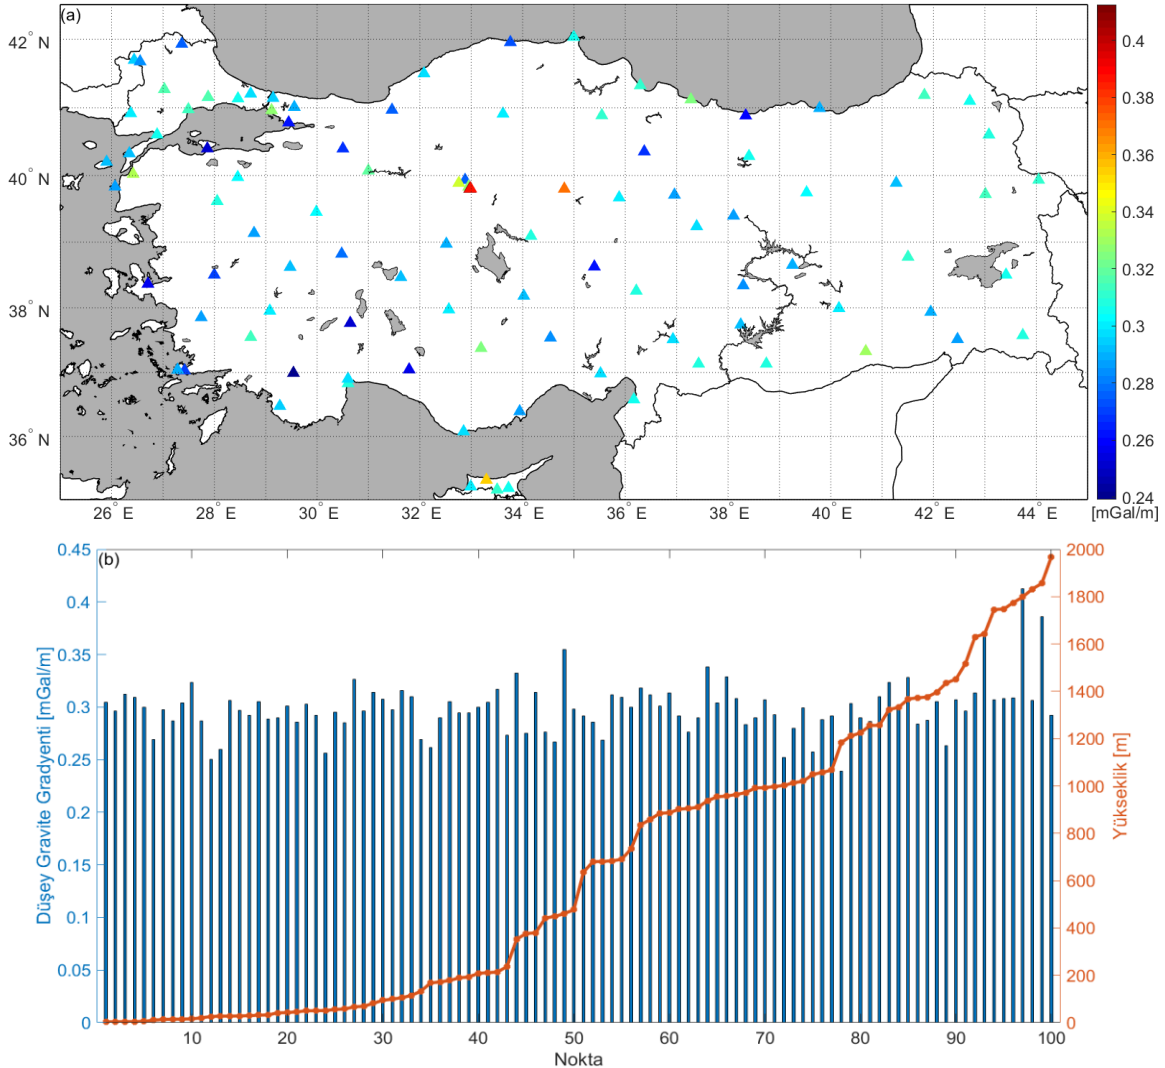
Yersel gravimetri noktalarında yeraltı su tablosu ile gravite okumaları arasındaki transfer fonksiyonu bilinmediğinden, ham okumalara yeraltı suyu ve toprak nemi değişimi düzeltmeleri uygulanmamıştır. (4) eşitliğinde verilen düzeltmelerin açık halleri Simav ve Yıldız (2019)'da verilmiş olup, hesaplamalar MATLAB ortamında geliştirilmiş bağıl gravimetri veri işlem yazılımı ile yapılmaktadır.

Bağıl gravimetri çalışmaları için kullanılan profil yönteminde ölçü bir noktadan başlayıp tekrar aynı

nokta üzerinde tamamlandığından, (5) eşitliği ile verilen günlük kapanma hatası, düzeltmelerin doğru uygulanıp uygulanmadığı, okumalarda kaba hata olup olmadığı konusunda bilgi verebilecek bir kontrol ölçütüdür.

$$C^{d,gr} = \sum \Delta R_{ij}^{d,gr} + \varepsilon_c \quad (5)$$

Her bir gün ve her bir gravimetre için belirlenen günlük kapanma hatasının $C^{d,gr}$ beklenen değeri sıfırdır. (5) eşitliğindeki $\Delta R_{ij}^{d,gr}$ terimi; d gününde gr gravimetresi ile ölçülen, i ve j noktaları arasındaki indirgenmiş okuma farkını, ε_c terimi ise modellenemeyen artık hataları ifade etmektedir. TRGrav-Net ve yersel gravimetri sıklaştırma çalışmaları kapsamında hesaplanan günlük kapanma hataları ortalama $\pm 5 \mu\text{Gal}$ seviyesindedir.



Şekil 4. 100 mutlak gravite noktasındaki düşey gravite gradyentleri. (a) Konumsal dağılımı, (b) Nokta yüksekliğine göre değişimi.

Bağlı gravimetri okuma farkları ölçü olarak alınarak ve aşağıdaki gözlem modeli kullanılarak ağırlıklı ve zorlamalı en küçük kareler yöntemi ile dengelenmektedir (Simav ve Yıldız, 2019).

$$\Delta l_{ij}^{gr} + v_{ij} = g_j - g_i + \sum_{n=1}^N d_n^{gr} (t_j - t_i) \quad (6)$$

$$\Delta l_{ij}^{gr} = R_j^{wm} - R_i^{wm} \quad (7)$$

$$R_i^{wm} = \frac{\sum_{n=1}^{NR} \frac{R_n^c}{SE_n^2}}{\sum_{n=1}^{NR} \frac{1}{SE_n^2}} \quad (8)$$

$$\sigma_i^{wm} = \sqrt{\frac{1}{\sum_{n=1}^{NR} \frac{1}{SE_n^2}}} \quad (9)$$

$$\sigma_{ij} = \sqrt{(\sigma_i^{wm})^2 + (\sigma_j^{wm})^2} \quad (10)$$

Bir yersel gravimetri noktası üzerinde bölüm 2.ç'de bahsedildiği gibi birden çok gravite okuması yapılmaktadır. Nokta üzerindeki ağırlıklı ortalama okuma değeri R_i^{wm} ve standart sapması σ_i^{wm} , (8) ve (9) eşitliklerinde gösterildiği şekilde NR adet okumanın ağırlıklı ortalaması şeklinde hesaplanmaktadır. (8) eşitliğindeki R_n^c terimi n 'inci indirgeniş gravite okumasını, SE terimi ise bu okumaya karşılık gelen standart hatayı ifade etmektedir. i ve j noktaları arasında t_i ve t_j zamanlarında gr bağlı gravimetresi ile bulunan okuma farkı ve bu farka ait standart sapma (7) ve (10) eşitlikleri ile verilmektedir. g_i ve g_j , noktaların gravite değerleri, d_n^{gr} ise gr gravimetresinin artık sürüklenme katsayısıdır.

(6) eşitliğinin en küçük kareler çözümü, değişik çözümler de olmakla birlikte, en az bir mutlak gravite noktasının datum noktası olarak sabit alınması veya ağırlı zorlanması ile elde edilebilir (Hwang ve diğerleri, 2002). n gözlem denklemi sayısı, r zorlamalı çözümde kullanılacak ilave gözlem sayısı, u kestirilecek parametre sayısı, L , $n \times 1$ boyutlu ve Δl_{ij}^{gr} değerlerinden oluşan gözlem vektörü, P , $n \times n$ boyutlu σ_{ij}^2 gözlem varyanslarına bağlı oluşturulan ağırlık matrisi, A , $n \times u$ boyutlu dizayn matrisi, L_g , öncül mutlak gravite değerlerinden oluşan ilave gözlem vektörü, P_g ve A_g ilave gözlemlere ilişkin ağırlık ve dizayn matrisi olmak üzere en küçük kareler çözümü

aşağıdaki eşitliklerle verilmektedir (Simav ve Yıldız, 2019).

$$\hat{X} = (A^T P A + A_g^T P_g A_g)^{-1} (A^T P L + A_g^T P_g L_g) \quad (11)$$

$$V = \begin{bmatrix} v \\ v_g \end{bmatrix} = \begin{bmatrix} A \\ A_g \end{bmatrix} \hat{X} - \begin{bmatrix} L \\ L_g \end{bmatrix} \quad (12)$$

$$\hat{\sigma}_0^2 = \frac{V^T P V + V_g^T P_g V_g}{n+r-u} \quad (13)$$

$$C_{\hat{X}} = \hat{\sigma}_0^2 (A^T P A + A_g^T P_g A_g)^{-1} \quad (14)$$

Dengeleme sonrası Chi-kare χ^2 global varyans testi (Koch, 1987) ve kaba hatalı ölçülerin belirlenmesi için Pope τ -testi (Pope, 1976) uygulanmaktadır.

3. ANKARA KALİBRASYON BAZI VE BAĞIL GRAVİMETRELERİN KALİBRASYONU

Bağlı gravimetri doğruluğunu etkileyen en önemli hususlardan biri kullanılan gravimetrelerin kalibrasyonudur (Torge, 1989; Hugill, 1990; Seigel ve diğerleri, 1995; Becker ve diğerleri, 1995). Yüksek doğruluklu ve duyarlı gözlemler için bağlı gravimetre kalibrasyon veya ölçek faktörünün %0.01 görece doğruluk (10 mGal gravite aralığında 1 μ Gal ölçü hatası) ile belirlenmesi gerekir (Gabalda ve diğerleri, 2003). Scintrex CG-5 ve CG-6 gravimetrelerinin GCAL1 isimli kalibrasyon sabiti, üretici tarafından Toronto/Kanada bölgesindeki kalibrasyon bazında belirlenmektedir. Ancak bu sabitin, gravimetre sensöründeki yaşlanmaya bağlı olarak belirli aralıklarla kontrol edilmesi ve gerekirse gravimetrenin yeniden kalibre edilmesi önerilmektedir (Scintrex, 2009; Scintrex, 2018). (15) ve (16) eşitliklerinde gösterildiği gibi, doğrusal ölçek faktörü k 'nin doğruluğu, kalibrasyon bazı noktaları arasındaki gravite farkına Δg_{ij} , noktalar arasındaki okuma farkına ΔR_{ij} ve bu değerlerin doğruluğuna ($\sigma_{\Delta g}$ ve $\sigma_{\Delta R}$) bağlıdır.

$$\Delta g_{ij} = k \cdot \Delta R_{ij} \quad (15)$$

$$\sigma_k = \frac{1}{\Delta R_{ij}} \cdot \sqrt{\sigma_{\Delta g}^2 + \sigma_{\Delta R}^2 \frac{\Delta g_{ij}^2}{\Delta R_{ij}^2}} \quad (16)$$

Ankara ili sınırları içerisinde Şekil 5'de konumları gösterilen ve iki mutlak gravite noktasından oluşan (Cebeci ve Elmadağ) kalibrasyon bazı kurulmuştur. Bu yeni bazın en önemli yararı, noktaların coğrafi olarak birbirlerine yakın olması (~20 km, 15-20 dk. sürüş mesafesi)

ve noktalar arası yüksek gravite farkıdır (~210 mGal). Mesafenin kısa olması, gün içerisinde noktalar arasında çok sayıda ölçü alınabilmesine ve serbestlik derecesinin artırılmasına olanak sağlamaktadır.

Kalibrasyon bazı noktaları A10 (#044) mutlak gravimetresi ile Bölüm 2.c'de belirtilen standartlarda ölçülmüş ve Bölüm 2.d(1)'de anlatıldığı şekilde analiz edilmiştir. TRGrav-Net ve sıkıştırma çalışmalarında kullanılan Scintrex CG-5 ve CG-6 gravimetreleri, söz konusu bazda kalibrasyona tabi tutulmuş ve yeni ölçek katsayıları hesaplanmıştır (Simav ve Yıldız, 2019).



Şekil 5. Ankara kalibrasyon bazı noktalarının konumları ve Elmadağ kalibrasyon noktası.

4. TRGRAV-LAB LABORATUVARI

TRGrav-Net ve yersel sıkıştırma çalışmalarında kullanılan bağıl ve mutlak gravimetreler 2015 yılı Kasım ayında teslim alınmıştır. Üretici tavsiyesi dikkate alınarak, gravimetreler arazi çalışmaları öncesinde uzun süreli sabit gözlemlerle bir dizi kontrole tabi tutulmuş, gürültü karakteristikleri ve sürüklenme katsayıları düzenli aralıklarla izlenmiştir. Bu maksatla; doğal, çevresel ve insan kaynaklı gürültülerden olabildiğince arındırılmış, bina

temelinden bağımsız ve ana kaya üzerine oturtulmuş 4 adet sismik kütle platformundan oluşan bir laboratuvar (TRGrav-Lab) tesis edilmiştir. TRGrav-Lab, kesintisiz güç kaynağı ve bina çatısına yerleştirilmiş GNSS anteni, yangın algılama/uyarı/söndürme sistemi ile 10-40°C arası sıcaklık değişimi sağlayabilecek ısıtma/soğutma sistemine sahiptir. Laboratuvara ait görseller Şekil 6'da sunulmuştur.

Laboratuvarda gerçekleştirilen sürekli gözlemlerle bağıl gravimetrelerin gravite sensörü, gürültü karakteristikleri, sürüklenme katsayıları, sıcaklık değişimlerine duyarlılığı, düzeç sensörleri, bataryaları ve saat sapmaları (Scintrex, 2009; Scintrex, 2018) düzenli aralıklarla izlenmiştir.



Şekil 6. TRGrav-Lab laboratuvarı.

İlk birkaç ay boyunca, bağıl gravimetrelerin sürüklenme hızlarının 2.5 mGal/gün'e kadar ulaştığı ve zamanla azalarak 1mGal/gün altına indiği gözlenmiştir. Laboratuvar ve arazi şartlarında gerçekleştirilen tekrarlı gözlemlerin standart sapması, Scintrex CG-5 ve CG-6 gravimetrelerinin üretici kataloglarında (Scintrex, 2009; Scintrex, 2018) belirtildiği şekilde $\pm 5-10$ μ Gal aralığında bulunmuştur (Simav ve Yıldız, 2019).

A-10 (#044) mutlak gravimetresinin TÜBİTAK Ulusal Metroloji Enstitüsü laboratuvarında saat ve lazer kalibrasyonları yapılmış, FG-5X (#254) gravimetresi ile eş zamanlı olarak karşılaştırılması gerçekleştirilmiştir. Karşılaştırma sonuçları ve tekrarlıları değerlendirildiğinde, A-10 (#044) gravimetresinin üretici kataloğuyla uyumlu sonuçlar (≤ 10 μ Gal) verdiği gözlenmiştir (Micro-g LaCoste, 2008). FG-5X (#254) ve A-10 (#044) karşılaştırmasına ilişkin bir görsel Şekil 7'de sunulmuştur.



Şekil 7. FG-5X (#254) ve A-10 (#044) mutlak gravimetre karşılaştırması için laboratuvar çalışması.

5. TRGRAV-WEB VERİ PORTALI

Yersel gravimetri standardizasyonunun önemli unsurlarından biri de veri yönetimi ve sunumudur. Gravite alanı ölçümlerinde farklı tür ve formatta toplanan verilerin, ölçümün yapıldığı gün çevrimiçi olarak ilişkiyel bir veri tabanına yüklenmesi, yükleme sırasında bir dizi kontrolden geçirilmesi, verilerin belirli bir düzen içerisinde meta verileri ile birlikte depolanması ve altlık harita destekli görsel bir platform üzerinden sunularak gerekli sorgulamaların yapılabilmesi maksadıyla TRGrav-Web portalı geliştirilmiştir (Simav ve diğerleri, 2016).

<https://trgrav.harita.gov.tr> adresinden hizmet veren uygulama, PostGIS/PostgreSQL veri tabanı

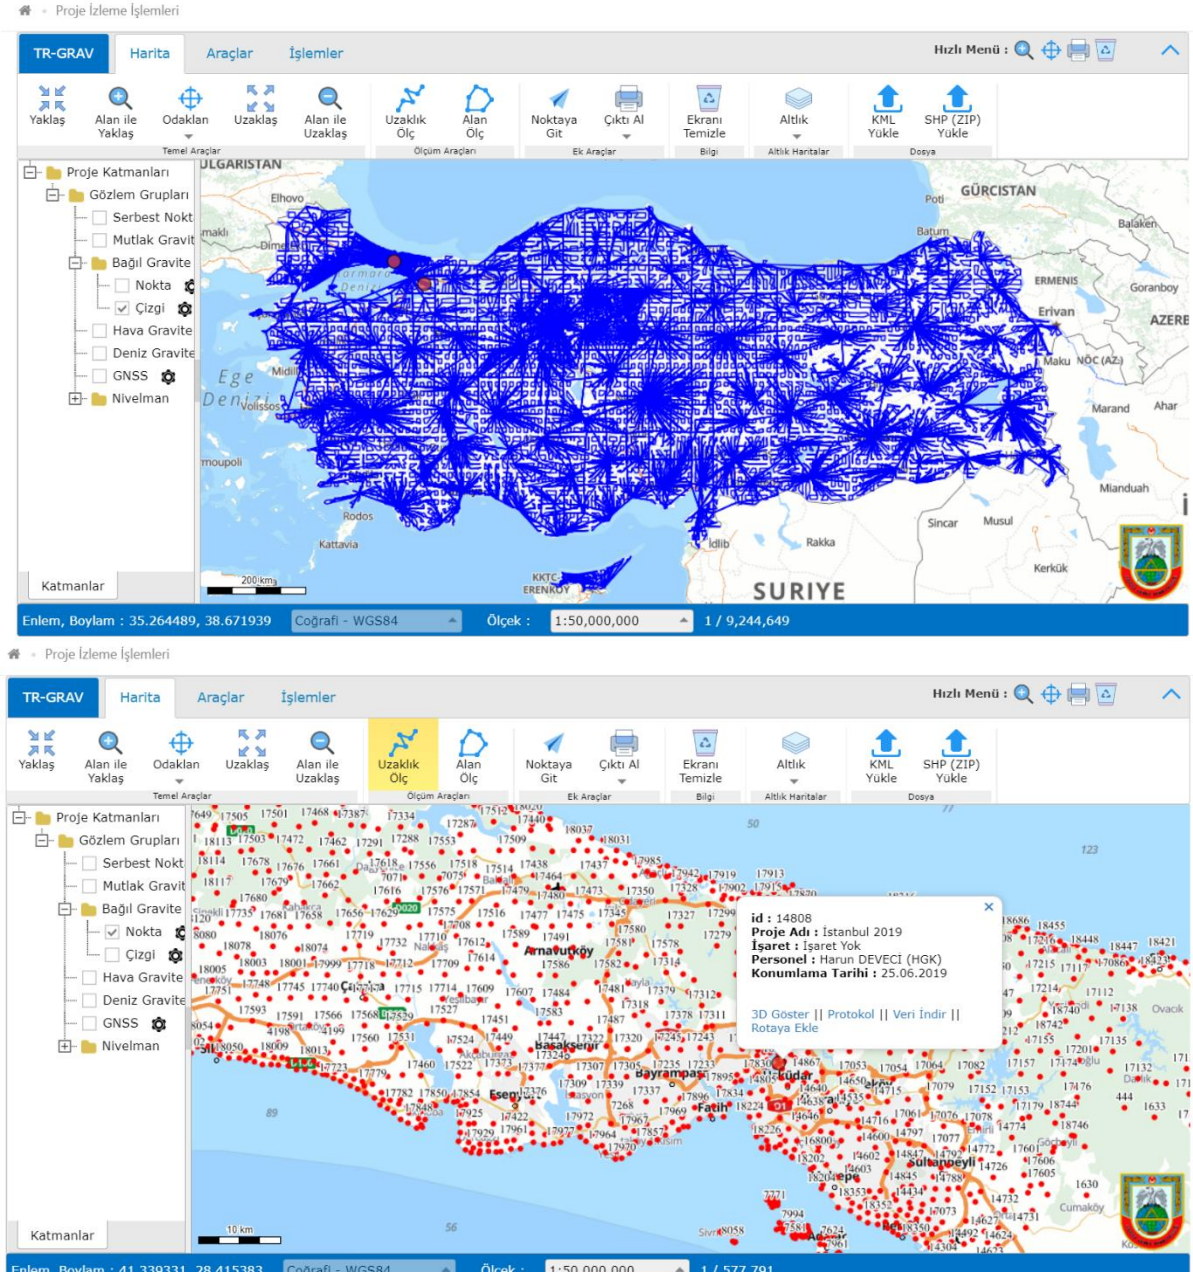
üzerine inşa edilmiştir. C# ve JavaScript dilleri kullanılarak geliştirilen arayüzlere, sadece sisteme tanımlı kullanıcılar erişebilmektedir. Tanımlı bir kullanıcı iki aşamalı kimlik doğrulamadan geçirildikten sonra sadece yetkili olduğu sayfalara ve projelere erişim sağlayabilmektedir.

Tanımlı ve yetkili bir kullanıcı, ölçü noktasının konumu ve konuma ilişkin meta verileri tanımlayabilmekte, listeledebilmekte, görüntüleyebilmekte, düzenleyip silebilmektedir. Nokta protokolleri PDF dosyası olarak anlık hazırlanmaktadır. Sisteme; Scintrex CG-5 ve CG-6 bağıl gravimetre çıktı dosyası, Micro g LaCoste FG5X ve A10 mutlak gravimetre çıktı dosyası, GNSS RINEX dosyaları, nivelman gözlem dosyası, hava gravimetrisi gözlem dosyaları kontrollü bir şekilde yüklenebilmektedir. Görselleştirmede farklı türlerde sayısal harita altlıkları seçilebilmekte, semboloji, yazı tipi/büyükklüğü değiştirme gibi kartografik zenginleştirmeler uygulanabilmektedir. TRGrav-Web portalına ait görüntüler Şekil 8'de sunulmuştur.

6. TRGRAV-NET ULUSAL GRAVİTE STANDARDİZASYON AĞI

Bağıl gravimetri, noktalar arası gravite farklarının ölçülmesi olarak tanımlanabilir. Ancak görelî ölçülerin datumunun ve ölçeğinin belirlenebilmesi için bir gravite referans sistemine bağlanması gerekmektedir. Bu amaçla, referans noktalarından oluşan gravite standardizasyon ağları kurulmakta ve yaşıatılmaktadır (Torge, 1989).

Türkiye'de ilk gravite ağı Harita Genel Müdürlüğü tarafından 1956-1960 yılları arasında kurulmuş, Norgaard gravimetresi ile ölçülmüş toplam 24 noktadan oluşan bir ağıdır. TTGA-56 olarak adlandırılan bu ağın doğruluğu zaman içinde jeodezik, jeofizik, jeodinamik ve mühendislik amaçlı çalışmalardaki beklentileri karşılamaktan uzak kalmıştır (Ayhan ve diğerleri, 1992). TTGA-56 datumunun tek nokta ile belirlenmesindeki olumsuzluk ve nokta gravite değerinin düşük doğrulukta olması nedeniyle bu ağın daha duyarlı gravimetreler ile yeniden ölçülmesi ve farklı kurumlar tarafından farklı bölgelerde tesis edilen kalibrasyon ağlarının birleştirilerek doğruluğu yüksek bir kalibrasyon bazının kurulması, Harita Genel Müdürlüğü ve MTA arasında 1993 yılında imzalanan protokol kapsamına alınmıştır. 1993-2001 yılları arasında yapılan çalışmalarla Türkiye Temel Gravite Ağı-1999 (TTGA-99) oluşturulmuştur (Demir ve diğerleri, 2006).



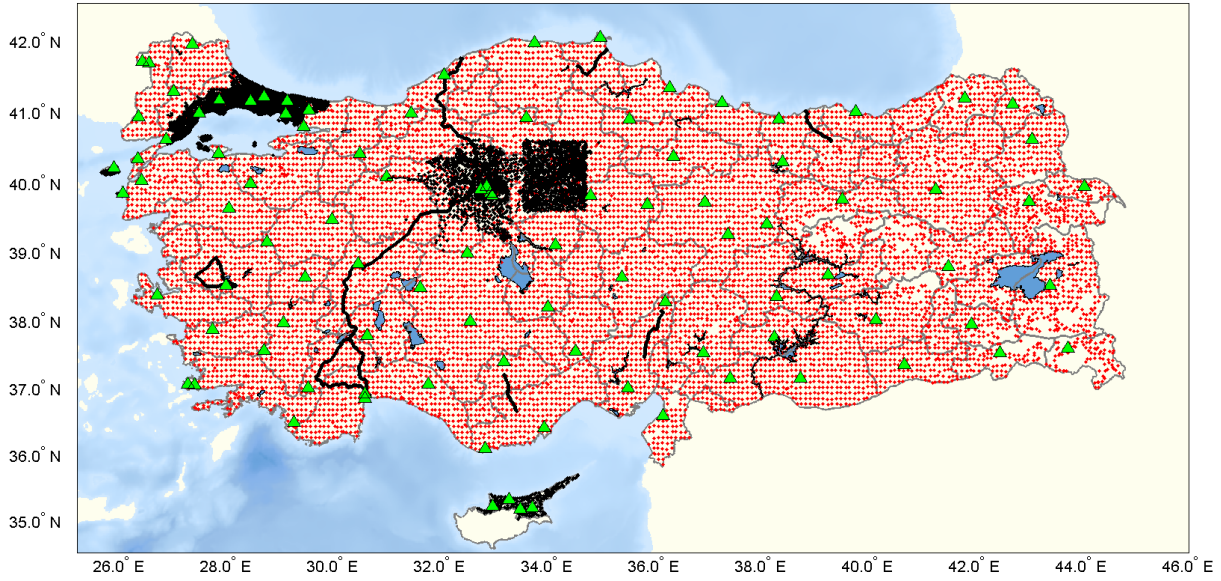
Şekil 8. TRGrav-Web portalı.

TTGA-99, 55 adet birinci derece ve 13 mutlak gravite noktası (Wilmes ve diğerleri, 1997) olmak üzere toplam 68 noktadan oluşmaktadır. TTGA-99 noktaları arasındaki 132 bağlantı ölçüsü, iki LCR-G gravimetresi ile gerçekleştirilmiştir. TTGA-99'un nokta sayısının az, dağılımın ise düzensiz olması, bunun yanında aradan geçen sürede noktaların doğal ve insan kaynaklı etkilere maruz kalarak tahrip olması sebebiyle yeni bir ulusal standardizasyon ağının kurulmasına ihtiyaç duyulmuştur.

Türkiye Yükseklik Sisteminin Modernizasyonu ve Gravite Altyapısının İyileştirilmesi (2015-2020)


projesi kapsamında; 2016-2020 yılları arasında Harita Genel Müdürlüğü, MTA, TPAO, TÜBİTAK-MAM ve TÜBİTAK UME iş birliği ile gerçekleştirilen mutlak ve bağıl gravimetri çalışmaları sonucu 100 adedi mutlak olmak üzere toplam 11783 noktadan oluşan yeni gravite standardizasyon ağı TRGrav-Net oluşturulmuştur (Şekil 9).

Her bir il sınırı içerisine en az bir mutlak gravite noktası düşecek şekilde TRGrav-Net ağ noktaları arası yaklaşık 10 km olarak seçilmiştir. Nokta yeri seçiminde, konumlamada ve gravite ölçümlerinde 2'nci bölümdeki standartlar uygulanmıştır.



Şekil 9. TRGrav-Net Ulusal Gravite Standardizasyon Ağı noktaları (kırmızı), TRGrav-Net mutlak gravimetri noktaları (yeşil), yersel gravite sıklaştırma ve gravite ölçüsü yapılan nivelman noktaları (siyah).

Ağın iç duyarlılığını test etmek ve varsa kaba ve sistematik hataları belirleyebilmek amacıyla ağ önce bir mutlak gravite noktası sabit alınarak minimum zorlamalı olarak dengelenmiştir. İlk iterasyon sonunda istatistiksel değerleri %95 güven düzeyinde kritik τ değerlerine yakın birkaç kaba hatalı ölçü tespit edilmiştir. Kritik değere yakın olması sebebiyle kaba hatalı ölçüler ölçü listesinden çıkarılmayıp ağırlıkları düşürülerek ikinci iterasyon çalıştırılmıştır. Bu iterasyon sonunda aposteriori varyans faktörü 1.001 olarak bulunmuş ve global testi başarıyla geçmiştir. Minimum zorlamada kullanılmayan 99 mutlak gravimetri noktasının A10 (#044) ile belirlenen gravite değerleri ile dengeleme sonrası bulunan değerleri arasında 28.2 μGal 'lik bir ortalama ve 34.9 μGal 'lik standart sapmaya sahip iyi bir uyum bulunmuştur (Şekil 10).




Şekil 10. Minimum zorlamalı ağ çözümünün mutlak gravimetri noktalarında karşılaştırılması.

Tüm mutlak gravimetri noktalarının dengelemeye dâhil edildiği zorlamalı çözüm sonuçları Tablo 1'de sunulmuştur.

Tablo 1: TRGrav-Net ağırlıklı ve zorlamalı en küçük kareler dengeleme istatistikleri (σ : Nokta gravite değeri standart sapmaları, v : Gözlem düzeltmeleri).

	Maks.	Min.	Ort.	RMS
σ (μGal)	65.2	10.1	34.9	35.3
v (μGal)	118.9	-129.8	-0.5	9.7

Gözlem düzeltmelerine (v) uygulanan tek-örneklem Kolmogorov-Smirnow testi, gözlem düzeltmelerinin %5 anlamlılık seviyesinde sıfır ortalama ve 10 μGal standart sapma ile normal dağılıma uyduğunu göstermektedir (Şekil 11).



Şekil 11. TRGrav-Net zorlamalı ağ dengelemesi gözlem düzeltmeleri.

7. SIKLAŞTIRMA ÇALIŞMALARI

TRGrav-Net ağ kurulum çalışmaları devam ederken, İstanbul, Ankara, Tekirdağ illeri ile ~110 x 100 km genişliğindeki Kırıkkale-Çorum hava gravimetrisi test alanında, Marmara Denizi'nde 1.5 km²'den daha büyük adaların tamamında, Gökçeada ve Bozcada ile KKTC genelinde birkaç kilometre konumsal çözünürlükte gravite sıklaştırma çalışmaları yapılmıştır. Bunun yanında ülke genelinde jeoit modeli kontrolü için farklı bölgelerde tesis edilen 7 farklı nivelman hattına ait 1757 noktada yersel gravimetri çalışmaları gerçekleştirilmiştir (Şekil 9). 2021 yılı içerisinde, Ankara'nın güney ve batı kesiminde, Tekirdağ'ın kuzey kesiminde ve Çanakkale ili genelinde sıklaştırma çalışmalarına devam edilmektedir. Sıklaştırma çalışmaları ikinci bölümde bahsedilen standartlara uygun olarak yürütülmekte olup, ilk dengeleme sonuçları TRGrav-Net ağ duyarlılığı ve doğruluğuna çok yakındır.

8. GÜNCEL YERSEL GRAVİTE VERİLERİYLE GERÇEKLEŞTİRİLEN UYGULAMALAR

2016 yılından itibaren devam etmekte olan yersel gravimetri çalışmaları kapsamında elde edilen yüksek konum ve ölçüm doğruluğuna sahip gravite verileri; tarihsel gravite verilerinin kalite kontrolünde, hava gravimetrisi test çalışmalarında ve TG-20 jeoit modeli hesaplamalarında kullanılmıştır.

a. Tarihsel Gravite Verilerinin Kalite Kontrolü

Tarihsel gravite verileri, MTA ve TPAO'dan temin edilen yaklaşık 300.000 nokta verisinden oluşmaktadır. Bu verilerin toplanması ve işlenmesi sırasında yeterli düzeyde kayıt tutulmaması, meta verilerinin olmaması, konum doğruluklarının düşük olması, koordinat ve gravite referans sistemlerinin farklı olması temel problemler olarak karşımıza çıkmaktadır. Tarihsel veriler, koordinat referans sistemleri ile ilgili gerekli dönüşümlerin yapılmasını müteakip, en küçük karelerle kolokasyon tekniği ile (Tscherning, 1991) kontrol edilmiştir. Bu kontrol sonucunda, MTA verilerinin bir kısmında 14 mGal civarında sistematik bir kayıklık tespit edilmiştir. Bu farkın gravite datumundan kaynaklandığı sonucuna varılmış ve gerekli datum düzeltmesi yapılmıştır. Ardından iteratif olarak $\pm 3\sigma$ kriteri uygulanarak tarihsel veriler içerisindeki olası hatalı veriler tespit edilmiştir. Bu analiz sonucunda veri kümesinin yaklaşık %5.2'sinin kaba hatalı olduğu sonuna


varılmış ve listeden çıkarılmıştır (Yıldız ve diğerleri, 2021).

b. Hava Gravimetrisi Test Alanında Uygulamalar

Kırıkkale-Çorum hava gravimetrisi test alanında gerçekleştirilen yersel gravimetri sıklaştırma verileri, 2017 ve 2018 yıllarında gerçekleştirilen ataletsel navigasyon/GNSS entegrasyonuna dayalı hava gravimetrisi testlerinde referans veri seti olarak kullanılmıştır. Yersel veriler en küçük karelerle kolokasyon yöntemiyle uçuş yüksekliğine yukarı yönlü olarak uzatılmış ve hava gravimetrisi çözümleri ile karşılaştırılmıştır. Her biri yaklaşık 100 km uzunluğundaki toplam 9 uçuş hattında yapılan karşılaştırmada, yersel veriler hava gravimetrisi çözümlerini uçuş yüksekliğinde ortalama 1 mGal uyumla doğrulamıştır (Simav ve diğerleri, 2020)

c. Türkiye Jeoit Modeli-2020

Türkiye Yükseklik Sisteminin Modernizasyonu ve Gravite Altyapısının İyileştirilmesi (2015-2020) projesinin nihai hedefi 1-3 km konumsal çözünürlükte 1-3 cm doğruluklu Türkiye Jeoit Modelini hesaplamaktır. Gravimetrik jeoit modeli çözünürlüğü ve doğruluğu, çözüme giren yersel verilerin dağılımı ve kalitesi ile yakından ilişkilidir. Proje kapsamında toplanan yüksek konum ve gravimetrik doğruluğuna sahip yersel veriler ve kalite kontrolü yapılmış tarihsel veriler, GOCE tabanlı güncel global jeopotansiyel model ve yüksek çözünürlüklü sayısal arazi modeli kullanılarak En Küçük Karelerle Stokes Modifikasyonu-İlave Düzeltmeler yöntemi (Sjöberg, 2003) ile Türkiye Jeoit Modeli-2020 hesaplanmıştır (Yıldız ve diğerleri, 2021). Proje kapsamında toplanan yeni GNSS/nivelman noktalarında yapılan karşılaştırmalarda TG-20'nin 1.2 - 6.3 cm doğruluğa eriştiği görülmüştür. Özellikle yeni yersel verinin sık olduğu Kırıkkale-Çorum bölgesindeki GNSS/nivelman noktalarında standart sapma değeri 1 cm civarında hesaplanmıştır (Yıldız ve diğerleri, 2021). Bu sonuç; yoğun ve doğru yersel gravite verisinin, gravimetrik jeoit modeli doğruluğuna etkisini göstermesi açısından önemlidir. Sonuç olarak, güncel yersel gravimetri verileri nihai proje hedefine ulaşılmasına, önceki jeoit modeli TG-03'e (Kılıçoğlu ve diğerleri, 2006) oranla, ülke sınırları içerisinde belirli karasal alanlarında maksimum 82 cm'ye (Şekil 12) ulaşan iyileştirmeler yapılmasına büyük katkı sağlamıştır.



Şekil 12. TG-20 ve TG-03 jeoit modelleri arasındaki farklar ve iyileşmeler (Yıldız ve diğerleri, 2021).

9. SONUÇ VE ÖNERİLER

Türkiye Yükseklik Sisteminin Modernizasyonu ve Gravite Altyapısının İyileştirilmesi (2015-2020) projesi kapsamında, 2016 yılından itibaren beş kurumun iş birliğiyle ülke genelinde yoğun yersel gravimetri çalışmaları gerçekleştirilmiştir. Bu çalışmaların temel hedefi ulusal gravite veri altyapısını geliştirmek ve Türkiye bölgesel gravite alanı modelini iyileştirmektir. Yersel gravimetri çalışmaları öncesinde veri toplama ve işleme standartları belirlenmiş, yeni bir kalibrasyon bazı oluşturulmuş, inşa edilen gravimetri laboratuvarında (TRGrav-Lab) çalışmalarda kullanılan gravimetrelerin performansı sürekli olarak izlenmiş ve bir veri portalı (TRGrav-Web) kurulmuştur. 2016 yılı Nisan ayından sonra ise mutlak ve bağıl gravimetri çalışmalarına başlanarak 11783 noktadan oluşan yeni bir gravite standardizasyon ağı (TRGrav-Net) oluşturulmuştur. Eş zamanlı olarak bu ağa dayalı olarak İstanbul, Ankara, Tekirdağ illeri ile Kırıkkale-Çorum hava gravimetrisi test alanında, Marmara Denizi adalarında, Gökçeada, Bozcaada ve KKTC'de sıklaştırma çalışmaları icra edilmiştir. 1707 km ve 1754 noktadan oluşan 7 farklı bölgedeki nivelman hatlarında gravite ölçümleri yapılmıştır. Bugüne kadar toplanan yüksek konum ve gravite doğruluğuna sahip yersel gravimetri verileri, tarihsel gravite verilerinin kalite kontrolünde, hava gravimetrisi test çalışmalarında ve TG-20 jeoit modeli hesaplamalarında kullanılmış ve proje hedefine ulaşılmasına önemli katkı sağlamıştır.

Halen Tekirdağ ve Çanakkale il sınırları içerisinde sıklaştırma çalışmalarına devam edilmektedir. Gelecek dönemde de büyük şehirler başta olmak üzere yersel, hava ve mobil gravimetri ile sıklaştırma işlerine devam edilecektir. Yeni verilerle Türkiye Jeoit modeli güncellenerek kullanıcıların hizmetine sunulacaktır.


TEŞEKKÜR

Bu çalışma, Harita Genel Müdürlüğü koordinatörlüğünde yürütülmüş olan T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı destekli ve 2015K090710 numaralı "Türkiye Yükseklik Sisteminin Modernizasyonu ve Gravite Altyapısının İyileştirilmesi (2015-2020)" projesinin bir parçasıdır. Yersel gravimetri çalışmalarındaki desteklerinden dolayı Maden Tetkik ve Arama Genel Müdürlüğüne, Türkiye Petrolleri Anonim Ortaklığına, TÜBİTAK Marmara Araştırma Merkezi ve Ulusal Metroloji Enstitüsü Müdürlüğüne ve çalışmalarda emeği geçen tüm Harita Genel Müdürlüğü personeline sonsuz şükranlarımızı sunarız.

ORCID

Mehmet SİMAV  <https://orcid.org/0000-0002-3963-3871>

İlyas AKPINAR  <https://orcid.org/0000-0001-8606-140X>

Yunus Aytaç AKDOĞAN 
https://orcid.org/0000-0003-2232-5327

Hasan YILDIZ 
https://orcid.org/0000-0003-0104-7778

KAYNAKLAR

- Akdoğan, Y. A., Yıldız, H. ve Ahi, G. O. (2019). Evaluation of global gravity models from absolute gravity and vertical gravity gradient measurements in Turkey. *Measurement Science and Technology*, 30(11). doi:10.1088/1361-6501/ab2f1c
- Ayhan, M. E., Demir, C. ve Alas, B. (1992). Türkiye Temel Gravite Ağı 1956 (TTGA-56)'nın Yeniden Dengelenmesi. *Harita Dergisi*, 108, 43-58.
- Aktuğ, B. (2005). Referans sistemlerinin zamansal evrimi ve Türkiye için ulusal bir model: TURES-96, *Harita Dergisi*, 133, 1-26.
- Becker, M., Balestri, L., Bartell, R., Berrino, G., Bonvalot, S., Csapo, G., ... Gagnon, C. (1995). Microgravimetric measurements at the 1994 international comparison of absolute gravimeters. *Metrologia*, 32(3), 145. doi:10.1088/0026-1394/32/3/002
- Bonvalot, S., Diament, M. ve Gabalda, G. (1998). Continuous gravity recording with Scintrex CG-3M meters: a promising tool for monitoring active zones. *Geophysical Journal International*, 135(2), 470-494. doi:10.1046/j.1365-246X.1998.00653.x
- Cattin, R., Mazzotti, S. ve Baratin, L.-M. (2015). GravProcess: An easy-to-use MATLAB software to process campaign gravity data and evaluate the associated uncertainties. *Computers & Geosciences*, 81, 20-27. doi:10.1016/j.cageo.2015.04.005
- Demir, C., Kılıçoğlu, A. ve Fırat, O. (2006). Türkiye Temel Gravite Ağı-1999 (TTGA-99). *Harita Dergisi*, 136, 49-63.
- Gabalda, G., Bonvalot, S. ve Hipkin, R. (2003). CG3TOOL: an interactive computer program to process Scintrex CG-3/3M gravity data for high-resolution applications. *Computers & Geosciences*, 29(2), 155-171. doi:10.1016/S0098-3004(02)00114-0
- Hector, B. ve Hinderer, J. (2016). pyGrav, a Python-based program for handling and processing relative gravity data. *Computers & Geosciences*, 91, 90-97. doi:10.1016/j.cageo.2016.03.010
- Hugill, A. (1990). Scintrex CG-3 automated gravity meter: Description and field results. İçinde *SEG Technical Program Expanded Abstracts 1990* (ss. 601-604). Society of Exploration Geophysicists. doi:10.1190/1.1890276
- Hwang, C., Wang, C.-G. ve Lee, L.-H. (2002). Adjustment of relative gravity measurements using weighted and datum-free constraints. *Computers & Geosciences*, 28(9), 1005-1015. doi:10.1016/S0098-3004(02)00005-5
- Jousset, P., Van Ruymbeke, M., Bonvalot, S. ve Diament, M. (1995). Performance of two Scintrex CG3-M gravity meters at the 4th International Absolute Intercomparison, Sèvres, France. *Metrologia*, 135, 231-244. doi:10.1088/0026-1394/32/3/012
- Kılıçoğlu, A., Lenk, O., Direnç, A., Simav, M., Yıldız, H., Aktuğ, B., ... Akçakaya, M. (2010). Türkiye İzostatik Gravite Anomali Haritası. *Harita Dergisi*, 144, 1-19.
- Kılıçoğlu, A., Fırat, O. ve Demir, C. (2006). Yeni Türkiye Jeoidi (TG-03)'nin hesabında kullanılan ölçüler ve yöntemler. *TUJK 2005 Yılı Bilimsel Toplantısı, Jeoid ve Düşey Datum Çalıştayı Bildiriler ve Konuşma Tutanakları Kitabı*, 53-76, ISBN:975-6983-48-5, Karadeniz Teknik Üniversitesi, Trabzon. (Editörler: Ahmet Kaya, Mualla Yalçınkaya, Faruk Yıldırım).
- Kılıçoğlu, A., Direnç, A., Yıldız, H., Bölme, M., Aktuğ, B., Simav, M. ve Lenk, O. (2011). Regional gravimetric quasi-geoid model and transformation surface to national height system for Turkey (THG-09). *Stud Geophys Geod*, 55, 557. doi:10.1007/s11200-010-9023-z
- Koch, K.-R. (2013). *Parameter estimation and hypothesis testing in linear models*. Springer Science & Business Media.
- Micro-g LaCoste. (2008). A-10 Portable Gravimeter User's Manual. *Micro-g LaCoste Inc.*, USA.
- Micro-g LaCoste. (2012). g9 absolute gravity data acquisition and processing software. *Micro-g LaCoste Inc.*, USA.

- Lederer, M. (2009). Accuracy of the relative gravity measurement. *Acta Geodyn. Geomater*, 6(3), 155.
- Lyard, F., Lefevre, F., Letellier, T. ve Francis, O. (2006). Modelling the global ocean tides: modern insights from FES2004. *Ocean dynamics*, 56(5-6), 394-415. doi: 10.1007/s10236-006-0086-x
- Pope, A.J. (1976). The statistics of residuals and the detection of outliers. *MD: NOAA Technical Report NOS 65 NGS 1*, Rockville.
- Scintrex (2009). *CG-5 Scintrex Autograv System Operation Manual, Revision 5* (s. 304). Scintrex Limited Concord, Ontario.
- Scintrex (2018). *CG-6 Autograv Gravity Meter Operation Manual*. Scintrex Limited Concord, Ontario.
- Seigel, H. O., Brcic, I. ve Mistry, P. (1995). A guide to high precision land gravimeter surveys. *Scintrex Limited*, 222(1), 1-122.
- Simav, M., Becker, D., Yıldız, H. ve Hoss, M. (2020). Impact of temperature stabilization on the strapdown airborne gravimetry: a case study in Central Turkey. *Journal of Geodesy*, 94(4), 1-11. doi: 10.1007/s00190-020-01369-5
- Simav, M. ve Yıldız, H. (2019). Evaluation of EGM2008 and latest GOCE-based satellite only global gravity field models using densified gravity network: A case study in south-western Turkey. *Bollettino di Geofisica Teorica ed Applicata*, 60(1), 49-68. doi:10.4430/bgta0255
- Simav, M., Akpınar, İ., Sezen, E., Cingöz, A. ve Yıldız, H. (2016). TR-GRAV: National Center for Turkish Gravity Field, *EGU General Assembly, Geophysical Research Abstracts*, 18, 14110.
- Simav, M., Yıldız, H., Cingöz, A., Sezen, E., Demirsoy, N. S., Akpınar, İ., ... Yılmaz, S. (2015). Türkiye Yükseklik Sisteminin Modernizasyonu ve Gravite Altyapısının İyileştirilmesi Projesi, 15. *Türkiye Harita Bilimsel ve Teknik Kurultayı*, 25-28.
- Simav, M., Direnç, A., Türkezer, A., Kurt, A.İ. ve Kurt, M. (2012). Türkiye Yersel Gravite Veri Kütüğü Hakkında Değerlendirme. *TUJK 2012, Türkiye Yükseklik Sisteminin Modernizasyonu Çalıştayı*, 28-30 Mart, Zonguldak.
- Sjöberg, L. E. (2003). A solution to the downward continuation effect on the geoid determined by Stokes' formula. *Journal of Geodesy*, 77, 94-100. doi: 10.1007/s00190-002-0306-1
- Tamura, Y. (1987) A harmonic development of the tide-generating potential. *Bull. Inf. Marées Terr.*, 99, 6813-6855.
- Timmen, L. (2003). Precise definition of the effective measurement height of free-fall absolute gravimeters. *Metrologia*, 40(2), 62-65. doi: 10.1088/0026-1394/40/2/310
- Timmen, L. (2010). Absolute and relative gravimetry. İçinde *Sciences of Geodesy-I* (ss. 1-48). Springer. doi: 10.1007/978-3-642-11741-1_1
- Torge, W. (1989). *Gravimetry*. Walter de Gruyter, Berlin.
- Tscherning, C.C. (1991). The use of optimal estimation for gross-error detection in databases of spatially correlated data. *Bulletin d'Information*, 68, 79-89, Bureau Gravimetric International.
- Wenzel, H.-G. (1996). The nanoGal software: Earth tide data processing package: Eterna 3.3. *Bull. Info. Marées Terr.*, 124, 9425-9439.
- Wilmes, H., Falk, R., Lothhammer, A., Kressman, A., Lang, O. ve Kılıçoğlu, A. (1997). Absolute Gravity Campaign in Turkey 1996-First Results. *Proceedings of the Second Turkish-German Joint Geodetic Days* (Eds. O. Altan, L. Grundig), 27-29.
- Yıldız, H., Simav, M., Sezen, E., Akpınar, İ., Akdoğan, Y.A., Cingöz, A. ve Akabalı, O.A. (2021). Determination and validation of the Turkish Geoid-2020 (TG-20). *Bollettino di Geofisica Teorica ed Applicata*, doi.org:10.4430/bgta0346.

Derin Öğrenmenin Temel Prensipleri ve Uzaktan Algılama Alanındaki Uygulamaları

(Basic Principles of Deep Learning and Its Applications in Remote Sensing)

Elif Özlem YILMAZ , Taşkın KAVZOĞLU 

Gebze Teknik Üniversitesi, Harita Mühendisliği Bölümü, Gebze, Kocaeli
eoyilmaz@gtu.edu.tr, kavzoglu@gtu.edu.tr

Geliş Tarihi (Received): 07.01.2021

Kabul Tarihi (Accepted): 12.07.2021

ÖZ

Günümüzde, derin öğrenme mimarilerinin uzaktan algılama uygulamalarında kullanımı her geçen gün daha yaygın hale gelmektedir. Geleneksel yöntemlerle karşılaştırıldığında, uzaktan algılanmış verilerin işlenmesinde derin öğrenme modellerinin daha başarılı sonuçlar ürettiği görülmektedir. Bu modeller, bilgisayar donanımlarının gelişimine paralel olarak özellikle görüntü işleme alanında sıklıkla tercih edilmektedir. Derin öğrenme yaklaşımının uygulanması esnasında insan müdahalesinin minimum seviyede olması, nesne tespiti ve sınıflandırma gibi karmaşık problemleri çözebilmesi ve yüksek çözünürlüklü uydu görüntülerinin işlenmesindeki etkinliği gibi önemli avantajları bulunmaktadır. Ancak, derin öğrenme modellerinin eğitimi için etiketlenmiş büyük veri seti ihtiyacı ise önemli bir problem olarak karşımıza çıkmaktadır. Bu veri setlerinin yüksek doğrulukla oluşturulabilmesi zaman ve iş yükü gerektirmektedir. Bu çalışmada, bir derin öğrenme modeli olan evrimsel sinir ağı mimarisine ait evrişim, ortaklama, düzleştirme ve seyreltme katmanları ayrıntılı bir şekilde açıklanmıştır. Ayrıca, derin öğrenme mimarisini etkileyen harekete geçirme ve maliyet fonksiyonlarının çalışma prensipleri detaylı şekilde sunulmuştur. Ayrıca, uzaktan algılamada derin öğrenme mimarilerinin kullanımı; ön işleme, görüntü sınıflandırma, nesne tespiti, görüntü yorumlama ve diğer uygulama alanları başlıkları altında irdelenmiştir. Sonuç olarak, derin öğrenmenin güncel uzaktan algılama literatüründeki yeri ve önemi ortaya koyularak güncel literatür özeti de sunulmuştur.

Anahtar Kelimeler: Uzaktan Algılama, Derin Öğrenme, Evrimsel Sinir Ağları, Sınıflandırma, Görüntü İşleme.

ABSTRACT

Today, the use of deep learning architectures in remote sensing applications is becoming more and more common every day. Compared to traditional methods, deep learning models appear to produce more successful results in the processing of remotely detected data. These models are often preferred, especially in the field of image processing, in parallel with the development of computer hardware. The deep learning approach has important advantages such as the minimum level of human intervention during its implementation, the ability to solve complex problems such as object detection and classification, and its effectiveness in processing high-resolution satellite images. However, the need for a large data set labeled for training deep learning models is a major problem. Creating these data sets with high accuracy requires time and workload. In this study, convolution, pooling,

flattening, and dropout layers, which are main components of convolutional neural networks, a deep learning model, are described in detail. In addition, the principles of activation and cost functions affecting deep learning architecture are presented. In addition, the use of deep learning architectures in remote sensing has been studied under the headings of preprocessing, image classification, object detection, image interpretation and other application areas. As a result, the place and importance of deep learning in the current remote sensing literature is reviewed and the current literature summary is also presented.

Keywords: Remote Sensing, Deep Learning, Convolutional Neural Networks, Classification, Image Processing.

1. GİRİŞ

Yapay zekanın bir alt kümesi olan makine öğrenme yaklaşımı günümüzde birçok alanda yaygın olarak tercih edilmektedir. Bu yaklaşım, mühendislik alanında görüntü/video işleme, nesne tespiti ve görüntü sınıflandırma uygulamalarının yanında sağlık, ekonomi, savunma ve güvenlik gibi birçok sektörlerde kullanılmaktadır. Makine öğrenmesi yaklaşımı, veriler içindeki ilişkileri öncül bir tanımlamaya gerek duymadan belirlemek için matematiksel yöntemleri kullanan bir sistem olarak tanımlanmaktadır (Schwalbe, 2019). Son yıllarda, makine öğrenmesinin bazı karmaşık problemlere çözüm üretememesi, fazla insan müdahalesi gerektirmesi ve az miktarda veri ile işlem yapamaması gibi zayıf yönlerinin giderilmesi için araştırmalar yapılmaktadır (LeCun, Bengio ve Hinton, 2015; Zhang, Zhang, ve Du, 2016; Ma ve diğerleri, 2019). Derin öğrenme yaklaşımı da belirtilen dezavantajların önüne geçilmesi için birçok uygulamada kullanılmaktadır (Ball, Anderson ve Chan, 2017; Li ve diğerleri, 2018). Uzaktan algılamada kullanılan algılama sistemlerinin çeşitliliği (farklı çözünürlük ve algılayıcı kullanılması) ve anlık veri toplanabilmesi sebebiyle, büyük hacimli veri elde edilmektedir. Bu tür verilerin işlenmesinde derin öğrenme yöntemlerinin kullanılması çoğunlukla diğer yöntemlere göre daha başarılı sonuçlar vermektedir (Ma ve diğerleri, 2015; Zhang, Zhang ve Du, 2016; Sofu, Imamoglu, Kahraman, Cetin ve Aptoula, 2020; Suresh ve diğerleri, 2020). Az sayıda çalışmada ise makine öğrenme algoritmalarının derin öğrenme metodlarından

daha iyi sonuçlar verdiği tespit edilmiştir (örn. Dong ve diğerleri, 2020). Makine öğrenme ve derin öğrenme metodlarının bir arada kullanılması ile çalışmalarda elde edilen doğrulukların arttığı da rapor edilmiştir (Han, Ma, ve Chen, 2019). Bu nedenle, uzaktan algılama uygulamalarında derin öğrenme mimarileri sıklıkla tercih edilmekte ve diğer yöntemlere göre daha yüksek doğruluğa sahip sonuçlar vermektedir.

Derin öğrenme kavramının daha iyi bir şekilde anlaşılması için ilk olarak geçirdiği tarihsel gelişimin incelenmesi gerekmektedir. 1943 yılında McCulloch ve Pitts tarafından insan beyninin çalışma prensibini anlamak için nöronların birbirleri ile olan bağlantıları incelenerek, bir nöronun ilk matematiksel modeli oluşturulmuştur (McCulloch ve Pitts, 1943). Aynı yıl sinir ağının içerdiği parametrelerin değişebileceği üzerine bir çalışma gerçekleştirmiş ve nöronların öğrenme işlemini gerçekleştirebileceğine dair ilk fikri ortaya atmıştır (Hebb, 1943). Rosenblatt (1958)'de ise tek katmanlı algılayıcıyı, doğrusal sınıflandırma amaçlı çalışmalar için kullanılabileceğini gösterilmiştir. Bu çalışma, çok katmanlı algılayıcılara öncül bir çalışma olarak literatürdeki yerini almıştır. Tek katmanlı algılayıcıya göre daha gelişmiş bir öğrenme metoduna sahip bir algılayıcı modeli Windrof ve Hoff (1960) tarafından sunulmuştur. Burada kullanılan öğrenme metodu, nöronlara ait ağırlıkları güncelleyen bir türev (gradyan) iniş yöntemi içermektedir. Bu yaklaşımların ÖZELVEYA (XOR) problemlerinin çözümleri için yetersiz kaldığı belirlenerek kontrolsüz öğrenmenin temelleri atılmıştır (Minsky ve Papert, 1970). (Fukushima, 1980) ise görsel örüntü tanıma işlemi için çok katmanlı bir sinir ağı kullanmış ve Evrimsel Sinir Ağları fikrini ortaya atmıştır. 1982 yılında ise günümüzde kullanılan tekrarlayan sinir ağlarının atası olan Hopfield Ağı tanıtılmıştır (Hopfield, 1982). LeCunn (1989) tarafından geri yayılım prensibini kullanarak el yazısı ile yazılmış rakamları tahmin edebilen geri yayılım algoritması ile çalışan bir evrimsel sinir ağı modeli tasarlanmıştır. Daha sonra, geri yayılım algoritmasının sinir ağlarını eğitmede yetersiz kalması ve hibrit öğrenme yöntemlerinin kullanılabilmesi amacıyla, yeni sinir ağ türlerini araştırma çalışmaları hız kazanmıştır. Günümüzde ise, derin öğrenmenin problemlerinden biri olan optimizasyon gibi problemlerin yanında, bilgisayar teknolojisinin gelişmesi ile üretilen modellerin içerikleri ve öğrenme hızlarının da geliştiği gösteren çalışmalar gerçekleştirilmiştir (Ghamisi, Chen ve Zhu, 2016; Li, Zhan, Huang, Wang ve Zheng, 2016; Luus, Slamon, Van Den Berg ve Maharaj, 2015). Ayrıca, oluşturulan derin öğrenme

modeline ait ağıncültülmesi üzerine birçok araştırma yapılmaktadır. Bu çalışmalardan biri büyük boyuttaki sinir ağlarının küçültülmesi işlemidir (Sildir, Aydın ve Kavzoglu, 2020). Ağıncültülmesiyle yapılan görüntü sınıflandırma uygulamalarında modelin performansının anlamlı seviyede arttığı belirlenmiştir (Kavzoglu ve Mather, 1998, 1999). Bu alanlarda yapılmış uluslararası çalışmaların yanında, Türkiye'de de uzaktan algılama alanında derin öğrenme yöntemi kullanılarak yapılan çalışmalar bulunmaktadır (Tuna, Ünal, ve Sertel, 2018; Erdem, Bayram, Bakırmann, Bayrak ve Akpınar, 2021; Özçelik, Algancı, Sertel, ve Ünal, 2021; Wang, Algancı, ve Sertel, 2021).

Derin öğrenme yaklaşımı, canlılara ait öğrenme mekanizmasını taklit eden bir yapıya sahiptir (Wang ve Raj, 2017). Buradaki öğrenme işlemi, öğrenen modelin belirli bir görevi yerine getirmesi için modele ait parametrelerin tahmin edilmesi yoluyla gerçekleşir. Literatürde farklı derin öğrenme yaklaşımları mevcuttur. Bu yaklaşımlar; kontrollü, kontrolsüz ve hibrit öğrenme çeşitleri olarak adlandırılmaktadır (Schmidhuber, 2015; Salman, Grover, ve Shankar, 2018). Kontrollü öğrenme, etiketli verilerin kullanılması ile gerçekleştirilen bir öğrenme metodu iken, kontrolsüz öğrenme ise veriye ait öncül bir bilgi olmadan yapılan öğrenme yaklaşımıdır. Hibrit öğrenme metodu da kontrollü ve kontrolsüz öğrenme işlemlerinin birlikte kullanılmasıyla uygulanan bir öğrenme yaklaşımıdır (Alom ve diğerleri, 2019). Derin öğrenme yapıları geleneksel yapay sinir ağlarının geliştirilmiş bir versiyonu olarak değerlendirilebilir. Yapay sinir ağlarına ait sinir hücreleri girdi, gizli ve çıktı katmanlarının bir araya gelmesi ile oluşmaktadır. Tahmin edilen çıktı ile olması gereken çıktı arasındaki bağlantı ise geri yayılma metodu ile kurulur. Bu metod, sinir ağına ait parametrelerin türevinin hesaplanmasını sağlar ve ardından çıktı katmanından girdi katmanına doğru türevini hesaplayarak modelin öğrenme işlemine yardımcı olur (Kavzoglu ve Mather, 2003). Derin öğrenme modelinin gizli katman sayısının artması, modelin daha da derinleştiğinin göstergesi olduğu için derinlik kavramı kullanılmaktadır. Üçten fazla katmandan oluşan yapay sinir ağları derin öğrenme yönteminin temelini oluşturmaktadır.

Her yaklaşımda olduğu gibi derin öğrenme yaklaşımının da üstün ve zayıf yönleri bulunmaktadır. Karmaşık problemleri çözebilmesi, öğrenme işleminde kullanıcı faktörünü en aza indirmesi, büyük veride iyi performans gösterebilmesi, öğrenme işleminin kontrol edilebilmesi ve problemi çözmek için karşısına

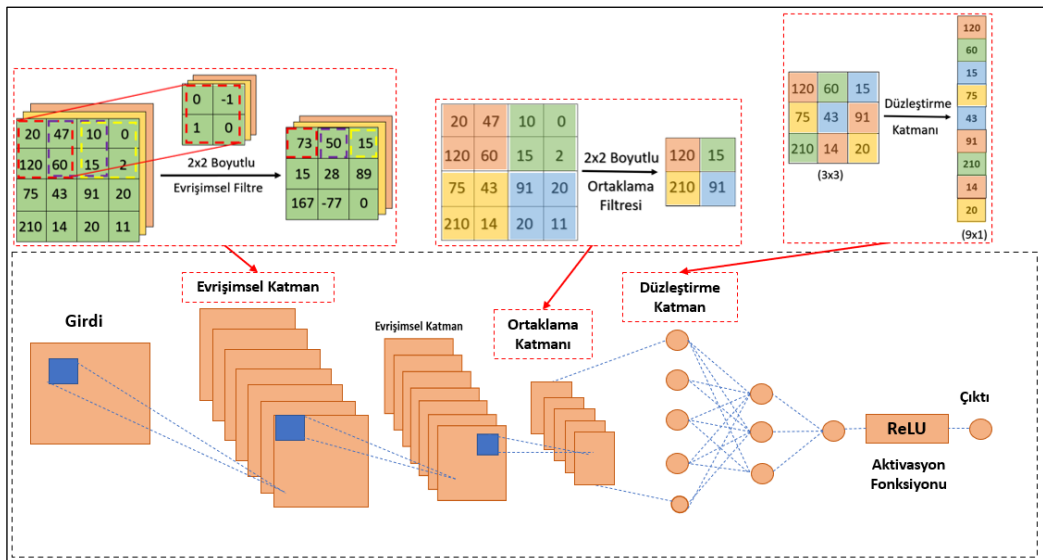
çıkan yeni sorunlara karşı adapte olabilmesi bu yaklaşımın en önemli üstün yönleridir (Claesson ve Hansson, 2017; Vali, Comai ve Matteucci, 2020). Öte yandan, derin öğrenme ağları göreceli olarak daha büyük ağlar olduğundan eğitim için daha çok veriye ihtiyaç duyması, kullandığı teknolojinin pahalı olması (özellikle yüksek Graphics Processing Unit (GPU) gereksinimi), kara kutu prensibi ile çalışması ve modele ait mimarinin oluşturulmasının zorlu bir süreç gerektirmesi, olumsuz yönlerini olarak ifade edilebilir (Yue, Zhao, Mao ve Liu, 2015; Ball, Anderson ve Chan, 2017; Parvat, Chavan, Kadam, Dev ve Pathak, 2017).

2014 yılından itibaren uzaktan algılama alanında derin öğrenme konusunda yapılan çalışmalarda ciddi bir artış görülmektedir. Bu durumun temel nedeni, farklı algılayıcılarla elde edilmiş veya farklı özelliklere sahip uzaktan algılanmış veri çeşitlerinin artması ile bu verileri değerlendirilebilmesi için derin öğrenme gibi güçlü bir yaklaşıma ihtiyaç duyulmasıdır (Zhu ve diğerleri, 2017; Zhang ve diğerleri, 2016). Bu çalışmada, derin öğrenme yönteminin uzaktan algılama alanındaki kullanımları literatürdeki çalışmalara desteklenerek sunulmuştur. Bu çalışmanın amacı, derin öğrenme yöntemini detaylı şekilde açıklayarak uzaktan algılama alanında derin öğrenme yöntemi kullanılarak yapılmış hem ulusal hem de uluslararası önem arz eden araştırmaların derlenmesidir. Bu çalışmada, derin öğrenmenin uzaktan algılama alanında kullanımı beş başlık altında incelenmiştir.

2. EVRİŞİMSSEL SİNİR AĞLARI

Evrışimsel sinir ağları (ESA) görüntü bölütleme ve sınıflandırması, nesne tespiti (araç, gemi, uçak, bulut, bina sel alanları), görüntü birleştirme,

konuşma tanıma ve görüntü/video işleme gibi amaçlarla kullanılan çok katmanlı özel bir sinir ağı türüdür (Abdel-Hamid ve diğerleri, 2014; Ren, He, Girshick, ve Sun, 2017; Qing, Ruan, Xu, Ren ve Zabalza, 2019; Zhang, Zhang ve Li, 2020). Evrışimsel filtre içeren katmanlara sahip olması bu sinir ağını diğer ağ türlerinden ayıran en temel özelliktir (Khan, Rahmani, Shah ve Bennamoun, 2018). Bu sinir ağı yapısı ilk olarak Fukushima tarafından önerilmiştir (Fukushima, 1980). Ancak, sinir ağı yapısının eğitimi için kullanılan hesaplamaların sınırlı olması nedeniyle yaygın olarak kullanılmamıştır. 1990'lı yıllardan ESA'ya türev tabanlı öğrenme algoritması uygulanmış ve bu sinir ağı türüyle yapılan çalışmalarda başarılı sonuçlar elde edilmiştir (LeCunn, 1989). ESA yapısının insana ait görsel işleme sistemine çok fazla benzerlik göstermesinin yanında, 2 boyutlu ve 3 boyutlu görüntüleri işleyebilme kabiliyetinin olması diğer sinir ağlarına göre avantaj sağlamaktadır. ESA modelleri, türev tabanlı bir algoritma ile çalışmaktadır ve yüksek düzeyde optimize edilmiş ağırlıklar üretme kabiliyetine sahiptirler (Alom ve diğerleri, 2019). Evrışimsel sinir ağına kullanılan diğer bir önemli faktör ise üstün parametre (hiperparametre) seçimidir. Derin öğrenme algoritmalarında kullanılan üstün parametre kavramı modelin kendisini ve çalışmasını etkileyen birçok parametreyi içermektedir. Bu parametrelerin modelin eğitiminden önce ayarlanması gerekmektedir. Modelin mimarisi içinde kullanılan üstün parametrelerden başlıca olanlar, gizli katman sayısının belirlenmesi, modelde kullanılan başarımların iyileştirme tekniklerinin uygulanması, yapılacak uygulama için uygun modelin seçimi ve harekete geçirme (aktivasyon) fonksiyonlarının tanımlanmasıdır.



Şekil 1. Evrışimsel sinir ağı modeli.

Modelin eğitimi aşamasında ise öğrenme hızı, sönüm parametresi, iterasyon sayısı, maliyet fonksiyonu, küme boyutunun (batch size) belirlenmesi, epok sayısı gibi modelin optimizasyonunu sağlayan parametreler örnek olarak gösterilebilir (Demyanov, 2015; Koutsoukas, Monaghan, Li, ve Huan, 2017). Bu parametreler eğitim aşamasında ayarlanabilirler ancak güncellenmezler. Derin öğrenme modellerinin çalışabilmesi için modele ait üstün parametrelerin ayarlanması gerekmektedir. Belirlenen optimum üstün parametreler, modelin tüm öğrenme sürecini etkilemektedir. Bu nedenle, bu üstün parametrelerin modelin eğitiminden önce ayarlanması gerekmektedir. Türev tabanlı optimizasyon algoritmaları, özellikle uzaktan algılama uygulamalarında üstün parametrelerin optimizasyonunda yaygın olarak kullanılmaktadır (Yuan ve diğerleri, 2019; He, Zhang, Ren ve Sun, 2016).

ESA modelleri, evrişim katmanı, yoğunlaştırma katmanı, harekete geçirme katmanı dahil olmak üzere temel katmanlardan oluşmaktadır. ESA mimarisi evrişimsel katmanın yanında normalleştirme, ortaklama, seyreltme gibi başka katmanlar da içeren ileri beslemeli sinir ağıdır. Literatürde hâlihazırda kullanılan birçok popüler evrişimsel sinir ağı mimarisi mevcuttur. Bilinen hazır ESA mimarilerine örnek olarak, LeNet (LeCun, Bottou, Bengio ve Haffner, 1998), AlexNet (Krizhevsky, Sutskever ve Hinton, 2017), VGGNet (Simonyan, ve Zisserman, 2015), GoogLeNet (Szegedy ve diğerleri, 2015), ResNet (He, Zhang, Ren, ve Sun, 2016) ve DenseNet (Huang, Liu, Van Der Maaten ve Weinberger, 2017) verilebilir. Yapılacak çalışmanın amacına bağlı olarak farklı türde ESA mimarisi oluşturulması mümkündür. ESA mimarisi genel olarak, özellik çıkartma ve sınıflandırma olmak üzere iki ana bölümden oluşmaktadır. ESA'ların en önemli avantajlarından biri, büyük ölçekte verilere ait özelliklerin çıkartılması aşamasında kullanılmalarıdır (Khan, Sohail, Zahoora ve Qureshi, 2020). Bu mimariler, uzaktan algılamada hem kontrollü hem de kontrolsüz öğrenme algoritmaları ile görüntü sınıflandırma uygulamalarında yaygın olarak tercih edilmektedir (Chen ve diğerleri, 2021).

a. Evrişimsel Katman

Evrişimsel katman, veriye ait özellik haritasını oluşturmak için kullanılan evrişimsel filtreyi içeren mimarinin en temel katmanıdır. Eğitim sırasında evrişimsel filtrelerin ağırlıkları ilk aşamada rastgele seçilir ve derin öğrenme modelinin içinde matematiksel işlemlerde kullanılır. Bu filtreler tüm

veri boyunca hareket ederek veriye ait bir özellik haritası çıkarır. Şekil 1'de evrişimsel filtrenin girdi verisine nasıl uygulandığı gösterilmiştir.

Evrişimsel katmanın 1 boyutlu, 2 boyutlu ve 3 boyutlu olmak üzere farklı boyutta çeşitleri mevcuttur. Bir boyutlu evrişimsel katman, tek boyutlu veriler veya zamansal verilerin analizi için kullanılan basit bir ağ çeşididir. Bu ağ türü görüntülerde ise spektral analizlerde kullanılır. Bu evrişimsel katmanı içeren modeller, girdi verisi olarak bir boyutlu vektörel yapıları kullanırlar. Bu katman, görüntülerde piksel tabanlı analiz yaparken çok ölçekli bir şekilde çalışarak görüntü bantları arasındaki piksellere ait karşılıklı bilgileri araştırmak için tercih edilmektedir (Song ve diğerleri, 2019). Ayrıca bu katmanı içeren modellerde işlem süresi kısalmaktadır. Örneğin; hiperspektral görüntü kullanan uygulamalarda 1 boyutlu katman, spektral analiz yaparken sadece derinlemesine spektral bilgilere odaklanır (Liu, Li, Li, ve Liu, 2019).

İki boyutlu evrişimsel katman, uydu görüntüleri gibi 2 boyutlu verilerin analizi için kullanılır. Bu katman içindeki evrişimsel filtreler görüntünün hem enine hem de boyuna olacak şekilde hareket eder. İki boyutlu evrişimsel katman, özellikle görüntülerde kullanıldığında görüntüye ait mekânsal-spektral özellikleri öğrenebilen bir katmandır. Bu katman, görüntüdeki piksellerin hem parlaklık değerlerini hem de diğer pikseller ile olan komşuluk ilişkilerini kullanarak mekânsal-spektral özellikleri çıkartmaktadır (Audebert, Le Saux ve Lefevre, 2019). Ayrıca bu filtreler hiperspektral gibi küp veri setlerine (3 boyutlu veri) uygulandığında çıktı olarak 2 boyutlu bir özellik haritası oluşmaktadır (Garcia-Garcia ve diğerleri, 2018). Üç boyutlu evrişimsel katmanlar ise video işleme, hiperspektral görüntüler ve LIDAR nokta bulutu gibi büyük boyutlu verilerin değerlendirilmesinde kullanılmaktadır (Li ve diğerleri, 2019).

Üç boyutlu evrişimsel katman ise genellikle mekânsal-zamansal verilerin ayırt edici özelliklerin analizinde tercih edilmektedir. Bu katman ile özellikle uzaktan algılama uygulamalarında dinamik ve zamansal bilgi çıkarımı yapılabilir (Ji, Zhang, Xu, Shi ve Duan, 2018). Üç boyutlu evrişimsel katman, 2 boyutlu evrişimsel katmanın genişletilmiş halidir. Ancak, bu katman kullanılarak oluşturulmuş derin öğrenme modellerinin eğitim işlemi diğer modellere göre daha maliyetlidir. Aynı zamanda bu modellerin, diğer modellere göre eğitilebilmesi için daha geniş eğitim veri setine ihtiyaç duymaktadır (Yang ve diğerleri, 2019).

b. Ortaklama Katmanı

Ortaklama katmanı, kendisinden önceki katman çıktısını ölçeklendirir, veriye ait önemli bilgileri saklar ve bu yüzden modelin işlem yükünü azaltır. Ayrıca, ortalama ve maksimum gibi çeşitleri de literatürde özel ortaklama katmanı olarak mevcuttur. Derin öğrenme modelinde, bu katman genellikle evrimsel katmandan sonra kullanılır. Teknik olarak, ortaklama katmanı özellik haritaları içindeki veriyi azaltarak, bir sonraki katmanda işlenecek olan veri boyutunu azaltır ve böylece modeldeki parametre sayısını düşürür. Diğer bir deyişle, görüntüden elde edilen özellik haritasındaki önemli bilgilerin kullanılmasına olanak sağlar. Ortaklama katmanının çalışma prensibi, 2 boyutlu matris formundaki bir veri üzerinde küçük filtreler kullanılarak, veri üzerindeki küçük filtreyi kapsayan alandaki maksimum veya ortalama değerler alınarak yeni bir matris formunun oluşturulmasına dayandırılır. Böylelikle hem işlem yükü azalırken hem de derin öğrenme modelinin aşırı öğrenme durumu engellenir (Claesson ve Hansson, 2017). Şekil 1'de, 2x2 boyutunda bir ortaklama filtresi gösterilmiştir. 4x4 boyutundaki veri üzerinde bu filtre gezdirilerek en büyük değere sahip özellikler çıktı matrisine yazdırılmıştır.

c. Düzleştirme Katmanı


Düzleştirme katmanı, çok boyutlu bir özellik matrisini bir sonraki katmanı beslemek için tek boyutlu bir vektöre dönüştüren özel bir katmandır. Matrisin ilk elemanından başlanarak, matrise ait tüm elemanlar bir boyutlu vektör matrisine dönüştürülür. Bu katmanda kullanılan filtreler tek

boyutludur. Ayrıca düzleştirme katmanı ile oluşturulan derin öğrenme modelinde, model içi parametrelerinin azalması ile öğrenme hızının arttığı görülmüştür (Jin, Dundar ve Culurciello, 2015). Şekil 1'de iki boyutlu bir görüntü matrisine düzleştirme katmanının uygulandığı gösterilmiştir. Böylece tek boyutlu bir görüntüye ait verileri içeren bir vektörel matris oluşturulmuştur

ç. Seyreltme Katmanı

Derin öğrenme modelleri çok sayıda parametre ile çalışmaktadır. Ancak bu durum, aşırı öğrenme problemini de beraberinde getirmektedir. Özellikle büyük sinir ağlarında çıktının üretilmesi önemli bir zaman almaktadır. Seyreltme katmanı ise derin öğrenme modelinin aşırı öğrenmesini engeller ve öğrenme süresinin kısaltmaya yardımcı olur (Srivastava, Hinton, Krizhevsky, Sutskever ve Salakhutdinov, 2014). Derin öğrenme modelindeki tüm sinir hücreleri birbirlerine düğümlerle bağlıdır. Seyreltme katmanı, modeldeki düğümlerin her iterasyonda belli bir yüzdesel oranda rastgele ve geçici olarak modelin eğitiminde kullanılmamasını sağlamaktadır.

Sonuç olarak, modeldeki tüm düğümlerin aynı anda kullanılması verinin ezberlenmesine neden olurken, her iterasyonda bazı düğümlerin geçici olarak açılıp-kapatılması ile veriye ait diğer özellikler ön plana çıkacağı için modelin veri setini ezberlemesinin önüne geçilir. Seyreltme işlemi çok katmanlı algılayıcıdaki budama ile benzer bir işlemdir. Şekil 2'de derin öğrenme modelinde seyreltme katmanının çalışma prensibi gösterilmiştir.



Şekil 2. Seyreltme katmanı uygulaması. (a) Seyreltme katmanı kullanılmadan oluşturulmuş sinir ağı, (b), (c), (ç) Seyreltme katmanı kullanılarak oluşturulmuş modelin farklı iterasyonlardaki durumu.

d. Harekete Geçirme Fonksiyonları

Harekete geçirme fonksiyonları, derin öğrenme modelindeki öğrenme sürecini etkileyen en önemli etmenlerden biridir. Öğrenme işlemi gerçekleştirilirken, bu fonksiyonlar modelin hesaplama yükünü azaltmaktadır. Harekete geçirme fonksiyonları, sinir hücresinden üretilen çıktı üzerinden matematiksel işlem gerçekleştirirler. Derin öğrenme modeli tarafından çözülecek bir problemin türüne bağlı olarak daha karmaşık harekete geçirme fonksiyonları da kullanılabilir. Harekete geçirme fonksiyonları doğrusal bir yapıya sahip değildir. Modeldeki sinir hücresinden gelen çıktı doğası gereği doğrusal bir yapıda olduğundan, harekete geçirme fonksiyonları bu çıktıları doğrusal olmayan çıktılarına dönüştürmek için kullanılmaktadır. Harekete geçirme fonksiyonları sistemin doğrusal olmamasını sağlamak için kullanılır. Harekete geçirme fonksiyonları, her bir sinir hücresinin çıktısını 1 ile 0 veya -1 ile 1 arasında normalleştirir. Ayrıca harekete geçirme fonksiyonları türevlenebilir bir yapıda olduğu için geri yayılım algoritması ile uyumlu bir şekilde çalışmaktadır.


Kullanılan uygulamanın amacına göre farklı harekete geçirme fonksiyonları mevcuttur. Bunlar; hiperbolik tanjant (tanh), eşiksiz en büyük işlev (softmax), sigmoid, doğrultulmuş doğrusal birim (ReLU) ve bu birimin farklı çeşitleridir. Hiperbolik tanjant, aldığı girdi değerini -1 ile 1 arasında normalize eder. Sigmoid fonksiyonu ise hiperbolik tanjant ile çok benzerdir, tek farkı, çıktı değerlerini 0 veya 1 olarak etiketler. Eşiksiz en büyük işlev ise girdilerin hangi sınıflara ait olduğunu belirten olasılık değerlerini 0 ile 1 arasında etiketlemeyi sağlar. Doğrutulmuş doğrusal birim ve çeşitleri ise doğrusal olmayan model çıktıları için kullanılmaktadır. Bu fonksiyon, sigmoid ve hiperbolik tanjant fonksiyonlarına göre

hesaplamalarda daha fazla verim sağlamaktadır (Gu ve diğerleri, 2018; Nwankpa, Ijomah, Gachagan ve Marshall, 2020) (Şekil 3). Tüm bu fonksiyonların birbirlerine göre olumlu veya olumsuz yönleri mevcuttur (Khan ve diğerleri, 2020). Örneğin, ReLU'nun hesaplama yükü sigmoid harekete geçirme fonksiyonuna göre daha azdır ve bu nedenle çok katmanlı derin öğrenme modellerinde çoğunlukla tercih edilmektedir.

e. Maliyet Fonksiyonları

Maliyet fonksiyonları, modelin eğitimi esnasında kullanılır ve tahmin edilen çıktı ile gerçek çıktı arasındaki ilişkiyi kurmayı sağlar. Derin öğrenme modelinin eğitim başlangıcında, sinir hücrelerine ait ağırlıklar rastgele olacak şekilde atanır ve ardından model ağırlık tahminlerini oluşturmaya başlar. Derin öğrenme modeline ait ağırlıklar diğer iterasyonlarda değişmeye devam eder. Her bir iterasyonda bu üretilen çıktıları tahminlerin ve doğru çıktılar arasındaki farkların toplamı, maliyet fonksiyonları ile hesaplanır. Ardından optimizasyon problemi yaşamayan bir modele ait ağırlıklar eğitim sırasında güncellendikçe, modelin maliyet fonksiyonunda da bir azalma görülmeye başlanır. Uygun optimizasyon algoritmasının seçilmesi, modelin hem eğitim sürecini hem de eğitim kalitesini etkilemektedir. Bu algoritmalar, maliyet fonksiyonun hesaplanmasında büyük rol oynamaktadır. Bir derin öğrenme modelinin eğitimi sırasında kullanılan maliyet fonksiyon çeşitleri regresyon, ikili sınıflandırma ve çoklu sınıflandırmadır. Maliyet fonksiyonun matematiksel ifadesi Eşitlik (1)'de verilmiştir.

$$J = \sum_{i=1}^n (y^i - \hat{y}^i)^2 \quad (1)$$



Şekil 3. Bazı harekete geçirme fonksiyonlarının grafiksel gösterimi.

y^i terimi olması gereken çıktı değerini ifade ederken \hat{y}^i terimi ise modelin öğrenme işlemi tamamlandıktan sonra model tarafından tahmin edilen değerini gösterir. i değeri ise veri setindeki i . veri olarak ifade edilirken n ise toplam veri sayısı olarak ifade edilmiştir. Eşitlik 1 ile derin öğrenme modeline ait maliyet fonksiyonu (J) hesaplanır (Khan, Rahmani, Shah, ve Bennamoun, 2018). Uzaktan algılama uygulamaları özellikle görüntü sınıflandırma işlemlerinde, çapraz entropi maliyet fonksiyonu tercih edilmektedir (Audebert, Le Saux ve Lefevre, 2019).

3. UZAKTAN ALGILAMA ALANINDA DERİN ÖĞRENME KULLANIMI

Son yıllarda uydu sayısının artması ile farklı spektral, radyometrik ve geometrik çözünürlüklere sahip görüntülerin kaydedilmesi ile veri çeşitliği, sayısı ve geçmişten günümüze veri hacmi artmaktadır. Uzaktan algılanmış verilerdeki bu artış büyük verinin oluşmasına neden olmaktadır. Üretilen büyük verinin işlenmesi ve analizinde geleneksel yöntemlerin kullanılmasını, derin öğrenme algoritmaları kadar başarılı sonuçlar vermediği birçok çalışmada belirtilmiştir (Li ve diğerleri, 2015; Zhang ve diğerleri, 2016; Liu ve diğerleri, 2017; Yuan ve diğerleri, 2020). Bu gibi durumlarda derin öğrenme algoritmaları tercih edilmektedir. Uzaktan algılama alanında yapılan birçok görüntü sınıflandırma ve bölütleme işlemi, nesne tespiti ve görüntü füzyonu çalışmalarında, derin öğrenme yöntemlerinin, klasik yöntemlere göre daha iyi sonuçlar ürettiği raporlanmıştır (Zhang, Zhang ve Du, 2016; Zhang, Xv, Shen, He ve Du, 2018; Yılmaz, 2020). Uzaktan algılama uygulamalarında radar görüntüleri, yüksek çözünürlüklü uydu görüntüleri ve hiperspektral görüntüler üzerinde derin öğrenme metotları kullanılarak çalışmalar gerçekleştirildiği literatür araştırmasında görülmüştür (Li, Zhang, ve Shen, 2017; Furukawa, 2018; Saha ve diğerleri, 2020).

Derin öğrenme yaklaşımının uzaktan algılama uygulamaları için uygunluğu üç temel nedene dayandırılabilir. İlk olarak, derin öğrenme yaklaşımının kullanılabilmesi için çok miktarda etiketli veriye ihtiyaç duyulmaktadır. Uzaktan algılama uygulamalarında etiketlenmiş verilerin üretilmesi için hem saha hem de laboratuvar çalışmaları gereklidir. Saha çalışmaları ile yeryüzüne ait referans yer doğrulama veri setleri oluşturulabilir. Aynı zamanda çalışma alanının ait öncül bilgiler mevcut ise etiketlenmiş veri setleri laboratuvar ortamında üretilebilir. Bu veri setlerinin üretimi için insan faktörüne ihtiyaç duyulması ve bu veri setlerinin hazırlanma süresinin zaman

alması bir dezavantaj olarak değerlendirilebilir. Ayrıca, derin öğrenme modelinin eğitimi için optimize edilmiş GPU artık daha kolay ulaşılabilir hale gelmiştir ve bu donanım sayesinde paralel işlem yapma olanağı bulunmaktadır. Ek olarak, derin öğrenme uygulamalarının yaygınlaştırılması için örneğin, Google gibi şirketler bulut üzerinden 12 saatlik ücretsiz GPU ve TPU (Tensor Processing Unit) desteği sağlamaktadır (Google Colab). Bulut platformlar, K80s, T4s, P4s ve P100s GPU desteğine sahip olmasının yanında derin öğrenme uygulamalarında için Python dilinde yazılmış hazır kütüphaneler içermektedir. Aynı zamanda ücretsiz olarak, her bir kullanıcı için 12 GB RAM kullanımına izin verilmektedir. Ancak ücretsiz versiyon, kullanıcılar için sınırlandırılmıştır (Google, 2021). Son olarak da derin öğrenme yaklaşımı, geleneksel yöntemlerle karşılaştırıldığında model mimarisinin hem derinlik hem de çıktı boyutlarına müdahale edilebilmesi durumu derin öğrenme metodunun üstün bir performans sergilemesini sağlamıştır. Uzaktan algılama alanında derin öğrenme mimarilerinin kullanıldığı alanlar görüntü ön işleme, görüntü sınıflandırma, nesne tespiti, görüntü yorumlama ve diğer uygulama alanları olmak üzere beş alt başlıkta incelenmiştir.

a. Ön İşlem

Uzaktan algılanmış görüntülerde, algılayıcılarda zamanla bozulmalar veya çevresel faktörlerin etkilerinden kaynaklı hatalar oluşabilmektedir. Bu oluşan bozulmaların yanında görüntü kalitesini iyileştirme işlemleri için ham görüntülere uygulanan tüm teknikler de ön işlem adımları olarak tanımlanmaktadır. Ön işlem adımlarının veri üzerinde yorumlama veya analiz yapılmadan önce gerçekleştirilmesi gerekir. Görüntü giderme ve görüntü füzyonu gibi ön işlem adımları ile verilerin işlenmesi daha kolay hale getirilmektedir. Görüntü kalitesini arttırmak için yapılan ön işlem adımlarında derin öğrenme yaklaşımları kullanılmaktadır. En çok kullanılan yöntemlerden biri görüntü keskinleştirme işlemidir. Uzaktan algılanmış veriler çok bantlı ve siyah-beyaz (pankromatik) bantlardan oluşabilir. Çok bantlı spektral bantların mekânsal çözünürlüğü, siyah-beyaz bantlara göre daha düşüktür. Bu sebeple, çok bantlı spektral verilerin mekânsal çözünürlüğünü arttırmak amacıyla siyah-beyaz bantların çözünürlüğüne örneklenmesi işlemidir (Özdemir, 2017; Meng, Shen, Li, Zhang ve Fu, 2019). Görüntü kalitesini arttırmak için kullanılan görüntü keskinleştirme uygulamasında, girdi ve çıktı verileri arasında bir korelasyon bulunmaktadır (Gu, Wang ve Li, 2019). Eğer bu korelasyon derin öğrenme mimarisi ile

modellenebilirse, algılanan başka bir görüntüye bu mimari uygulanabilir ve görüntü keskinleştirme işlemi uygulanmış bir çıktı verisi elde edilebilir (Zhang, Xia, Wu, Lin ve Tai, 2016).

Meteorolojik koşullara bağlı olarak optik uydu görüntülerinde bulut ve gölgeler görüntünün kalitesini ve analizini olumsuz yönde etkilemektedir. Bu görüntülerin kullanılabilmesi için öncelikle bulutlu alanların belirlenmesi gerekmektedir. Bu konuyla ilgili bir çalışmada GaoFen-1 uydu görüntülerine uygulamak üzere evrimsel sinir ağı içeren bir model üretilmiştir. Bu derin öğrenme modeli, görüntüdeki bulutların tespitini amacıyla kullanılmıştır (Li, Zou ve Shi, 2020). Başka bir çalışmada ise bulut tespit çalışmalarında benzer özellik gösteren kar kaplı alanları ayırt etmek için evrimsel sinir ağı modeli kullanılmış ve başarılı sonuçlar elde edilmiştir (Sun, Li, Xu, Li ve Huang, 2020).

Görüntü füzyonu, birden fazla görüntüde bulunan bilgilerin tek bir görüntüye entegre edilmesi işlemidir. Görüntü füzyon uygulamalarından biri de görüntü keskinleştirme işlemidir. Bu işlem adımında yüksek çözünürlüklü görüntü elde etmek amacıyla düşük çözünürlüklü çok bantlı spektral görüntülerin siyah-beyaz bantlı görüntü ile birleştirilmesi yapılmaktadır. (Zhang, Liu, Sun ve Ou, 2019). Evrimsel sinir ağları kullanılarak yapılan bir çalışmada çok bantlı spektral ve siyah-beyaz görüntü füzyonu işlemi gerçekleştirilmiştir. Bu çalışmada, özellikle derin öğrenme metodunun doğrusal bir yapıda olmamasının avantajlı bir durum olduğu belirtilmiştir. Çünkü, bu metod geleneksel uygulamalara göre daha yüksek doğruluk vermiştir (Wei, Yuan, Shen ve Zhang, 2017). Huang ve diğerleri (2015) tarafından yapılan bir çalışmada ise yüksek ve düşük çözünürlüklü iki görüntü arasındaki ilişkiyi modellemek için Otokodlayıcı algoritması önerilmiştir. Bu çalışmada kullanılan derin öğrenme modeli, ön eğitimden sonra geri yayılım algoritması ile tekrardan eğitilmiştir. Böylece görüntü keskinleştirme işlemlerinde derin öğrenme modelinin iyi bir performans gösterdiği belirtilmiştir.

Gürültü, algılayıcının hatalı çalışması ile ortaya çıkabilen ve görüntüde istenmeyen sinyaller olarak adlandırılabilir. Bu gürültüler, görüntü işlemede sorunlar yaratır. Bu nedenle görüntüdeki gürültülerin giderilmesi için çeşitli teknikler kullanılmaktadır. Gürültü giderme, uydu görüntülerinin analizinde yaygın olarak kullanılan bir ön işleme adımıdır (Al-amri, Kalyankar ve Khamitkar, 2010). Bu işlemin geleneksel

yöntemlerle uygulanması özellikle hiperspektral görüntülerde başarısız sonuçlar verebilmektedir (Maffei ve diğerleri, 2020). Hiperspektral görüntüler spektral bilgi açısından zengin bir veri türüdür, ancak spektral bantlar arasındaki korelasyon yüksektir. Bu durumun üstesinden gelmek için evrimsel sinir ağı tabanlı HSI-SDeCNN (Maffei ve diğerleri, 2020), SURE-CNN (Nguyen, Ulfarsson, ve Sveinsson, 2020) ve Decs-Net (Liu ve diğerleri, 2019) gibi derin öğrenme modeli literatürde önerilmiştir. Bu modeller, hiperspektral görüntüye ait hem geometrik hem de spektral özellikleri birlikte kullanmaktadır. Derin öğrenme modellerinin, hiperspektral verilerde gürültü azaltma geleneksel yöntemler arasında iyi bir performansla sahip olduğu belirtilmiştir (Yuan, Zhang, Li, Shen ve Zhang, 2019). Gürültü giderme işlemleri hiperspektral görüntü dışında radar görüntülerine de uygulanmaktadır. Evrimsel sinir ağlarını kullanılarak DeepInSAR adında bir derin öğrenme modeli tasarlanmış ve bu model radar görüntüsüne ait faz bilgileri koruyan ve koherens verisinin hem açık hem de keskin yapıda olmasına olanak sağlamıştır (Ghuman ve Cheng, 2020).

Uzaktan algılanmış görüntülerde mekânsal çözünürlükten kaynaklı iki farklı nesne sınıfının sınırları birbirleri ile karışabilmektedir. Bu nedenle, nesne sınırlarının karışmaması için görüntüye ait mekânsal çözünürlüklerin geliştirilmesi için çalışmalar yürütülmüştür (Zhu ve diğerleri, 2017). Düşük mekânsal çözünürlük ile yüksek mekânsal çözünürlüğe ait iki görüntü birbirleri ile birleştirilerek bulanık nesne sınırları ortadan kaldırılabilir (Hao, Wang, Ye, Li, ve Bruzzone, 2018). Bu konuyla ilgili yapılmış bir çalışmada, hiperspektral görüntü kullanılarak görüntüden çeşitli alt ölçekte görüntü parçacıkları çıkartılmıştır. Ardından yukarı örnekleme işlemi içinde 2 ve 3 boyutlu ESA derin öğrenme modelleri kullanılmıştır (Sidorov ve Hardeberg, 2019). Başka bir çalışmada ise okyanus veri setleri kullanılarak, bu verilerin çözünürlüklerini arttırmak için süper piksel ESA derin öğrenme modeli önerilmiştir (Ducournau ve Fablet, 2016). Sentinel-1 görüntüleri kullanılarak yapılan bir çalışmada ise düşük çözünürlükteki bantları yüksek çözünürlüğe çıkartmak için ESA tabanlı bir model geliştirilmiştir (Gargiulo ve diğerleri, 2018).

b. Görüntü Sınıflandırma

Son yıllarda birçok çalışmada, sınıflandırma işlemlerinde klasik yöntemler yerine derin öğrenme yöntemleri kullanılmaktadır. Derin öğrenme yaklaşımı ile görüntüye ait hem spektral hem de geometrik özellikler birlikte

değerlendirilebilmektedir. Böylece görüntüye ait belirgin özellikler içeren bir özellik haritası çıkartılabilmektedir. Görüntü sınıflandırma uygulamalarında kullanılan klasik yöntemler siğ bir yapıdan oluşmaktadır, ancak sınıflandırma işleminde kullanılan derin öğrenme metotları, klasik yöntemlere göre verilerin analizinde daha başarılı olabilmektedir. Spektral ve geometrik özelliklerin birlikte değerlendirilmesi ile daha yüksek doğrulukla tematik haritalar üretebildiğinden derin öğrenme yaklaşımları tercih edilmektedir (Zhao ve Du, 2016).

Genel olarak uzaktan algılamada derin öğrenme ile yapılmış sınıflandırma uygulamaları spektral bilgi, mekânsal bilgi veya spektral-mekânsal bilgileri kullanılarak üç farklı biçimde gerçekleştirilir. Derin öğrenme yaklaşımı kullanılarak bir hiperspektral görüntü sınıflandırması yapılmış ve Otokodlayıcılar kullanılarak farklı katman sayısına sahip iki adet mimari oluşturulmuştur. Az katman içeren mimari spektral özellikleri kullanarak sınıflandırma işlemi yaparken çok katman içeren mimari ise mekânsal özellikleri kullanarak sınıflandırma yapmıştır. Ardından daha yüksek sınıflandırma doğruluğu için bu iki özelliği de kullanan başka bir derin öğrenme modeli geliştirilmiştir (Chen, Lin, Zhao, Wang, Gu, 2014). Derin inanç ağları kullanılarak yapılan diğer bir çalışmada hem spektral hem de mekânsal bilgiler kullanılmıştır. En uygun katman sayısı gibi parametrelerin seçimi tüm kombinasyonlarının kapsamlı bir şekilde kullanılması ile belirlenmiştir. Çalışmada önerilen modelin ürettiği doğruluğunun, destek vektör makineleri ile üretilen doğruluğa göre daha yüksek olduğu belirtilmiştir (Chen, Zhao ve Jia, 2015). Bir başka uygulamada sadece görüntüye ait piksel tabanlı bir uygulama yapılmıştır. Yapılan bu çalışmada önerilen model mimarisinde evrişimsel sinir ağları kullanılarak manuel olarak etiketlenmiş veri ile OpenStreetMap verisi sınıflandırılmıştır (Maggiori, Tarabalka, Charpiat ve Alliez 2017). RapidEye optik görüntüsü ile derin öğrenme modeli kullanılarak yapılan bir çalışmayla sulak alan içeren bölge sınıflandırılmıştır. Bu çalışmada derin öğrenmedeki DenseNet121, InceptionV3, VGG16, VGG19, Xception, ResNet50 ve InceptionResNetV2 gibi hazır mimariler kullanılarak sınıflandırma kapasiteleri incelenmiştir. Ayrıca bu yöntemlerin yanında rastgele orman ve destek vektör makinesi metotları kullanılarak da sınıflandırma işlemi gerçekleştirilmiştir. Derin öğrenme mimarileri arasında en iyi performansı %96,17 genel doğrulukla InceptionResNetV2 modeli üretmiştir (Mahdianpari, Salehi, Rezaee, Mohammadimanesh ve Zhang, 2018). Diğer bir

çalışmada, hem hiperspektral görüntüler hem de LİDAR verileri birlikte kullanılarak sınıflandırma işlemi yapılmıştır. Burada önerilen sinir ağı modeli iki kollu yapıda olup hem 1 boyutlu hem de 2, boyutlu evrişimsel sinir ağı şeklindedir. Oluşturulan modelin geleneksel yöntemlere göre daha iyi sonuç verdiği ortaya koyulmuştur (Xu ve diğerleri, 2018). Sınırlı miktarda eğitim verisi kullanılarak yapılan çalışmada 11 katmanlı bir evrişimsel sinir ağı ile Pavia, Indian Pines ve Salinas hiperspektral görüntüleri %96 üzeri bir doğrulukla sınıflandırılmıştır (Feng, Wang, Wang ve Zhang, 2019).

Görüntü sınıflandırmada güncel yaklaşımlardan biri de sınıflandırmanın görüntü bölümleri üzerinden yapılmasıdır. Görüntü bölütleme, görüntüdeki nesnelere ait mekânsal-spektral özelliklerini kullanarak nesnelere ait bölümlere yani bölgelere ayrılmasıdır. Derin öğrenme modelleri, anlamlı nesnelere oluşturmak için görüntü üzerinde bölütlemeler yapıp nesnelere anlamsal bütünlüğüne göre birleştirme işlemleri uygulamaktadır (Kaiser ve diğerleri, 2017). Görüntü bölütleme sadece şehir alanları için değil atmosferik araştırmalarda da kullanılmaktadır. Bu konu ile ilgili bulut bölütlemesi yapan bir ESA modeli önerilmiştir (Rusyn, Korniy, Lutsyk ve Kosarevych, 2019). Önerilen bu model bölütleme yapan diğer modellere göre daha hızlı ve daha kaliteli bulut bölütleri oluşturduğu gösterilmiştir. Görüntü bölütlemesi yapılan başka bir çalışmada ise çok bantlı spektral görüntülerden oluşturulmuş Gaofen-2 veri seti kullanılmıştır. Bölütleme işlemi için hazır bir mimari olan U-net modeli kullanılmış ve sonuç olarak %80 üzeri bir genel doğruluk elde edilmiştir (Zheng ve Chen, 2020). Görüntü bölütlemesine ait başka bir uygulama alanı ise uzaktan algılanmış görüntülerde su kütlelerinin tespit edilmesidir. Bu konuyla ilgili yapılmış bir uygulamada çok ölçekli bir ESA tabanlı hazır mimari (DeepLabV3) kullanılmış ve bu mimarinin yapısı iyileştirilmiştir. Su kütlelerinin ayrıntılı sınırlarının tespiti için Koşullu Rastgele Alan algoritması tercih edilmiştir. Yapılan bu çalışmada su kütlelerinin tespitinde %95 üzeri doğruluğa ulaşılmıştır (Li, Wang, Zhang, Hu, ve Meng, 2019).

c. Nesne Tespiti

Nesne tespiti uygulamaları, görüntü işleme uygulamalarında son dönemde yaygın olarak kullanılmaktadır. Bu uygulamalarda hem nesnelere tespit edip hem de nesnelere hangi sınıfa ait olduğunu gösterilebilmektedir. Bu durum yapılan çalışmaların amacına göre şekillenmektedir (Jiao ve diğerleri, 2019). Uydu görüntülerinde yer alan

gemi, yol, bina, uçak gibi nesnelerin tespiti yüksek doğrulukla yapılabilmektedir (Cheng ve Han, 2016). Ancak bu nesnelerin büyüklüğü, yönü, sayısı, çevresindeki cisimlerle karışması gibi problemlerle karşılaşmaktadır. Bu problemler de nesnenin yanlış algılanmasına veya hedefin tespit edilmesinde olumsuzluklara neden olmaktadır. Nesne tespiti uygulamalarında nesneye ait spektral, mekânsal ve doku özelliklerini kullanarak sınıflandırma işlemi gerçekleştirilir ve diğer nesnelere ayırt edilmesi sağlanır. Nesne tespiti uygulamaları radar, hiperspektral veya çok bantlı spektral görüntüler kullanılarak gerçekleştirilebilir.

Nesne tespitiyle ilgili yapılan bir çalışmada binalar gibi insan yapımı nesnelerin tespiti için yüksek çözünürlüklü çok bantlı spektral uydu görüntüleri kullanılmıştır. Eğitim esnasında, ImageNet derin öğrenme modeline spektral bilgilerde eklenmiş ve yüksek doğrulukla bina tespiti gerçekleştirilmiştir (Vakalopoulou, Karantzalos, Komodakis ve Paragios, 2015). Bina tespiti yapılan başka bir çalışmada ise genelleme yapabilen bir ESA modeli oluşturulmuştur. Böylelikle, binaların şekilsel-boyutsal farklılıkların, bina tespiti uygulamalarındaki olumsuzlukların giderilmesi hedeflenmiştir (Chen ve diğerleri, 2017). Radar görüntüsü kullanılarak gemi tespitinin yapıldığı bir çalışmada ise görüntüye uygulanan Sabit Yanlış Alarm Oranı algoritmasının eksik kaldığı yönler, hızlı evrimsel sinir ağı ile tekrar değerlendirilmiştir (Kang, Lin, Xiangguang ve Ji, 2017). Bölge tabanlı evrimsel sinir ağı araçları algılayan bir derin öğrenme modeli olarak kullanılmıştır (Deng, Sun, Zhou, Zhao ve Zou, 2017). Özellikle, bu çalışmada aşırı öğrenmeyi engellemek için eğitim verisi artırma uygulaması yapılmıştır. Önerilen yöntemin doğruluğunun %70 üzeri olduğu ve diğer raporlara göre daha iyi performans gösterdiği raporlanmıştır. Gemi tespiti yapılan başka bir çalışmada ise 20 adet yapay açıklı radar görüntüsü kullanılmıştır. Bu görüntüler Radarsat-2, TerraSAR ve Sentinel-1 uydularına aittir. Bu çalışmada gemilerin tespit edilebilmesi için çok ölçekli derin öğrenme modelleri kullanılmıştır. Nesnelere ait alt ve üst ölçekli özellik haritaları çıkarılmıştır (Jiao ve diğerleri, 2018). Uçak tespiti yapılan bir çalışmada yüksek çözünürlüklü (0,11 ile 2 metre arasında) Jilin-1 ve Gaofen-2 uydularına ait görüntüleri kullanılarak uçak tespiti ESA tabanlı YOLO, SSD ve Hızlı ESA (Faster R-CNN) modellerini içeren üç farklı yöntem ile yapılmıştır. Sinir ağlarını eğitmek için sınırlı sayıda kullanılacak görüntülere, kırpma, yeniden ölçeklendirme gibi işlemler yapılarak etiketli veri sayısı artırılmıştır. Bu modellerin

performanslarının değerlendirilebilmesi için farklı çözünürlüğe sahip görüntüler eğitim aşamasında kullanılmıştır. Bu yöntemler arasında en yüksek doğruluk hızlı ESA modeliyle elde edilmiştir (Alganci, Soydas ve Sertel, 2020). Aynı zamanda araç tespiti yapılmış başka bir çalışmada da hızlı ESA algoritması kullanılmıştır. Bu çalışmanın diğer çalışmalardan farkı ise; hızlı giden araçların tespit edilmesi, yol durumu ve trafik akış bilgilerinin elde etmesidir (Tan, Ling, Hu, Qin, ve Hu, 2020). İnsansız hava araçları (İHA) ile uzaktan algılanmış veriler toplanabilmekte ve bu veriler üzerinden de nesne tespit uygulamaları yapılabilmektedir. Özel bir ağaç türünün tespiti uygulamasını gerçekleştiren bir çalışmada İHA ile toplanmış üç bantlı veri kullanılmıştır. Tespit işlemi için ESA mimari kullanılarak oluşturulmuş Faster R-CNN, YOLOv3 ve RetinaNet sinir ağı mimarileri test edilmiş ve RetinaNet mimarisi %92,64 ortalama doğruluk ile en yüksek doğruluğu üretmiştir (dos Santos ve diğerleri, 2019). Diğer bir çalışmada gerçek zamanlı İHA verileri kullanılarak elde edilmiş görüntülerden, boru hatlarına zarar vermemesi için kazı çalışmalarını kontrol eden ESA tabanlı YOLOv3 mimarisi kullanılmıştır (Meng ve diğerleri, 2020).

ç. Görüntü Yorumlama

Uzaktan algılanmış görüntüler, bir veya birden fazla nesnenin birleşimi ve bu nesnelerin çevresel etkileşimleri ile oluşmaktadır. Görüntüdeki nesnelere ise birden fazla pikselin bir araya gelmesi ile tanımlanır. Uzaktan algılamada son yıllarda gelişen teknolojinin eşlik etmesiyle görüntüye ait mekânsal çözünürlük artmıştır. Görüntü çözünürlüğünün artması, görüntünün içerdiği bilginin de artması anlamına gelmektedir. Böylelikle görüntü içindeki nesnelerin, çevresindeki nesnelere ile arasında anlamsal bir bütün oluşmaktadır. Bu kapsamda değerlendirildiğinde görüntü içinde yorumlanacak veri miktarı artması ile derin öğrenme modeli ile veriye ait anlamsal bütünlüğün çıkartılması esnasında yorumlama işlemi, görüntünün yorumlanmasındaki zorluğu artıran bir faktördür. Derin öğrenme modelleri, doğrusal olmayan işlemleri kullanarak görüntü tanıma uygulamaları yapabilmektedir. Görüntü yorumlama uygulaması için arazi kullanım haritasının üretildiği bir çalışmada hem derin öğrenme yöntemiyle hem de diğer öğrenme yöntemlerinin bir arada kullanılması ile gerçekleştirilmiştir. Bu konuyla ilgili bir çalışmada, önceden eğitilmiş bir evrimsel sinir ağı, verilere ait özellikleri öğrenmek için kullanılmıştır. Ardından daha iyi doğruluk elde etmek için aşırı öğrenen makineler (extreme learning machine) kullanılarak, öğrenilen

özellikleri eğiten bir sınıflandırıcı tercih edilmiştir. Genel olarak bu çalışmada önerilen ESA tabanlı model ile %95 üzerinde bir doğruluk elde edilmiştir. Ayrıca farklı özelliklere sahip görüntülerin bu model ile değerlendirilebilmesi için model içindeki parametrelerin değiştirilmesinin gerektiği ortaya konulmuştur (Weng, Mao, Lin ve Guo, 2017).

Görüntü yorumlamasının yapılabilmesi için öncelikle görüntünün sınıflandırması gerekmektedir. Genel olarak, bu uygulamaların çalışma prensibi, görüntüdeki nesnelere diğer nesnelere veya çevre ile arasındaki ilişkinin kurulmasına dayanmaktadır. Böylelikle uzaktan algılanmış görüntülerden arazi örtüsü bilgisi çıkartılabilir. Sanayi ve yerleşim yeri gibi farklı bölgelerde benzer nesnelere olmaları görüntülerin yorumlanması açısından zorluk meydana getirmektedir. GoogleNet bu zorlukların üstesinden gelmek üzere kurulmuş bir derin öğrenme modeli olarak literatürde yer almaktadır (Li, Peng, Tao, Chen ve Deng, 2017). Zhao ve diğerleri (2019) çalışmalarında, yüksek çözünürlüklü görüntüler kullanılarak karmaşık kentsel bölgelerin tespit edilmesi için bir evrimsel sinir ağı modeli geliştirilmiştir. Coğrafi nesnelere ait anlamsal bilgiler için OpenStreetMap veri seti sinir ağının eğitimi esnasında kullanılmıştır. Kent içindeki bölgelerin tespitinde %88,5 sınıflandırma doğruluğu elde edilmiştir. .

d. Diğer Uygulama Alanları

Uzaktan algılanmış görüntülerde derin öğrenme yaklaşımının kullanımı, nesne tespiti, görüntü sınıflandırma, ön işleme ve görüntü yorumlama dışında da birçok uygulama alanına sahiptir. Bu alanlardan önemlilerinden bir tanesi değişim analizidir. İki farklı periyotta alınmış görüntülerin zamansal değişimleri derin öğrenme modelleri ile incelenmektedir. Aynı zamanda bu tip çalışmalar da kontrollü ve kontrolsüz öğrenme yöntemleri bir arada kullanılabilir (Khelifi ve Mignotte, 2020). Bu alanda yapılan bir çalışmada, WorldView-2 görüntüleri kullanılarak 2017 ve 2018 yılları arasında değişim incelenmiştir. İki görüntü arasındaki tüm değişimleri algılayabilen bir derin öğrenme modeli geliştirilmiştir ve bu model değişim alanlarını %80 F-skor doğruluk seviyesinde tespit etmiştir (Yang, Gu, Han ve Li, 2020). Değişim analizi yapılan başka bir çalışmada ise hiperspektral görüntüler üzerinden 2 Boyutlu ESA mimarisi (GETNET) kullanılmıştır. Bu çalışmanın sonucunda %97 üzerinde genel doğruluk ile değişim analizi yapılmıştır (Wang, Yuan, Du, ve Li, 2019).

Değişim analizi dışında 3 boyutlu yapılandırma işlemlerinde de derin öğrenme mimari kullanılmaktadır. Uzaktan algılanmış stereo verilerin kullanılması ile iki adımda 3 boyutlu veriler üretilmektedir. İlk olarak, algılayıcının konumu hesaplanarak, görüntülerin oryantasyonu belirlenir. Diğer adım da ise görüntüler üzerinden ortak noktalar belirlenerek üçgenleme metodu ile 3 boyutlu veriler yapılandırılmaktadır (Zhu ve diğerleri, 2017). Bu alanda yapılmış bir çalışmada tek bir radar görüntüsünden elde edilmiş 3 boyutlu nokta bulutu verisi ile optik görüntüler Çekişmeli Üretici Ağ modellerinde eğitilerek, nesneye ait yapısal özelliklerin çıkartılması hedeflenmiştir (Peng, Qiu, Ding, ve Tie, 2019).

Derin öğrenme yaklaşımları tahmin uygulamalarında da kullanılmaktadır. Özellikle, tarımsal verimlilik üzerine yapılan çalışmalarda derin öğrenme yaklaşımı bir yol gösterici olmaktadır. Tarımsal verimliliği etkileyen meteorolojik parametreler, topografik etmenler, bitkisel hastalıklar (uzaktan algılanmış görüntü üzerinden bitki indekslerin kullanılması) gibi faktörlerin derin öğrenme modeli için girdi verisi olarak kullanılmaktadır (Yuan ve diğerleri, 2020). Tarımsal üretimin incelenmesi ve üretim tahmininin yapılabilmesi için derin öğrenme yaklaşımı kullanılmıştır. İlgili çalışmada, Sentinel-2 uydu görüntüsünün yanında yardımcı veri olarak MODIS (Moderate Resolution Imaging Spectroradiometer) uydusuna ait sıcaklık ve buharlaşma verileri kullanılmıştır. Bu veriler, ESA ve tekrarlayan yapay sinir ağı modelinde kullanılmıştır. Çalışmanın sonucunda, önerilen derin öğrenme modeli ile verim tahmini yapmanın mümkün olduğu belirtilmiştir (Ghazaryan ve diğerleri, 2020). Son olarak, bahsedilen uygulama alanlarının yanında görüntüden özellik çıkartma, yağış-sıcaklık tahmini, volkan, sel, deprem gibi doğa olaylarının izlenmesi ve takibinde de derin öğrenme yaklaşımları kullanılmaktadır (Zhang ve diğerleri, 2016; Ma ve diğerleri, 2019; Yuan ve diğerleri, 2020)

4. SONUÇ VE ÖNERİLER

Derin öğrenme yaklaşımı, uzaktan algılama çalışmalarında özellikle nesne tespiti, özellik çıkarımı ve sınıflandırma gibi uygulamalarda yaygın olarak kullanılmaktadır. Derin öğrenme kullanılarak yapılan çalışmalarda diğer metotlara göre önemli bir başarı gözlenmektedir. Özellikle, büyük veri kategorisine giren hiperspektral, çok bantlı görüntüler ve radar görüntülerinin analizinde geleneksel yöntemlere göre derin öğrenme yaklaşımı daha iyi performans göstermektedir. Büyük verilerin, objektif bir şekilde


değerlendirilmesinin yanında, bu verileri içeren karmaşık problemlerin çözülebilmesi, derin öğrenme mimarilerinin en önemli avantajlarıdır. Derin öğrenme yönteminin yaygın olarak kullanılmasının diğer sebeplerinden bir de, bilgisayar donanımlarının gelişmesi ve Google gibi şirketlerin kullanıcılara ücretsiz GPU servisi sağlamasıdır.

Bu makalede, derin öğrenme modellerinden biri olan ESA katmanlarının çalışma prensibinden ve bu modelin eğitimi esnasında ESA katmanlarının sağladığı avantajlar açıklanmıştır. Bunların yanında derin öğrenme mimarisinin eğitimini etkileyen harekete geçirme ve maliyet fonksiyonları üzerinde durulmuştur. Uzaktan algılama uygulamalarından ön işlem, görüntü sınıflandırma, nesne tespiti, görüntü yorumlama ve diğer uygulama alanları için literatür taraması yapılmıştır. Ön işlem uygulamalarında, derin öğrenme yaklaşımı görüntü zenginleştirme veya görüntüden bulut çıkartma işlemleri için kullanıldığı görülmüştür. Görüntü sınıflandırma çalışmalarında ise genellikle hiperspektral veya yüksek çözünürlük görüntülerin sınıflandırma işlemi yapıldığı ve derin öğrenme yöntemiyle başarılı sonuçlar elde edildiği raporlanmıştır. Nesne tespiti uygulamalarında ise radar veya çok bantlı görüntüler kullanılarak bina, araç ve gemi gibi nesnelerin tespiti için derin öğrenme mimarileri kullanılmıştır. Son olarak, uydu görüntülerindeki nesnelere arasındaki hem semantik hem de mekânsal ilişkilerin kurulabilmesi için derin öğrenme mimarileri ile görüntü yorumlama uygulamalarının yapıldığı gösterilmiştir.

Derin öğrenme modelleri kara kutu prensibi ile çalıştığı için gerçekleşen matematiksel işlemler hakkında bilgi edinme bir problem olarak karşımıza çıkmaktadır. Bu nedenle, modelin eğitimini etkileyen iç faktörler bilinmediği için bunlar üzerine çalışılmaktadır. Eğitimde kullanılan örneklem sayısının veya örneklem boyutundaki değişimlerin eğitimi nasıl etkileyeceği üzerinde yapılan çalışmaların yanında, görüntü sınıflandırması için oluşturulan derin öğrenme modelinin nasıl bir mimariye sahip olması gerektiği ve bu mimaride kullanılan parametrelerin nasıl seçilmesi gerektiği ile ilgili optimizasyon çalışmalarının yoğun olarak devam ettiği görülmüştür.

ORCID

Elif Özlem YILMAZ  <https://orcid.org/0000-0002-6853-2148>

Taşkın KAVZOĞLU  <https://orcid.org/0000-0002-9779-3443>

KAYNAKLAR

- Abdel-Hamid, O., Mohamed, A.R., Jiang, H., Deng, L., Penn, G. ve Yu, D. (2014). Convolutional neural networks for speech recognition. *IEEE Transactions on Audio, Speech and Language Processing*, 22(10), 1533-1545. doi:10.1109/TASLP.2014.2339736
- Al-amri, S.S., Kalyankar, N.V. ve Khamitkar, S.D. (2010). A comparative Study of Removal Noise from Remote Sensing Image. *International Journal of Computer Science Issues*, 7(1), 32–36. arXiv:1002.1148
- Alganci, U., Soydas, M. ve Sertel, E. (2020). Comparative research on deep learning approaches for airplane detection from very high-resolution satellite images. *Remote Sensing*, 12(3), 458. doi:10.3390/rs12030458
- Alom, M.Z., Taha, T.M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M.S., ... Asari, V.K. (2019). A state-of-the-art survey on deep learning theory and architectures. *Electronics*, 8(3), 292. doi:10.3390/electronics8030292
- Audebert, N., Le Saux, B. ve Lefevre, S. (2019). Deep learning for classification of hyperspectral data: A comparative review. *IEEE Geoscience and Remote Sensing Magazine*, 7(2), 159-173. doi:10.1109/MGRS.2019.2912563
- Ball, J.E., Anderson, D.T. ve Chan, C.S. (2017). Comprehensive survey of deep learning in remote sensing: theories, tools, and challenges for the community. *Journal of Applied Remote Sensing*, 11(04), 042609. doi:10.1117/1.jrs.11.042609
- Chen, K., Fu, K., Gao, X., Yan, M., Sun, X. ve Zhang, H. (2017, Aralık). *Building extraction from remote sensing images with deep learning in a supervised manner*. 2017 IEEE International Geoscience and Remote Sensing Symposium, Teksas, ABD.
- Chen, J., Huang, H., Peng, J., Zhu, J., Chen, L., Tao, C. ve Li, H. (2021). Contextual Information-Preserved Architecture Learning for Remote-Sensing Scene Classification. *IEEE Transactions on Geoscience and Remote Sensing (Early Access)*. doi: 10.1109/TGRS.2021.3063287

- Chen, Y., Lin, Z., Zhao, X., Wang, G. ve Gu, Y. (2014). Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6), 2094-2107. doi: 10.1109/JSTARS.2014.2329330
- Chen, Y., Zhao, X. ve Jia, X. (2015). Spectral-spatial classification of hyperspectral data based on deep belief network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6), 2381-2392. doi:10.1109/JSTARS.2015.2388577
- Cheng, G. ve Han, J. (2016). A survey on object detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 117, 11–28. doi:10.1016/j.isprsjrs.2016.03.014
- Claesson, L. ve Hansson, B. (2017). *Deep learning methods and applications* (Yüksek Lisans Tezi). Chalmers University of Technology, İsveç.
- Demyanov, S. (2015). *Regularization methods for neural networks and related models* (Doktora Tezi). The University of Melbourne, Avustralya.
- Deng, Z., Sun, H., Zhou, S., Zhao, J. ve Zou, H. (2017). Toward fast and accurate vehicle detection in aerial images using coupled region-based convolutional neural networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(8), 3652-3664. doi:10.1109/JSTARS.2017.2694890
- dos Santos, A.A., Marcato Junior, J., Araújo, M.S., Di Martini, D.R., Tetila, E.C., Siqueira, H.L., ... Gonçalves, W.N. (2019). Assessment of CNN-based methods for individual tree detection on images captured by RGB cameras attached to UAVS. *Sensors*, 19(16), 3595. doi:10.3390/s19163595
- Dong, L., Du, H., Mao, F., Han, N., Li, X., Zhou, G., ... Liu, T. (2020). Very high resolution remote sensing imagery classification using a fusion of random forest and deep learning technique—Subtropical area for example. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 113–128. doi:10.1109/JSTARS.2019.2953234
- Ducournau, A. ve Fablet, R. (2016, Mart). *Deep learning for ocean remote sensing: An application of convolutional neural networks for super-resolution on satellite-derived SST data*. 9th IAPR Workshop on Pattern Recognition in Remote Sensing, Cancun, Meksika.
- Erdem, F., Bayram, B., Bakirman, T., Bayrak, O.C., Akpınar, B. (2021). An ensemble deep learning based shoreline segmentation approach (WaterNet) from Landsat 8 OLI images. *Advances in Space Research*, 67(3) 964-974, doi:10.1016/j.asr.2020.10.043.
- Feng, F., Wang, S., Wang, C. ve Zhang, J. (2019). Learning deep hierarchical spatial–spectral features for hyperspectral image classification based on residual 3D-2D CNN. *Sensors*, 19(23), 5276. doi:10.3390/s19235276
- Fukushima, K. (1980). Neocognitron: a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol. Cybernetics* 36, 193-202. doi:10.1007/BF00344251
- Furukawa, H. (2018). *Deep Learning for End-to-End Automatic Target Recognition from Synthetic Aperture Radar Imagery*. (SANE2017-92), Japonya: The Institute of Electronics, Information and Communication Engineers.
- Garcia-Garcia, A., Orts-Escolano, S., Oprea, S., Villena-Martinez, V., Martinez-Gonzalez, P. ve Garcia-Rodriguez, J. (2018). A survey on deep learning techniques for image and video semantic segmentation. *Applied Soft Computing*, 70, 41-65. doi: 10.1016/j.asoc.2018.05.018
- Gargiulo, M., Mazza, A., Gaetano, R., Ruello, G. ve Scarpa, G. (2018, Kasım). *A CNN-Based fusion method for super-resolution of Sentinel-2 data*. IEEE International Geoscience and Remote Sensing Symposium, Valensiya, İspanya.
- Ghamisi, P., Chen, Y. ve Zhu, X.X. (2016). A self-improving convolution neural network for the classification of hyperspectral data. *IEEE Geoscience and Remote Sensing Letters*, 13(10), 1537-1541. doi:10.1109/LGRS.2016.2595108

- Ghazaryan, G., Skakun, S., Konig, S., Rezaei, E. E., Siebert, S. ve Dubovyk, O. (2020, Şubat). *Crop yield estimation using multi-source satellite image series and deep learning*. IEEE International Geoscience and Remote Sensing Symposium, Waikoloa, USA.
- Ghuman, P. ve Cheng, I. (2020). DeepInSAR-a deep learning framework for sar interferometric phase restoration and coherence estimation. *Remote Sensing*, 12(14), 2340. doi:10.3390/rs12142340
- Google. (2021) Colaboratory. Erişim Adresi: <https://research.google.com/colaboratory/faq.html>
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354–377. doi:10.1016/j.patcog.2017.10.013
- Gu, Y., Wang, Y. ve Li, Y. (2019). A survey on deep learning-driven remote sensing image scene understanding: scene classification, scene retrieval and scene-guided object detection. *Applied Sciences*, 9(10), 2110. doi:10.3390/app9102110
- Han, Z., Ma, L. ve Chen, H. (2019, Kasım). *Optimization of ship target detection algorithm based on random forest and regional convolutional network*. International Conference on Electronic Engineering and Informatics, Nanjing, Çin.
- Hao, S., Wang, W., Ye, Y., Li, E. ve Bruzzone, L. (2018). A deep network architecture for super-resolution-aided hyperspectral image classification with classwise loss. *IEEE Transactions on Geoscience and Remote Sensing*, 56(8), 4650–4663. doi:10.1109/TGRS.2018.2832228
- He, K., Zhang, X., Ren, S. ve Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016(12), 770–778. doi:10.1109/CVPR.2016.90
- Hebb, D. (1943). *The organization of behavior: a neuropsychological theory* (2. baskı). London: Lawrence Erlbaum Associates.
- Hopfield, J.J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Biophyscs*, 79(8), 2554-2558. doi:10.1073/pnas.79.8.2554
- Huang, W., Xiao, L., Wei, Z., Liu, H. ve Tang, S. (2015). A new pan-sharpening method with deep neural networks. *IEEE Geoscience and Remote Sensing Letters*, 12(5), 1037-1041. doi:10.1109/LGRS.2014.2376034
- Huang, G., Liu, Z., Van Der Maaten, L. ve Weinberger, K.Q. (2017, Haziran). *Densely connected convolutional networks*. IEEE Conference on Computer Vision and Pattern Recognition, HI, USA.
- Ji, S., Zhang, C., Xu, A., Shi, Y. ve Duan, Y. (2018). 3D convolutional neural networks for crop classification with multi-temporal remote sensing images. *Remote Sensing*, 10(1), 75. doi:10.3390/rs10010075
- Jiao, J., Zhang, Y., Sun, H., Yang, X., Gao, X., Hong, W., ... Sun, X. (2018). A densely connected end-to-end neural network for multiscale and multiscene SAR ship detection. *IEEE Access*, 6, 20881-20892. doi:10.1109/ACCESS.2018.2825376
- Jiao, L., Zhang, F., Liu, F., Yang, S., Li, L., Feng, Z. ve Qu, R. (2019). A survey of deep learning-based object detection. *IEEE Access*, 7, 128837-128868. doi:10.1109/ACCESS.2019.2939201
- Jin, J., Dundar, A. ve Culurciello, E. (2015, Aralık). *Flattened convolutional neural networks for feedforward acceleration*. International Conference on Learning Representations, San Diego, ABD.
- Kaiser, P., Wegner, J. D., Lucchi, A., Jaggi, M., Hofmann, T. ve Schindler, K. (2017). Learning aerial image segmentation from online maps. *IEEE Transactions on Geoscience and Remote Sensing*, 55(11), 6054-6068. doi:10.1109/TGRS.2017.2719738
- Kang, M., Lin, Z., Xiangguang, L. ve Ji, K. (2017, Mayıs). *A modified faster R-CNN based on CFAR algorithm for SAR ship detection*. International Workshop on Remote Sensing with Intelligent Processing, Shanghai, Çin.

- Kavzoglu, T. ve Mather, P.M. (1998, Eylül). *Assessing artificial neural network pruning algorithms*. Proceedings of the 24th Annual Conference and Exhibition of the Remote Sensing Society, Greenwich, Birleşik Krallık.
- Kavzoglu, T. ve Mather, P.M. (1999). Pruning artificial neural networks: an example using land cover classification of multi-sensor images. *International Journal of Remote Sensing*, 20(14), 2787-2803. doi:10.1080/014311699211796
- Kavzoglu, T. ve Mather, P.M. (2003). The use of backpropagating artificial neural networks in land cover classification. *International Journal of Remote Sensing*, 24(23), 4907-4938. doi:10.1080/0143116031000114851
- Khelifi, L. ve Mignotte, M. (2020). Deep learning for change detection in remote sensing images: Comprehensive review and meta-analysis. *IEEE Access*, 8, 126385–126400. doi:10.1109/ACCESS.2020.3008036
- Khan, A., Sohail, A., Zahoora, U. ve Qureshi, A.S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53(8), 5455-5516. doi:10.1007/s10462-020-09825-6
- Khan, S., Rahmani, H., Shah, S.A.A. ve Bennamoun, M. (2018). A guide to convolutional neural networks for computer vision (1. baskı). *Avustralya: Morgan & Claypool*
- Koutsoukas, A., Monaghan, K.J., Li, X. ve Huan, J. (2017). Deep-learning: Investigating deep neural networks hyper-parameters and comparison of performance to shallow methods for modeling bioactivity data. *Journal of Cheminformatics*, 9(1), 42. doi:10.1186/s13321-017-0226-y
- Krizhevsky, A., Sutskever, I. ve Hinton, G.E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90. doi:10.1145/3065386
- LeCun, Y. (1989). *Generalization and network design strategies* (CRGTR-89-4), University of Toronto.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2323. doi:10.1109/5.726791
- LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep Learning. *Nature*, 521, 436-444. doi:10.1038/nature14539
- Li, H., Peng, J., Tao, C., Chen, J.J. ve Deng, M. (2017). What do we learn by semantic scene understanding for remote sensing imagery in CNN framework? Erişim Adresi: <https://arxiv.org/abs/1705.07077>
- Li, S., Song, W., Fang, L., Chen, Y., Ghamisi, P. ve Benediktsson, J.A. (2019). Deep learning for hyperspectral image classification: an overview. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9), 6690-6709. doi:10.1109/TGRS.2019.2907932
- Li, S., Dragicevic, S., Anton, F., Sester, M., Winter, S., Coltekin, A., ... Cheng, T. (2015). Geospatial big data handling theory and methods: a review and research challenges. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115(2016), 119-133. doi:10.3390/ijgi5050055.
- Li, Z., Wang, R., Zhang, W., Hu, F. ve Meng, L. (2019). Multiscale features supported Deeplabv3+ optimization scheme for accurate water semantic segmentation. *IEEE Access*, 7, 155787-155804. doi:10.1109/ACCESS.2019.2949635
- Li, W., Zou, Z. ve Shi, Z. (2020). Deep matting for cloud detection in remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 58(12), 8490-8502. doi:10.1109/tgrs.2020.2988265
- Li, X., Zhan, G., Huang, H.H., Wang, Z. ve Zheng, W. (2016, Ağustos). *Performance analysis of GPU-based convolutional neural networks*. Proceedings of the International Conference on Parallel Processing, PA, USA.
- Li, Y., Zhang, H. ve Shen, Q. (2017). Spectral – spatial classification of hyperspectral imagery with 3D Convolutional Neural Network. *Remote Sensing*, 9(1), 67. doi:10.3390/rs9010067

- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y. ve Alsaadi, F.E. (2017). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11–26. doi:10.1016/j.neucom.2016.12.038
- Liu, B., Li, Y., Li, G. ve Liu, A. (2019). A Spectral feature based convolutional neural network for classification of sea surface oil spill. *ISPRS International Journal of Geo-Information*, 8(4), 160. doi:10.3390/ijgi8040160
- Liu, X., Mei, S., Zhang, Z., Zhang, Y., Ji, J. ve Du, Q. (2019, Kasım). *Decs-Net: Convolutional Self-Encoding network for hyperspectral image denoising*. IEEE International Geoscience and Remote Sensing Symposium, Yokohama, Japonya.
- Luus, F.P.S., Salmon, B.P., Van Den Bergh, F. ve Maharaj, B.T.J. (2015). Multiview deep learning for land-use classification. *IEEE Geoscience and Remote Sensing Letters*, 12(12), 2448-2452. doi:10.1109/LGRS.2015.2483680
- Ma, Y., Wu, H., Wang, L., Huang, B., Ranjan, R., Zomaya, A. ve Jie, W. (2015). Remote sensing big data computing: challenges and opportunities. *Future Generation Computer Systems*, 51, 47-60. doi:10.1016/j.future.2014.10.029
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G. ve Johnson, B.A. (2019). Deep learning in remote sensing applications: a meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166-177. doi:10.1016/j.isprsjprs.2019.04.01
- Maffei, A., Haut, J.M., Paoletti, M.E., Plaza, J., Bruzzone, L. ve Plaza, A. (2020). A single model CNN for hyperspectral image denoising. *IEEE Transactions on Geoscience and Remote Sensing*, 58(4), 2516-2529. doi:10.1109/TGRS.2019.295206
- Mahdianpari, M., Salehi, B., Rezaee, M., Mohammadimanesh, F. ve Zhang, Y. (2018). Very deep convolutional neural networks for complex land cover mapping using multispectral remote sensing imagery. *Remote Sensing*, 10(7), 1119. doi:10.3390/rs10071119
- Maggiori, E., Tarabalka, Y., Charpiat, G. ve Alliez, P. (2017). Convolutional neural networks for large-scale remote sensing image classification. *IEEE Transactions On Geoscience And Remote Sensing*, 55(2), 645-657. doi:10.1109/TGRS.2016.2612821
- McCulloch, W.S. ve Pitts, W. (1943). A logical calculus of the ideas immanent innervous activity. *Bulletin of Mathematical Biophysics*, 5, 115-133. doi:10.1007/BF02478259
- Meng, X., Shen, H., Li, H., Zhang, L. ve Fu, R. (2019). Review of the pansharpening methods for remote sensing images based on the idea of meta-analysis: Practical discussion and challenges. *Information Fusion*, 46(June), 102–113. doi:10.1016/j.inffus.2018.05.006
- Meng, L., Peng, Z., Zhou, J., Zhang, J., Lu, Z., Baumann, A. ve Du, Y. (2020). Real-time detection of ground objects based on unmanned aerial vehicle remote sensing with deep learning: application in excavator detection for dipeline safety. *Remote Sensing*, 12(1), 182. doi:10.3390/RS12010182
- Minsky, M. ve Papert, S. (1970). A review of perceptrons : an introduction to computational geometry. *Information and Control*, 17, 501-522. doi:10.1016/S0019-9958(70)90409-2
- Nguyen, H.V., Ulfarsson, M.O. ve Sveinsson, J.R. (2020, Ekim). Sure based Convolutional Neural Networks for hyperspectral image denoising. *International Geoscience and Remote Sensing Symposium*, HI, ABD.
- Nwankpa, C., Ijomah, W., Gachagan, A. ve Marshall, S. (2020, Aralık). *Activation functions: comparison of trends in practice and research for deep learning*. 2nd International Conference on Computational Sciences and Technologies, Jamshoro, Pakistan.
- Özçelik, F., Algancı, U., Sertel, E. ve Ünal, G., (2021). Rethinking CNN-Based pan-sharpening: guided colorization of panchromatic images via GANs. *IEEE Transactions on Geoscience And Remote Sensing*, 59(4), 3486-3501. doi:10.1109/TGRS.2020.3010441.
- Özdemir, M. (2017). Görüntü Keskinleştirme Yöntemlerinin Nesne-Yönelimli Sınıflandırma Açısından Değerlendirilmesi. *Harita Dergisi*, Temmuz(158), 26–34.

- Parvat, A., Chavan, J., Kadam, S., Dev, S. ve Pathak, V. (2017, Ocak) *A survey of deep-learning frameworks*. International Conference on Inventive Systems and Control, Coimbatore, Hindistan.
- Peng, L., Qiu, X., Ding, C. ve Tie, W. (2019, Kasım). *Generating 3d point clouds from a single SAR image using 3d reconstruction network*. IEEE International Geoscience and Remote Sensing Symposium, Yokohama, Japan.
- Ren, S., He, K., Girshick, R. ve Sun, J. (2017). Faster R-CNN: towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137–1149. doi:10.1109/TAMI.2016.2577031
- Qing, C., Ruan, J., Xu, X., Ren, J. ve Zabalza, J. (2019). Spatial-spectral classification of hyperspectral images: A deep learning framework with Markov Random fields-based modelling. *IET Image Processing*, 13(2), 235–245. doi:10.1049/ietipr.2018.5727
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. doi:10.1037/h0042519
- Rusyn, B., Korniy, V., Lutsyk, O. ve Kosarevych, R. (2019, Eylül). Deep learning for atmospheric cloud image segmentation. *International Scientific and Practical Conference on Electronics and Information Technologies*, Lviv, Ukraine.
- Saha, S., Mou, L., Qiu, C., Zhu, X. X., Bovolo, F., ve Bruzzone, L. (2020, Ekim). *A novel approach to unsupervised segmentation of multitemporal VHR images based on deep learning*. International Geoscience and Remote Sensing Symposium, Waikoloa, ABD.
- Salman, H., Grover, J. ve Shankar, T. (2018). Hierarchical Reinforcement Learning for Sequencing Behaviors. *Neural Computation*, 27(3), 2709–2733. doi:10.1162/NECO_a_00990
- Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. *Neural Networks*, 61, 85–117. doi:10.1016/j.neunet.201409.003
- Schwalbe, U. (2019). Algorithms, machine learning, and collusion. *Journal of Competition Law & Economics*. 14(4), 568–607. doi:10.1093/joclec/nhz004
- Sidorov, O. ve Hardeberg, J. Y. (2019, Ekim). *Deep hyperspectral prior: Single-image denoising, inpainting, super-resolution*. International Conference on Computer Vision Workshop, Seoul, Kore.
- Simonyan, K. ve Zisserman, A. (2015, Mayıs). *Very deep convolutional networks for large-scale image recognition*. 3rd International Conference on Learning Representations, CA, ABD.
- Sildir, H., Aydin, E. ve Kavzoglu, T. (2020). Design of feedforward neural networks in the classification of hyperspectral imagery using superstructural optimization. *Remote Sensing*, 12(6), 956. doi:10.3390/rs12060956
- Sofu, A. M., Imamoglu, M., Kahraman, F., Cetin, G.B. ve Aptoula, E. (2020, Ekim). Fine-Grained Urban land use and land cover classification through multi-temporal and multispectral remote sensing images. Signal Processing and Communications Applications Conference, Gaziantep, Türkiye.
- Song, Y., Zhang, Z., Baghbaderani, R. K., Wang, F., Qu, Y., Stutts, C. ve Qi, H. (2019, Eylül). *Land cover classification for satellite images through 1D CNN*. 10th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing, Amsterdam, Hollanda.
- Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15, 399–421. doi:10.1016/B978-1-4832-1446-7.50035-2
- Suresh Kumar, M., Keerthi, V., Anjnai, R. N., Manju Sarma, M. ve Bothale, V. (2020, Şubat). *Evaluation of machine learning methods for hyperspectral image classification*. IEEE India Geoscience and Remote Sensing Symposium, Gujarat, Hindistan.
- Sun, H., Li, L., Xu, M., Li, Q. ve Huang, Z. (2020). Using minimum component and CNN for satellite remote sensing image cloud detection. *IEEE Geoscience and Remote Sensing Letters*, 1–5. doi:10.1109/lgrs.2020.3014358

- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... Rabinovich, A. (2015). *Going deeper with convolutions*. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Boston, ABD.
- Tan, Q., Ling, J., Hu, J., Qin, X., ve Hu, J. (2020). Vehicle detection in high resolution satellite remote sensing images based on deep learning. *IEEE Access*, 8, 153394-153402. doi:10.1109/ACCESS.2020.301789
- Tuna, C., Ünal, G. ve Sertel, E., (2018). Single-frame super resolution of remote-sensing images by convolutional neural networks. *International Journal of Remote Sensing*, 39(8), 2463-2479. doi:10.1080/01431161.2018.1425561.
- Vakalopoulou, M., Karantzalos, K., Komodakis, N. ve Paragios, N. (2015, Temmuz). *Building detection in very high resolution multispektral data with deep learning features*. IEEE International Geoscience and Remote Sensing Symposium, Milano, İtalya.
- Vali, A., Comai, S. ve Matteucci, M. (2020). Deep learning for land use and land cover classification based on hyperspectral and multispectral earth observation data: A review. *Remote Sensing*, 12(15), 2495. doi:10.3390/rs12152495
- Wang, P., Alganci, U. ve Sertel, E. (2021). Comparative analysis on deep learning based pan-sharpening of very high-resolution satellite images. *International Journal of Environment and Geoinformatics*, 8(2), 150-165. doi:10.30897/ijegeo.834760
- Wang, H. ve Raj, B. (2017). On the origin of deep learning. Erişim Adresi: <http://arxiv.org/abs/1702.07800>
- Wei, Y., Yuan, Q., Shen, H. ve Zhang, L. (2017). Boosting the accuracy of multi-spectral image pan-sharpening by learning a deep residual network. *IEEE Geoscience and Remote Sensing Letters*, 14(10), 1795-1799. doi:10.1109/LGRS.2017.2736020
- Wang, Q., Yuan, Z., Du, Q. ve Li, X. (2019). GETNET: a general end-to-end 2-d CNN framework for hyperspectral image change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 57(1), 3–13. doi:10.1109/TGRS.2018.2849692
- Weng, Q., Mao, Z., Lin, J. ve Guo, W. (2017). Land-use classification via extreme learning classifier based on deep convolutional features. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 704-708. doi:10.1109/LGRS.2017.2672643
- Widrow, B. ve Hoff, M.E. (1960, Ağustos). *Adaptive switching circuits*. 1960 IRE WESCON Convention Record, CA, ABD.
- Xu, X., Li, W., Ran, Q., Du, Q., Gao, L. ve Zhang, B. (2018). Multisource remote sensing data classification based on convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 56(2), 937-949. doi:10.1109/TGRS.2017.2756851
- Yang, Y., Gu, H., Han, Y. ve Li, H. (2020, Ekim). An end-to-end deep learning change detection framework for remote sensing images. *IEEE International Geoscience and Remote Sensing Symposium, HI, ABD*.
- Yang, H., Yuan, C., Li, B., Du, Y., Xing, J., Hu, W. ve Maybank, S.J. (2019). Asymmetric 3D Convolutional Neural Networks for action recognition. *Pattern Recognition*, 85(6), 1–12. doi:10.1016/j.patcog.2018.07.028
- Yılmaz, E.Ö. (2020). Uzaktan algılanmış verilerin derin öğrenme yöntemiyle sınıflandırılması (Yüksek Lisans Tezi). GTÜ, Fen Bilimleri Enstitüsü, Kocaeli.
- Yuan, M., Liu, Z., Wang, F., Yuan, M., Liu, Z. ve Wang, F. (2019). Evaluation of pre-training impact on fine-tuning for remote sensing scene classification sensing scene classification. *Remote Sensing Letters*, 10(1), 49-58. doi:10.1080/2150704X.2018.1526423
- Yuan, Q., Shen, H., Li, T., Li, Z., Li, S., Jiang, Y., ... Zhang, L. (2020). Deep learning in environmental remote sensing: achievements and challenges. *Remote Sensing of Environment*, 241, 111716. doi:10.1016/j.rse.2020.111716
- Yuan, Q., Zhang, Q., Li, J., Shen, H. ve Zhang, L. (2019). Hyperspectral image denoising employing a spatial-spectral deep residual convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 57(2), 1205-1218. doi:10.1109/TGRS.2018.2865197

- Yue, J., Zhao, W., Mao, S. ve Liu, H. (2015). Spectral-spatial classification of hyperspectral images using deep convolutional neural networks. *Remote Sensing Letters*, 6(6), 468-477. doi:10.1080/2150704X.2015.1047045
- Zhang, L., Zhang, L. ve Du, B. (2016). Deep learning for remote sensing data: a technical tutorial on the state of the art. *IEEE Geoscience and Remote Sensing Magazine*, 4(2), 22-40. doi:10.1109/MGRS.2016.2540798
- Zhang, X., Xu, C., Shen, M., He, X. ve Du, W. (2018). Survey of convolutional neural network. *Advances in Intelligent Systems Research*, 147, 93-97. doi:10.2991/ncce18.2018.16
- Zhang, Y., Liu, C., Sun, M. ve Ou, Y. (2019). Pan-sharpening using an efficient bidirectional pyramid network. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8), 5549-5563. doi:10.1109/TGRS.2019.2900419
- Zhang, Z., Zhang, C. ve Li, W. (2020, Ekim). Semantic segmentation of urban buildings from VHR remotely sensed imagery using attention-based CNN. *IEEE International Geoscience and Remote Sensing Symposium, HI, ABD*.
- Zhao, W. ve Du, S. (2016). Learning multiscale and deep representations for classifying remotely sensed imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 113(March), 155-165. doi:10.1016/j.isprsjprs.2016.01.004
- Zhao, W., Bo, Y., Chen, J., Tiede, D., Blaschke, T. ve Emery W.J. (2019). Exploring semantic elements for urban scene recognition: deep integration of high-resolution imagery and OpenStreetMap. *ISPRS Journal of Photogrammetry and Remote Sensing*, 151(2019), 237-250. doi:10.1016/j.isprsjprs.2019.03.019
- Zheng, X. ve Chen, T. (2020, Ekim). Segmentation of high spatial resolution remote sensing image based on U-Net Convolutional Networks. *2020 IEEE International Geoscience and Remote Sensing Symposium, HI, ABD*.
- Zhu, X.X., Tuia, D., Mou, L., Xia, G.S., Zhang, L., Xu, F. ve Fraundorfer, F. (2017). Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4), 8-36. doi:10.1109/MGRS.2017.2762307

YAZIM ESASLARI

1. Harita Dergisine Yazı Hazırlama Esasları

a. Sayfa büyüklüğü A4 (210x297 mm) standardında olmalı; her sayfanın sağ kenarından 2 cm diğer kenarlarından 3'er cm boşluk bırakılmalıdır. Yazı zorunlu olmadıkça toplam 15 sayfayı geçmemelidir. Yazı, bilgisayarda Microsoft Word formatında Arial Türkçe fontu bir satır aralığı ile yazılmalıdır. Paragraflar arasında bir satır boşluk bırakılmalıdır.

b. Makale adı, Türkçe ve İngilizce olarak kelimelerin ilk harfleri büyük olacak şekilde 12 punto büyüklüğünde sayfanın üst ortasına gelecek şekilde yazılmalı ve iki satırı geçmemelidir. Makale adı, makale içeriğini en fazla ölçüde yansıtmalı; makale içeriğinde anlatılan konuların büyük çoğunluğu, makale adı ile doğrudan ilgili olmalıdır. Makale adından sonra bir satır boşluk bırakıp ortalayarak yazar adı ve soyadı koyu (bold) ve 10 punto harf büyüklüğünde yazılmalıdır (Soyadı büyük harflerle). Yazar adının altına ortalayarak adres ve elektronik posta adresi 9 punto harf büyüklüğünde yazılır.

c. Yazı; makalenin başlangıç kısmına yazılmış, tek paragraf Türkçe ve İngilizce olarak 100-250 kelime arası Türkçe "Öz" ile İngilizce "Abstract", ortalama 5 adet Anahtar Kelime içeren Anahtar Kelimeler ile Key Words (İngilizce anahtar kelimeler), Giriş, Bölümler, Sonuç ve Kaynaklar şeklindeki ana bölümlerden oluşur. Bu bölümlerin tamamı sayfada iki sütun olacak şekilde yazılır. Sütunlar arasında 0,5 cm boşluk bırakılır. Her ana bölüm ve alt bölüm başlığı öncesi ve sonrası bir satır boşluk bırakılır.

Öz bölümünde, yapılan çalışma tanıtılarak kullanılan yöntemler ve sonuçlar kısaca belirtilmeli; abstract bölümü, özün doğru ve eksiksiz tercümesini içermelidir. Giriş bölümünde, çalışmanın amacı ve konuyla ilgili diğer çalışmalar anlatılmalıdır. Ara bölümlerde, kullanılan yöntemler ve veriler açıklanmalı; sonuç bölümünde, bulgular başka araştırmacıların bulguları ile karşılaştırılmalı, yazarın yorumu belirtilmeli ve ayrıca bulgulardan çıkan sonuçlar ve varsa öneriler yazılmalıdır. Öz, abstract, anahtar kelimeler ve key words, 9 punto büyüklüğünde italik harflerle yazılmalıdır. Diğer bölümler 10 punto harf büyüklüğünde normal yazılır.

Ana bölüm başlıkları büyük harflerle koyu (bold) olarak ve alt bölümlerin başlıkları

kelimelerin ilk harfleri büyük diğerleri küçük ve sadece birinci düzey alt bölümlerin başlıkları koyu (bold) olarak yazılmalıdır. Yazının geri kalan kısmı normal baskıda yazılmalı, italik ya da altı çizgili karakterler kullanılmamalıdır. Öz, Anahtar Kelime, Abstract (ingilizce özet), Key Words (İngilizce anahtar kelimeler) ve kaynaklar ana bölümleri dışındaki ana bölüm başlıkları 1., 2., 3.; alt bölüm başlıkları a., b., c.; (1), (2), (3); (a), (b), (c); (i), (ii), (iii); (aa), (bb), (cc) şeklinde hiyerarşik düzeyde numaralandırılmalı; ardışık düzeylerin numaraları arasındaki dikey fark 0.5 cm olmalıdır. Numaralandırılan bölümlerin başlıkları, numaralarının başlangıç hizasından 0.5 cm içeriden; bir alt satıra devam eden bölüm başlıkları sayfa başından; tüm paragraflar sayfanın 0.5 cm içerisinden başlamalıdır.

Noktalama ve imlâ için Türk Dil Kurumu tarafından en son yayımlanan İmlâ Kılavuzu ve Türkçe sözlüğüne, Haritacılık ile ilgili Yönetmeliklerde kullanılan deyimlere uyulmalıdır. İfadelerde üçüncü şahıs kullanılmalı; her sembol ilk geçtiği yerde tanımlanmalı; her kısaltma ilk geçtiği yerde parantez içinde yazılmalı (örneğin, Coğrafi Bilgi Sistemi (CBS)); kelime ikiye bölünmemelidir. Noktalama işaretlerinden sonra bir karakter boşluk bırakılmalı; sayfa numaralama yapılmamalıdır.

ç. Tablo isimleri, tablonun üstüne sol üst köşesinden itibaren yazılmalı (örneğin, Tablo 1. Karesel ortalama hatalar.); şekil isimleri, şeklin altına ortalayarak yazılmalı (örneğin, Şekil 1. CBS tasarımı.); tablo isimlerinden ve şekillerden önce, şekil isimlerinden ve tablolardan sonra bir satır boşluk bırakılmalı; tablolar ve şekiller sayfaya ortalaymalıdır. Tablolar ve şekillerin boyutu tek sütundan büyük olduğu durumlarda, sayfanın tamamına ortalı olarak yazılabilir. Bu durumda tablo ve şekiller metni bölmemeli sayfanın en altında ya da en üstünde yer almalıdır.

d. Denklemlere verilen numaralar, kendi hizalarına ve sayfa sağ kenarına çakışacak şekilde parantez içinde (1),(2),(3),... şeklinde yazılmalıdır. Metin içerisindeki denklemlerin kendi aralarında ve metin ile aralarında bir satır boşluk bırakılır.

e. Makaleler, "MAKALE ÖRNEĞİ"nde sunulan boşluk ve yapılandırılmaya uyularak; Şekil, Tablo ve Denklemler tek sütunda olacak ise metin aralarına konularak; iki sütuna yayılan bir bütün halindeki metin bloğundan sonra veya önce sayfanın alt veya üstünde olacak ve okuma akıcılığını bozmayacak şekilde yazılır.

f. Yazarlar; unvanlarını, görev yaptıkları kurumları, iletişim adreslerini, telefon numaralarını, e-posta adreslerini ve ORCID (Open Researcher ve Contributor ID) numarasını bildirmelidir. <https://orcid.org>

g. Öz ve abstract bölümlerinde kaynak atfı yapılmamalıdır. Metin içinde kaynak gösterme şekilleri aşağıda verilmiştir:

Tek yazarlı çalışmada ilk gönderme ve diğer göndermeler aynı biçimde olacak; gönderme cümle içerisinde yapılıyorsa Ceylan (2018) **veya** gönderme cümlelerinin sonunda yapılıyorsa (Ceylan, 2018)

İki yazarlı çalışmada ilk gönderme ve diğer göndermeler aynı biçimde olacak; gönderme cümle içerisinde yapılıyorsa Simav ve Türkezer (2019) **veya** gönderme cümlelerinin sonunda yapılıyorsa (Simav ve Türkezer, 2019)

Üç, dört ve beş yazarlı çalışmalarda ilk göndermede tüm yazarların soyadları Şengün, Yılmaz ve Kurt (2013) ve diğer göndermelerde Şengün ve diğerleri (2013) **veya** ilk göndermede (Şengün, Yılmaz ve Kurt, 2013) ve diğer göndermelerde (Şengün ve diğerleri, 2013)

Altı ve daha fazla yazarlı çalışmalarda ilk ve diğer göndermelerde sadece ilk yazarın soyadı belirtilir. Yıldız ve diğerleri (2014) veya (Yıldız ve diğerleri, 2014)

Tüzel yazarlı çalışmalarda ilk göndermede Maden Tetkik ve Arama Genel Müdürlüğü (MTA, 2017) ve diğer göndermelerde MTA (2017) **veya** ilk göndermede (Maden Tetkik ve Arama Genel Müdürlüğü [MTA], 2017) ve diğer göndermelerde (MTA, 2017)

ğ. Kaynakların hazırlanmasında Amerikan Psikoloji Birliği (American Psychology Association)'nin hazırladığı rehberin altıncı baskısı (Publication Manual of the American Psychological Association, Sixth Edition) kuralları uygulanacaktır. <https://www.apastyle.org>

Kaynaklar ana bölümü başlığı birer aralıklı büyük harflerle koyu (bold) ve sayfa ortalanarak yazılmalıdır

Kaynaklar ilk yazarlarının soyadına göre alfabetik sırada sıralanır.

Makale veya bölüm başlığındaki ilk kelimenin ilk harfi ve eğer varsa özel adların ilk harfleri büyük yazılır.

İnternet üzerinden ulaşılan ve zaman içerisinde değiştiği düşünülen kaynağın erişim tarihi internet adresi verilmeden önce (Erişim Adresi (19 Mayıs 2018): ...) belirtilmelidir.

Özellikle faydalanılan elektronik kaynağın varsa doi numarası yoksa erişim adresi kaynağın sonuna eklenmelidir.

Elektronik Kaynaklar: Talimat, Rehber vb.

INSPIRE. (2014). *D2.8.1.1 Data Specification on Coordinate Reference Systems – Technical Guidelines* (D2.8.1.1_v3.2). Erişim Adresi: <https://inspire.ec.europa.eu/id/document/tg/rs>

ISO 19111. (2007). *Geographic information - Spatial referencing by coordinates*. Erişim Adresi: <https://www.iso.org/standard/41126.html>

Jekeli, C. (2016). *Geometric Reference Systems in Geodesy*. Erişim Adresi: https://kb.osu.edu/bitstream/handle/1811/77986/Geom_Ref_Sys_Geodesy_2016.pdf?sequence=1&isAllowed=y

EU Official Journal. (2007). *Directive 2007/2/EC of the European Parliament and of the Council of 14 March 2007: Establishing an Infrastructure for Spatial Information in the European Community (INSPIRE)*, (L 108/1). Erişim Adresi: <https://eur-lex.europa.eu/legal-content/EN/ALL/?uri=CELEX:32007L0002>

Teknik Rapor:

Demir, C. (1999). *Türkiye Ulusal Düşey Kontrol Ağı* (JEOFNIV-02-1999). Ankara: Harita Genel Komutanlığı.

Sürelî yayın:

Geymen, A., Yomralıoğlu, T. ve Baz, I. (2008). Developing an urban information system for local governments. *Proceedings of the Institution of Civil Engineers-Municipal Engineer: Published for the Institution of Civil Engineers*, 161(3), 163-173. doi: 10.1680/muen.2008.161.3.163

Moritz, H. (1988). Geodetic Reference System 1980. *Bulletin Géodésique*, 62(3), 348-358. doi:10.1007/bf02520722

Zandbergen, P.A. (2008). A Comparison of address point, parcel and street geocoding techniques. *Computers, Environment and Urban Systems*, 32, 214-232. doi: 10.1016/j.compenvurbsys.2007.11.006

Kitap:

Torge, W. ve Müller, J. (2012). *Geodesy* (4. baskı). Berlin: Walter de Gruyter.

Vanícek, P. ve Krakiwsky, E. (1986). *Geodesy: The Concepts* (2. baskı). Amsterdam: Elsevier.

Day, R.A. (2000). *Bilimsel bir makale nasıl yazılır ve yayımlanır?* (G. A. Altay, Çev.). Ankara: TÜBİTAK.

Sempozyum, Bildiri vb:

Kılıç B. ve Gülgen F. (2017, Kasım). *A Research on Standard Address Usage in Turkey*. UCTEA International Geographical Information Systems Congress 2017, Adana, Türkiye.

Bard, G.V. (2007, Ocak). *Spelling-error tolerant, order-independent pass-phrases via the Damerau-Levenshtein string-edit distance metric*. In Proceedings of the fifth Australasian symposium on ACSW frontiers, Ballarat, Avustralya.

Yakar, M. ve Doğan, Y. (2017, Nisan). Silifke Aşağı Dünya Obruğunun İHA Kullanılarak 3B Modellenmesi. *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği Teknik Sempozyum*, Afyonkarahisar.

Tez:

Kellison, M.T. (2012). *Address points and A Master address file: Improving efficiency in the city of Chino* (Doktora Tezi). ProQuest Dissertations and Theses veri tabanından erişildi. (UMI No. 1532831)

Gençerk, E. Y. (2016). *İnsansız Hava Aracı Fotogrametrisi Uygulaması İle İnşaat Projesi İmalat Durumunun Araştırılması* (Yayımlanmamış Yüksek Lisans Tezi). İTÜ, Fen Bilimleri Enstitüsü, İstanbul.

2. Makalelerin Gönderilmesi

Makaleler, "haritadergisi@harita.gov.tr" adresine e-posta ile gönderilir.

(MAKALE ÖRNEĞİ)

(1) XXXXX XXXXXX XXXXXX XXXXXXXXXXXX.

(2 nci düzey alt bölüm başlığı)

(1 satır boşluk)

XXXXXXXXX XXXX XXXXXX XXXXXXXXXXXX

XXXX XXXXXX XXXXXXXXXXX XXXXXX XXXXXX.

(2 nci düzey alt bölüm 1 nci paragraf)

(1 satır boşluk)

(a) XXXXX XXXXXX XXXXXX XXXX

(3 üncü düzey alt bölüm başlığı)

(1 satır boşluk)

XXXXXXXXX XXXXXXXXXXX XXXXXXXXXXX

XXXX XXXXXX XXXXXXXXXXX XXXXXXX XXXXXXX

XXXXXXXXXX XXXXXXXXXXX XXXX XXXXXX XXXXXXX

XXXXXXXXXXXX XXXXXXXXXXX XXXXXXXXXXX XXXXXXX

XXXXXXXXXX XXXXXXXXXXX XXXXXXXXXXX XXXXXXXXXXX

XXXXXXXXXXXX XXXX XXXXXXX XXXXXX XXXXXXX

XXXXXXXXXXXX XXXXXXXXXXX XXXXXXXXXXX XXXXXXX

XXXX XXXX XXXX XXXXXXXXXXX XXXXXXXXXXX

XXXXXXXXXXXX XXXXXXXXXXXXXXXXXXXX.

(1 satır boşluk)

(b) XXXXX XXXXXX XXXXXX XXXX

(3 üncü düzey alt bölüm başlığı)

(1 satır boşluk)

XXXXXXXXX XXXX XXXXXX XXXXXXX

XXXXXXXX XXXXXX XXXXXX XXXXXX XXXXXXX

XXXXXXXXXXXX XXXX XXXXXX XXXXXX XXXXXXX

XXXXXXXXXXXX XXXX XXXXXXX XXXXXX XXXXXX XXXXXX

XXXX XXXX XXXXXXXXXXX XXXXXXXXXXX XXXXXXXXXXX

XXXXXXXXXXXX XXXXXXXXXXX XXXXXXXXXXX XXXXXX XXXX

XXXXXXXXXXXX XXXXXXXXXXX XXXXXX XXXXXXXXXXX XXX

XXXXXXXXXXXX XXXXXXXXXXX XXXXXX XXXXXXXXXXX XXX

XXXXXXXX XXXXXX XXXX XXXX.

(1 satır boşluk)

(l) XXXXX XXXXXX XXXXXX XXXX

(4 üncü düzey alt bölüm başlığı)

(1 satır boşluk)

XXXX XXXX XXX XXXXXXX XXXXXXX

XXXXXXXX XXXX XXXXXXXXXXX XXXXXX XXXXXXX

XXXXXXXXXXXXXXXX XXXXXXXXXXX XXXXXX XXXXXXX

XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX XXXXXXXXXXX XXXXXX

XXXXXXXX XXXXXX XXXXXXXXXXX XXXXXXXXXXXXXXXXXXX

XXXXXXXX XXXXXX XXXXXXXXXXX XXXXXXXXXXX XXXX XXXXXXX

XXXXXXXX XXXXXXXXXXX XXXXXXXXXXX XXXXXXXXXXX

XXXXXXXXXXXXXXXX XXXX XXXXXX XXXXXXXXXXX XXX XXXX.

(1 satır boşluk)

Tablo 1. XXXX XXXXXXX XXXXXXX XXXXXXX

(1 satır boşluk)

XXXXXXXX XXXX XXX XXXXXX XXXXXXXXXXXXXXXXXXX

XXXXXXXX XXXXXX XXXXXX XXXXXX XXXXXX XXXXXXXXXXX

XXXX XXX XXXX XXXXXX XXXXXX.

(1 satır boşluk)

$$KOH = \sqrt{\frac{\sum_{i=1}^n X_i - X_{i(RASAT)}}{n}} \quad (1)$$


(1 satır boşluk)

XXXXXXXX XXXX XXX XXXX XXXXXXXXXXXXXXXXXXX

XXXXXXXX XXXXXX XXXXXX XXXXXX XXXXXX XXXXXXXXXXX

XXXX XXX XXXXXX XXXXXX .

(1 satır boşluk)



(1 satır boşluk)

Şekil 1. XXXXXX XXX XXXXXXXXXXX XXXXXX

(1 satır boşluk)

XXXXXXXX XXXXXX XXXX XXXXXX XXXX XXXXXXX

XXXXXXXX XXXXXX XXXX XX XXXXX

XXXXXXXXXXXXXXXXXXXXXXXX XXXXXXXXXXXXXXXXXXX

XXXX.

(1 satır boşluk)

3. SONUÇ

(1 satır boşluk)

XXXX XXXXXXXXXXX XXXXXXXXXXXXXXXXXXX

XXXXXXXXXXXXXXXX XXXXXX XXXXXX XXXX XXXXX.

(1 satır boşluk)

KAYNAKLAR

(1 satır boşluk)

Sürelî Yayınlar:

Yazar, A. A., Yazar, B. B. ve Yazar, C. C. (Yıl).

Yazının başlığı. *Sürelî Yayının Başlığı*, Cilt, s-

s. doi:xx.xxxxxxxxxx (veya Erişim Adresi:)

Kitap:Yazar, A. A. (Yıl). *Eserin başlığı*. Yer: Yayıncı.Yazar, A. A. (Yıl). *Eserin başlığı*. Erişim adresi:<http://www.xxxxxxxxxx>Yazar, A. A. (Yıl). *Eserin başlığı*.

doi:xxxxxxxxxxxx

Editor, A. A. (Ed.). (Yıl). *Eserin başlığı*. Yer:

Yayıncı.

Yazar, A. A. ve Yazar, B. B. (Yıl). *Bölüm ya da**giriş başlığı*. A. Editör, B. Editör ve C. Editör

(Ed.), Kitap başlığı (s. xxx-xxx) içinde. Yer:

Yayıncı.

Doktora ve yüksek lisans tezleri:Yazar, A. A. (Yıl). *Doktora ya da yüksek lisans**tezinin başlığı* (Yüksek lisans tezi/Doktora

tezi). ... veri tabanından erişildi (Erişim ya da

Sipariş No.).

Yazar, A. A. (Yıl). *Doktora ya da yüksek lisans**tezinin başlığı* (Yayımlanmamış doktora

tezi/yüksek lisans tezi). Kurum adı, Yer bilgisi.

Teknik raporlar ve araştırma raporları:Yazar, A. A. (Yıl). *Çalışmanın başlığı* (Rapor No.

xxx). Yer bilgisi: Yayıncı.

Toplantı ve sempozyumlar:Sunan, A. A. (Yıl, Ay). *Bildiri ya da poster başlığı*.

Kuruluş Adının toplantısında sunulan bildiri ya

da poster, Yer bilgisi.

