



2020

Turkish Journal of
Remote Sensing and GIS

Turkish Journal of Remote Sensing and GIS

Türk Uzaktan Algılama
ve CBS Dergisi



Baş Editör / Editor in Chief

Doç. Dr. Halil AKINCI, Artvin Çoruh Üniversitesi, Artvin, Türkiye.

Yardımcı Editörler / Associate Editors

Dr. Öğr. Üyesi Mustafa ZEYBEK, Artvin Çoruh Üniversitesi, Artvin, Türkiye.

Dr. Öğr. Üyesi Volkan YILMAZ, Artvin Çoruh Üniversitesi, Artvin, Türkiye.

Yabancı Dil Editörü / Language Editor

Dr. Öğr. Üyesi Volkan YILMAZ, Artvin Çoruh Üniversitesi, Artvin, Türkiye.

Sorumlu Yazı İşleri Müdürü / Managing Editor

Doç. Dr. Ayşe YAVUZ ÖZALP, Artvin Çoruh Üniversitesi, Artvin, Türkiye.

Yayın Kurulu / Publishing Board

Prof. Dr. Çetin CÖMERT, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye.

Prof. Dr. Dursun Zafer ŞEKER, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. İbrahim Öztuğ BİLDİRİCİ, Konya Teknik Üniversitesi, Konya, Türkiye.

Prof. Dr. Mustafa TÜRKER, Hacettepe Üniversitesi, Ankara, Türkiye.

Prof. Dr. Oğuz GÜNGÖR, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye.

Doç. Dr. Sedat DOĞAN, Ondokuz Mayıs Üniversitesi, Samsun, Türkiye.

Editör Kurulu / Editorial Board

Prof. Dr. Ali Melih BAŞARANER, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. Arzu ÇÖLTEKİN, University of Applied Sciences and Arts Northwestern Switzerland.

Prof. Dr. Bülent BAYRAM, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. Çetin CÖMERT, Karadeniz Teknik Üniversitesi, Türkiye.

Prof. Dr. Çiğdem GÖKSEL, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. Dursun Zafer ŞEKER, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. Fevzi KARSLI, Karadeniz Teknik Üniversitesi, Türkiye.

Prof. Dr. Fusun Balık ŞANLI, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. İbrahim Öztuğ BİLDİRİCİ, Konya Teknik Üniversitesi, Konya, Türkiye.

Prof. Dr. İsmail Rakıp KARAŞ, Karabük Üniversitesi, Türkiye.

Prof. Dr. Mustafa TÜRKER, Hacettepe Üniversitesi, Ankara, Türkiye.

Prof. Dr. Nesibe Necla ULUĞTEKİN, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.

Prof. Dr. Oğuz GÜNGÖR, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye.

Prof. Dr. Süleyman Savaş DURDURAN, Necmettin Erbakan Üniversitesi, Konya, Türkiye.

Prof. Dr. Tarık TÜRK, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye.

Doç. Dr. Ahmet Özgür DOĞRU, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.

Doç. Dr. Arzu ERENER, Kocaeli Üniversitesi, Kocaeli, Türkiye.

Doç. Dr. Derya ÖZTÜRK, Ondokuz Mayıs Üniversitesi, Samsun, Türkiye.

Doç. Dr. Mehmet Ali YÜCEL, Çanakkale Onsekiz Mart Üniversitesi, Çanakkale, Türkiye.

Doç. Dr. Mehmet Devrim AKÇA, Işık Üniversitesi, İstanbul, Türkiye.

Doç. Dr. Mehmet ALKAN, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.

Doç. Dr. Krzysztof STERENCZAK, Instytut Badawczy Leśnictwa, Poland.

Doç. Dr. Saygın ABDİKAN, Zonguldak Bülent Ecevit Üniversitesi, Zonguldak, Türkiye.

Doç. Dr. Sultan KOCAMAN, Hacettepe Üniversitesi, Ankara, Türkiye.

Doç. Dr. Uğur ALGANCI, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.

Doç. Dr. Umut Güneş SEFERCİK, Zonguldak Bülent Ecevit Üniversitesi, Zonguldak, Türkiye.

Dr. Öğr. Üyesi Caner GÜNEY, İstanbul Teknik Üniversitesi, İstanbul, Türkiye.



Editör Kurulu / Editorial Board

- Dr. Öğr. Üyesi Deniztan ULUTAŞ KARAKOL, Karadeniz Teknik Üniversitesi, Türkiye.
Dr. Öğr. Üyesi Esra TUNÇ GÖRMÜŞ, Karadeniz Teknik Üniversitesi, Türkiye.
Dr. Öğr. Üyesi Gülten KARA, Karadeniz Teknik Üniversitesi, Türkiye.
Dr. Öğr. Üyesi Hasan Tahsin BOSTANCI, Gümüşhane Üniversitesi, Gümüşhane, Türkiye.
Dr. Öğr. Üyesi İsmail Ercüment AYAZLI, Sivas Cumhuriyet Üniversitesi, Sivas, Türkiye.
Dr. Öğr. Üyesi Nusret DEMİR, Akdeniz Üniversitesi, Antalya, Türkiye.
Dr. Öğr. Üyesi Özlem AKAR, Erzincan Binali Yıldırım Üniversitesi, Erzincan, Türkiye.
Dr. Öğr. Üyesi Resul ÇÖMERT, Gümüşhane Üniversitesi, Gümüşhane, Türkiye.
Dr. Abdulla M. AL-RAWABDEH, Yarmouk University, Irbid, Jordan.
Dr. Aikaterini KARAGIANNI, Aristotle University of Thessaloniki, Greece.
Dr. Davod POREH, University of Napoli Federico II, Napoli, Italy.
Dr. Manohar YADAV, Motilal Nehru National Institute of Technology (MNNIT) Allahabad Prayagraj, India.
Dr. Mohammed DABBOOR, Environment and Climate Change Canada.
Dr. Mustafa ÜSTÜNER, Yıldız Teknik Üniversitesi, İstanbul, Türkiye.
Dr. Serkan URAL, ETH Zurich- Computational Physics, Switzerland.
Dr. Yasemin KUZU SINRAM, Hexagon Geospatial Ltd. USA.



İÇİNDEKİLER / CONTENTS

ARAŞTIRMA MAKALELERİ RESEARCH ARTICLES

- Metasezgisel Guguk Kuşu Arama Algoritması ile Görüntü Kaynaştırma
Image Fusion with Metaheuristic Cuckoo Search Algorithm
Volkan Yılmaz..... 1 - 12
- İHA Kullanarak Yol Bozukluk Ölçmeleri
Road Distress Measurements Using UAV
Mustafa Zeybek, Serkan Biçici..... 13 - 23
- Derin Öğrenme Amaçlı Etiketli Veri Üretimi İçin Bir Web Platformu
A Web Platform for the Generation of Labeled Data for Deep Learning
Ekrem Saralioğlu, Oğuz Güngör..... 24 - 33
- Kaynaştırılmış Görüntülerden Elde Edilen Gabor Doku Özellikleri ile DVM Sınıflandırma Performansının İyileştirilmesi
Improving SVM Classification Accuracy with Image Fusion-Based Gabor Texture Features
Çiğdem Şerifoğlu Yılmaz, Oğuz Güngör..... 34 - 44
- Mimari Dökümantasyonda Yersel Lazer Tarama Teknolojisi Kullanımı: Tarihi Sismoloji Binası Örneği
The Use of Terrestrial Laser Scanning Technology in Architectural Documentation: A case study of Historical Seismology Building
Aslı Sabuncu, Haluk Özener..... 45 - 52
- Yer Yüzeyi Kararlılığının Radar Uydu Görüntüleriyle Gözlenmesi
The Earth Surface Stability Observation by Satellite Radar Images
Davod Poreh..... 53 - 60

Metasezgisel Guguk Kuşu Arama Algoritması ile Görüntü Kaynaştırma Image Fusion with Metaheuristic Cuckoo Search Algorithm

Volkan Yılmaz^{1*} 

¹ Artvin Çoruh Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 08100, Artvin/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Volkan Yılmaz
volkanyilmaz.jdz@gmail.com

doi:

Yayın süreci

Geliş tarihi : 28.12.2019

Kabul tarihi : 11.02.2020

Basım tarihi: 31.03.2020

Özet

Bileşen değişimi tabanlı görüntü kaynaştırma yöntemleri literatürde en fazla kullanılan görüntü kaynaştırma yöntemleri arasındadır. Bu yöntemler konumsal detayları iyileştirmedeki başarılarına rağmen girdi çok bantlı görüntülerin renk yapısını bozma eğilimindedirler. Bu durumun temel nedeni bu yöntemlerin girdi çok bantlı görüntülerin bantlarından elde ettikleri yoğunluk bileşenini optimize edememeleridir. Bu çalışmada, yoğunluk bileşeninin optimize edilebilmesi için metasezgisel guguk kuşu arama algoritmasından yararlanan bir görüntü kaynaştırma yöntemi önerilmiştir. Önerilen yaklaşım en yaygın kullanılan bileşen değişimi tabanlı kaynaştırma yöntemlerinden biri olan Gram-Schmidt (GS) yöntemi üzerinde uygulanmıştır. Önerilen yöntemin renk koruma performansı Yüksek Geçirgen Filtreleme (HPF) yönteminin yanı sıra popüler bileşen değişimi tabanlı yöntemlerden olan Multiplicative (MCV), Brovey (BRV), Temel Bileşen Analizi (PCA), Ehlers (EHL), Modifiye edilmiş Intensity-Hue-Saturation (MIHS), Synthetic Variable Ratio (SVR) ve orijinal GS yöntemlerinin renk koruma performansları ile iki test bölgesinde niteliksel ve niceliksel olarak karşılaştırılmıştır. Elde edilen sonuçlar önerilen yöntemin yoğunluk bileşenini başarılı bir şekilde optimize ettiğini ve bu nedenle de girdi çok bantlı görüntünün renk içeriğini kullanılan diğer yöntemlere oranla daha başarılı bir şekilde koruduğunu göstermiştir.

Anahtar kelimeler: Görüntü kaynaştırma, Metasezgisel optimizasyon, Gram-Schmidt, Guguk kuşu arama algoritması, Pankromatik keskinleştirme, Bileşen değişimi tabanlı görüntü kaynaştırma

Abstract

Component substitution-based fusion methods are among the most widespread image fusion methods in the literature. Despite the fact that these methods are very successful in enhancing the spatial detail quality, they tend to deteriorate the spectral quality of the input multispectral images. The main reason for this is that they are not so successful in optimizing the intensity component produced from the input multispectral bands. In this study, an image fusion method which utilizes metaheuristic cuckoo search algorithm was proposed to optimize the intensity component used in fusion process. The proposed method was applied on the Gram-Schmidt (GS) method, one of the most widely-used component substitution-based image fusion methods. The colour preservation performance of the proposed method was qualitatively and quantitatively compared not only against that of the High-Pass Filtering (HPF) method, but also against those of popular component substitution-based methods Multiplicative (MCV), Brovey (BRV), Principal Component Analysis (PCA), Ehlers (EHL), Modified Intensity-Hue-Saturation (MIHS), Synthetic Variable Ratio (SVR) and original GS in two test sites. The results showed that the proposed method was successful in optimizing the intensity component and therefore preserved the colour content of the input multispectral image more successfully than other methods used.

Keywords: Image fusion, Metaheuristic optimization, Gram-Schmidt, Cuckoo search algorithm, Pansharpening, Component substitution-based image fusion

1. Giriş

Son yıllarda, yüksek konfigürasyonlara sahip uyduların geliştirilmesi ile yeryüzünün daha detaylı bir şekilde incelenmesi mümkün olmaktadır. Sürekli gelişen uydu teknolojileri yüksek konumsal ve spektral çözünürlüklü görüntülerin kullanımının yaygınlaşmasını sağlamaktadır. Yüksek spektral çözünürlüklü görüntüler yeryüzü nesnelere birbirlerinden daha başarılı bir şekilde ayırt edilebilmesine olanak sağlarken, yüksek konumsal çözünürlüklü görüntüler de hem yeryüzü nesnelere insan gözü için daha anlamlı olmasına hem de bu nesnelere konumlarının daha hassas bir şekilde elde edilebilmesini sağlamaktadırlar. Uydularda daha fazla spektral bant üretimini sağlamak için daha fazla sayıda algılayıcı kullanılması gerekmektedir. Bu durum algılayıcı başına düşen enerji miktarını azaltacaktır. Enerji kaybını telafi etmek için daha büyük boyutlu algılayıcılar kullanılması ise üretilen spektral bantların konumsal çözünürlüklerinin azalmasına neden olacaktır. Bu teknik kısıtlamadan dolayı uydulardaki spektral bantların sayısı arttıkça konumsal çözünürlük azalmaktadır (Yılmaz ve Gungor, 2016). Görüntü kaynaştırma teknikleri, yüksek spektral çözünürlüğe sahip olan yüksek konumsal çözünürlüklü görüntüler üreterek bu probleme çözüm sunmaktadırlar.

Görüntü kaynaştırma, yüksek konumsal çözünürlüğe sahip bir tek bantlı (pankromatik) görüntünün konumsal detaylarının düşük konumsal çözünürlüklü bir çok bantlı görüntüye aktarılarak yüksek konumsal ve spektral çözünürlüğe sahip bir çok bantlı görüntü üretilmesini amaçlamaktadır. Literatürde birçok görüntü kaynaştırma yöntemi önerilmiştir. Başarılı bir görüntü kaynaştırma yöntemi konumsal detayları aktarırken çok bantlı görüntünün renk yapısını da korumalıdır (Serifoglu Yılmaz vd., 2019). Görüntü kaynaştırma yöntemleri bileşen değişimi tabanlı yöntemler, çoklu çözünürlük tabanlı yöntemler ve renk tabanlı yöntemler olmak üzere üç başlık altında toplanabilir (Serifoglu Yılmaz vd., 2019). Bileşen değişimi tabanlı kaynaştırma yöntemleri girdi çok bantlı görüntüyü konumsal detayların renk detaylarından kolaylıkla ayrılabilceği başka bir uzaya dönüştürür. Bu uzayda, girdi tek bant görüntü ile konumsal detayları barındıran bileşen yer değiştirir. Orijinal uzaya ters dönüşüm gerçekleştirilerek kaynaştırılmış görüntü elde edilir (Ghassemian, 2016). Bileşen değişimi tabanlı kaynaştırma yöntemlerinin en büyük avantajları konumsal detayları aktarmalarındaki başarıları iken, en büyük dezavantajları ise konumsal detayları aktarırken girdi çok bantlı görüntünün renk yapısını bozmalarıdır (Xing vd., 2018; Ghahremani vd., 2019; Serifoglu Yılmaz vd., 2019). Bileşen değişimi tabanlı yöntemlerin bir diğer avantajları ise fazla işlem yükü gerektirmemeleri ve kısa zamanda sonuç üretebilmeleridir (Ghahremani vd., 2019). Çoklu çözünürlük tabanlı kaynaştırma yöntemleri ise girdi tek bant görüntüdeki konumsal detayları wavelet (dalgalı), curvelet veya contourlet gibi bir çoklu çözünürlük dönüşümü yöntemi aracılığıyla çıkarır (Gogineni ve Chaturvedi, 2018). Çıkarılan bu konumsal detaylar daha sonra girdi çok bantlı görüntüye aktarılır (Xing vd., 2018). Çoklu çözünürlük tabanlı kaynaştırma yöntemleri girdi çok bantlı görüntünün renk yapısını korumada oldukça başarılı olmalarına rağmen girdi tek bantlı görüntünün içerdiği konumsal detayları aktarmada problem yaşamaktadırlar (Gogineni ve Chaturvedi, 2018). Bu yöntemler kaynaştırılmış görüntüdeki konumsal detayların yutulmasına neden olabilmelerinin yanı sıra, aynı zamanda görüntüyü bulanıklaştırma eğilimindedirler. Renk tabanlı yöntemlerin temel amacı ise girdi çok bantlı görüntünün renk yapısını kaynaştırma işleminden sonra korumaktır. Bu yöntemlerde, kaynaştırılmış görüntüdeki renk kalitesi ile konumsal detay kalitesi arasındaki dengenin sağlanması oldukça zordur. Renk tabanlı yöntemlerin temel avantajı ise oldukça kolay uygulanabilir olmalarıdır (Serifoglu Yılmaz vd., 2019). Görüldüğü üzere, kaynaştırılmış görüntülerin renk kalitesinin ve konumsal detay kalitesinin aynı oranda korunması oldukça güçtür. Her bir görüntü kaynaştırma yönteminin keskinleştirilmiş görüntü üretirken renk yapısına belli bir oranda zarar vermesi kaçınılmazdır. Bu nedenle, 'en iyi görüntü kaynaştırma yöntemi' diye bir şeyden söz edilemez (Pohl ve van Genderen, 2016; Yılmaz vd., 2020).

Görüntü kaynaştırma yöntemlerinin temel amacı kaynaştırma işlemine dâhil olan girdi görüntülerin bantlarının kaynaştırılmış görüntüye katkılarının başarılı bir şekilde belirlenmesidir. Ancak, söz konusu katkı oranlarının ne şekilde belirlenmesi gerektiği hususunda kesin yargılar yoktur. Bu nedenle, her bir kaynaştırma yöntemi girdi bantları farklı şekilde kullanılmaktadır. Literatürde az sayıda çalışma metasezgisel optimizasyon algoritmalarından yararlanarak girdi çok bantlı görüntülerin spektral bantlarının kaynaştırılmış görüntüye katkılarını belirlemeyi amaçlamaktadır. Metasezgisel algoritmalar canlıların birbirleri ile etkileşimlerinden esinlenilerek ileri sürülen popülasyon tabanlı arama algoritmalarıdır. Metasezgisel algoritmalar çözüm uzayında olasılık temelli ancak bilinçli bir yaklaşımla arama yapabilmektedirler. Amaçları, çözüm uzayında en uygun çözümü bulana kadar yeni çözümler üretmektir (Bir Yazılımcının Günlüğü, 2019). Garzelli ve Nencini (2006a) Genelleştirilmiş IHS (Intensity-Hue-Saturation) yönteminde kullanılan yoğunluk bileşenini optimize etmek için Genetik Algoritma (GA) (Holland, 1975) dan faydalanmıştır. Garzelli ve Nencini (2006b) ise GA' dan faydalanarak à-trous dönüşümü tabanlı kaynaştırma yönteminin performansını iyileştirmişlerdir. Masoudi ve Kabiri (2014) IHS kaynaştırma yönteminde kullanılan yoğunluk bileşenini optimize etmek için GA' dan yararlanmışlardır. GA aracılığıyla IHS kaynaştırma yönteminin performansını iyileştiren diğer çalışmalardan bazıları ise Lari ve Yazdi (2016) ve Niazi vd. (2016) tarafından gerçekleştirilmiştir. Yılmaz vd. (2019) GA'dan faydalanarak SVR (Synthetic Variable Ratio) kaynaştırma yönteminde kullanılan yoğunluk bileşenini optimize ederken, Yılmaz vd. (2020) ise çalışmalarında Gram-Schmidt (GS) (Laben ve Brower, 2000) kaynaştırma yönteminin performansını GA ile optimize etmeyi başarmışlardır.

Güncel literatür incelendiğinde metasezgisel algoritmaların kaynaştırma uygulamalarında oldukça az kullanıldığı görülmektedir. Metasezgisel optimizasyon algoritmalarından yararlanılan çalışmalarda ise metasezgisel algoritma olarak genellikle GA'nın kullanıldığı görülmektedir. Oysa ki, GA metasezgisel optimizasyon algoritmalarının ilki ve en basit olanıdır. Zaman içerisinde birçok gelişmiş metasezgisel algoritma geliştirilmiştir. Koloni optimizasyonu (Dorigo ve Stützle, 2004), arı algoritması (Pham vd., 2006), yapay arı kolonisi (Karaboga ve Basturk, 2007), ateşböceği algoritması (Yang, 2009), guguk kuşu arama algoritması (Yang ve Deb, 2009) ve simbiyotik organizma arama algoritması (Cheng ve Prayogo, 2014) bunlardan bazılarıdır. Simbiyotik organizma arama algoritması Serifoglu Yılmaz vd. (2019) tarafından SVR kaynaştırma yönteminin performansının iyileştirilmesinde kullanılmıştır.

Bileşen değişimi tabanlı kaynaştırma yöntemlerinin performansı girdi çok bantlı görüntünün bantları ile üretilen yoğunluk bileşeninin hesaplanmasında takip edilen metodolojiye bağlıdır. Başarılı bir kaynaştırma performansı için üretilen yoğunluk bileşeni ile girdi tek bantlı görüntünün istatistiksel olarak birbirine benzer olması gerekmektedir. Elverişsiz bir metodoloji girdi çok bantlı görüntünün renk yapısının korunamamasına neden olabilmektedir. Bu nedenle, girdi çok bantlı görüntünün her bir bandının yoğunluk bileşenine katkısının hassas bir şekilde belirlenmesi gerekmektedir. Bu çalışmada, bileşen değişimi tabanlı kaynaştırma yöntemleri tarafından kullanılan yoğunluk bileşenlerinin optimize edilerek bu yöntemlerin performanslarının iyileştirilebilmesi için guguk kuşu arama algoritması tabanlı bir metodoloji önerilmiştir.

Makalenin ana hatları şu şekilde özetlenmiştir; 2. bölüm guguk kuşu arama algoritması ile ilgili teorik bilgi sağlamaktadır. 3. bölüm ise çalışma kapsamında kullanılan verileri, önerilen guguk kuşu arama algoritması tabanlı görüntü kaynaştırma yöntemini ve kaynaştırılmış görüntülerin renk kalitelerinin irdelenmesinde kullanılan metrikleri tanıtmaktadır. 4. bölüm elde edilen görüntü kaynaştırma sonuçlarını aktarırken 5. bölüm ise çalışmadan elde edilen genel sonuçları içermektedir.

2. Guguk Kuşu Arama Algoritması

Yang ve Deb (2009; 2010) tarafından guguk kuşlarının kuluçka parazitliği gibi ilginç üreme davranışlarından esinlenilerek önerilmiştir. Guguk kuşları başka canlılara ait yuvalarda yumurtlamaktadırlar ve ev sahibi canlının yumurtalarından yavru çıkma ihtimali yüksek olanları yuvadan atmaktadırlar. Bu algoritma üç temel ilkeye dayanır;

- Her bir guguk kuşu bir seferde bir yumurtayı rastgele seçilen bir yuvaya bırakır.
- Yüksek kaliteli yumurtalar (çözümlerin) gelecek nesillere aktarılır.
- Kullanılabilir konak yuva sayısı sabittir ve konak yuva sahibi bırakılan bir guguk kuşu yumurtasını 0-1 aralığında bir olasılıkla tanıyabilir. Eğer yumurtayı tanırsa ya onu dışarı atar ya da yuvayı terk ederek başka bir yuva inşa eder.

Diğer metasezgisel algoritmalarda olduğu gibi guguk kuşu arama algoritmasında da en iyi çözüme ulaşabilmek için global ve lokal arama yapılmaktadır. Bu nedenle, guguk kuşu arama algoritması her bir iterasyonda global Lévy yürüyüşü (Lévy flight) ve lokal Lévy yürüyüşü aşamalarını gerçekleştirmektedir. Lévy yürüyüşü, yönleri rastgele olan ve adım uzunlukları Lévy dağılımından türetilen rastgele yürüyüşlerdir. Bu yürüyüş hayvanlar ve böcekler tarafından gerçekleştirilir ve 90 derecelik ani dönüşleri takip eden doğrusal yürüyüş serisi şeklinde karakterize edilir. Normal rastgele yürüyüşlere kıyasla, Lévy yürüyüşü büyük ölçekli arama alanlarını keşfetme konusunda daha verimlidir. Bunun nedeni, Lévy yürüyüşlerindeki varyansların normal rasgele yürüyüşten çok daha hızlı artmasıdır. Lévy yürüyüşleri, normal rasgele yürüyüşe kıyasla optimizasyon algoritmasının iterasyon sayısını 4 kata kadar azaltabilmektedir (Yang, 2014; Mareli ve Twala, 2018). Lévy yürüyüş hareketi manevra parametresi (p_a) kullanılarak kontrol edilmektedir. Lokal Lévy yürüyüşü şu şekilde modellenmektedir (Yang, 2014);

$$x_i^{t+1} = x_i^t + as \otimes H(p_a - \varepsilon) \otimes (x_j^t - x_k^t) \quad (1)$$

Bu denklemde x_j^t ve x_k^t rassal permutasyonla seçilen iki farklı çözüm adayını, $H(u)$ birim adım fonksiyonunu, ε düzgün dağılımdan gelen rassal sayıyı, s ise adım büyüklüğünü temsil etmektedir (Yang, 2014; Zeybekoğlu, 2017). Global Lévy yürüyüşü ise şu şekilde modellenmektedir (Yang, 2014; Zeybekoğlu, 2017);

$$x_i^{t+1} = x_i^t + \alpha L(s, \lambda) \quad (2)$$


$$L(s, \lambda) = \frac{\lambda \Gamma(\lambda) \sin\left(\frac{\pi\lambda}{2}\right)}{\pi} \frac{1}{s^{1+\lambda}} (s) \gg s_0 \gg 0 \quad (3)$$

Burada, $a > 0$ adım büyüklüğü ölçekleme faktörünü ve λ Lévy eksponentini göstermektedir. Gerçek dünyada, eğer bir guguk kuşu yumurtası konak yuvadaki yumurtalara çok benziyorsa konak canlının bu yumurtaları fark etmesi daha zordur. Dolayısıyla, uyumluluk fonksiyonu aday çözümler arasındaki farkla ilişkili olmalıdır. Bu nedenle, Lévy yürüyüşleri rastgele seçilen adım uzunluklarında ve belli bir oranda hatalı olarak gerçekleştirmek en iyi çözümün bulunmasına katkı sağlamaktadır. Guguk kuşu arama algoritması, yerel rastgele yürüyüş ile global rastgele yürüyüş arasında bir denge kurduğu için global optimizasyon problemleri için oldukça kullanışlıdır (Mareli ve Twala, 2018).

3. Materyal ve Metodoloji

3.1 Kullanılan Veri

Bu çalışma Trabzon’ da bulunan iki test bölgesinde gerçekleştirilmiştir. Birinci test bölgesi kırsal bir bölge olup 2012 yılında WorldView-2 uydusu tarafından görüntülenmiştir. WorldView-2 uydusu 2 m konumsal çözünürlüğe sahip olan sekiz bantlı (kıyasal, mavi, yeşil, sarı, kırmızı, kırmızı kenar, kızılötesi 1, kızılötesi 2) bir çok bantlı görüntü ve 50 cm konumsal çözünürlüklü bir tek bantlı görüntü sunmaktadır. İkinci test bölgesi ise kentsel bir bölge olup 2003 yılında IKONOS uydusu tarafından görüntülenmiştir. IKONOS uydusu 4 m konumsal çözünürlüklü dört adet (mavi, yeşil, kırmızı, kızılötesi) spektral banda sahip olan bir çok bantlı görüntü ve 1 m konumsal çözünürlüklü bir tek bantlı görüntü üretmektedir. WorldView-2 ve IKONOS uydu görüntülerinin radyometrik çözünürlüğü 11 bit’ tir. Bu çalışmanın gerçekleştirildiği test bölgeleri Şekil 1’ de gösterilmiştir.



Şekil 1. Test bölgeleri

3.2 Önerilen Görüntü Kaynaştırma Yöntemi

Önerilen görüntü kaynaştırma yöntemi GS yöntemine metasezgisel guguk kuşu arama algoritmasının entegre edilmesi prensibine dayanmaktadır. Laben ve Brower (2000) tarafından ileri sürülen GS yöntemi literatürde sıklıkla kullanılan istatistik tabanlı bir kaynaştırma yöntemidir. Bu yöntem kovaryans değerlerinden faydalanarak girdi bantları arasındaki korelasyonu ortadan kaldırmaktadır (Laben ve Brower, 2000; Pohl ve van Genderen, 2016). GS yönteminin ilk aşaması girdi çok bantlı görüntünün bantlarını kullanarak yeni bir düşük çözünürlüklü yoğunluk bileşeninin üretilmesidir.

GS yöntemi girdi çok bantlı görüntünün her bir bandını yüksek boyutlu bir vektör olarak kabul eder ve üretilen yoğunluk bileşeni vektörü ilk vektör olmak üzere bütün bantlara ait vektörler ile yoğunluk bileşeni vektörünü birleştirir. Daha sonra, birleştirilmiş veriye GS dönüşümü uygulanarak ortogonal vektörler elde edilir. GS algoritması projeksiyon operatörünü ($Proj_a$) a ve b vektörleri için şu şekilde uygular (Pohl ve van Genderen, 2016; Yılmaz vd., 2020);

$$Proj_a(b) = \frac{\langle a|b \rangle}{\langle a|a \rangle} a \quad (4)$$

Burada, $a|b$ a ve b vektörlerinin içsel çarpımını göstermektedir. Bu operatörün sonucu b vektörünün a vektörü ile sarmalanmış çizgiye göre projeksiyonudur (Pohl ve van Genderen, 2016). GS yöntemi ortogonal vektörleri şu şekilde üretir (Pohl ve van Genderen, 2016; Yılmaz vd., 2020);

$$a_m = b_m - \sum_{j=1}^{m-1} Proj_{a_j}(v_m) \quad (5)$$

Burada, $m = n + 1$ (girdi çok bantlı görüntünün bant sayısı + 1) olmaktadır. $a_1, a_2 \dots a_m$ ise normalize edilmiş ortogonal vektörlerdir. Bu vektörler daha sonradan aşağıdaki şekilde ortonormalize edilerek $c_1, c_2 \dots c_m$ elde edilir (Pohl ve van Genderen, 2016; Yılmaz vd., 2020);

$$c_m = \frac{a_m}{\|a_m\|} \quad (6)$$

GS dönüşümünden sonra girdi tek bantlı görüntü ilk GS bileşeni ile yer değiştirir. Son aşama olarak, elde edilen görüntüye ters GS dönüşümü uygulanır ve kaynaştırılmış bantlar elde edilir (Laben ve Brower, 2000; Pohl ve van Genderen, 2016). GS yönteminin performansı üretilen yoğunluk bileşeninin istatistiksel özelliklerine bağlıdır. Bu nedenle, araştırmacılar optimum yoğunluk bileşeni üretimi için çeşitli yöntemler kullanmışlardır. Laben ve Brower (2000) yoğunluk bileşeninin girdi çok bantlı görüntülerin bantlarının ortalaması şeklinde üretilebileceği gibi bir alçak geçiren filtre (low-pass filter) kullanılarak da üretilebileceğini belirtmişlerdir. Garzelli vd. (2008) yoğunluk bileşenini girdi bantların ağırlıklı ortalamaları şeklinde hesaplarken, Maurer (2013) girdi çok bantlı görüntünün kovaryans matrisinden girdi bantlar için elde edilen ağırlık değerlerinden faydalanarak yoğunluk bileşenini üretmiştir. Pohl ve van Genderen (2016) doğrusal regresyon, en küçük kareler yöntemi veya algılayıcıların spektral duyarlılık eğrileri kullanılarak optimum yoğunluk bileşeninin üretilebileceğini belirtmişlerdir. Yılmaz vd. (2020) ise yoğunluk bileşenini GA' dan faydalanarak buldukları bant ağırlıklarını kullanarak üretmişlerdir.

Bu çalışma kapsamında ise yoğunluk bileşeninin üretimi metasezgisel guguk kuşu arama algoritmasından yararlanılarak gerçekleştirilmiştir. Bu algoritmanın amaç fonksiyonu olarak GS kaynaştırma yöntemi kullanılırken, uygunluk fonksiyonu olarak ise Erreur Relative Globale Adimensionnelle de Synthèse (ERGAS) (Wald, 2002) metriği kullanılmıştır. Bu çalışma kapsamında ERGAS metriğinin kullanılmasının nedeni bu metriğin kaynaştırılmış görüntülerin renk kalitelerinin değerlendirilmesinde başarısını ispat etmiş olmasıdır. Bir kaynaştırılmış görüntünün ERGAS değeri ne kadar küçük olursa renk kalitesi de o kadar iyi olmaktadır. ERGAS metriği şu şekilde hesaplanmaktadır (Wald, 2002);

$$ERGAS = 100 \frac{h}{l} \sqrt{\frac{1}{N} \sum_{k=1}^N \left(\frac{KOH(k)}{\mu(k)} \right)^2} \quad (7)$$

Burada, h ve l sırasıyla girdi tek bantlı ve çok bantlı görüntünün konumsal çözünürlüklerini, $\mu(k)$ girdi çok bantlı görüntünün k . bandının ortalamasını, $KOH(k)$ girdi çok bantlı görüntünün k . bandı ile kaynaştırılmış görüntünün k . bandı arasında hesaplanan karesel ortalama hatayı ve N ise toplam bant sayısını temsil etmektedir.

Guguk kuşu arama algoritmasında 25 adet konak yuva kullanılmıştır. Her iki test bölgesi için de minimum bant ağırlığı 0, maksimum bant ağırlığı ise 1 olarak belirlenmiştir. Konak yuva sahibinin bırakılan bir guguk kuşu yumurtasını bulma olasılığı 0.25 olarak belirlenirken, maksimum iterasyon sayısı ise 100 olarak belirlenmiştir. Literatürde guguk kuşu arama algoritmasında kullanılan parametrelerin kestirimi ile ilgili kesin kabuller olmadığından bu değerler deneme yanılma yoluyla elde edilmiştir. Algoritma her bir iterasyonda girdi çok bantlı görüntünün bantları ile optimum bant ağırlıklarından üretilen yoğunluk bileşeni kullanılarak elde edilen kaynaştırılmış bantlar arasındaki ERGAS değerini minimize etmeye çalışmaktadır. Önerilen görüntü kaynaştırma yöntemi MATLAB ortamında programlanmıştır.

Önerilen yöntem 1. test bölgesinde optimum renk kalitesi için en uygun bant ağırlıklarını 0.72, 0.76, 0.83, 0.79, 0, 0.31, 0.46 ve 0.24 olarak belirlerken 2. test bölgesinde 0.04, 0.11, 0.34 ve 0.80 olarak belirlemiştir.

3.3 Kaynaştırılmış görüntülerin renk kalitelerinin irdelenmesi

Çalışma kapsamında üretilen bütün kaynaştırılmış görüntülerin spektral kaliteleri hem niteliksel hem de niceliksel olarak irdelenmiştir. Niteliksel incelemede kaynaştırılmış görüntülerin renk içeriklerinin görsel olarak girdi çok bantlı görüntüye ne oranda benzediği incelenmiştir. Niteliksel incelemede ise literatürde sıklıkla kullanılan KOH, ERGAS, Structural Similarity (SSIM) (Wang vd., 2004), Spectral Angular Mapper (SAM) (Alparone vd., 2006), Universal Image Quality Index (UIQI) (Wang ve Bovik, 2002) ve Information Content Weighted Structural Similarity (IWSSIM) (Wang ve Li, 2011) metriklerinden faydalanılmıştır. Bu metrikler Wald vd. (1997) tarafından önerilen ve oldukça yaygın olarak kullanılan protokollerden ilki dikkate alınarak hesaplanmıştır. Bu protokole göre, boyutları girdi çok bantlı görüntünün boyutlarına indirgenmiş olan kaynaştırılmış görüntü girdi çok bantlı görüntüyle mümkün olduğunca özdeş olmalıdır. Ayrıca, literatürdeki bazı yaklaşımlar ise kaynaştırılmış görüntülerin renk kalitesinin, kaynaştırılmış görüntünün boyutuna yükseltilebilir girdi çok bantlı görüntünün referans olarak kullanılarak irdelenmesi gerektiğini göstermiştir (Liu vd., 2015; Jagalingam ve Hegde, 2015; Serifoglu Yılmaz vd., 2019). Bu nedenle, bu çalışma kapsamında söz edilen metrikler girdi çok bantlı görüntüler ile boyutları indirgenmiş sonuç görüntüleri arasında hesaplandığı gibi kaynaştırılmış görüntüler ile kaynaştırılmış görüntünün boyutuna yükseltilebilir girdi çok bantlı görüntüler arasında da hesaplanmıştır.

Çalışma kapsamında kullanılan metriklerin matematiksel ifadeleri aşağıda verilmiştir;

$$KOH = \sqrt{\frac{1}{n} \sum_{i=1}^n (\zeta BG(k)_i - KG(k)_i)^2} \quad (8)$$

$$SSIM = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (9)$$

$$SAM \triangleq \arccos\left(\frac{\langle x, y \rangle}{\|x\|_2 \cdot \|y\|_2}\right) \quad (10)$$

$$UIQI = \frac{4\mu_x\mu_y\sigma_{xy}}{(\mu_x^2 + \mu_y^2)(\sigma_x^2 + \sigma_y^2)} \quad (11)$$


$$IWSSIM_j = \frac{\sum_i w_{j,i} c(x_{j,i}, y_{j,i}) s(x_{j,i}, y_{j,i})}{\sum w_{j,i}} \quad (12)$$

Burada, ζBG girdi çok bantlı görüntüyü, KG kaynaştırılmış görüntüyü, n görüntüdeki toplam piksel sayısını, x girdi çok bantlı görüntüdeki bir piksel vektörünü, y kaynaştırılmış görüntüdeki bir piksel vektörünü, μ ortalama işlemi, C_1 ve C_2 $C_1 = (Y_1L)^2$ ve $C_2 = (Y_2L)^2$ şeklinde hesaplanan iki sabit değeri, σ varyansı ve \cdot ise içsel çarpım işlemi ifade etmektedir.

4. Bulgular ve İrdeme

1. ve 2. test bölgeleri için üretilen kaynaştırılmış görüntüler sırasıyla Şekil 2 ve Şekil 3' de gösterilmiştir. Adil bir karşılaştırma olması açısından bu şekillerde gösterilen bütün kaynaştırılmış görüntüler gerçek bant kombinasyonunda ve herhangi bir kontrast germe işlemi uygulanmadan gösterilmiştir. Şekil 2' de görüldüğü üzere 1. test bölgesinde görsel olarak girdi çok bantlı görüntüye en yakın renkleri önerilen GK-GS yöntemi üretmiştir. EHL, SVR ve HPF yöntemleri ise 1. test bölgesinde girdi çok bantlı görüntünün renklerine yakın renkler üreten diğer yöntemlerdendir. GS ve PCA yöntemleri görsel olarak kabul edilebilir renkler üretmişlerdir. Ayrıca, MIHS, BRV ve MCV yöntemleri 1. test bölgesinde girdi çok bantlı görüntünün renk içeriğini yüksek oranda bozmuşlardır. GK-GS yöntemi renk koruma başarısını 2. test bölgesinde de göstermiştir. Şekil 3' de görüldüğü üzere bu yöntem 2. test bölgesinde en yüksek renk koruma performansını göstermiştir. SVR ve PCA yöntemleri ise 2. test bölgesinde GK-GS yönteminden sonra en tutarlı renk içeriğini üretmişlerdir. EHL yöntemi 2. test bölgesinde yeşil alanların spektral içeriğini koruyamamasına rağmen yol sınıfına ait spektral içeriği koruyabilmiştir. Şekil 3' de görüldüğü üzere, GS ve HPF yöntemleri ile 2. test bölgesi için üretilen kaynaştırılmış görüntüler ortalama renk kalitesindedir.

1. test bölgesinde olduğu gibi 2. test bölgesinde de MIHS, BRV ve MCV yöntemleri renk içeriğini koruyamamışlardır. Niteliksel değerlendirme kaynaştırma yöntemlerinin başarısı hakkında yüzeysel bir genel bakış sunar ve sadece analistin bakış açısına değil, aynı zamanda monitörün teknik özelliklerine de bağlıdır (Serifoglu Yılmaz vd., 2019). Bu nedenle kaynaştırılmış görüntülerin kaliteleri niceliksel olarak da irdelenmelidir.



Şekil 2. 1. test bölgesi için elde edilen kaynaştırılmış görüntüler



Girdi çok bantlı görüntü

Girdi tek bantlı görüntü



MCV sonucu



BRV sonucu



PCA sonucu



EHL sonucu



HPF sonucu



MIHS sonucu



SVR sonucu



GS sonucu



GK-GS sonucu

Şekil 3. 2. test bölgesi için elde edilen kaynaştırılmış görüntüler

Girdi çok bantlı görüntüler ile indirgenmiş boyuttaki sonuç görüntüleri arasında hesaplanan metrik değerleri Tablo 1’de gösterilmiştir. Bu tabloda her bir metrik için elde edilen optimum değer kalın gösterilmiştir. Tablo 1’de görüldüğü üzere önerilen GK-GS yöntemi ile üretilen görüntü 1. test bölgesinde en iyi KOH, ERGAS, SSIM ve SAM değerlerini vermiştir. Bu bölgedeki en iyi UIQI ve IWSSIM değerleri ise HPF yöntemiyle elde edilen görüntü tarafından elde edilmiştir. Tablo 1’e göre, GS, SVR ve EHL yöntemleri 1. test bölgesinde renk kalitesini ortalama seviyede korumuşlarken, PCA, BRV ve MCV yöntemleri en kötü metrik değerlerini alarak renk yapısını en fazla bozan yöntemler olmuşlardır. 2. test bölgesinde ise en iyi SSIM, SAM, UIQI ve IWSSIM değerlerinin elde edilmesini sağlayan GK-GS yöntemi bu bölgede renk kalitesini en fazla başarıyla koruyan yöntem olmuştur. Bu test bölgesinde en iyi KOH ve ERGAS değerlerini ise SVR yöntemiyle üretilen kaynaştırılmış görüntü vermiştir. Ayrıca, bu bölgede, GK-GS ve SVR yöntemlerinden sonra en başarılı şekilde renk yapısını koruyan yöntemler HPF ve GS yöntemleri olmuştur. Tablo 1’e göre, PCA, BRV ve MCV yöntemleri 2. test bölgesinde renk içeriğini korumada en başarısız yöntemler olmuşlardır. Bu durum görsel inceleme sonuçlarını doğrulamaktadır.

Tablo 1. İndirgenmiş boyuttaki kaynaştırma sonuçları için elde edilen metrik değerleri

Test bölgesi	Yöntem	KOH	ERGAS	SSIM	SAM	UIQI	IWSSIM
	Optimum	Küçük	Küçük	1	0	1	1
1	MCV	1.30E+05	8.50E+03	3.10E-05	1.718	2.50E-05	4.80E-05
	BRV	392.595	23.362	0.316	1.687	0.040	0.094
	PCA	576.558	22.760	0.724	15.119	0.444	0.479
	EHL	94.018	25.625	0.913	12.355	0.759	0.864
	HPF	31.618	2.387	0.978	2.067	0.821	0.949
	MIHS	88.067	5.600	0.835	4.644	0.242	0.405
	SVR	60.741	14.621	0.920	7.634	0.751	0.853
	GS	45.690	3.008	0.956	2.732	0.770	0.882
	GK-GS	22.988	1.675	0.985	1.384	0.820	0.932
2	MCV	1.60E+05	1.00E+04	1.70E-05	2.994	1.70E-05	3.10E-05
	BRV	308.970	20.392	0.321	2.905	0.160	0.206
	PCA	64.470	4.268	0.878	3.855	0.782	0.865
	EHL	103.232	6.815	0.886	6.467	0.807	0.888
	HPF	58.508	3.871	0.909	4.393	0.839	0.898
	MIHS	63.112	4.171	0.883	3.208	0.786	0.863
	SVR	54.443	3.600	0.915	3.094	0.855	0.914
	GS	60.830	4.024	0.895	3.720	0.813	0.892
	GK-GS	55.265	3.651	0.916	2.730	0.858	0.923

Tablo 2. Orijinal boyuttaki kaynaştırma sonuçları için elde edilen metrik değerleri

Test bölgesi	Yöntem	KOH	ERGAS	SSIM	SAM	UIQI	IWSSIM
	Optimum	Küçük	Küçük	1	0	1	1
1	MCV	1.30E+05	8.70E+03	2.60E-05	1.065	1.60E-05	3.00E-05
	BRV	392.124	23.323	0.320	1.064	0.041	0.122
	PCA	577.997	22.823	0.728	15.046	0.368	0.484
	EHL	93.073	25.651	0.923	12.356	0.542	0.749
	HPF	44.686	3.311	0.975	1.853	0.398	0.630
	MIHS	86.597	5.490	0.849	4.417	0.296	0.503
	SVR	64.265	14.921	0.920	7.606	0.451	0.651
	GS	50.492	2.942	0.965	2.396	0.483	0.726
	GK-GS	29.147	1.944	0.987	1.154	0.513	0.764
2	MCV	1.70E+05	1.10E+04	1.30E-05	1.772	1.20E-05	2.10E-05
	BRV	306.219	20.219	0.376	1.772	0.164	0.211
	PCA	75.472	5.015	0.877	3.408	0.508	0.599
	EHL	113.019	7.466	0.859	6.028	0.483	0.574
	HPF	85.577	5.671	0.870	4.159	0.502	0.605
	MIHS	76.247	5.044	0.867	2.258	0.474	0.570
	SVR	79.579	5.275	0.880	2.892	0.519	0.615
	GS	80.090	5.331	0.870	3.428	0.495	0.588
	GK-GS	70.972	4.674	0.901	3.044	0.578	0.657

Kaynaştırılmış görüntüler ile kaynaştırılmış görüntünün boyutuna yükseltile girdi çok bantlı görüntüler arasında hesaplanan metrik değerleri Tablo 2' de gösterilmiştir. Bu tabloda her bir metrik için elde edilen optimum değer kalın gösterilmiştir. Bu tabloya göre, 1. test bölgesinde en iyi KOH, ERGAS, SSIM ve IWSSIM değerleri GK-GS yöntemiyle üretilen kaynaştırılmış görüntü tarafından elde edilmiştir. Ayrıca, bu bölgede en iyi SAM değerini BRV sonucu alırken, en iyi UIQI değerini ise EHL sonucu almıştır. Tablo 2' ye göre, 1. test bölgesinde GK-GS ile üretilen kaynaştırılmış görüntüden sonra en başarılı metrik değerlerini alan kaynaştırılmış görüntüler GS ve HPF yöntemleri tarafından üretilmiştir. PCA, BRV ve MCV yöntemlerinin sonuçları bu bölgede de en kötü metrik değerlerini almışlardır. Tablo 2' de görüldüğü üzere 2. test bölgesinde GK-GS yönteminin sonucu SAM hariç bütün metriklerden optimum değeri almıştır. Bu bölgede en iyi SAM değerini BRV ve MCV sonuçları elde etmiştir. Tablo 2' ye göre 2. test bölgesinde renk kalitesini koruyan diğer yöntemler PCA ve SVR yöntemleridir. HPF ve GS yöntemleri renk içeriğini kabul edilebilir derecede koruyabilmişlerken, MCV, BRV ve EHL yöntemleri renk içeriğine en fazla zarar veren yöntemler olmuşlardır.

MCV yöntemi girdi çok bantlı görüntünün her bir bandını girdi tek bantlı görüntüyle çarparak kaynaştırılmış bantları üretmektedir. Bu durum piksel vektörlerinin yönlerinde fazla değişikliğe neden olmazken büyüklüklerinde çarpıcı derecede uzamalara yol açarak renk yapısını bozmaktadır. Benzer bir durum BRV yöntemi için de geçerlidir. BRV yöntemi girdi görüntünün her bir bandını eşit ağırlıkta kabul etmek suretiyle toplayarak bir yoğunluk bileşeni elde eder. Elde edilen yoğunluk bileşeninin girdi çok bantlı görüntünün her bir bandına bölünmesi ve elde edilen sonucun girdi tek bantlı görüntüyle çarpılmasıyla da kaynaştırılmış bantları üretir. Böylece, sonuç gri değerler normalize edilemediğinden dolayı renk yapısında ciddi bozulmalar meydana gelir. Buradan da anlaşılacağı üzere, girdi çok bantlı görüntünün her bir bandının kaynaştırma işleminde eşit derecede önemde olması mantıklı değildir. SVR yöntemi bu probleme çözüm bulmak için geliştirilmiştir. Bu yöntem girdi çok bantlı ve tek bantlı görüntüler arasında regresyon analizi uygulayarak her bir bant için bir ağırlık kestirimi yapar. Sonuçlardan da görüleceği üzere SVR yöntemi MCV ve BRV yöntemine oranla daha mantıklı şekilde bant ağırlıklarını hesapladığı için renk kalitesini korumada bu yöntemlere göre daha başarılı olmuştur. Bu çalışma kapsamında kullanılan GS yöntemi kullandığı düşük çözünürlüklü yoğunluk bileşenini girdi çok bantlı görüntünün bantlarının ortalaması şeklinde hesaplamaktadır. Yoğunluk bileşeninin bu şekilde hesaplanması üretilen bu bileşenin ortalama ve standart sapma değerlerinin girdi tek bantlı görüntününkilerden daha farklı olmasına yol açtığı için GS yöntemi her iki test bölgesinde de renk bozulmalarına neden olmuştur. Çalışma kapsamında kullanılan MIHS yöntemi de yoğunluk bileşenini girdi çok bantlı görüntünün bantlarının ortalaması şeklinde hesaplamıştır. Bu durum renk içeriğinde ciddi bozulmalara yol açmıştır. GS yöntemine oldukça benzer olan PCA yöntemi de girdi çok bantlı görüntüyü aralarında korelasyon olmayan bileşenlerden oluşan farklı bir uzaya dönüştürme mantığına dayanır. Elde edilen ilk bileşen girdi tek bant görüntüyle yer değiştirir ve ters PCA dönüşümü ile kaynaştırılmış görüntü elde edilir (Kwarteng ve Chavez, 1989). PCA dönüşümü ile üretilen ilk bileşen istatistiksel olarak girdi tek bantlı görüntüye benzer olamayabilmektedir. Bu nedenden dolayı da performansı görüntüden görüntüye değişebilmektedir. EHL yöntemi girdi çok bantlı görüntüyü gerçek renk uzayından IHS uzayına dönüştürür. Ardından, elde edilen yoğunluk bileşenini ve girdi tek bant görüntüyü Fourier dönüşümü ile frekans uzayına dönüştürür. Bu uzayda, yoğunluk spektrumuna düşük geçiren filtre ve girdi tek bant spektruma da yüksek geçiren (high-pass) filtre uygular. Elde edilen her iki filtrelenmiş veriye de ters Fourier dönüşümü uygulanır ve elde edilen görüntüler toplanarak yeni bir yoğunluk bileşeni elde edilir. Kaynaştırılmış görüntü bu yeni yoğunluk bileşeni kullanılarak uygulanan ters IHS dönüşümü ile üretilir (Ehlers, 2004; Klonus ve Ehlers, 2007). Bu kaynaştırma yöntemi uygulanırken frekans uzayında yüksek geçiren ve alçak geçiren filtreleme yapılması renk kalitesinin ve konumsal detay kalitesinin belli oranda korunmasını sağlamıştır. EHL yönteminin performansını arttırmak için farklı yüksek geçiren ve alçak geçiren filtreler kullanmak mümkündür. Ancak, bu durumda da optimum renk kalitesi ve konumsal detay kalitesi arasındaki dengenin kurulması güçleşecektir. HPF yöntemi girdi tek bantlı görüntüdeki konumsal detayları bir yüksek geçiren filtre yardımıyla iyileştirir ve elde ettiği iyileştirilmiş konumsal detayları girdi çok bantlı görüntüye aktarır. Bu yöntemin performansı kullanılan filtrenin boyutuna ve içeriğine bağlıdır. Filtrenin boyutu artırılarak daha keskin görüntüler üretilebilir, ancak, bu durumda da renk kalitesi bozulur.

Önerilen GK-GS yöntemi her bir iterasyonda girdi çok bantlı görüntüler ile kaynaştırılmış görüntüler arasında hesaplanan ERGAS değerlerini minimize etmeye çalıştığından optimum renk kalitesinin sağlanmasına neden olmuştur. Guguk kuşu arama algoritması Lévy yürüyüşünü gerçekleştirirken rastgele adım uzunluklarından faydalanır ve her bir Lévy adımı belli bir oranda hatalı olarak kabul edildiğinden dolayı bu algoritmanın parametre uzayındaki arama kapasitesi oldukça yüksektir. Bu nedenlerden dolayı guguk kuşu arama algoritması optimum bant ağırlıklarının belirlenmesinde oldukça başarılı olmuştur. Guguk kuşu arama algoritmasının bir diğer avantajı ise global ve lokal aramada oldukça başarılı olmasıdır. Bu nedenle de görüntü kaynaştırma problemleri için oldukça uygundur. Konak yuva sayısı ve konak yuva sahibinin bırakılan bir guguk kuşu yumurtasını bulma olasılığı için tanımlanan değerler değiştirilerek renk kalitesinin daha da artırılması mümkündür, ancak bu durumda da konumsal detayların aktarımındaki başarı düşecektir. Guguk kuşu arama algoritmasında kullanılan parametre değerlerinin belirlenmesi oldukça güçtür. Optimum parametre değerlerinin belirlenmesi için genel kabuller olmadığından kullanıcılar parametre değerlerini belirlemek için deneme yanılma yöntemini kullanmak zorundadırlar. Guguk kuşu arama algoritmasının çalışma süresinin fazla olması bu algoritmanın bir diğer dezavantajıdır.

5. Sonuç

Bu çalışma kapsamında bileşen değişimi tabanlı görüntü kaynaştırma yöntemlerinin renk koruma başarılarının arttırılabilmesi için metasezgisel guguk kuşu arama algoritması tabanlı bir kaynaştırma yöntemi geliştirilmiştir. Önerilen metodoloji yaygın olarak kullanılan bileşen değişimi tabanlı görüntü kaynaştırma yöntemlerinden biri olan GS yöntemi üzerinde uygulanmıştır. Önerilen yöntemle elde edilen kaynaştırılmış görüntülerin renk kalitesi literatürde sıklıkla kullanılan MCV, BRV, PCA, EHL, HPF, MIHS, SVR ve orijinal GS yöntemleriyle elde edilen kaynaştırılmış görüntülerin renk kaliteleriyle niteliksel ve niceliksel olarak karşılaştırılmıştır. Karşılaştırmalar sonucunda önerilen yöntemin girdi çok bantlı görüntünün her bir bandına mantıklı bir şekilde ağırlık kestirimi yaptığı ve dolayısıyla da çok bantlı görüntünün renk içeriğini korumada diğer yöntemlere oranla daha başarılı olduğu sonucuna varılmıştır. Önerilen yöntemin dezavantajı guguk kuşu arama algoritmasında kullanılan parametrelerin belirlenmesinin güç olması ve bu algoritmanın çalışma süresinin uzun olmasıdır. Tablo 3 önerilen GK-GS yönteminin avantajlarını ve dezavantajlarını göstermektedir. Gelecek çalışmalar guguk kuşu arama algoritması aracılığıyla daha başarılı renk korunumunun sağlanmasına yönelik olacaktır.

Tablo 3. Önerilen GK-GS yönteminin avantajları ve dezavantajları

Avantajlar	Dezavantajlar
<ul style="list-style-type: none"> • Başarılı yoğunluk bileşeni optimizasyonu sağlar. • Rastgele adım uzunluklu Lévy yürüyüşü sayesinde parametre uzayındaki arama kapasitesi oldukça yüksektir. • Literatürdeki birçok bileşen değişimi tabanlı görüntü kaynaştırma yöntemine göre daha başarılı renk korunumu sağlar. 	<ul style="list-style-type: none"> • Çalışma süresi uzundur. • Parametre kestirimi güçtür.

Teşekkür

Çalışma kapsamında kullanılan uydu görüntülerinin sağlanmasında Karadeniz Teknik Üniversitesi, Harita Mühendisliği Bölümüne katkılarından dolayı teşekkürü borç bilirim.

Kaynaklar

- Alparone, L., Aiazzi, B., Baronti, S., Garzelli, A., & Nencini, F. (2006). Information-theoretic image fusion assessment without reference. *ESA-EUSC 2006*.
- Bir Yazılımcının Günlüğü, (2019, Aralık 20). <https://biryazilimciningunlugu.wordpress.com/2017/05/16/metasezgisel-algoritmalar/>
- Cheng, M. Y., & Prayogo, D. (2014). Symbiotic organisms search: a new metaheuristic optimization algorithm. *Computers & Structures*, 139, 98-112. doi:10.1016/j.compstruc.2014.03.007.
- Dorigo, M., & Stützle, T. (2004). *Ant Colony Optimization*. Bradford Company.
- Ehlers, M. (2004, October). Spectral characteristics preserving image fusion based on Fourier domain filtering. In *Remote sensing for environmental monitoring, GIS applications, and geology IV* (Vol. 5574, pp. 1-13). International Society for Optics and Photonics. doi:10.1117/12.565160.
- Garzelli, A., & Nencini, F. (2006a, July). Fusion of panchromatic and multispectral images by genetic algorithms. In *2006 IEEE International Symposium on Geoscience and Remote Sensing* (pp. 3810-3813). IEEE. doi:10.1109/IGARSS.2006.976.
- Garzelli, A., & Nencini, F. (2006b). PAN-sharpening of very high resolution multispectral images using genetic algorithms. *International Journal of Remote Sensing*, 27(15), 3273-3292. doi:10.1080/0143116060054991.
- Garzelli, A., Nencini, F., & Capobianco, L. (2007). Optimal MMSE pan sharpening of very high resolution multispectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 46(1), 228-236. doi:10.1109/TGRS.2007.907604.
- Ghahremani, M., Liu, Y., Yuen, P., & Behera, A. (2019). Remote sensing image fusion via compressive sensing. *ISPRS journal of photogrammetry and remote sensing*, 152, 34-48. doi:10.1016/j.isprsjprs.2019.04.001.
- Ghassemian, H. (2016). A review of remote sensing image fusion methods. *Information Fusion*, 32, 75-89. doi:10.1016/j.inffus.2016.03.003.
- Gogineni, R., & Chaturvedi, A. (2018). Sparsity inspired pan-sharpening technique using multi-scale learned dictionary. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 360-372. doi:10.1016/j.isprsjprs.2018.10.009.
- Holland, H. (1975). *Adaptation in Natural and Artificial Systems*. Ann Arbor: University of Michigan Press.

- Jagalingam, P., & Hegde, A. V. (2015). A review of quality metrics for fused image. *Aquatic Procedia*, 4(1cwrcoe), 133-142. doi:10.1016/j.aqpro.2015.02.019.
- Karaboga, D., & Basturk, B. (2007). A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm. *Journal of global optimization*, 39(3), 459-471. doi: 0.1007/s10898-007-9149-x.
- Klonus, S., & Ehlers, M. (2007). Image fusion using the Ehlers spectral characteristics preservation algorithm. *GIScience & Remote Sensing*, 44(2), 93-116. doi:10.2747/1548-1603.44.2.93.
- Kwarteng, P., & Chavez, A. (1989). Extracting spectral contrast in Landsat Thematic Mapper image data using selective principal component analysis. *Photogrammetric Engineering & Remote Sensing*, 55(339-348), 1.
- Laben, C. A., & Brower, B. V. (2000). *U.S. Patent No. 6,011,875*. Washington, DC: U.S. Patent and Trademark Office.
- Lari, S. N., & Yazdi, M. (2016). Improved IHS pan-sharpening method based on adaptive injection of à trous wavelet decomposition. *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 9(3), 291-308. doi:10.14257/ijcip.2016.9.3.26.
- Liu, J., Huang, J., Liu, S., Li, H., Zhou, Q., & Liu, J. (2015). Human visual system consistent quality assessment for remote sensing image fusion. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105, 79-90. doi:10.1016/j.isprsjprs.2014.12.018.
- Mareli, M., & Twala, B. (2018). An adaptive Cuckoo search algorithm for optimisation. *Applied computing and informatics*, 14(2), 107-115. doi:10.1016/j.aci.2017.09.001.
- Masoudi, R., & Kabiri, P. (2014). New intensity-hue-saturation pan-sharpening method based on texture analysis and genetic algorithm-adaption. *Journal of Applied Remote Sensing*, 8(1), 083640. doi:10.1117/1.JRS.8.083640.
- Maurer, T. (2013). How to pan-sharpen images using the Gram-Schmidt pan-sharpen method-a recipe. *International archives of the photogrammetry, remote sensing and spatial information sciences*, 1, W1, 239-244.
- Niazi, M., N., S., Mokhtar Zade, M., & Saeed Zadeh, F. (2016). A Novel IHS-GA Fusion Method Based on Enhancement Vegetated Area. *Journal of Geomatics Science and Technology*, 6(1), 235-248.
- Pham, D. T., Ghanbarzadeh, A., Koç, E., Otri, S., Rahim, S., & Zaidi, M. (2006). The bees algorithm—a novel tool for complex optimisation problems. In *Intelligent production machines and systems* (pp. 454-459). Elsevier Science Ltd.
- Pohl, C., & van Genderen, J. (2016). *Remote sensing image fusion: A practical guide*. Crc Press.
- Serifoglu Yilmaz, C., Yilmaz, V., Gungor, O., & Shan, J. (2019). Metaheuristic pansharpening based on symbiotic organisms search optimization. *ISPRS Journal of Photogrammetry and Remote Sensing*, 158, 167-187. doi:10.1016/j.isprsjprs.2019.10.014.
- Wald, L. (2002). *Data fusion: definitions and architectures: fusion of images of different spatial resolutions*. Presses des MINES.
- Wald, L., Ranchin, T., & Mangolini, M. (1997). Fusion of satellite images of different spatial resolutions: Assessing the quality of resulting images. *Photogrammetric Engineering & Remote Sensing*, 63, 691-699.
- Wang, Z., & Bovik, A. C. (2002). A universal image quality index. *IEEE signal processing letters*, 9(3), 81-84. doi:10.1109/97.995823.
- Wang, Z., & Li, Q. (2011). Information content weighting for perceptual image quality assessment. *IEEE Transactions on image processing*, 20(5), 1185-1198. doi:10.1109/TIP.2010.2092435.
- Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600-612. doi:10.1109/TIP.2003.819861.
- Xing, Y., Wang, M., Yang, S., & Jiao, L. (2018). Pan-sharpening via deep metric learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 145, 165-183. doi: 10.1016/j.isprsjprs.2018.01.016.
- Yang, X. S. (2009, October). Firefly algorithms for multimodal optimization. In *International symposium on stochastic algorithms* (pp. 169-178). Springer, Berlin, Heidelberg.
- Yang, X. S. (2014). *Nature-inspired optimization algorithms*. 1st Edition, Elsevier.
- Yang, X. S., & Deb, S. (2009, December). Cuckoo search via Lévy flights. In *2009 World congress on nature & biologically inspired computing (NaBIC)* (pp. 210-214).
- Yang, X. S., & Deb, S. (2010). Engineering optimisation by cuckoo search. *International Journal of Mathematical Modelling and Numerical Optimisation*, 1(4), 330-343.
- Yilmaz, V., & Gungor, O. (2016). Determining the optimum image fusion method for better interpretation of the surface of the Earth. *Norsk Geografisk Tidsskrift-Norwegian Journal of Geography*, 70(2), 69-81. doi: 10.1080/00291951.2015.1126761.
- Yilmaz, V., Serifoglu Yilmaz, C., & Gungor, O. (2019). Genetic algorithm-based synthetic variable ratio image fusion. *Geocarto International*, (just-accepted), 1-17. doi: 10.1080/10106049.2019.1629649.
- Yilmaz, V., Serifoglu Yilmaz, C., Güngör, O., & Shan, J. (2020). A genetic algorithm solution to the gram-schmidt image fusion. *International Journal of Remote Sensing*, 41(4), 1458-1485. doi: 10.1080/01431161.2019.1667553.
- Zeybekoğlu, U. (2017). Metasezgisel optimizasyon yöntemlerinin performanslarının basit bir su dağıtım şebekesi kullanılarak araştırılması, *Karadeniz Fen Bilimleri Dergisi*, 7(2), 57-67. doi: 10.31466/kfbd.338197.

Road Distress Measurements Using UAV

İHA Kullanarak Yol Bozukluk Ölçmeleri

Mustafa Zeybek^{1*}, Serkan Biçici²

¹Artvin Coruh University, Engineering Faculty, Geomatics Engineering, 08100, Artvin/Turkey.

²Artvin Coruh University, Engineering Faculty, Civil Engineering, 08100, Artvin/Turkey.

ORIGINAL PAPER

*Corresponding author:

Mustafa Zeybek
mzeybek@artvin.edu.tr

doi:

Article history:

Received : 22.01.2020

Accepted : 16.03.2020

Published: 31.03.2020

Abstract

Maintenance and rehabilitation of the road are very serious actions. Therefore, road conditions should be inspected accurately before taking these actions. Manual and visual inspection in the field is the traditionally used method to monitor road conditions. However, it is time-consuming, labor-intense and costly. In addition, the traditional inspection method is unsafe directly for the inspectors and indirectly for primary users of the road, such as pedestrians and drivers. In this study, the unmanned aerial vehicle (UAV) was used to inspect the road condition. UAV technology is becoming a valuable tool for collecting data efficiently and accurately. The proposed method involved three steps. First, several images were acquired from a UAV flight. Then, these images were used to generate a three-dimensional (3D) point cloud, digital surface model and orthomosaic. Finally, road distresses were detected and measured from two-dimensional (2D) and 3D data. The measurements obtained from the proposed methodology were compared against the measurements obtained from the traditional inspection method. It was found that both measurements produced similar results. In conclusion, the use of the UAV measurement technique was found to be suitable for detecting road distress. Given the advantages of the proposed methodology, it can also be inferred that UAVs can be used instead of the traditional inspection method.

Keywords: UAV, DSM, Orthomosaic, Road distress, Rut, Pothole

Özet

Yolun bakımı ve iyileştirilmesi çok önemli eylemlerdir. Bu nedenle, bu eylemler yapılmadan önce yol koşulları doğru bir şekilde incelenmelidir. Arazideki manuel ve görsel olarak yapılan inceleme, yol durumunu izlemek için geleneksel olarak kullanılan yöntemdir. Ancak, bu, zaman alıcı, yoğun emek isteyen ve maliyetli bir yöntemdir. Buna ek olarak, geleneksel inceleme yöntemi sadece denetleyiciler için değil aynı zamanda yayalar ve sürücüler gibi yolun birincil kullanıcıları için de güvenlik problemi oluşturur. Bu çalışmada, yol durumunun incelenmesi için insansız hava aracı (İHA) kullanılmaktadır. İHA teknolojisi, verileri verimli ve doğru bir şekilde toplamak için önemli bir araç haline gelmektedir. Önerilen yöntem üç adımdan oluşur. İlk olarak, İHA uçuşundan birçok görüntü elde edilir. Daha sonra, görüntüler, üç boyutlu (3B) nokta bulutu, sayısal yüzey modeli ve ortomozaik oluşturmak için kullanılır. Son olarak, iki boyutlu (2B) ve 3B verilerden yol bozuklukları tespit edilir ve ölçülür. Önerilen metodolojiden elde edilen ölçüler, geleneksel inceleme yönteminden alınan ölçülerle karşılaştırılmıştır. Her iki ölçümden de nispeten benzer sonuçlar elde edilmiştir. Sonuç olarak, İHA ölçüm tekniğinin kullanımı yol bozukluklarını tespit etmek için uygundur. Önerilen yöntemin avantajları göz önüne alındığında, geleneksel inceleme yöntemi yerine İHA'nın kullanılabileceği sonucuna varmak oldukça güvenilirdir.

Anahtar kelimeler: İHA, SYM, Ortomozaik, Yol bozuklukları, Tekerlek izi, Çukur

1. Introduction

Imaging and analysis studies with unmanned aircraft vehicle (UAV) are carried out by different disciplines such as agricultural applications, urban mapping, topographic mapping, mining, coastal management, forestry and many other disciplines (Buğday, 2018; Doshi et al., 2015; Feng et al., 2015; Gulci, 2019; Johansen et al., 2019; Ochoa and Guo, 2019; Pijl et al., 2019; Tomastik et al., 2019). Besides, current practices and regulations for civil engineering are summarized by Yildizel and Calış (2019). Thus, UAV systems become a valuable supporting tool for researchers and practitioners who deal with problems in many fields in fast decision-making, maintenance, and improvement of the applications. One of the areas that lately starts to use UAV technology is transportation engineering. Maintenance and rehabilitation of the road are very serious activities and the compressive data collections regarding the condition of the road are necessary to decide whether or not these actions are needed.

Traditionally, an assigned person goes out there and monitor the condition of the road. However, the traditional inspection methods are time-consuming, labor-intense and unsafe not only for drivers but also for other users of the road (Kim and Ryu, 2014; Saad and Tahar, 2019; Tan and Li, 2019). Today, some major software and application developers promote some civilian mobile applications. Users of the road provide information about road conditions, thanks to these mobile applications (Saad and Tahar, 2019). However, this information is limited and does not provide detailed information regarding road conditions. Over the years, new technologies and approaches are also introduced to inspect road conditions more effectively (Kim and Ryu, 2014).

Road inspection methods can be classified into three methods, namely, vibration-based method, two-dimensional (2D) image-based method and three-dimensional (3D) model-based method. In the vibration-based method, vibration due to road roughness is analysed in real-time. However, complete detail of the road is not inspected and the equipment for this method is costly (Eriksson et al., 2008). In the 2D image-based method, several images are processed by traditional image processing algorithms to inspect road conditions. Similarly, several technologies such as laser scanner, Kinect sensor and stereo vision are used to produce a 3D model of the road surface to inspect road conditions (Gezero and Antunes, 2019; Neupane and Gharaibeh, 2019). However, these methods are very expensive and require a long post-processing time (Kim and Ryu, 2014; Yadav and Singh, 2018).

UAV technology is also introduced to monitor road conditions. Several studies produce 3D models of road surfaces using UAVs. Zhang (2008) proposed a strategy for monitoring unpaved road conditions and developed a UAV based remote sensing system for obtaining road image and collecting road condition parameters. Inzerillo et al. (2018) proposed a semi-automated technique for diagnosing the road pavement distress with the use of structure from motion (SfM). Saad and Tahar (2019) and Tan and Li (2019) also developed a 3D model of the road surface from UAV images and then they used a software to detect road distress in the paved road. The authors stated that the proposed approaches are convenient to inspect road conditions.

In this study, we focus on the detection of road distress namely, rut and pothole on the paved road surface from point clouds, digital surface model (DSM) and orthomosaic obtained by UAV images. The main objective and contribution of this study are to inspect road condition using 3D model produced from low-cost UAV systems. The advantage of this approach over traditional inspection methods is that it is performed in normal traffic flow.

The remainder of the study is organized as follows. First, the study area is presented. Then, the proposed methodology is summarized. The results are discussed in the next section. Finally, the conclusion and final remarks are summarized in the last section.

2. Study Area

The study area is located in Artvin, Turkey. Figure 1 presents the study area and the location of the selected road. The local road that connects Artvin Coruh University Seyitler Campus and several areas such as the biggest high school in Artvin, a large-extent housing area and main Police Station etc. was selected. The inspected road, which was approximately 100 meters long, included several potholes and ruts.

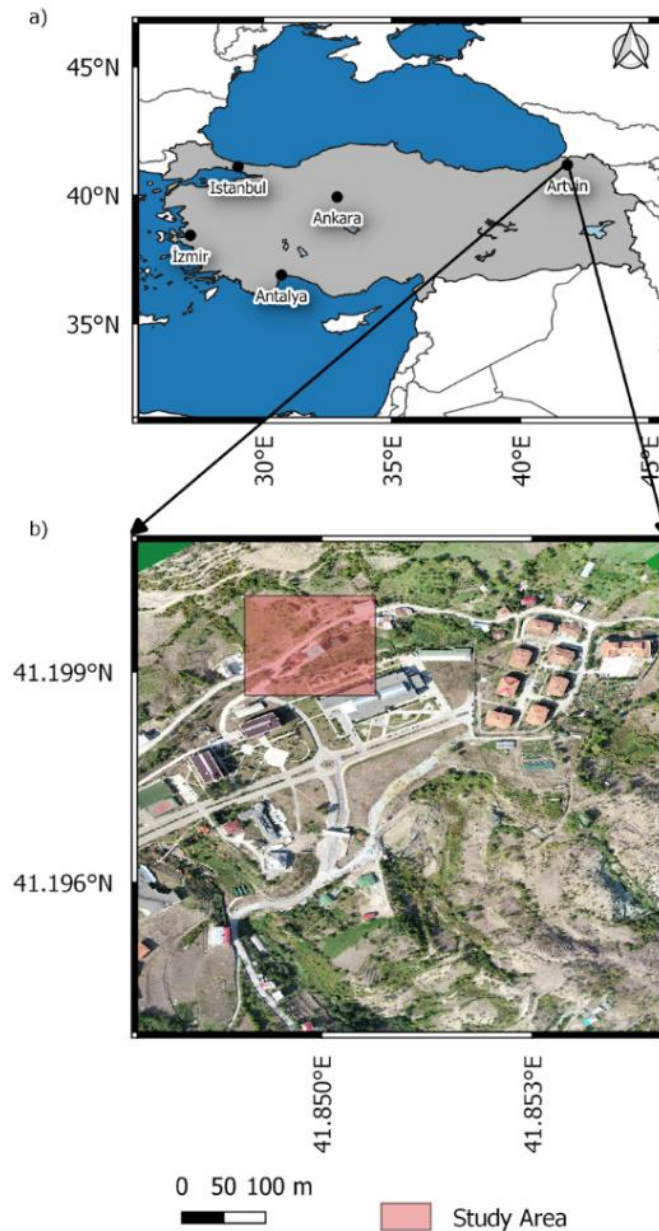


Figure 1. a) Location of the study area and b) selected road presented on the orthomosaic

3. Material and Methods

This study comprised four basic steps. The first step is to make traditional measurements in the field to which the proposed UAV-based method was compared. The next three steps are related to the proposed methodology in this study. Firstly, a UAV flight was conducted over the study area to capture the complete detail of the study area. Then, the images obtained from the flight were processed through an image processing software to generate photogrammetric products. The image processing step involved image alignment (initial processing), dense point cloud generation (point cloud and mesh), DSM and orthomosaic production (DSM- DTM and orthomosaic), as seen in Figure 2. In the last step, several road distresses were detected and measured from orthomosaic and DSM data using Global Mapper Software.




Figure 2. The overall methodology and image processing flowchart

3.1. UAV Device and Data Acquisition

DJI Phantom 4 RTK (P4RTK) mini UAV was used to investigate the selected road in this study. It is a low weight platform of 1391 g and has a flight time of about 25-30 minutes. It uses GPS, GLONASS, BeiDou and Galileo positioning systems. The camera of UAV has a 20 M CMOS sensor that offers 5472 × 3648 image resolution (Peppas et al., 2019). Ground sampling distance (GSD) is calculated as $H/36.5$ cm per pixel, where H denotes flying altitudes in the meter unit. The average flight altitude was around 5.5 m. It was important to capture images close to the ground to produce high-resolution data. Extra attention was paid not to fly close to the wires, buildings and vehicles in the flight area.

The production of photogrammetric data from UAVs is a preferred technology today. Thus, a wide range of software has been developed for flight planning, monitoring and communication between the operator and the UAV. Furthermore, automatic flight software do not require human control except for security reasons. Operation plans are prepared by selecting the region whose map will be produced. Then, the overlap and flight heights are set in parallel to the demand for high-resolution data.

In order to improve the image alignment accuracy and to acquire a detailed point cloud, in addition to the nadir (vertical) image, oblique image capturing can be performed. Figure 3 summarizes image acquisition types, which can be done with the UAV. The nadir direction image means that the direction of the lens is perpendicular to the ground or object. In this study, the oblique images were captured by adjusting the camera angle to 60° degrees. Therefore, several images that give great detail condition of the road were obtained.

Since Fixed ground control point (GCP) marking method requires intense labor, it is not preferred in this study. Instead of indirect georeferencing of the reconstructed model, direct georeferencing methods is preferred. To do that, the images must always be geotagged with the GNSS/INS (Global navigational satellite systems and inertial measurement unit) data for the camera location and orientation of each image.




Figure 3. Image acquisition types: vertical and oblique images

3.2. UAV Data Process

For 3D modeling, different software packages that follow the standard structure from motion (SfM) workflow of oblique images and nadir direction images have been used in many studies (Javernick et al. 2014). Some of the widespread SfM software packages are the Agisoft Metashape, Pix4DMapper, 3Df Zephyr, SURE, MicMac (MM), VisualSfM (VSfM), and ContextCapture. There are differences in the algorithms used in these softwares, specifically in image processing and matching step as well as some parameter setting. However, most of the software produce similar results in the alignment of the images, the production of dense point clouds, and the generation of a triangulated network in DEM and orthomosaic. In general, the only input data required by these software to perform 3D model generation are acquired images. If GCPs or GNSS/IMU data are available, this data contributes to the positioning of the generated maps.

In the study, the Pix4DMapper (www.pix4d.com) software was used to process acquired UAV images. In the first part of the 3D reconstruction process, the software prepares the images to match extracted features for bundle block adjustment using variations of the Scale Invariant Feature Transformation (SIFT) algorithm (Lowe, 2004).

Subsequently, the image locations and orientations are determined in the bundle block adjustment by evaluating the detected and matched key points after the image alignment process. Multi-view stereo (MVS) algorithms are used to produce detailed object surface geometries in high-dense 3D point cloud and triangular mesh models. Different algorithms are implemented in different software and these software do not provide detailed information on this step since they are commercial software. However, the semi-global matching (SGM) based stereo method is commonly used to achieve accurate, pixel-based matching with high stability. With the Pix4DMapper software, more than 20 million points were reconstructed in the dense point cloud production step.

Since the orthomosaic is a 2D map, the orthomosaic generation is different from photo stitching. Each pixel on this map contains the location and RGB color information. The orthomosaic has a uniform scale. Thus, 2D measurements, such as distance and area on the orthomosaics are possible. It does not contain camera distortion and therefore, it corrects the different scales based on the distance. The orthomosaic production is based on the orthorectification process, which uses undistorted images and DSM data.

3.3. Detection and Measurement of Road Distress

It is possible to measure the surface distress from any computer-aided design (CAD) or geographical information system (GIS) based software. In this study, the Global Mapper software was used to detect several ruts and potholes. Then, the features of ruts and potholes on the road surface were measured on a 3D DSM and 2D orthomosaics.

Four different features, namely, diameter, perimeter, length and depth were measured using the Global Mapper Software. Specifically, diameter, perimeter and depth were used for four potholes while length and depth were used for ruts. Firstly, a polygon was drawn manually on the 3D model and 2D orthomosaic for the detection of the pothole as shown in Figure 4. Then, the perimeter of the pothole was calculated as the sum of the length of each line that encloses the polygon. The diameter of the pothole was also measured as the maximum distance from one corner to another. In addition, the length of the rut was measured as the maximum distance with road distress. The depth of the potholes and ruts were calculated from the DSM profiles as shown in Figure 5 and Figure 6, respectively. In these figures, yellow lines represent the direction of profile. Road slope should be taken into account when taking the direction of profile. For this, it is possible to benefit from the contour lines. Thus, the profile following the contour line is taken and the slope factor is eliminated. Rut and pothole depths on the profile were obtained more accurately.




Figure 4. a) DSM and b) orthomosaic based pothole measurements

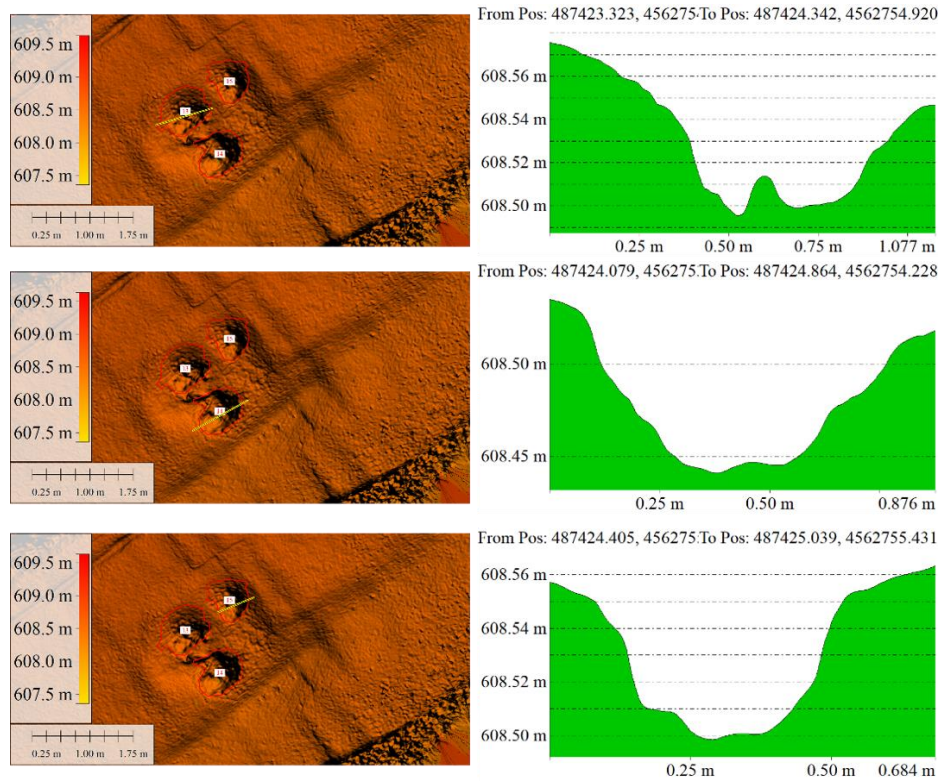


Figure 5. Pothole detection and measurement

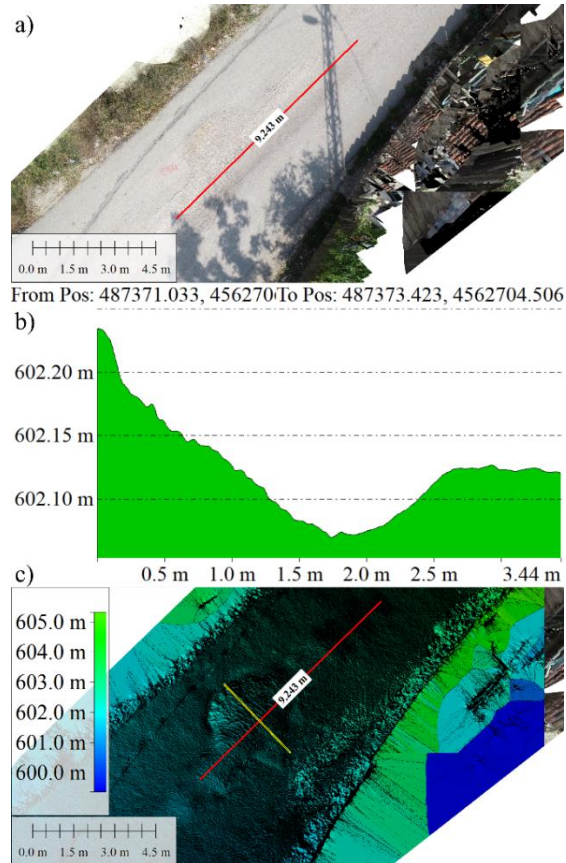


Figure 6. a) Rut length, b) profile perpendicular to the slope of the road and c) depth measurement on profile

4. Results and Discussions

Four potholes and seven ruts were detected in the study area. Four measures, namely diameter, length, perimeter and depth were measured manually in the field using a ruler and tape meter. The measures obtained from both field and Global Mapper Software are presented in Table 1. In addition, the accuracy assessment was conducted to compare the measurements obtained from the field and Global Mapper Software. Equation 1 shows the error (E) between two types of measurements.

$$E = M_{Software} - M_{Field} \quad (1)$$

where $M_{Software}$ is a measurement obtained using the Global Mapper Software and M_{Field} is a measurement obtained from field inspection. A positive error value means that the measurements obtained from the Global Mapper Software are greater than the measurements from field inspection while a negative error value means that the measurements obtained from the Global Mapper Software are lower than the measurements from field inspection. Zero error value is obtained when two types of measurements are equal to each other.

Table 1. Differences between measurements from field inspection and from the Global Mapper Software for diameter, length, perimeter and depth of the road distress.

Road Distress ID	Road Distress Type	Diameter (m)				Length (m)			
		Field	UAV	Error (m)	Error (%)	Field	UAV	Error (m)	Error (%)
Distress 1	Rut	-	-	-	-	9.200	8.895	-0.305	-0.033
Distress 2	Pothole	4.420	4.411	-0.009	-0.002	-	-	-	-
Distress 3	Rut	-	-	-	-	1.800	1.748	-0.052	-0.029
Distress 4	Rut	-	-	-	-	4.400	4.201	-0.199	-0.045
Distress 5	Rut	-	-	-	-	3.400	3.350	-0.050	-0.015
Distress 6	Pothole	1.030	1.015	-0.015	-0.015	-	-	-	-
Distress 7	Pothole	0.890	0.893	0.003	0.003	-	-	-	-
Distress 8	Pothole	0.760	0.761	0.001	0.001	-	-	-	-
Distress 9	Rut	-	-	-	-	6.500	6.345	-0.155	-0.024
Distress 10	Rut	-	-	-	-	1.900	1.946	0.046	0.024
Distress 11	Rut	-	-	-	-	9.900	9.564	-0.336	-0.034

Road Distress ID	Road Distress Type	Perimeter (m)				Depth (m)			
		Field	UAV	Error (m)	Error (%)	Field	UAV	Error (m)	Error (%)
Distress 1	Rut	-	-	-	-	0.092	0.093	0.001	0.011
Distress 2	Pothole	6.550	6.250	-0.300	-0.046	0.094	0.088	-0.006	-0.064
Distress 3	Rut	-	-	-	-	0.035	0.072	0.037	1.057
Distress 4	Rut	-	-	-	-	0.111	0.104	-0.007	-0.063
Distress 5	Rut	-	-	-	-	0.040	0.035	-0.005	-0.125
Distress 6	Pothole	3.280	2.958	-0.322	-0.098	0.077	0.074	-0.003	-0.039
Distress 7	Pothole	2.720	2.854	0.134	0.049	0.079	0.092	0.013	0.165
Distress 8	Pothole	2.250	2.514	0.264	0.117	0.069	0.065	-0.004	-0.058
Distress 9	Rut	-	-	-	-	0.091	0.092	0.001	0.011
Distress 10	Rut	-	-	-	-	0.030	0.044	0.014	0.467
Distress 11	Rut	-	-	-	-	0.060	0.072	0.012	0.200

When it comes to diameter, the error between two types of measurements ranges from 0.1 cm to 1.5 cm. These errors are considered small when taking into account the advantages of using the Global Mapper Software over field inspection. Similarly, a range from 0.1 cm to 3.7 cm was obtained when measuring the depth, which is also considered small. On the other hand, the errors are higher for length and perimeter. Specifically, a range from 2.0 cm to 15.5 cm was obtained for length and a range from 13.4 cm to 32.2 cm was obtained for the perimeter. It is most likely to have human-error in field inspection. For example, the shapes of the four potholes are irregular. It is hard to detect the boundary of these potholes in field, which leads to relatively higher human-error.

To assess the differences between two types of measurements, the root mean square error (RMSE) is also reported in Table 2. RMSE is defined as the following equation;

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (M_{Software} - M_{Field})^2}{N - 1}} \tag{2}$$

where N is the number of observation and $M_{Software}$ and M_{Field} are described as above.

Table 2. The root mean square error (RMSE) for diameter, length, perimeter and depth of the road distress

	Sample Size (N)	RMSE
Diameter	4	0.010
Length	7	0.076
Perimeter	4	0.301
Depth	11	0.009

These RMSE values were also consistent with the conclusions above. Smaller RMSE values were obtained when measuring the diameter, length and depth while larger RMSE values were obtained for the perimeter.

In addition to these discussions, a commonly used hypothesis test, so called *t*-test, was applied to statistically testing whether the mean of the differences between two types of measurements is equal to zero. The null hypothesis, H_0 and alternative hypothesis, H_A are as follows;

$$\begin{aligned} H_0 : \mu_{error} &= 0 \\ H_A : \mu_{error} &\neq 0 \end{aligned} \tag{3}$$

where μ_{error} is the mean of the differences between two types of measurements. The null hypothesis is rejected when the absolute value of the test statistic $|t_{test}|$ is greater than or equal to the critical t-value. The *t*-test results are shown in Table 3 for four different scenarios. For example, the four errors obtained when measuring diameters were used for the *t*-test. The test statistic $|t_{test}|$ is 1.1785 and the critical t-value is 2.7764 at 5% significance level. Since the test statistic is higher than the critical t-value, the null hypothesis is refused to reject. *t*-test is refused to reject for all scenarios. This means that both measurement types produce statistically similar results.

Table 3. The t-test results at 5% significance level

	$ t_{test} $	Critical t values	Decision
Diameter	1.1785	2.7764	Refuse to reject null
Length	0.599	2.3646	Refuse to reject null
Perimeter	0.3525	2.7764	Refuse to reject null
Depth	1.2047	2.201	Refuse to reject null

The observations show that the measurements obtained using the Global Mapper Software are similar to those obtained from the traditional inspection method. In addition, the errors obtained in this study are similar to those obtained by Saad and Tahar (2019) and Tan and Li (2019). Given the advantages of using the Global Mapper Software over the traditional inspection method, it can be concluded that the Global Mapper Software produces reasonable measurements and they can be used instead of the traditional inspection method.

5. Conclusion

In transportation engineering, road condition inspection is a challenging process and requires a complete detailed picture of the road before taking maintenance or rehabilitation actions. However, traditional inspection methods are time-consuming, labor-intensive and unsafe for all users of the road.

UAV is a lately growing technology used in many fields, including transportation engineering. This study used the UAV data to detect road distress. Specifically, UAV was operated over the study area to evaluate the road condition through several images. Then, the Pix4DMapper software, a commercial image processing software, was used to produce the photogrammetric products. The image processing step involved image alignment, dense point cloud generation, DSM and orthomosaic production. Finally, several road distresses were detected and measured from the orthomosaic and DSM data using the GIS-based Global Mapper Software.

The measurements obtained from the Global Mapper Software were compared against the measurements from the traditional inspection method. It was found that both measurements produced relatively similar results.

We can conclude that the use of the UAV measurement technique is suitable for detecting potholes and ruts on the road surface. With the help of UAV images, detailed information about the road surface can be obtained from 2D and 3D data. In addition, it is easier to determine the ruts and potholes on the road surface in the office environment than to measure in the field because 3D model production is automatic, fast, safe and high resolution.

References

- Buğday, E. (2018). Capabilities of using UAVs in forest road construction activities. *European Journal of Forest Engineering*, 4(2), 56-62. doi:10.33904/ejfe.499784.
- Desa, H., bin Azizan, M. A., Khadir, M. S. A., Suhaimi, M. S., Ramli, N. Z., & Hat, Z. (2019). Feasibility Study of UAV Implementation in Route Surveying. *Journal of Robotics, Networking and Artificial Life*, 6(2), 84-88. doi:10.2991/jrnal.k.190828.003.
- Doshi, A. A., Postula, A. J., Fletcher, A., & Singh, S. P. (2015). Development of micro-UAV with integrated motion planning for open-cut mining surveillance. *Microprocessors and Microsystems*, 39(8), 829-835.
- Eriksson, J., Girod, L., Hull, B., Newton, R., Madden, S., & Balakrishnan, H. (2008, June). The pothole patrol: using a mobile sensor network for road surface monitoring. In *Proceedings of the 6th international conference on Mobile systems, applications, and services* (pp. 29-39).
- Feng, Q., Liu, J., & Gong, J. (2015). Urban flood mapping based on unmanned aerial vehicle remote sensing and random forest classifier—A case of Yuyao, China. *Water*, 7(4), 1437-1455.
- Fryskowska, A. (2019). Improvement of 3D Power Line Extraction from Multiple Low-Cost UAV Imagery Using Wavelet Analysis. *Sensors*, 19(3), 700. doi:10.3390/s19030700.
- Gezero, L., & Antunes, C. (2019). Road Rutting Measurement Using Mobile LiDAR Systems Point Cloud. *ISPRS International Journal of Geo-Information*, 8(9), 404. doi:10.3390/ijgi8090404.
- Gulci, S. (2019). The determination of some stand parameters using SfM-based spatial 3D point cloud in forestry studies: an analysis of data production in pure coniferous young forest stands. *Environmental monitoring and assessment*, 191(8), 495. doi:10.1007/s10661-019-7628-4.
- Inzerillo, L., Di Mino, G., & Roberts, R. (2018). Image-based 3D reconstruction using traditional and UAV datasets for analysis of road pavement distress. *Automation in Construction*, 96, 457-469. doi:10.1016/j.autcon.2018.10.010.
- Javernick, L., Brasington, J., & Caruso, B. (2014). Modeling the topography of shallow braided rivers using Structure-from-Motion photogrammetry. *Geomorphology*, 213, 166-182. doi:10.1016/j.geomorph.2014.01.006.
- Johansen, K., Erskine, P. D., & McCabe, M. F. (2019). Using Unmanned Aerial Vehicles to assess the rehabilitation performance of open cut coal mines. *Journal of cleaner production*, 209, 819-833. doi:10.1016/j.jclepro.2018.10.287.
- Kim, T., & Ryu, S. K. (2014). Review and analysis of pothole detection methods. *Journal of Emerging Trends in Computing and Information Sciences*, 5(8), 603-608.
- Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60(2), 91-110. doi:10.1023/b:Visi.0000029664.99615.94.
- Neupane, S. R., & Gharaibeh, N. G. (2019). A heuristics-based method for obtaining road surface type information from mobile lidar for use in network-level infrastructure management. *Measurement*, 131, 664-670. doi:10.1016/j.measurement.2018.09.015.
- Ochoa, K. S., & Guo, Z. (2019). A framework for the management of agricultural resources with automated aerial imagery detection. *Computers and Electronics in Agriculture*, 162, 53-69. doi:10.1016/j.compag.2019.03.028

- Peppas, M. V., Hall, J., Goodyear, J., & Mills, J. P. (2019). Photogrammetric assessment and comparison of DJI Phantom 4 pro and phantom 4 RTK small unmanned aircraft systems. *ISPRS Geospatial Week 2019*.
- Pijl, A., Tosoni, M., Roder, G., Sofia, G., & Tarolli, P. (2019). Design of Terrace drainage networks using UAV-based high-resolution topographic data. *Water*, 11(4), 814. doi:10.3390/w11040814
- Saad, A. M., & Tahar, K. N. (2019). Identification of rut and pothole by using multirotor unmanned aerial vehicle (UAV). *Measurement*, 137, 647-654. doi:10.1016/j.measurement.2019.01.093
- Tan, Y., & Li, Y. (2019). UAV Photogrammetry-Based 3D Road Distress Detection. *ISPRS International Journal of Geo-Information*, 8(9), 409. doi:10.3390/ijgi8090409.
- Tomastik, J., Mokroš, M., Surový, P., Grznárová, A., & Merganič, J. (2019). UAV RTK/PPK Method—An Optimal Solution for Mapping Inaccessible Forested Areas?. *Remote sensing*, 11(6), 721. doi:10.3390/rs11060721.
- Yadav, M., & Singh, A. K. (2018). Rural road surface extraction using mobile LiDAR point cloud data. *Journal of the Indian Society of Remote Sensing*, 46(4), 531-538. doi:10.1007/s12524-017-0732-4.
- Yıldız, S. A., & Çalış, G. (2019). Unmanned Aerial Vehicles for Civil Engineering: Current Practises and Regulations. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 925-932. doi:10.31590/ejosat.565499.
- Zhang, C. (2008). An UAV-based photogrammetric mapping system for road condition assessment. *International Archives of the Photogrammetry. Remote Sensing Spatial Information Sciences. Sci*, 37, 627-632.

Derin Öğrenme Amaçlı Etiketli Veri Üretimi İçin Bir Web Platformu A Web Platform for the Generation of Labeled Data for Deep Learning

Ekrem Saralioğlu^{1*}, Oğuz Güngör¹

¹Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 61080, Trabzon/Türkiye.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Ekrem Saralioğlu
ekrem.saralioglu@ktu.edu.tr

doi:

Yayın süreci

Geliş tarihi : 30.01.2020
Kabul tarihi : 16.03.2020
Basım tarihi: 31.03.2020

Özet

Klasik RGB görüntülerine göre uydu görüntülerinin derin öğrenme amaçlı kullanımında önemli problemler bulunmaktadır. Uzaktan algılanmış görüntüler için etiketli eğitim verisi eksikliği bu problemlerden biridir. Uydu görüntüleri için yetersiz etiketli eğitim verisi sorununun çözümünü doğru ve kısa sürede sağlayabilecek en önemli yöntemlerden biri kitle kaynak kullanımudur. Bu çalışmada yüksek çözünürlüklü uydu görüntüleri için etiketli verilerin kitleler tarafından toplanmasını sağlamak amacıyla oluşturulan web platform tanıtılmaktadır. Bu platform dinamik bir yapıda olup aynı anda farklı kullanıcıların da kullanabileceği şekilde tasarlanmıştır. Platformda kullanıcılar Dünya yüzeyini kapsayan Google uydu althığı kullanılabildiği gibi veri tabanına eklenecek görüntüler üzerinden de etiketli veri oluşturabilmektedir. Bu sayede yüksek çözünürlüklü uydu görüntüleri için Dünya çapında görüntülerden çıkarılabilecek bütün sınıflara ait (bina, yol, orman, akarsu, fındık, çay, gemi, uçak vb.) etiketli verilerin hazırlanması mümkün olmaktadır. İstenen eğitim sınıflarının tanımı ve kullanıcıların platformu efektif kullanmaları amacıyla yardım dokümanları web platforma eklenmiştir. Kullanıcılar görüntüler üzerinden poligon aracı ile yardım dokümanında belirtilen sınıfları çevirebilmektedir. Daha sonra kullanıcılar tarafından bu sınıflara etiket değeri verilmektedir. Oluşturulan etiketli verilerden doğru ve yanlışların tespit edilebilmesi amacıyla veri doğrulama modülü de web platforma eklenmiştir. Bu modülde kullanıcılar önceki kişilerin çevirdikleri ve etiketledikleri sınıfları yardım dokümanından kontrol ederek puanlandırmaktadır. Sonuçta en yüksek puan alan doğru etiketli veriler seçilmektedir.

Anahtar kelimeler: CBS, Uzaktan algılama, Uzamsal analiz, Kitle kaynak

Abstract

Compared to conventional RGB images, new problems arise in the use of satellite images for deep learning. The absence of labeled training data for remotely sensed images is one of these problems. One of the methods that can solve the problem of insufficient labelled data available for satellite images in a short time and accurately is crowdsourcing. This study introduces a web platform created to ensure that the labelled data for high-resolution satellite images can be collected by the masses. This platform has a dynamic structure and is designed to be used by different users simultaneously. In order to create tagged data, users can use Google Earth satellite images covering the entire Earth's surface as well as new images added to the database. In this way, it will be possible to generate labelled data for all types of classes (buildings, roads, forests, streams, hazelnuts, tea, ships, planes, etc.) that can be extracted from images around the world. Help documents have been added to the web platform to identify training classes for users, enabling them to use the platform effectively. Users can use the polygon tool to create descriptive fields for the classes specified in the help document to create labels. Data verification module has also been added to the web platform in order to determine the correct and incorrect labels. In this module, users verify and score the labels created by other people using the help document. As a result, the correctly labelled data with the highest score are selected.

Keywords: GIS, Remote sensing, Spatial analysis, Crowdsourcing

1. Giriş

Uzaktan algılama (UA), insanların Dünya'yı daha iyi anlamalarını sağlayan bir kapı açmıştır. Son teknolojik gelişmeler, mevcut uydu görüntülerinin miktarını önemli ölçüde arttırmıştır. Bu veri kümelerinin büyük ölçekli ve farklı tiplerdeki yapıları, görüntü analizinde yeni zorluklar ortaya çıkarmaktadır (Maggiori vd., 2016). Uzaktan algılanmış yüksek uzamsal çözünürlüklü verilerden değerli bilgiler en iyi şekilde nasıl elde edilebilir? Sürekli artan veri türleri ve hacmi ile nasıl başa çıkmalıyız? Bu soruların çözümü üzerine uzaktan algılama alanında yoğun bir çalışma vardır. Örneğin, uzaktan algılanmış görüntüler kullanarak otomatik arazi örtüsü sınıflandırma yöntemlerini geliştirmek için büyük çaba harcanmıştır (Zhang, 2018). Geleneksel yöntemler uzaktan algılanmış görüntülerin spektral, dokusal ve geometrik özelliklerine odaklanarak görüntü nesnelerinin özelliklerini çok fazla müdahale ile yakalayabilmektedir. Son 20 yılda, K-NN, Rastgele Orman (RO), Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM) gibi başarılı yöntemler arazi örtüsü sınıflandırmada yoğun olarak kullanılmıştır (Carranza-García vd., 2019). Doku ekleme, özellik çıkarma, indeksler, yardımcı veriler, görüntü ön işlemleri gibi çeşitli yöntemler ile zenginleştirilen görüntüler üzerinde bu sınıflandırma yöntemleri ile daha yüksek doğrulukta sınıflandırma yapılmaktadır (Akar ve Gungör, 2015). Çok yakın bir zamanda, derin öğrenme (DÖ) teknikleri, görüntü tanıma gibi birçok alanda vazgeçilmez hale gelmiştir (He vd., 2016). DÖ üzerine yapılan çalışmalar, bu yaklaşımın önceki makine öğrenme yaklaşımlarını geride bıraktığını göstermektedir (Chen vd., 2014). UA görevleri için CNN, Otomatik Kodlayıcı ve Derin İnanç Ağları gibi çeşitli DÖ mimarileri analiz edilmiştir (Chen vd., 2015). Son yıllarda yapılan çalışmalar, görüntüler üzerinde CNN'lerin genellikle daha iyi bir performans sağladığını göstermiştir (Li vd., 2018). DÖ'nün en önemli özelliklerinden biri temsili ve ayırt edici özellikleri hiyerarşik olarak öğrenilebilmesidir (Arel vd., 2010). Bu sayede DÖ, klasik makine öğrenmesi yöntemleri gibi önceden özelliklerin belirlenmesine ve insan müdahalelerine çok bağımlı olmak yerine, genelleme yeteneklerini geliştirmek için üst düzey özellik temsillerini otomatik olarak öğrenmektedir (Li vd., 2018).

Yeterli eğitim verisi, derin öğrenme yöntemleri ile görüntü sınıflandırma başarısında anahtar rol oynamaktadır. Fakat uzaktan algılamada eğitim veri kümeleri, bilgisayarlı görme alanındaki görüntü veri kümelerinden çok daha azdır (Li vd., 2018, Song vd., 2019). Bu durum, uzaktan algılanmış eğitim verilerinin hazırlanmasının çok daha fazla zaman alıcı olmasından, uzaktan algılanmış görüntüler üzerine derin öğrenmeye dayalı araştırmalara odaklanmış bilim insanlarının sayısının göreceli daha az olmasından ve bunların da çok azının UA eğitim veri seti üretimi için uğraşmakta olmasından kaynaklanmaktadır (Song vd., 2019). Bazı çalışmalarda (örn: Yu vd., 2017; Ghaffar vd., 2019), yetersiz eğitim verisi sorununun çözümü için veri artırma teknikleri kullanılmaktadır. Veri artırma teknikleri ile eğitim örnek büyüklüğü ve çeşitliliği artırılmaktadır. Bununla birlikte, veri artırma yöntemleri karmaşık ve büyük derin öğrenme modellerinin eğitiminde uygulandığında yetersiz kalmaktadır. Song vd. (2019) tarafından uzaktan algılanmış görüntülerin CNN ile sınıflandırılması üzerine yapılan kapsamlı araştırmada uzaktan algılamada yetersiz eğitim verisi eksikliğine değinilerek, bu sorunun dünya çapında UA topluluklarının dikkatini çekmesi gerektiği ve UA eğitim veri kümelerinin geliştirilmesi için bazı girişimlerin ve teşviklerin sağlanabileceği ortaya konulmaktadır. Bu durum UA uygulamalarında DÖ'nün tam potansiyelinden yararlanılamamasına neden olmaktadır (Kemker vd., 2018). Bu sorunun çözümü amacıyla, yüksek uzamsal çözünürlüklü uydu görüntülerinde etiketli eğitim verilerinin oluşturulabilmesini kitle kaynak ile sağlayabilecek bir web platform oluşturulmuştur. Bu platform, Saraliođlu ve Gungor (2019) tarafından sınıflandırma sonrası doğruluđu değerlendirme için kitle kaynađın kullanılması amacıyla oluşturulan web platformun (www.crrremotesensingapp.com) derin öğrenme için etiketli veri oluşturmayı sağlayacak şekilde modüllerin eklenmesi ile geliştirilmiştir. Web platform aynı anda pek çok kullanıcının etiketli veri üretebileceđi şekilde oluşturulmuştur. Eğitim verileri görüntüler üzerinden poligon aracıyla çizilmektedir. Daha sonra çizilen poligonlara kullanıcılar tarafından yardım dokümanında tanımlanan eğitim sınıflarına göre etiket değeri girilmektedir. Oluşturulan verilerin doğruluklarının kontrolü için veri doğrulama modülü web platforma eklenmiştir. Bu modüde, önceki modüde üretilmiş olan etiketli veriler kullanıcıların ekranına gelmektedir. Kullanıcılar, bu verilerin doğruluklarını altık görüntüde doğru sınıfa ve konuma denk gelmeleri ile kontrol ederek puanlandırmaktadır. Doğrulamaları yapılan bu verilere eşik değeri uygulanarak doğru olanların seçimi ve yanlışların elenmesi sağlanmaktadır. Sonuç veriler GeoJSON formatında kaydedilmektedir.

2. Materyal ve Metodoloji


2.1. Kitle Kaynak Yöntemi

Resmi kayıtlara göre kitle kaynak (crowdsourcing) terimini ilk kez 2006 yılında Howe "Wired" dergisindeki makalesinde kullanmasına rağmen, belirli bir sorunun çözümü için kitlelerin kullanımı fikri yüzyıllar öncesine dayanmaktadır (Thenkabail, 2016). Web 2.0 teknolojileri sayesinde web sitesi ile kullanıcılar arasında etkileşim mümkün olmuştur. Bu sayede kitle kaynak kullanımı yaygınlaşmıştır. Kullanıcılar, web sitelerinde içerik oluşturma, fotoğraf yükleme, blog oluşturma, forum, wiki ve diđer web servislerini kullanma imkanlarına sahip olmuşturlardır.

Bu sayede kitle kaynak uygulamaları hızlı bir şekilde artmaya başlamıştır. İnternet, Dünya üzerindeki neredeyse her yerden katkıda bulunanların işe alınmasına, kaynakların kolaylıkla paylaşılmasına ve sonuçların hızlıca iletilmesine izin vermektedir. Günümüzde kitle kaynak sitelerinden en bilindik olanlardan biri “Amazon Mechanical Turk” (<https://www.mturk.com/>) web sitesidir. Bu platform, başlangıçta bir fotoğraftaki nesnelere tanımlamak ve listelemek gibi insanların bilgisayarlardan daha iyi yapabileceği pek çok görev olduğu fikrine dayanarak ortaya çıkmıştır. Wikipedia, I-Stock Photo, innocentine.com, OpenStreetMap kitle kaynak ile gerçekleştirilmiş diğer büyük projelerdir. Kitle kaynak yazılım alanında da açık kaynak projeleriyle ortaya çıkmıştır. Linux işletim sisteminden, Firefox web tarayıcısına, Python programlama diline ve Apache sunucu yazılımına kadar bilişim dünyasının altyapısının büyük bir kısmı, kendini örgütleyen ekipler tarafından oluşturulmuştur. İki yıl boyunca binlerce kodlayıcının Linux’u iyileştirme çabalarına katılmasıyla büyük bir topluluk oluşturulmuştur. Günümüzde Linux milyonlarca kişisel bilgisayarda bulunmasının yanında, süper bilgisayarlardan cep telefonlarına kadar çeşitli platformlarda kullanılmaktadır. Ayrıca Linux açık kaynak yazılım projelerinin yaygınlaşmasını sağlamıştır (Howe, 2008). Kitle kaynak ile çok büyük boyuttaki projeler küçük parçalara ayrılmakta ve kitlelerden bu küçük ve kendi başına çok basit olan işleri yapmaları istenmektedir.

2.2. Derin Öğrenme Amaçlı Eğitim Verisi Oluşturma İçin Web Platform

Web platform, Ön Kısım (Front-End), Javascript, html, CSS, Bootstrap ve Arka Kısım (Back-End) C#, jQuery ve çeşitli kütüphaneler kullanılarak oluşturulmuştur. Veri tabanı olarak MSSQL kullanılmıştır. Site alan adı “www.crremotesensingapp.com”, satın alınmıştır. Proje Visual Studio ortamında hazırlanmıştır. Altlık haritalar ve çizim araçları için OpenLayer kütüphanelerinden faydalanılmıştır. Web sunucu olarak ISS sunucusu kullanılmıştır. Şekil 1’de web platformun genel yapısı gösterilmektedir.



Şekil 1. Web platformunun mimarisi

2.2.1. Kullanıcı Kayıt Kısmı

Web platformunun kullanılması aşamasında, kullanıcılardan kayıt olması istenmektedir. Bunun için istenen gerekli bilgiler; ad, soyad ve e-mail adresidir. Ek olarak cep telefonu bilgisi de istenmektedir. Fakat bu kısmın doldurulması zorunlu tutulmamıştır. Kullanıcı web platformuna kayıt olduktan sonra yönetici girişiyle siteye girildiğinde kayıt isteği gönderen kullanıcılar listelenmektedir. Bu durumda istek gönderen kişilerin onaylanması yapılabilmektedir. Onay işlemi yapılmadan kullanıcının sisteme girmesine izin verilmemektedir. Kayıt yaptıktan sonra üyeliği aktif olmadan sisteme giriş yapmaya çalışan kullanıcıya “kullanıcı aktif değil” şeklinde mesaj gönderilmektedir. Şekil 2’de kullanıcı kayıt kısmı ve web platformunun giriş görüntüsü gösterilmektedir.



Şekil 2. Kullanıcı kayıt girişı ekranı

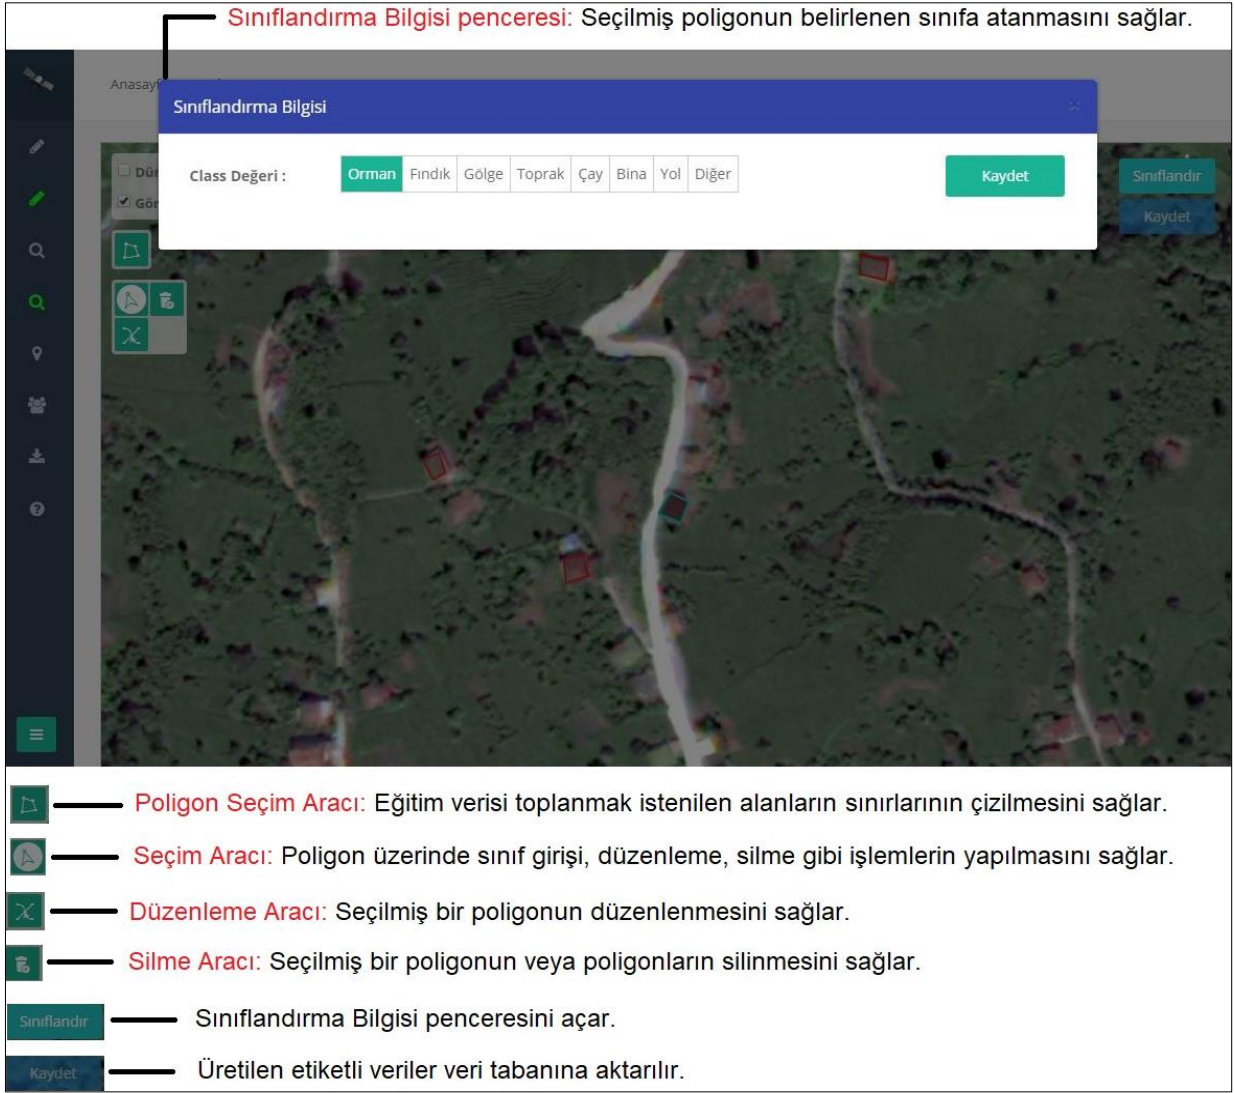
2.2.2. Eđitim Amaçlı Etiketli Veri Seti uretimi

Bu bolum derin ogrenme amaçlı veri seti oluřturulması iin kullanıcıların veri oluřturabileceđi ve oluřturulmuř verilerin dođrulamasının yapılabilmesi řekilde hazırlanmıřtır. Bu kısımdaki buton ve menulerin kullanımı Şekil 3'te gosterilen ve web platforma eklenen "Veri Oluřturma Yardım Dokumanında" gosterilmektedir.

Şekil 3'de gorulduđ gibi etiketli veri uretimi ařamasında, web platformu zerinde kullanıcıların yapacađı temel iřlemler poligon evirme aracı, seim aracı, duzenleme aracı ve silme aracı ile gerekleřtirilmektedir. Sınıflandırma bilgisi penceresi ise sınırları belirlenmiř olan nesnelere etiket bilgisi atamada kullanılmaktadır. Ařađıda web platformda kullanılan aralar tanıtılmaktadır.

- Poligon Aracı: Poligon aracı web platforma ekli goruntuler zerinde veya Google uydu goruntuleri altlıđı zerinde eđitim amacıyla toplanacak sınıfların iziminde kullanılmaktadır.
- Seim Aracı: Seim aracı izilmiř poligonlardan duzenleme yapma, silme veya sınıf etiket deđeri vermek iin hangi poligonda iřlem yapılacađını belirtmek amacıyla kullanılmaktadır.
- Duzenleme Aracı: Seilen bir poligonu duzenlenmesi iin aktif hale getirmektedir.
- Silme Aracı: Seilmiř bir poligonu silmektedir.

Bunların dıřında "Sınıflandır" butonu Şekil 3'te gorulduđ gibi "sınıflandırma bilgisi" penceresini amaktadır. Bu pencerede seili poligonun hangi sınıfa ait olduđuna dair etiketleme iřlemi yapılmaktadır. "Orman, Fındık, Golge, Toprak, ay, Bina, Yol" sınıfları iin kolaylık aısından dođrudan butonlar tanımlanmıřtır. Bunların dıřında bir sınıfa ait etiketleme yapılması istendiđinde "Diđer" butonuna tıklanır. "Diđer" butonu tıklanıđında kullanıcıya yeni bir pencere aılmaktadır. Bu pencerede kullanıcı eđer isterse etiket vermek istediđi farklı sınıf adlarını tanımlayabilmektedir (rn: ua, gol, deniz, vb.). Bu buton web platformunun dinamik yapıda olmasını sađlamaktadır. Kullanıcıların "Diđer" butonu ile girmeleri istenilen sınıfların, web platformunda yardım dokumanı kısmında tanımlanması gerekmektedir. rneđin web platformunda otomatik tanımlı bir sınıf olmayan gol sınıfı iin, "Diđer" butonuna basılarak aıklama kısmına "Gol" girilmesi gerektiđi yardım dokumanında belirtilmelidir. Aksi durumda kullanıcıların bu sınıfı "GOL, GOL, Gol, gol..." gibi farklı řekillerde oluřturmaları mumkun olacaktır.



řekil 3. Veri oluřturma yardım dokümanı

2.2.3. Eđitim Verilerini Tanımlayan Yardım Dokümanı

Kullanıcıların etiketli eđitim verilerini oluřturabilmesi ve hangi sınıfları neye gore iřaretleyeceklerinin gosterilmesi amacıyla řekil 4'te gorulduđ gibi rnek yardım dokümanı hazırlanıp web platformda "Yardım" kısmına eklenmiřtir. Veri izimi iin rnek sınıfların farklı özunrluklerde altlık uydu goruntulerinde nasıl gorundukleri gosterilmiřtir.

Goruntulenen resmin sol ust koesinde Worldview katmanı iřaretli olmalıdır. Diđer katmanları kapatabilirsiniz. Goruntu zerinde bir nokta tıkladıđında, o nokta iin 1'den 7'ye kadar bir sınıf deđerini girilmelidir. Her bir noktanın sınıf deđerini belirlerken, WorldView katmanına gore deđer giriři yapınız.


			Orman	Sınıf deđerini = 1
			Fındık	Sınıf deđerini = 2
			Golge	Sınıf deđerini = 3
			Toprak	Sınıf deđerini=4
			ay	Sınıf deđerini =5
			Bina	Sınıf deđerini =6
			Yol	Sınıf deđerini = 7

řekil 4. Yardım dokmanı

Yardım dokmanında her bir sınıfa ait yuksek ozunurluklu uydu goruntu paralarındaki farklı yakınlama seviyelerinde ve rneklerde sınıfların nasıl gorunduđu gosterilmektedir. Sađ tarafta 7 sınıfın veri tabanında tutulduđu rakamlar gosterilmektedir. Kullanıcılardan web platformunda bir noktaya tıkladıklarında, bu noktanın sınıfını temsil eden rakamı aılan pencerede girmesi istenmektedir. Bu gorev insanlar iin olduka kolay olan benzer goruntuleri eřleřtirme iřlemidir. Ayrıca bina, yol, toprak, golge sınıfları zaten herkesin hibir aıklamaya ihtiya duymadan ayırt edebilecekleri sınıfları oluřturmaktadır. Bunun dıřında orman, fındık ve ay sınıflarının da goruntu zerinde nasıl bir dokuya sahip oldukları yardım dokmanında gosterilmiřtir. İstenilen diđer sınıflar iin bu řekilde yardım dokmanları oluřturulup web platforma eklenmelidir.

2.2.4. Uydu Görüntü Parçaları ile Etiketli Eğitim Verisi Oluşturma

Kullanıcıların etiketli eğitim verilerini oluşturabilmeleri için “Veri Seçme” modülü yukarıda bahsedilen poligon çevirme, düzenleme, silme ve seçme araçlarını içermektedir. Çalışma veya proje amacıyla yüksek çözünürlüklü uydu görüntüleri temin edilmişse ve bu görüntüler üzerinden kullanıcılara etiketli veri oluşturulması isteniyorsa bu durumda “Veri Seçme” modülü kullanılmaktadır. İlk olarak, yüksek çözünürlüklü görüntüler kolaylık sağlanması amacıyla parçalara ayrılmakta ve koordinatlı olarak web platform veri tabanına çalışmayı yaptıracak kişi tarafından eklenmektedir. Bu işlemden sonra kullanıcılar “Veri Seçme” modülüne giriş yaptıklarında ilk başta web platforma eklenen yüksek çözünürlüklü görüntü parçaları rastgele olarak kullanıcılara otomatik olarak gönderilir. Sisteme giren her bir kullanıcı bir görüntü parçasını görmektedir. Bu görüntüler üzerinde poligon çizimleri yapıldıkça ve bu çizimler kullanıcılar tarafından sisteme kaydedildikçe görüntü parçalarının işlem sayısı artmaktadır. Daha sonra kullanıcılara görüntülerin gönderim sırası en az işlem yapılan görüntü parçası olacak şekilde devam etmektedir. Çünkü rastgele gönderme durumunda, bazı görüntüler kullanıcılara hiç gönderilmezken diğer görüntülerin de daha fazla gönderimi problemi ortaya çıkmaktadır. Tüm görüntüler üzerinden etiketli veri toplanabilmesini sağlayabilmek amacıyla bu sıralama izlenmiştir.

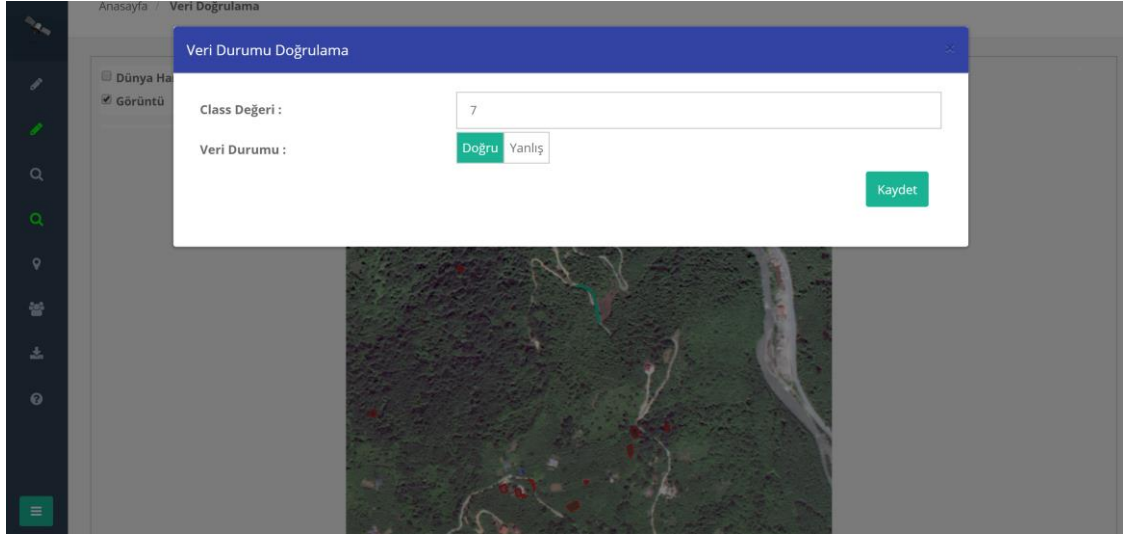


Şekil 5. Etiket değerlerinin kullanıcılar tarafından oluşturulmasını sağlayan etiket veri girişi penceresi

Sınıf sınırları belirlenip çizildikten sonra kullanıcı çevirdiği poligonlara etiket değeri vermektedir. Daha sonra ilgili sınıf seçilmekte ve bu pencerede “Kaydet” butonuna basılarak veri oluşturma işi tamamlanmaktadır. Bütün yapılan işlemler tamamlandığında web platformdaki “Kaydet” butonuna basılıp tüm sınıfların veri tabanına kaydedilmesi sağlanmaktadır. Ayrıca veri oluşturmada fikir alınabilmesi amacıyla Google Haritalar uydu görüntüsü altlığı da bu modülde kullanıcıların ilgili butonu aktif hale getirmesiyle kullanılmaktadır.

2.2.5. Oluşturulan Etiketli Eğitim Verilerinin Kontrolü

Kullanıcılar tarafından oluşturulan verilerin doğruluğunun tespiti, yanlış verilerin ayırt edilmesi ve sonuç doğru eğitimli veri setine ulaşılabilmesi amacıyla “Veri Doğrulama” modülü oluşturularak web platformuna eklenmiştir. Bu modül yukarıda bahsedilen “Veri Seçme” modülünde kullanıcılar tarafından oluşturulan eğitim verilerinden doğru ve yanlış olanları ayırt etmeyi sağlamaktadır. Kullanıcı tarafından “Veri Doğrulama” modülü açıldığında, kullanıcının karşısına bir uydu görüntü parçası ve bu parçaya ait çizili poligonlar gelmektedir. Kullanıcılara geliş sırası yukarıda anlatıldığı gibi en az işlem yapılanına göre gerçekleşmektedir. Kullanıcılar bu görüntü üzerindeki poligonları kontrol etmektedir. Kullanıcı tarafından bir poligona tıklandığında Şekil 6’da gösterildiği gibi bir pencere açılmaktadır.




řekil 6. Veri dođrulama iřleminin kullanıcılar tarafından yapılmasını sađlayan pencere

Bu pencerede zerinde iřlem yapılan sınıfa ait etiket deđeri ve “dođru”, “yanlıř” seeneklerini ieren iki adet buton bulunmaktadır. Her bir sınıfa ait etiket deđeri “orman=1, fındık=2, glge=3, toprak=4, ay=5, bina=6, yol=7 ve diđer=8” řeklinde dir. Bu deđerler yardım dokmanında (řekil 4) gsterilmektedir. Kullanıcının iřaretlediđi poligon birden fazla sınıfa ierecek řekilde izilmişse bu durumda etiket deđerine bakılmaksızın yanlıř butonu kullanıcı tarafından iřaretlenmektedir. Eđer poligon izimi dođru ise yani tam olarak ilgili sınıfa kapsayacak řekilde evirme yapılmıřsa kullanıcı tarafından bu sefer sınıf etiket deđerini dođruluđu kontrol edilir ve bu deđer de dođru ise “dođru” butonuna, yanlıř ise “yanlıř” butonuna basılır. En son “Kaydet” butonu ile yapılan iřlemlerin veri tabanına aktarımı sađlanmaktadır. Web platformunun yneticisi tarafından veri tabanında en yksek puan alan etiketli veriler seilerek dođru etiketli eđitim verileri seilebilmektedir.

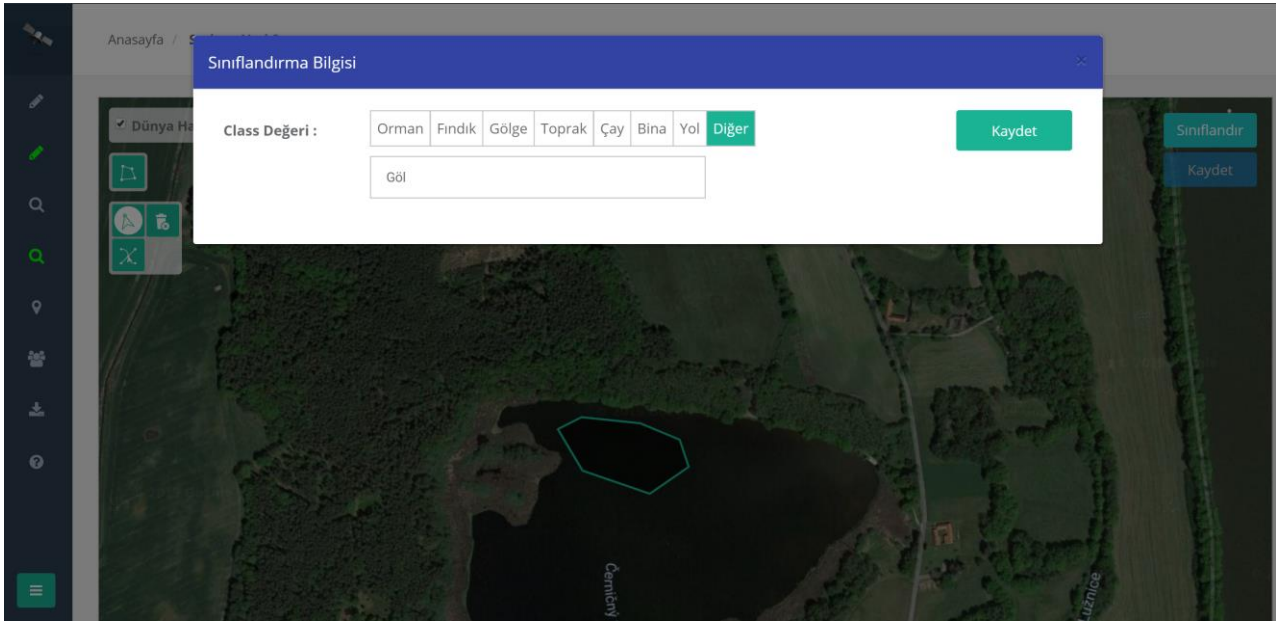
2.2.6. Google Uydu Grntleri Altlıđından Etiketli Veri Oluřturma

“Serbest Veri Seme” modl web platformun dinamik olarak derin đrenme amalı etiketli veri seti oluřturulmasında kullanılablmesini sađlamaktadır. İeriđi temelde “Veri Seme” modl ile aynıdır. Sadece bu modle ilk girildiđinde, kullanıcılara web platformuna eklenmiř uydu grnt paraları gsterilmez. Onun yerine kullanıcıya altlık olarak Google Haritalar uydu grnts altlıđı gsterilmektedir. Kullanıcı poligon evirme aracıyla bu altlık zerinden Dnya zerindeki herhangi bir yere ve sınıfa ait bir evirme yapabilmektedir. řekil 7’de Google Harita uydu atlıđından Prag řehrinde bina sınıfı iin evrilen bir poligon gsterilmektedir.



řekil 7. Serbest veri seme modl

Daha sonra seim aracıyla evirme yapılan poligona kullanıcı tarafından tıklanır ve veri giriři penceresinin aılması sađlanır. Bu kısımda kullanıcı sınıf etiketi iin yukarıda bahsedilen sınıfların dıřında sınıflandırma yapmak istiyorsa “Diđer” seeneđini iřaretlemelidir. Bu seenek iřaretlendiđinde aıklama kısmı gelir ve bu kısma kullanıcı evirmiş olduđu poligon sınıfının adını yazar. rneđin akarsu, deniz, araba, gemi, havaalanı vb. En son “Kaydet” butonuna basılarak butun etiketli verilerin veri tabanına aktarılması sađlanmaktadır. Diđer seeneđi ile etiketlenen verilerin hem sınıf deđerleri hem de aıklamaları veri tabanına kaydedilir. Őekil 8’de gol sınıfı iin kullanılabilcek poligon izimi ve etiket deđerı gsterilmektedir.



Őekil 8. Serbest veri seme modulu ile gol sınıfı oluřturulması

2.2.7. Oluřturulan Serbest Etiketli Eđitim Verilerinin Kontrolu

“Serbest Veri Dođrulama” modulu de “Veri Dođrulama” modulu ile aynıdır. Sadece bu module ilk girildiđinde, kullanıcılara web platformuna eklenmiş uydu goruntu paraları gsterilmez. Onun yerine kullanıcıya altlık olarak Google Haritalar uydu goruntusu altlığı gsterilmektedir. Bu altlık zerinde kullanıcılar serbest veri seme modulu ile sınıflara ait evrili poligonları grmektedir. Kullanıcılar tm Dnya apındaki geniř alandan istedikleri evirili sınıfların kontrollerini sađlayabilmektedir.

3. Sonular ve neriler

Bu alıřmada yksek uzamsal ozunrluklu uydu goruntulerindeki yetersiz etiketli eđitim verisi sorununu ozmek amacıyla oluřturulan web platformu tanıtılmıştır. Bu web platformu sayesinde uydu goruntulerinde gz ile ayırt edilebilen tm nesnelerin etiketli eđitim verilerinin oluřturulması mmkun olmaktadır. Web platformu bu iřlemlerin yapılabileceđi Őekilde dinamik bir yapıda hazırlanmıştır. Ayrıca web platformu, kitleler ile uydu goruntulerinin sınıflandırılması ve herhangi bir sınıflandırma algoritması ile sınıflandırılan goruntudaki hataların kitleler yardımıyla bulunarak dzeltilmesi gibi eřitli amalar iin de kullanılabilir. Yksek ozunrluklu uydu goruntulerinden etiketli verilerin retimini sađlamak derin đrenme yntemlerinin uydu goruntulerindeki sınıflandırma bařarısını arttıracaktır. Gnmzde pek ok alanda bařarıyla uygulanan derin đrenme yntemleri uzaktan algılama alanında da kullanılmaya bařlanmıştır. Fakat uydu goruntuleri iin ok az sayıda eđitim verisi olması derin đrenme yntemlerinin potansiyellerinden tam olarak yararlanılamamasına neden olmaktadır. Byk lekli alıřmalarda etiketli veri oluřturma bir kiři veya kuk bir topluluđun yerine getiremeyeceđi bir govendir. Bu sorun geniř kitlelerin katılabileceđi bir web platformunun etiketli veri retilmesinde kullanımı ile ozulebilir. Kitlelerin oluřturdukları ham etiketli veriler yanlıřlıklar ierebilmektedir. Bu nedenle hazırlanan platformda verilerin kontrolunun yapılmasını ieren bir modul eklenmiştir. Bu sayede hatasız etiketli verilerin oluřturulması mmkun olmaktadır. Oluřturulan web platformu etiketli eđitim verisi sorununun nasıl ozulebileceđini gstermektedir.

Kaynaklar

- Akar, Ö., & Gungör, O. (2015). Integrating multiple texture methods and NDVI to the Random Forest classification algorithm to detect tea and hazelnut plantation areas in northeast Turkey. *International Journal of Remote Sensing*, 36(2), 442-464.
- Arel, I., Rose, D. C., & Karnowski, T. P. (2010). Deep machine learning-a new frontier in artificial intelligence research. *IEEE computational intelligence magazine*, 5(4), 13-18.
- Carranza-García, M., García-Gutiérrez, J., & Riquelme, J. C. (2019). A framework for evaluating land use and land cover classification using convolutional neural networks. *Remote Sensing*, 11(3), 274.
- Chen, Y., Lin, Z., Zhao, X., Wang, G., & 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.
- Chen, Y., Zhao, X., & 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.
- Ghaffar, M. A. A., McKinstry, A., Maul, T., & Vu, T. T. (2019). Data augmentation approaches for satellite image super-resolution. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, Vol. IV-2/W7, 47-54, <https://doi.org/10.5194/isprs-annals-IV-2-W7-47-2019>.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Howe, J. (2008). *Crowdsourcing: Kalabalıkların gücü bir işin geleceğine nasıl şekil verebilir?*. Birinci Baskı, Koç Sistem Yayınları, İstanbul.
- Howe, J. (2006). The Rise of Crowdsourcing, *Wired*, <https://www.wired.com/wired/archive/14.06/crowds.html>, Erişim Tarihi: 10 Ekim 2019.
- Kemker, R., Salvaggio, C., & Kanan, C. (2018). Algorithms for semantic segmentation of multispectral remote sensing imagery using deep learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 145, 60-77.
- Li, Y., Zhang, H., Xue, X., Jiang, Y., & Shen, Q. (2018). Deep learning for remote sensing image classification: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(6), e1264.
- Maggiori, E., Tarabalka, Y., Charpiat, G., & Alliez, P. (2016). Convolutional neural networks for large-scale remote-sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2), 645-657.
- Saraliođlu, E., & Gungör, O. (2019). Use of crowdsourcing in evaluating post-classification accuracy. *European Journal of Remote Sensing*, 52(sup1), 137-147.
- Song, J., Gao, S., Zhu, Y., & Ma, C. (2019). A survey of remote sensing image classification based on CNNs. *Big Earth Data*, 3(3), 232-254.
- Thenkabail, P. S. (2016). *Remote Sensing Handbook; Volume 1: Remotely Sensed Data Characterization, Classification, and Accuracies*. Taylor & Francis.
- Yu, X., Wu, X., Luo, C., & Ren, P. (2017). Deep learning in remote sensing scene classification: a data augmentation enhanced convolutional neural network framework. *GIScience & Remote Sensing*, 54(5), 741-758.
- Zhang, C. (2018). *Deep learning for land cover and land use classification* (Doctoral dissertation, Lancaster University).

Improving SVM Classification Accuracy with Image Fusion-Based Gabor Texture Features

Kaynaştırılmış Görüntülerden Elde Edilen Gabor Doku Özellikleri ile DVM Sınıflandırma Performansının İyileştirilmesi

Cigdem Serifoglu Yilmaz^{1*}, Oguz Gungor¹

¹Karadeniz Technical University, Engineering Faculty, Department of Geomatics Engineering, 61080, Trabzon/Turkey.

ORIGINAL PAPER

*Corresponding author:

Cigdem Serifoglu Yilmaz
cigdemserifoglu@ktu.edu.tr

doi:

Article history:

Received : 04.02.2020

Accepted : 16.03.2020

Published: 31.03.2020

Abstract

Image fusion is one of the most common techniques used to enhance the interpretability and functionality of remotely sensed data. The aim of this study was to improve the performance of the SVM (Support Vector Machines) classifier with the aid of texture features (TF) extracted from fused images. As a first step, the spatial resolution of the WorldView-2 MS (multispectral) imagery was increased by fusing it with a WorldView-2 PAN (panchromatic) image using the PCA (Principal Component Analysis), WSB (Wavelet Single Band), GS (Gram-Schmidt), BRV (Brovey), EHL (Ehlers), HCS (Hyperspherical Colour Space), HPF (High-Pass Filtering) and MCV (Multiplicative) algorithms. A PCA transform was then applied on all fused images. The first principal component obtained from each fused image was used to extract the Gabor TFs. As a final step, extracted Gabor TFs were combined with the original MS image. Resultant images were classified with the SVM algorithm to investigate to what degree the used methodology affect the classification accuracy. The results showed that the GS fusion-based Gabor TFs provided the greatest classification accuracy increase with 19.3%, whereas the PCA fusion-based Gabor TFs resulted in the second best classification accuracy increase with 18.7%.

Keywords: Texture feature extraction, Image fusion, Gabor texture features, Principal component analysis, Image classification

Özet

Görüntü kaynaştırma, uzaktan algılanan verilerin yorumlanabilirliğini ve işlevselliğini artırmak için en yaygın olarak kullanılan tekniklerden biridir. Bu çalışmanın amacı Destek Vektör Makineleri (DVM) sınıflandırma algoritmasının performansının kaynaştırılmış görüntülerden elde edilen doku özellikleri yardımıyla iyileştirilmesidir. Bu amaçla, ilk aşama olarak bir WorldView-2 çok bantlı görüntüsü bir WorldView-2 pankromatik görüntüsü ile PCA (Principal Component Analysis), WSB (Wavelet Single Band), GS (Gram-Schmidt), BRV (Brovey), EHL (Ehlers), HCS (Hyperspherical Colour Space), HPF (High-Pass Filtering) ve MCV (Multiplicative) yöntemleri kullanılarak kaynaştırılmıştır. Daha sonra her bir kaynaştırılmış görüntüye Temel Bileşenler Analizi uygulanmıştır. Her bir kaynaştırılmış görüntü için elde edilen birinci temel bileşen Gabor doku özelliklerinin çıkartılması amacıyla kullanılmıştır. Son aşama olarak da elde edilen doku özellikleri girdi çok bantlı görüntüye eklenmiştir. Elde edilen bu görüntüler DVM algoritmasıyla sınıflandırılarak kullanılan metodolojinin sınıflandırma doğruluğunu ne derece etkilediği incelenmiştir. Sonuç olarak, GS yöntemiyle elde edilen Gabor doku özelliklerinin %19.3 artış ile sınıflandırma doğruluğunu en fazla oranda arttıran doku özelliği olduğu ve PCA yöntemiyle elde edilen Gabor doku özelliklerinin ise %18.7 artış ile sınıflandırma doğruluğunu en fazla oranda arttıran ikinci doku özelliği olduğu tespit edilmiştir.

Anahtar kelimeler: Doku özellik çıkarımı, Görüntü kaynaştırma, Gabor doku özellikleri, Temel bileşenler analizi, Görüntü sınıflandırma

1. Introduction

Image classification, which is one of the most widely-used techniques that increases the interpretability of the features on the image, categorizes image pixels with respect to their spectral features, i.e. spectrally similar pixels are assigned to the same class. Image classification is implemented for a wide range of purposes, including land use classification (Johnsson, 1994), geological mapping (Ricchetti, 2000), burned area mapping (Gitas et al., 2004), mapping crops and forest areas (Zabala et al., 2006), weed detection in crops (Eddy et al., 2006), imaging urban areas (Omkar et al., 2007), marine habitat mapping (Laurer and Aswani, 2008), crop identification (Yang et al., 2011), flood hazard assessment (Shaker et al., 2012), ocean mapping (Almendros-Jiménez et al., 2012), mapping riparian vegetation habitats (Kollár et al., 2013), land cover mapping (Damodaran and Nidamanuri, 2014), detection of land cover changes (Dube et al., 2014), mapping agricultural tillage practices (Ran et al., 2015), rice lodging assessment (Yang et al., 2017), and point cloud filtering (Yilmaz et al., 2018).

Image classification is a complex task and its success depends on several factors. Since bad atmospheric conditions and sensor malfunctions may affect the quality of the satellite imageries, atmospheric and radiometric corrections should be conducted to the imageries prior to classification, if necessary. Another important factor that plays a significant role in the success of a classification process is the experience of the analyst, especially when conducting supervised image classification that relies on the training pixels (signatures) collected by the analyst. Improper collection of signatures may lead to the confusion of the classes in the classified image. Spatial resolution of the image to be classified also affects the performance of the classification procedure employed. Since lower-resolution imageries are hard to interpret by the human eye, it may be very hard to collect signatures on this kind of imageries. Image fusion may provide an efficient solution to this problem. Since image fusion aims to produce spatially enhanced images by combining the spatial detail content of a panchromatic (PAN) image with the colour features of a lower-resolution multispectral (MS) image, it increases the interpretability of the images and makes it a lot easier to collect signatures for classification. The success of a classification process depends also on the spectral resolution (i.e. the ability to record the electromagnetic energy in a large number of spectral bands with narrow spectral band intervals) of the image to be classified. Images of higher spectral resolution are more effective in distinguishing land cover features, especially features with similar colour characteristics. On the other hand, classification of lower spectral resolution images requires some additional procedures to improve their classification performances. In this context, incorporating texture information to the classification process is a reasonable approach to enhance the performance of classification methods.

Until today, a great deal of effort has been made to use the texture features in image classification process to achieve better classification results. Baraldi and Parmiggiani (1995) incorporated six (energy, contrast, variance, correlation, entropy and inverse difference moment) of the Grey Level Cooccurrence Matrix (GLCM) texture features introduced by Haralick et al. (1973) into the classification process. Kurosu et al. (2001), Rao et al. (2002), Podest and Saatchi (2002), Butusov (2003), Sambodo et al. (2010), Hermosilla et al. (2010), Pathak and Dikshit (2010), Devi and Rekha (2013), Nanni et al. (2013) and Yilmaz (2019) are just some of the other studies where the use of GLCM texture features was investigated to achieve more accurate classification results. Augusteijn et al. (1995) performed image classification by using the texture features extracted from cooccurrence matrices, texture-tone analysis, grey level differences, Fourier spectrum and Gabor filters. Chen et al. 1997, incorporated the intensity and texture information into the classification process. In the study, the authors employed a wavelet transform to extract the fractal dimensions as texture features. Low et al. (1999) made use of texture features average intensity, second moment of intensity histogram and fractal surface dimension in an artificial neural network classifier. Nyongui et al. (2002) improved the classification accuracy by using texture features derived from first-, second-, and third-order statistics in spatial domain, texture features obtained from the texture spectrum, and texture features obtained from the grey level difference vector. Angelo and Haertel (2003) utilized the Gabor texture features in supervised image classification. Lloyd et al. (2004) indicated that the texture features extracted from variograms could be useful in increasing the classification accuracy. Zhang et al. (2004) increased the classification accuracy by using grey level cooccurrence texture features derived with geostatistical analysis. Jin et al. (2012) increased the classification accuracy by using multi-temporal texture features. Akar and Güngör (2015) integrated the GLCM and Gabor texture features into the random forest classifier to improve its performance. Yilmaz (2019) enhanced the performance of the support vector machines (SVM) classifier by using the GLCM texture features extracted from image segments obtained from fused images.

This study aimed to increase the SVM classification accuracy by integrating the Gabor texture features extracted from fused images. To this aim, the Gabor texture features derived from the results of various popular image fusion methods were integrated into the SVM classifier to see which fusion method provided the texture features that led to the greatest overall classification accuracy increase.

The remainder of this paper is as follows: Section 2 will give brief theoretical background for the image fusion methods used in this study. Section 3 will give information about the Gabor feature extraction process, whereas Section 4 will briefly explain the SVM classifier. Section 5 will introduce the study area and the methodology followed in this study.

The results regarding which fusion methods achieved the best texture features leading to the greatest classification accuracy increase will be given in Section 6. Finally, the conclusions drawn from this study will be given in Section 7.

2. Image Fusion

Image fusion combines the spatial characteristics of a high-resolution PAN band and colour features of low-resolution MS bands to produce spatially enhanced images. Fused images increase the interpretability of the images, enabling the users to extract meaningful information from the surface of the earth. Fused images have a wide variety of application areas, including topographic map updating (Pohl, 1996), RGB representation (Tsagaris and Anastassopoulos, 2005), building database updating (Poulain et al., 2011), visual display (Peli et al., 1999), land cover change detection (Zeng et al., 2010), marine monitoring (Du et al., 2003), mapping (Acerbi-Junior et al., 2006), flood plain mapping (Kedzierski et al., 2014), coastal monitoring (Yang et al., 2012), vegetation monitoring (Johnson et al., 2013) etc. A large number of image fusion approaches have been developed so far. Following are some brief information about the theories of the image fusion methods used in this study.

- The MCV method, which is the simplest of all, performs fusion by multiplying the input PAN and MS bands (Crippen, 1989). The BRV method calculates an intensity band by summing all MS bands. The ratio between each MS band and intensity band is multiplied by the PAN image to produce the fused bands (Hallada and Cox, 1983).
- The HPF method injects the spatial details enhanced by a high-pass filter into the MS image (Schowengerdt, 1980).
- The PCA method applies a PCA transformation of the input MS bands to de-correlate the image bands. The first principal component, which includes the majority of the total variance (i.e. spatial information), is then replaced by the input PAN image. The fused image is obtained through an inverse PCA transformation (Chavez and Kwarteng, 1989). The GS method, a statistical method like the PCA, combines the MS bands with a PAN band simulated from the MS bands, simulated PAN being the first band. A GS transformation is applied on this combined data. Then, the first GS component is replaced by the histogram-matched PAN band. An inverse GS transformation results in the fused image (Laben and Brower, 2000).
- The EHL method applies a high-pass filter on the panchromatic spectrum obtained from the Fast Fourier Transform (FFT) of the PAN image and a low-pass filter on the intensity spectrum obtained from the FFT of the intensity component generated through the IHS transformation of the MS bands. An inverse FFT is applied on both filtered spectrums and the results are summed to form a new intensity. Finally, an inverse IHS transformation with the new intensity results in the fused image (Ehlers, 2004; Klonus and Ehlers, 2007).
- The HCS method first simulates a smoothed PAN image and transforms the input data from native colour space to hyperspherical colour space. The intensity of the MS image is matched to those of the squares of the original and smoothed PAN image. Then, a new intensity component is generated using the squares of smoothed PAN, original PAN and MS intensity. Finally, an inverse transform is employed to produce the fused image (Padwick et al., 2010).
- The WSB method generates an approximation band from successive Discrete Wavelet Transformations (DWT). The generated approximation band is replaced by the input PAN image. An inverse DWT gives the fused bands (Hill et al., 2002; Yilmaz and Gungor, 2016; ERDAS IMAGINE Field Guide 2013).

3. Gabor Texture Feature Extraction

Texture information increases the meaningfulness of images. The Gabor filters, which are widely used to extract texture information from images, are a group of wavelets, each of them being able to acquire the energy at a given frequency and a given direction (Zhang et al., 2000). The Gabor filters provide optimal localization properties in both frequency and spatial domain, which makes them suitable for texture extraction (Yang et al., 2003; Huang et al., 2010). The Gabor transformation defines any signal as a summation of orthogonal frequency-shift and time-shift Gaussian functions. The Gabor space is obtained by convolving the image with a filter bank that includes various rotations and scales. Texture information is retrieved from the statistics of the filtering results (Akar and Güngör, 2015). The 2-D Gabor filter was given by Petkov and Wieling (2008) and Akar and Güngör (2015) as;

$$g_{\lambda,\theta,\varphi,\sigma,\gamma}(x,y) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(2\pi\frac{x'}{\lambda} + \varphi\right) \quad (1)$$

$$\begin{aligned} x' &= x \cos \theta + y \sin \theta \\ y' &= -x \sin \theta + y \cos \theta \end{aligned}$$

where, θ defines the orientation, λ is the wavelength of the filter, γ is the spatial aspect ratio and φ is the phase offset.

4. SVM Classification

The SVM method is based on the identification of decision boundaries, called hyperplanes, to optimize the boundaries between classes based on the sample pixels defined, thereby minimizing the possibility of misclassification between the pixels. The method was first designed to solve linear classification problems which can be labelled as $\{-1, +1\}$ to separate the two classes. In linear problems, the hyperplanes must have the highest level of aperture (i.e. margin) to effectively separate two classes. More specifically, the SVM method is based on the definition of the optimal hyperplane that maximizes the distance between the hyperplane and sample pixels (Vapnik 1995; 1998). Pixels on the optimal hyperplanes form support vectors and are used to classify the unknown pixels in the image (Özdarıcı Ok and Akyürek, 2013). Linear planes are often insufficient to solve real life problems. The concept of non-linear hyperplanes was developed for such cases. According to this concept, in order to ensure the best separation between classes, the data is transformed into the Euclidean space, also called multidimensional Hilbert space (Özdarıcı Ok and Akyürek, 2013). This transformation is done through the use of some kernel functions including the linear, polynomial, sigmoid and radial basis function kernels. These functions enable the transformation into a new higher dimensional space, where distinction between classes is more possible (Mathur and Foody, 2008). Among all, radial basis function is the most preferred one due to its efficiency in achieving high classification accuracy (Huang et al., 2002; Melgani and Bruzzone, 2004). Various multi-class approaches have been developed for cases where more than two classes should be separated. The One-Against-All approach forms an SVM for each class. Each SVM is trained to separate the samples of one class from the samples of all other classes (Milgram et al., 2006). On the other hand, the One-Against-One approach forms an SVM for each pair of classes. Let n be the number of classes in a problem, $n(n-1)/2$ SVMs are trained to separate the samples of a class from those of another (Milgram et al., 2006).

5. Application

5.1 Study Area

This study was conducted in the Surmene province of the city of Trabzon, Turkey. The study area was captured by the WorldView-2 satellite, which produces an 8-band MS image and a PAN image with spatial resolutions of 2 m and 0.5 m, respectively. The imageries produced by this satellite have a radiometric resolution of 11 bits. The location of the study area and Surmene province can be seen in Figure 1. As seen in the figure, the study area is a rural area covered by various types of vegetation and a certain amount of urban features.




Figure 1. Study area

5.2 Methodology

Since the input images were atmospherically and radiometrically corrected, no preprocessing correction procedures were conducted before fusion. As the very first step, the spatial detail content of the WorldView-2 MS image was increased by fusing it with the WorldView-2 PAN image by means of the PCA, WSB, GS, BRV, EHL, HCS, HPF and MCV methods. The ERDAS IMAGINE software was used to apply all fusion methods except the GS, which was applied with a MATLAB script. All fusion methods were applied with default settings.

The next step was to apply a PCA transform on the fused images in order to de-correlate their bands. Since the first principal component of the transformed images contained the majority of the variance (i.e. spatial detail) of the fused bands, the Gabor TFs were extracted on them. The extracted TFs were combined with the original MS bands, which were upsampled to the size of the fused bands. When applying the Gabor transform, a scale of 5, a rotation of 8 and a window size of 39 were found to be efficient for texture features extraction. These parameter values were obtained by trial and error. It is important to note that, it was, of course, possible to extract the Gabor TFs from any PAN image without applying image fusion. However, the texture features are not only based on spatial features, but also on colour features. This is the reason that the TFs were extracted from the fused images in this study.

As the final step, the original MS image and the combined images were classified by the SVM method to investigate whether or not the followed procedure led to an increase in the classification accuracy, compared to the original MS image. The reason for using the SVM classifier in this study is because it has been proven to be one of the best classifiers in the literature (Bigdeli et al., 2012; Mathew and Anto, 2017). All images were classified into eight classes (i.e. tiled roof building, concrete roof building, road, soil, shadow, tea, hazelnut and tree) using the same signatures. The classification accuracy of each classified image was determined with respect to the reference control points that were randomly distributed over the study area. The actual class of each control point was identified by examining it on the high-resolution fused images. The overall classification accuracy of each classified image was calculated based on the number of the correctly classified control points. To conduct a robust classification performance evaluation, the number of the control points should be adequate to test the whole study area. This study used the multinomial distribution approach (Congalton and Green, 1999) to estimate the minimum number of control points required to compute the overall classification accuracy. This approach estimates the minimum number of required control points (N) as;

$$\begin{aligned} N &= \frac{S}{4b^2} \\ S &= a/k \end{aligned} \quad (2)$$

where, k is the total number of classes, a is the confidence interval and b is the desired accuracy. This study considered the confidence interval as 96%. Since each classified image consisted of 8 classes, S was computed as 0.005 ($S = 0.04/8$). χ^2 distribution table revealed that the probability level of 0.005 corresponds to 7.87 in one degree of freedom, hence, N was determined as 1229.7 ($7.87/(4 \times 0.04^2)$). Considering this, 2045 control points were decided to use to compute the classification accuracy of each classified image.

6. Results and Discussion

Figure 2 shows the images produced by the fusion methods used. As seen in the figure, all methods achieved to increase the spatial detail content to some degree. On the other hand, the WSB, GS and EHL methods produced images whose colour content was similar to that of the original MS image. The PCA, BRV, HCS and HPF methods presented moderate spectral consistency and the MCV method caused significant colour distortions, which can be seen in Figure 2.

The component substitution-based image fusion methods such as the BRV, PCA, GS and MCV are known for their success in enhancing the spatial detail quality. The MCV method injects the spatial details through the multiplication of the input MS bands by the input PAN band, which ensures a sharper image but increases the magnitudes of the pixel vectors after fusion, distorting the colour characteristics. The same is true for the BRV method, which sums all input MS bands to simulate an intensity component that is used to normalize the fusion results. The BRV method causes increases in the magnitudes of the pixel vectors, but not as much as the MCV does. This is why the BRV method achieved more realistic colours than the MCV method (see Figure 2).

The PCA method applies a PCA transform to the input MS image relying on the hypothesis that the first principal component of the transformed data includes the same amount of spatial detail content as the input PAN band. The first principal component is then replaced by the input PAN band. This procedure is successful in sharpening the images most of the time. But for some input MS images, it may produce blurry images or images with pixel block effects.

This happens when the first principal component does not include a reasonable amount of total variance (i.e. spatial detail content), which was the case in this study. It should be noted that the total amount of the variance contained in the first principal content varies from image to image.

For some input images, the first principal component contains almost all of the variance information, whereas less variance information may be contained in the first principal component of another images. If the input MS and PAN images are highly correlated, then the PCA method is expected to present a good performance in both spectral and spatial manner.

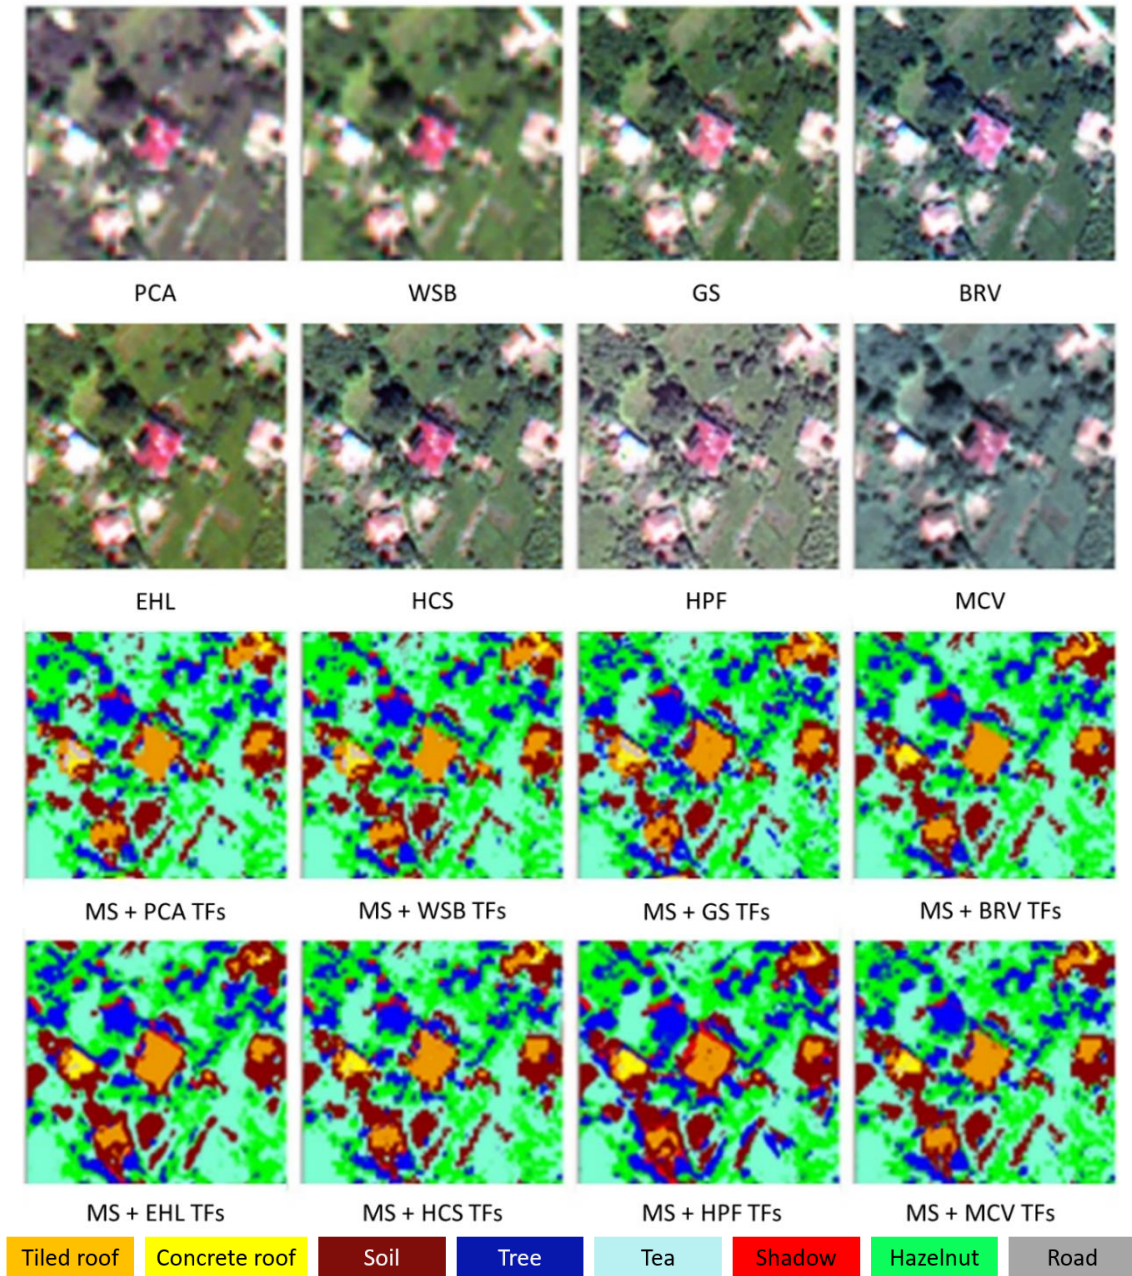


Figure 2. Classification accuracies of the original MS image combined with the image fusion-based TFs

The GS method is very similar to the PCA method. The difference between these two is that the GS method uses a lower resolution intensity image simulated from the input MS bands. The users may obtain the intensity band either by averaging the input MS bands or by linear combination of the input MS bands. It is also possible to define another lower resolution intensity image acquired from a different sensor. The success of the GS method depends on the statistical relationship between the lower resolution intensity image and input PAN band. If they have statistically similar characteristics, then the fusion result is expected to be spectrally and spatially more consistent.

This study used an intensity component obtained by averaging the input MS bands. Since the input images were acquired from the same sensor, the produced intensity component had similar statistics as the input PAN band. Also, the histogram matching applied between the intensity component and input PAN band ensured further resemblance between the statistical properties of both images. As seen in Figure 2, the GS method did not only preserved the colour features, but also injected the spatial details properly.

The EHL method applies a high-pass filter on the PAN spectrum and a low-pass filter on the intensity spectrum in the Fourier domain. This approach enabled the EHL method to better retain the colour features and enhance the spatial details of the PAN band. It is a well-known fact that, in most cases, filtering an image in the Fourier domain enables the extraction or enhancement of required features with less information loss, compared to the spatial domain. This was the case in this study. Hence, the new intensity component obtained by summing the inverse FFTs of both filtered spectrums helped transfer the spatial details without deteriorating the colour features of the input MS bands. The ERDAS IMAGINE software used to apply the EHL fusion method offers five window function for filtering in the Fourier domain; namely Ideal, Bartlett, Butterworth, Gaussian and Hanning. Our observations revealed that the Hanning filter achieved the best compromise between the colour and spatial detail quality of the fusion result. Hence this filter was used to filter the PAN and intensity spectrums in the Fourier domain. The ERDAS IMAGINE software allows the users to produce fused images with extreme colour or spatial detail quality. Since this study aimed to increase the SVM classification accuracy with the help of the Gabor texture features extracted from the fused images, both the spectral and spatial quality were important to us, therefore, we sought the best balance between the colour and spatial detail quality.

The WSB method applies DWT on the input PAN band until the spatial resolution of the input MS image is achieved. Each DWT results in four subbands (one approximation subband containing the colour information and three high frequency subbands containing the spatial content in horizontal, vertical and diagonal directions) with two times coarser spatial resolution. Since the spatial resolution of the input PAN band is four times better than that of the input MS image, two successive DWTs were applied on the input PAN band. These two DWTs caused a spatial detail loss to some degree. Another disadvantage of the DWT is that it extracts the spatial detail content in only horizontal, vertical and diagonal directions (Yilmaz et al., 2020), which led to a spatial detail loss in other directions in this study. As seen in Figure 2, the WSB method produced a blurry image despite its colour preservation success. Actually, this was expected because the multiresolution analysis based fusion methods have been proven to keep the colour content and deteriorate the spatial features (Gogineni and Chaturvedi, 2018; Serifoglu Yilmaz et al., 2019).

The HPF technique employs a high-pass filter on the input PAN image to enhance its spatial details. The ERDAS IMAGINE software used to implement this technique identifies the size and content of the high-pass filter with respect to the spatial resolution ratio (R) between the input images. Since the spatial resolution of the input PAN band was four times better than that of the input MS image, the software recommended to use a 9×9 high pass filter whose elements were set to -1 except the centre element, which was set to 80. The ERDAS IMAGINE software allows the users to define their own high-pass filters. Since, the efficiency of texture features has a strong relationship with the spatial detail quality of the image, we employed a 11×11 high pass filter on the input PAN band to further sharpen the fusion result at the expense of colour distortion, which can be observed in Figure 2. The HPF image, which is a function of R, is weighted relative to the global standard deviation of the MS bands (ERDAS IMAGINE Field Guide, 2013). The weight is calculated using the R and standard deviations of the filtered PAN band and input MS bands. This procedure enabled the crispness of the fusion result.

Table 1 shows the classification accuracies of the original MS image combined with the image fusion-based TFs. As seen in the table, all methods provided TFs that achieved to increase the classification accuracy.

Table 1. Classification accuracy of the classes

Data	Accuracy	Accuracy Increase
MS	77.6%	---
MS + PCA-extracted TFs	92.1%	18.7%
MS + WSB-extracted TFs	82.4%	6.2%
MS + GS-extracted TFs	92.6%	19.3%
MS + BRV-extracted TFs	89.0%	14.7%
MS + EHL-extracted TFs	87.8%	13.1%
MS + HCS-extracted TFs	87.6%	12.9%
MS + HPF-extracted TFs	89.4%	15.2%
MS + MCV-extracted TFs	79.4%	2.3%

As also seen in Table 1, combining the MS image with the GS- and PCA-based TFs increased the classification accuracy from 77.6% to 92.6% and from 77.6% to 92.1%, which led to an increase of 19.3% and 18.7%, respectively. The HPF and BRV were found to provide third and fourth best TFs. The TFs obtained from the WSB and MCV methods were found to lead to the smallest classification accuracy increase.

7. Conclusions

This study aimed to integrate the Gabor texture information extracted from the fused images into the SVM classifier to increase its performance. For this purpose, the PCA, WSB, GS, BRV, EHL, HCS, HPF and MCV fusion techniques were used to fuse a WorldView-2 MS image with a WorldView-2 PAN image. The first principal components of the PCA transformation of the fused images were used to extract the Gabor texture features. The extracted features were combined with the original MS image and the combined data were classified by the SVM algorithm. The results showed that all fusion techniques used yielded images that were useful to extract efficient Gabor texture features. The GS and PCA methods were found to provide the most efficient Gabor texture features, as they increased the SVM classification accuracy by 19.3% and 18.7%, respectively. On the other hand, the WSB and MCV methods yielded the texture features that led to the least classification accuracy increase. Future studies will focus on utilizing more advanced image fusion approaches to produce more efficient texture features, providing a greater classification performance.

References

- Acerbi-Junior, F. W., Clevers, J. G. P. W., & Schaepman, M. E. (2006). The assessment of multi-sensor image fusion using wavelet transforms for mapping the Brazilian Savanna. *International Journal of Applied Earth Observation and Geoinformation*, 8(4), 278-288. doi:10.1016/j.jag.2006.01.001.
- Akar, Ö. & Güngör, O. (2015). Integrating multiple texture methods and NDVI to the Random Forest classification algorithm to detect tea and hazelnut plantation areas in northeast Turkey. *International Journal of Remote Sensing*, 36(2), 442-464. doi:10.1080/01431161.2014.995276.
- Almendros-Jiménez, J. M., Domene, L., & Piedra-Fernandez, J. A. (2012). A framework for ocean satellite image classification based on ontologies. *IEEE Journal of selected topics in applied earth observations and remote sensing*, 6(2), 1048-1063. doi:10.1109/JSTARS.2012.2217479.
- Angelo, N. P., & Haertel, V. (2003). On the application of Gabor filtering in supervised image classification. *International Journal of Remote Sensing*, 24(10), 2167-2189. doi:10.1080/01431160210163146.
- Augusteijn, M. F., Clemens, L. E., & Shaw, K. A. (1995). Performance evaluation of texture measures for ground cover identification in satellite images by means of a neural network classifier. *IEEE Transactions on Geoscience and Remote Sensing*, 33(3), 616-626. doi:10.1109/36.387577.
- Baraldi, A., & Pannigiani, F. (1995). An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. *IEEE Transactions on Geoscience and Remote Sensing*, 33(2), 293-304. doi:10.1109/TGRS.1995.8746010.
- Bigdeli, M., Vakilian, M., & Rahimpour, E. (2012). Transformer winding faults classification based on transfer function analysis by support vector machine. *IET Electric Power Applications*, 6(5), 268-276. doi:10.1049/iet-epa.2011.0232.
- Butusov, O. B. (2003). Textural classification of forest types from Landsat 7 imagery. *Mapping Sciences and Remote Sensing*, 40(2), 91-104. doi:10.2747/0749-3878.40.2.91.
- Chavez, A., & Kwarteng, P. (1989). Extracting spectral contrast in Landsat Thematic Mapper image data using selective principal component analysis. *Photogrammetric Engineering and Remote Sensing*, 55, 339-348.
- Chen, K. S., Yen, S. K., & Tsay, D. W. (1997). Neural classification of SPOT imagery through integration of intensity and fractal information. *International Journal of Remote Sensing*, 18(4), 763-783. doi:10.1080/014311697218746.
- Congalton, R. G., & Green, K. (1999). *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. Boca Raton, FL: Lewis.
- Crippen, R. E. (1989). A simple spatial filtering routine for the cosmetic removal of scan-line noise from Landsat TM P-tape imagery. *Photogrammetric Engineering & Remote Sensing*, 55, 327-331.
- Damodaran, B. B., & Nidamanuri, R. R. (2014). Dynamic linear classifier system for hyperspectral image classification for land cover mapping. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6), 2080-2093. doi:10.1109/JSTARS.2013.2294857.
- Devi, T. A. M., & Rekha, N. (2013). Hyperspectral Image Classification Using Spatial and Spectral Features. *International Journal of Scientific & Engineering Research*, 4(7), 1843-1847.

- Du, Y., Vachon, P. W., & Van der Sanden, J. J. (2003). Satellite image fusion with multiscale wavelet analysis for marine applications: preserving spatial information and minimizing artifacts (PSIMA). *Canadian Journal of Remote Sensing*, 29(1), 14-23. doi:10.5589/m02-079.
- Dube, T., Gumindoga, W., & Chawira, M. (2014). Detection of land cover changes around Lake Mutirikwi, Zimbabwe, based on traditional remote sensing image classification techniques. *African Journal of Aquatic Science*, 39(1), 89-95. doi:10.2989/16085914.2013.870068.
- Eddy, P., Smith, A., Hill, B., Peddle, D., Coburn, C., & Blackshaw, R. (2006, July). Comparison of neural network and maximum likelihood high resolution image classification for weed detection in crops: Applications in precision agriculture. In *2006 IEEE International Symposium on Geoscience and Remote Sensing* (pp. 116-119). IEEE. doi:10.1109/IGARSS.2006.35.
- Ehlers, M. (2004, October). Spectral characteristics preserving image fusion based on Fourier domain filtering. In *Remote sensing for environmental monitoring, GIS applications, and geology IV* (Vol. 5574, pp. 1-13). International Society for Optics and Photonics. doi: 10.1117/12.565160.
- ERDAS IMAGINE Field Guide 2013, Leica Geosystems, Atlanta, GA: ERDAS.
- Gitas, I. Z., Mitri, G. H., & Ventura, G. (2004). Object-based image classification for burned area mapping of Creus Cape, Spain, using NOAA-AVHRR imagery. *Remote Sensing of Environment*, 92(3), 409-413. doi: 10.1016/j.rse.2004.06.006.
- Gogineni, R., & Chaturvedi, A. (2018). Sparsity inspired pan-sharpening technique using multi-scale learned dictionary. *ISPRS journal of photogrammetry and remote sensing*, 146, 360-372. doi:10.1016/j.isprsjprs.2018.10.009.
- Hallada, W. A., & Cox, S. (1983, May). Image sharpening for mixed spatial and spectral resolution satellite systems. *Proceedings of the 17th International Symposium on Remote Sensing of Environment*, pp. 1023-1032, Ann Arbor, MI, USA.
- Haralick, R. M., Shanmugam, K., & Dinstein, I. H. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), 610-621. doi: 10.1109/TSMC.1973.4309314.
- Hermosilla, T., Almonacid, J., Fernández-Sarría, A., Ruiz, L. A., & Recio, J. A. (2010). Combining features extracted from imagery and lidar data for object-oriented classification of forest areas. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38, 194-200.
- Hill, P. R., Canagarajah, C. N., & Bull, D. R. (2002, September). Image Fusion Using Complex Wavelets. In *BMVC* (pp. 1-10).
- Huang, C., Davis, L. S., & Townshend, J. R. G. (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4), 725-749. doi: 10.1080/01431160110040323.
- Huang, Z. C., Chan, P. P., Ng, W. W., & Yeung, D. S. (2010, July). Content-based image retrieval using color moment and Gabor texture feature. In *2010 International Conference on Machine Learning and Cybernetics* (Vol. 2, pp. 719-724). IEEE, Qingdao, China. doi: 10.1109/ICMLC.2010.5580566.
- Jin, H., Li, P., Cheng, T., & Song, B. (2012). Land cover classification using CHRIS/PROBA images and multi-temporal texture. *International Journal of Remote Sensing*, 33(1), 101-119. doi: 10.1080/01431161.2011.584077.
- Johnson, B. A., Tateishi, R., & Hoan, N. T. (2013). A hybrid pansharpening approach and multiscale object-based image analysis for mapping diseased pine and oak trees. *International Journal of Remote Sensing*, 34(20), 6969-6982. doi:10.1080/01431161.2013.810825.
- Johnsson, K. (1994). Segment-based land-use classification from SPOT satellite data. *Photogrammetric Engineering and Remote Sensing*, 60(1), 47-54.
- Kedzierski, M., Wilinska, M., Wierzbicki, D., Fryskowska, A., & Delis, P. (2014, May). Image data fusion for flood plain mapping. In *Proceedings of the 9th International Conference on Environmental Engineering, Vilnius, Lithuania* (pp. 22-23).
- Klonus, S., & Ehlers, M. (2007). Image fusion using the Ehlers spectral characteristics preservation algorithm. *GIScience & Remote Sensing*, 44(2), 93-116. doi: 10.2747/1548-1603.44.2.93.
- Kollár, S., Vekerdy, Z., & Márkus, B. (2013). Aerial image classification for the mapping of riparian vegetation habitats. *Acta Silvatica et Lignaria Hungarica*, 9(1), 119-133.
- Kurosu, T., Yokoyama, S., Fujita, M., & Chiba, K. (2001). Land use classification with textural analysis and the aggregation technique using multi-temporal JERS-1 L-band SAR images. *International Journal of Remote Sensing*, 22(4), 595-613. doi: 10.1080/01431160050505874.
- Laben, C. A., & Brower, B. V. (2000). Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening. US Patent No. 6,011,875, filed 29 April 1998 and issued 4 January 2000 to the Eastman Kodak Company.
- Lauer, M., & Aswani, S. (2008). Integrating indigenous ecological knowledge and multi-spectral image classification for marine habitat mapping in Oceania. *Ocean & Coastal Management*, 51(6), 495-504. doi: 10.1016/j.ocecoaman.2008.04.006.

- Lloyd, C. D., Berberoglu, S., Curran, P. J., & Atkinson, P. M. (2004). A comparison of texture measures for the per-field classification of Mediterranean land cover. *International Journal of Remote Sensing*, 25(19), 3943-3965. doi: 10.1080/0143116042000192321.
- Low, H. K., Chuah, H. T., & Ewe, H. T. (1999). A Neural Network Landuse Classifier for SAR Images using Textural and Fractal Information. *Geocarto International*, 14(1), 66-73. doi: 10.1080/10106049908542096.
- Mathew, A. R., & Anto, P. B. (2017). Tumor detection and classification of MRI brain image using wavelet transform and SVM. In *IEEE 2017 International Conference on Signal Processing and Communication (ICSPC)*, pp. 75-78, Coimbatore, India. doi: 10.1109/CSPC.2017.8305810.
- Mathur, A., & Foody, G. M. (2008). Multiclass and binary SVM classification: Implications for training and classification users. *IEEE Geoscience and Remote Sensing Letters*, 5(2), 241-245. doi: 10.1109/LGRS.2008.915597.
- Melgani, F., & Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8), 1778-1790. doi: 10.1109/TGRS.2004.831865.
- Milgram, J., Cheriet, M., & Sabourin, R. (2006). "One against one" or "one against all": Which one is better for handwriting recognition with SVMs? *10th International Workshop on Frontiers in Handwriting Recognition*, Université de Rennes 1, La Baule, France.
- Nanni, L., Brahnam, S., Ghidoni, S., Menegatti, E., & Barrier, T. (2013). A comparison of methods for extracting information from the co-occurrence matrix for subcellular classification. *Expert Systems with Applications*, 40(18), 7457-7467. doi:10.1016/j.eswa.2013.07.047.
- Nyoungui, A. N., Tonye, E., & Akono, A. (2002). Evaluation of speckle filtering and texture analysis methods for land cover classification from SAR images. *International Journal of Remote Sensing*, 23(9), 1895-1925. doi:10.1080/01431160110036157.
- Omkar, S. N., Kumar, M. M., Mudigere, D., & Muley, D. (2007). Urban satellite image classification using biologically inspired techniques. In *IEEE International Symposium on Industrial Electronics* (pp. 1767-1772). doi:10.1109/ISIE.2007.4374873.
- Özdarıcı Ok, A., Akyürek, Z. (2013). Çok Tarihli Görüntü Sınıflandırmada Destek Vektör Makinaları ve Bulanık Mantık Yöntemi Kullanan Bölüt Tabanlı Bir Yaklaşım, *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VII. Teknik Sempozyumu (TUFUAB'2013)*, pp. 1-6, Trabzon, Türkiye.
- Padwick, C., Deskevich, M., Pacifici, F., & Smallwood, S. (2010, April). WorldView-2 pan-sharpening. In *Proceedings of the ASPRS 2010 Annual Conference*, San Diego, CA, USA, (Vol. 2630, pp. 1-14).
- Pathak, V., & Dikshit, O. (2010). A new approach for finding an appropriate combination of texture parameters for classification. *Geocarto International*, 25(4), 295-313. doi: 10.1080/10106040903576195.
- Peli, T., Peli, E., Ellis, K. K., & Stahl, R. (1999, March). Multispectral image fusion for visual display. In *Sensor Fusion: Architectures, Algorithms, and Applications III* (Vol. 3719, pp. 359-368). International Society for Optics and Photonics.
- Petkov, N., & Wieling, M. (2008). Gabor filter for image processing and computer vision. *On line*, <http://matlabserver.cs.rug.nl/edgedetectionweb/index.html>. Accessed on 18 February 2020.
- Podest, E., & Saatchi, S. (2002). Application of multiscale texture in classifying JERS-1 radar data over tropical vegetation. *International Journal of Remote Sensing*, 23(7), 1487-1506. doi: 10.1080/01431160110093000.
- Pohl, C. (1996). Geometric aspects of multisensor image fusion for topographic map updating in the humid tropics, PhD thesis, University of Twente.
- Poulain, V., Inglada, J., Spigai, M., Tournier, J. Y., & Marthon, P. (2011). High-Resolution Optical and SAR Image Fusion for Building Database Updating. *IEEE Transactions on Geoscience and Remote Sensing*, 49(8), 2900-2910. doi:10.1109/TGRS.2011.2113351.
- Ran, Q., Li, W., Du, Q., & Yang, C. (2015). Hyperspectral image classification for mapping agricultural tillage practices. *Journal of Applied Remote Sensing*, 9(1), 097298. doi:10.1117/1.JRS.9.097298.
- Rao, P. N., Sai, M. S., Sreenivas, K., Rao, M. K., Rao, B. R. M., Dwivedi, R. S., & Venkataratnam, L. (2002). Textural analysis of IRS-1D panchromatic data for land cover classification. *International Journal of Remote Sensing*, 23(17), 3327-3345. doi:10.1080/01431160110104665.
- Richetti, E. (2000). Multispectral satellite image and ancillary data integration for geological classification. *Photogrammetric Engineering and Remote Sensing*, 66(4), 429-435.
- Sambodo, K. A., Murni, A., & Kartasmita, M. (2010). Classification of polarimetric-SAR data with neural network using combined features extracted from scattering models and texture analysis. *International Journal of Remote Sensing and Earth Sciences*, 4(1), 1-17. doi:10.30536/j.ijreses.2007.v4.a1212.
- Schowengerdt, R. A. (1980). Reconstruction of multispatial, multispectral image data using spatial frequency content. *Photogrammetric Engineering and Remote Sensing*, 46(10), 1325-1334.

- Serifoglu Yilmaz, C., Yilmaz, V., Gungor, O., & Shan, J. (2019). Metaheuristic pansharpening based on symbiotic organisms search optimization. *ISPRS Journal of Photogrammetry and Remote Sensing*, 158, 167-187. doi:10.1016/j.isprsjprs.2019.10.014.
- Shaker, A., Yan, W. Y., & El-Ashmawy, N. (2012). Panchromatic satellite image classification for flood hazard assessment. *Journal of Applied Research and Technology*, 10(6), 902-911.
- Tsagaris, V., & Anastassopoulos, V. (2005). Multispectral image fusion for improved RGB representation based on perceptual attributes. *International Journal of Remote Sensing*, 26(15), 3241-3254. doi:10.1080/01431160500127609.
- Vapnik, V. (1995). *The Nature of Statistical Learning Theory*. New York, Springer-Verlag.
- Vapnik, V. (1998). *Statistical Learning Theory*. New York, Springer-John Wiley.
- Yang, B., Kim, M., & Madden, M. (2012). Assessing optimal image fusion methods for very high spatial resolution satellite images to support coastal monitoring. *GIScience & Remote Sensing*, 49(5), 687-710. doi:10.2747/1548-1603.49.5.687.
- Yang, C., Everitt, J. H., & Murden, D. (2011). Evaluating high resolution SPOT 5 satellite imagery for crop identification. *Computers and Electronics in Agriculture*, 75(2), 347-354. doi:10.1016/j.compag.2010.12.012.
- Yang, J., Liu, L., Jiang, T., & Fan, Y. (2003). A modified Gabor filter design method for fingerprint image enhancement. *Pattern Recognition Letters*, 24(12), 1805-1817. doi:10.1016/S0167-8655(03)00005-9.
- Yang, M. D., Huang, K. S., Kuo, Y. H., Tsai, H., & Lin, L. M. (2017). Spatial and spectral hybrid image classification for rice lodging assessment through UAV imagery. *Remote Sensing*, 9(6), 583. doi:10.3390/rs9060583.
- Yilmaz, V. (2019). Kaynaştırılmış Görüntülerden Elde Edilen Doku Özellikleri ile DVM Sınıflandırma Performansının İyileştirilmesi. *Geomatik*, 4(3), 190-200. doi: 10.29128/geomatik.507613.
- Yilmaz, V., & Gungor, O. (2016). Determining the optimum image fusion method for better interpretation of the surface of the Earth. *Norsk Geografisk Tidsskrift-Norwegian Journal of Geography*, 70(2), 69-81. doi:10.1080/00291951.2015.1126761.
- Yilmaz, V., Konakoglu, B., Serifoglu, C., Gungor, O., & Gökalp, E. (2018). Image classification-based ground filtering of point clouds extracted from UAV-based aerial photos. *Geocarto international*, 33(3), 310-320. doi:10.1080/10106049.2016.1250825.
- Yilmaz, V., Serifoglu Yilmaz, C., Güngör, O., & Shan, J. (2020). A genetic algorithm solution to the gram-schmidt image fusion. *International Journal of Remote Sensing*, 41(4), 1458-1485. doi:10.1080/01431161.2019.1667553.
- Zabala, A., Pons, X., Díaz-Delgado, R., García, F., Aulí-Llinàs, F., & Serra-Sagristà, J. (2006). Effects of JPEG and JPEG2000 lossy compression on remote sensing image classification for mapping crops and forest areas. In *IEEE International Symposium on Geoscience and Remote Sensing* (pp. 790-793). doi:10.1109/IGARSS.2006.203.
- Zeng, Y., Zhang, J., Van Genderen, J. L., & Zhang, Y. (2010). Image fusion for land cover change detection. *International Journal of Image and Data Fusion*, 1(2), 193-215. doi:10.1080/19479831003802832.
- Zhang, C., Franklin, S. E., & Wulder, M. A. (2004). Geostatistical and texture analysis of airborne-acquired images used in forest classification. *International Journal of Remote Sensing*, 25(4), 859-865. doi:10.1080/01431160310001618059.
- Zhang, D., Wong, A., Indrawan, M., & Lu, G. (2000). Content-based image retrieval using Gabor texture features. *IEEE Transactions PAMI*, 13-15.

Mimari Dökümantasyonda Yersel Lazer Tarama Teknolojisi Kullanımı: Tarihi Sismoloji Binası Örneği

The Use of Terrestrial Laser Scanning Technology in Architectural Documentation: A case study of Historical Seismology Building

Aslı Sabuncu^{1*}, Haluk Özener¹

¹Bogaziçi Üniversitesi, Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü, Jeodezi ABD, 34684, Üsküdar, İstanbul.

ARAŞTIRMA MAKALESİ

*Sorumlu yazar:

Aslı Sabuncu
asli.turgutalp@boun.edu.tr

doi:

Yayın süreci

Geliş tarihi : 29.01.2020
Kabul tarihi : 20.03.2020
Basım tarihi: 31.03.2020

Özet

Yersel lazer tarama teknolojisi, geomatik mühendisliği başta olmak üzere endüstriyel tasarım çalışmaları, madencilik ve altyapı çalışmaları, şehirlerin modellenmesi ve dizaynı, mimari restorasyon ve belgeleme çalışmaları vb. birçok farklı çalışmada sıklıkla kullanılan önemli bir teknolojik gelişmedir. Gerçekleştirilmiş bu çalışmada Boğaziçi Üniversitesi Kandilli kampüsü içinde yer alan Bilim Tarihi Koleksiyonu (Tarihi Sismoloji Binası) binasının yersel lazer tarama aleti kullanılarak 3 boyutlu olarak modelinin çıkarılması ve mimari olarak dökümantasyonunun yapılması amaçlanmıştır. Bu amaç doğrultusunda çalışma öncesi bina çevresinde istikşaf yapıp yersel lazer tarama aletinin ve istasyonların konumları nokta bulutlarının birleştirilmesindeki hatayı en aza indirmek için çalışma bölgesinde homojen olarak dağılmıştır. Tarihi Sismoloji binasının lazer tarama cihazı ile toplamda 17 istasyon noktasına kurularak ölçümü yapılmış ve elde edilen nokta bulutlarından binanın 3 boyutlu modeli oluşturulmuştur. Taramalar sonucu istasyonların dengelenmesi gerçekleştirilmiş ve yatayda 3.7 mm., düşeyde 1.5 mm. ortalama uzunlukta ise 4.1 mm. hata bulunmuş ve hata sınırları içinde kaldığı görülmüştür. Bu çalışma üniversite için başlangıç olup, üniversitenin Kandilli Kampüsü başta olmak üzere diğer kampüsleri içerisinde yer alan farklı kültür varlıklarının belgelenmesi çalışmalarında yersel tarama teknolojisine başvurulması amaçlanmaktadır.

Anahtar Kelimeler: Yersel lazer tarama, Mimari dokümantasyon, Nokta bulutu, Faro, Tarihi sismoloji binası

Abstract

Terrestrial laser scanning, one of the main subjects of geomatics engineering, is an important technological development that is frequently used in many different studies including industrial design studies, mining and infrastructure studies, modeling and design of cities, architectural restoration and documentation studies etc. In this study, it is aimed to modelling and documenting the architectural Science History Collection (Historical Seismology Building) building located in the Kandilli Campus of Boğaziçi University by using a terrestrial laser scanning tool. For this purpose, before the study, a reconnaissance survey was performed around the building and the positions of the terrestrial laser scanner and the stations were homogeneously distributed in the study area to minimize the error that may arise when combining point clouds. The Historical Seismology Building was measured by terrestrial laser scanning device from 17 stations and a 3D model of the building was produced from the obtained point clouds. All scanned stations of the point clouds were adjusted and errors of 3.7 mm, 1.5 mm and 4.1 mm were found in horizontal direction, vertical direction and average length, respectively. This error was found to be within the error limits. This study is just a start for the university, and it is aimed to apply terrestrial technology in the studies of documenting different cultural assets within the campuses of the university, especially Kandilli Campus.

Keywords: Terrestrial laser scanning, Architectural documentation, Point cloud, Faro, Historical seismological building

1. Giriş

Teknolojide son yıllarda yaşanan hızlı gelişmeler, jeodezik ölçme aletlerinde de etkisini göstermektedir. Lazer tarama teknolojisi, dünyada birçok çalışma grubundaki bilim insanları tarafından çalışmalarda verimliliği arttırmak, zaman ve maliyet tasarrufu elde etmek için özellikle son yıllarda sıklıkla başvurdukları yöntemlerin başında gelmektedir. Lazer teknolojisindeki araştırmalar 1960'lı yılların başına kadar uzanmakta ve bu konuda yapılan bilimsel çalışmalar teknolojik gelişmeler ile birlikte çeşitlilik kazanmaktadır. Gerçekleştirilen bilimsel araştırmaların sonucu olarak ortaya çıkmış olan lazer tarama teknolojisinin ölçüm aracı olarak kullanılması ise 1990'lı yılların ortalarına rastlamaktadır.

Yersel lazer tarama teknolojisi ile ilgili literatür incelendiğinde çok farklı çalışma alanlarında kullanıldığı bilgisine rastlanmaktadır. Günümüzde, lazer tarama teknolojisi geomatik mühendisliği başta olmak üzere, endüstriyel tasarım çalışmaları, madencilik ve altyapı çalışmaları, şehirlerin modellenmesi ve dizaynı, mimari restorasyon ve belgeleme çalışmaları, arkeolojik çalışmalar, olay yeri inceleme, sanal gerçeklik uygulamaları, imalat kontrolü, tersine mühendislik, deformasyon çalışmaları, sinema endüstrisi vb. bir çok çalışmada sıklıkla kullanılan önemli bir teknolojik gelişmedir. Mimari belgeleme ve dökümantasyon işlemleri kültürel mirasın korunması ve sürdürülebilmesi için özellikle mimarların sıklıkla başvurdukları yöntemlerin başında gelmektedir. Kültürel mirasın belgelenmesinde farklı yöntemler kullanılmaktadır.


Kültür varlıklarının korunması ve gelecek nesillere ulaştırılması için yapılmış çalışmalardan bir tanesi de Duran (2003) tarafından gerçekleştirilmiştir. Tamamlanan doktora tez çalışmasında tarihi niteliği bulunan eserlerin gelecek kuşaklara aktarılması ve özgün hallerini içeren dökümantasyonunun yapılması ve oluşmuş ve oluşacak hasarları tespit edilebilmesi için fotogrametrik yöntemler ile çalışmak oldukça önemli olduğu belirtilmiştir. Grussenmeyer vd. (2008) tamamlanmış oldukları çalışmada takeomaetri, klasik fotogrametri ve yersel lazer tarama teknolojilerini ele alarak bu yöntemlerden kültürel mirasın dökümantasyonu için nasıl veri toplandığı konusuna değinmişlerdir (Grussenmeyer vd., 2008). UNESCO Dünya mirası listesinde yer alan Karabük ilinin Safranbolu tarihi ilçesi sınırları dahilinde yer alan binalardan farklı özellikte binalar seçilerek önce yersel fotogrametri yöntemi ile röleleri hazırlanmış daha sonra ise 3 boyutlu modelleri oluşturulmuştur (Arca vd., 2011). Konya Sırçalı Medrese Taç kapısı ile Konya Karatay Medresesi Taç kapısının yersel fotogrametri kullanılarak mimari olarak dökümantasyonu kolaylıkla tamamlanmış olup çalışmada bu yöntemin kullanılabilirliği araştırılmıştır (Korumaz vd., 2011). Sille Aya-i Eleni kilisesi yersel fotogrametri yöntemi kullanılarak mimari dökümantasyonu yapılmış ve 3 Boyutlu modeli çıkartılmıştır. Kilisenin dış cephelerinin çiziminde Autocad programından yararlanılmıştır (Böge, 2013). Kuçak'ın tamamlanmış olduğu yüksek lisans çalışmasında Karlsruhe Teknoloji Enstitüsü Süd kampüsü sınırları dahilinde yer alan Chinese Tea House yapısının yersel lazer tarama yöntemi ile elde edilen nokta bulutlarından 3 boyutlu modeli yapılarak sayısal hali mimari dökümantasyonda kullanılmak üzere hazırlanmıştır (Kuçak, 2013). Katar İslami ve Arkeoloji Mirası projesi kapsamında Hafen City üniversitesi tarafından Al Zubarah kalesinin de yersel fotogrametri kullanılarak belgelenmesi ve farklı yazılımlar kullanılarak değerlendirilmesi çalışması başarı ile gerçekleştirilmiştir (Kersten vd., 2015). Kıvanç (2019), yapmış olduğu yüksek lisans tez çalışmasında kültürel mirasın belgelenmesi çalışmasında klasik fotogrametrik yöntem ve yersel lazer tarama teknolojisi ile karşılaştırma yapmıştır. Her iki yöntemin birbirine göre avantajları ve dezavantajları olduğunu ve birbirini tamamlayan teknikler olduğunu belirtmiştir (Kıvanç, 2019). Lazer tarama tekniği ile Glasgow'un ünlü King's Tiyatrosunun ile Birmingham yakınlarındaki Holly Lodge Lisesi'nin tüm ölçümleri nokta bulutlarından yararlanılarak tamamlandı. Klasik fotogrametri tekniği ile bu iki yapının tüm ölçümleri günlerce sürecek iken yersel lazer tarama tekniği tüm ölçümler 3 günde tamamlandı ve zaman ve maliyet tasarrufu sağlandı (FARO Bilgi Bankası, 2019a). Aksaray ili sınırları dahilinde yer alan Kızıl Kilisenin sayısal fotogrametri tekniği ile 3B modelinin oluşturulmasında nokta bulutlarından yararlanılmıştır. Bu çalışma türünün kültürel mirasın dökümantasyonu çalışmalarında birçok avantajı olduğu belirtilmiştir (Ulvi vd., 2020). Klasik ölçme yöntemleri ile yersel lazer tarama teknolojisinin çıktıları karşılaştırıldığında, süreç, performans, doğruluk ve maliyet analizleri açısından lazer tarama yönteminin daha avantajlı olduğu görülmektedir.

Gerçekleştirilen çalışmanın amacı, üniversitenin birden fazla kampüsü ve bu kampüslerin içerisinde yer alan tarihi nitelikte olan binaların sırası ile yersel lazer tarama aleti ile taranıp 3B dijital verisinin alınıp envanterlerinin oluşturulmasıdır. Bu araştırmanın konusu ise, tarihi sismoloji binasının bu çalışma kapsamında yersel lazer tarama aleti ile taranıp 3B dijital verisini elde etmek ve mimari olarak envanterinin oluşturulmasını sağlamaktır. Böylelikle, Boğaziçi Üniversitesi Kandilli Kampüsü içerisinde yer alan Tarihi Sismoloji Binasına ait yapısal ve dijital verilerin literatürdeki bilinmeyenlerini tamamlayarak alanına katkı sağlaması da amaçlanmıştır.

2. Çalışma Bölgesi

Gerçekleştirilen çalışma için İstanbul ili sınırları içinde yer alan Boğaziçi Üniversitesi Kandilli Kampüsü seçilmiştir. Kandilli Kampüsü İstanbul ilinin Anadolu yakasında yer almaktadır (Şekil 1). Kampüsün tarihçesi incelendiğinde, bilimsel çalışmalarına Anadolu yakası İcadiye tepesinde 1911 yılında başladığı görülmektedir.

Kampüs içerisinde birçok tarihi bina bulunmaktadır. Bu tarihi binalar içerisinde Bilim Tarihi Koleksiyonu binası (Tarihi Sismoloji Binası) yersel lazer tarama uygulaması için seçilmiştir. Bilim tarihi koleksiyonu binasının inşaatına 1930 yılında başlanmış ve 1934 yılında tamamlanmıştır. Geçmişte sismoloji binası olarak kullanılmak üzere tasarlanmış olan kagir bina 2 katlı olup iki bölümden oluşmaktadır. Birinci katın ön tarafı büro bölümü olup alt katta 3 üst katta 5 oda olmak üzere 8 odalıdır. Binanın ikinci bölümü ise sismografların bulunduğu Kav bölümü olup büyük bir salon ve 4 odadan oluşmaktadır (Boğaziçi Üniversitesi, 2019) (Şekil 2). Tarihi sismoloji binası 2006 yılında yapılan restorasyon sonucu Bilim Tarihi koleksiyonunun sergilendiği binaya dönüştürülmüştür.



Şekil 1. Çalışma bölgesi (Üsküdar/İstanbul)



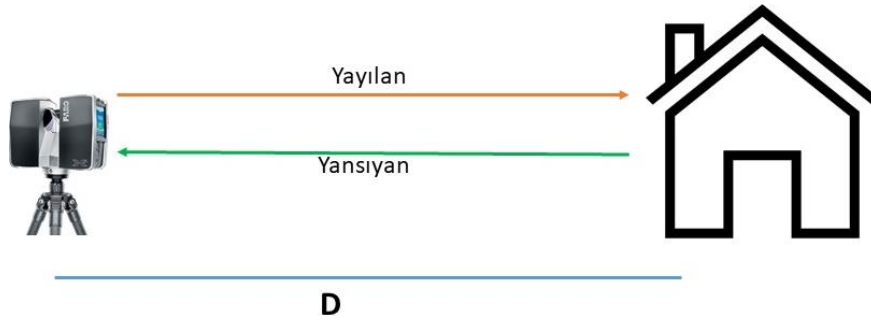
Şekil 2. Bilim tarihi koleksiyonu - tarihi sismoloji binası

3. Çalışma Prensipleri

Nesnelerin, yapıların ve alanların doğrudan ve temas olmaksızın hassas ve otomatik olarak üç boyutlu olarak tüm detaylarını içererek koordinatlarının mesafe ölçümü ile hesaplanması işlemi yersel lazer tarama teknolojisi olarak adlandırılmaktadır. Yersel lazer tarama teknolojisi özellikle mühendislik işlerinde kullanılmasının yanı sıra mimari olarak da kültürel mirasın kayıt altına alınması ve dökümantasyonunda son yıllarda sıklıkla başvurulan yöntemlerden biridir. Yersel lazer tarama teknolojisinde ölçme yöntemleri temelde 3 farklı şekildedir. Bu yöntemler uçuş zamanlı, faz karşılaştırma ve triangulasyon yöntemidir. Kültür varlıklarının belgelenmesi çalışmalarında özellikle müze vb. yerlerde yer alan küçük heykellerin, objelerin taranması sırasında yakın mesafe yersel lazer tarayıcılar kullanılarak üçgenleme metodu ile 3 boyutlu modelleme yapılmaktadır.

Tarihi binalar, arkeolojik alanlar ve büyük alanların mimari olarak dökümantasyonunun yapılması ve belgelenmesi işlemleri için ise uzun mesafeli yersel lazer tarama aletleri kullanılmaktadır. Uzun mesafeli tarayıcıların çalışma prensibi faz karşılaştırma metodu olup lazer ışını gidiş-geliş zamanı ile işlem yapan tarayıcılara başvurulmaktadır.

Bu çalışmada kullanılan yersel lazer tarama aleti olan FARO Focus 350S'nin çalışma prensibi ise faz karşılaştırma yöntemidir. Faz karşılaştırma yönteminde, tarama aleti ile nesne arasındaki uzunluk, yayılan ve yansıyan dalgalar arasındaki faz farkından hesaplanmaktadır (Şekil 3). Faz karşılaştırma yönteminin matematiksel formülü Formül 1'de verilmiştir. Bu formüle göre, D lazer tarayıcı ve nesne arasındaki mesafe olup, c ışık hızı, θ faz farkı, f ise frekansı belirtmektedir. Tarihi Sismoloji binasının taranması sırasında FARO Focus 350 S yersel lazer tarayıcı kullanılmıştır. FARO Focus 350 S, büyüklüğü, kompakt şekli ve genişletilmiş tarama menzili nedeniyle dış mekan uygulamaları için tasarlanmıştır (FARO Bilgi Bankası, 2019b). Faro Focus 350 S normal şartlar altında 25 metreye kadar 1 mm. doğruluğa sahip olup 0,6-330 m. arası veri alabilmektedir. Ayrıca tarayıcı, düşeyde 300° yatayda 360° dönüp veri alabilmektedir. Cihaz 1 saniyede 976000 nokta alabilirken bir taramada 198 adet fotoğraf çekebilmektedir. Uygulamada kullanılan yersel lazer tarama aletinin tüm teknik özellikleri tablo 1'de detaylı olarak verilmiştir (Şekil 4).




Şekil 3. Faz karşılaştırma yönteminin gösterimi

$$D = \frac{c \cdot \theta}{4\pi f} \quad (1)$$

Tablo 1. FARO Focus 350 Yersel lazer tarama aletinin teknik özellikleri

Tipi/Yöntem	Faz karşılaştırma
Pil Ömrü	4.5 saat
Ağırlık	5.2 kg
Boyut	240×240×100 mm
Menzil	0.6-330 m iç ve dış alan
Ölçme Hızı	122000/244000/488000/976000 nokta/saniye
Görüş Alanı	Düşey 300°/ Yatay 360°
Hata Sınırı	± 1 mm 10 m ve 25 m mesafede.
Sıcaklık	5-40° C sıcaklıkta en iyi çalışma performansı
Nem	Maksimum % 90

Yersel lazer tarama işlemi sırasında belirlenmiş istasyonların üstüne konulmak üzere hedefler kullanılmaktadır. Uygulama sırasında kullanılacak hedeflerin özellikleri, tarama yapılacak yere göre konumları ve geometrik konfigürasyonları önem arz etmekte olup farklı tasarım ve tipte hedefler bulunmaktadır (Gümüş, 2014). Bu referans hedefler küre, kağıt veya prizma şeklinde olabilmektedir. Uygulamada küre şeklinde referans hedefler kullanılmıştır (Şekil 4).

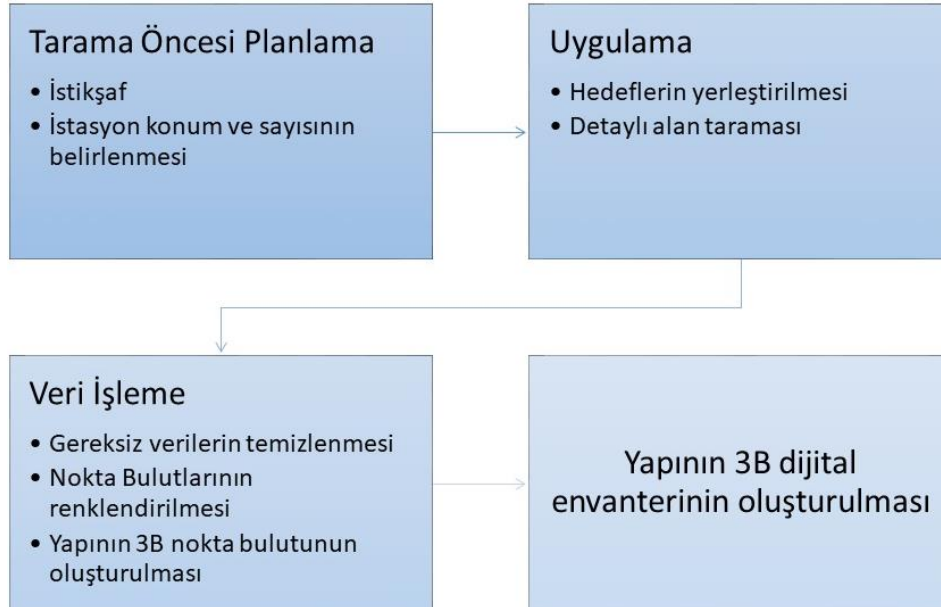


Şekil 4. Uygulamada kullanılan a) Faro focus 350S lazer tarayıcı b) Hedef referans küreler c) Arazide ölçümler sırasında referans hedef olan kürelerin konumları d) Referans hedef kürelerin planimetrik gösterimi

Yersel lazer tarama aletleri, taranacak nesneyi veya yapıyı düşey ve yatay yönde taramaktadır. Bu tarama sırasında her bir tarama için, tarayıcıdan taranan hedefe olan eğik mesafe ve bu doğrultunun aletin yatay ve düşey eksenleri ile yapmış olduğu açılar ölçülmektedir. Bu ölçümlerin dışında lazer ışınının taranan objeden yansıma şiddeti de tarama aletine kaydedilmektedir (Altuntaş, 2017). Bu tarama şekli ile nokta bulutları oluşmaktadır.

4. Uygulama

Tarihi sismoloji binasının yersel lazer tarama aleti ile mimari olarak belgelenmesi çalışması 4 aşamada gerçekleştirilmiştir. İşlem adımlarını gösteren iş akışı Şekil 5'te verilmiştir.



Şekil 5. Mimari dokümantasyonda yersel lazer tarama iş akışı

Tarama işlemine başlamadan önce yapı etrafında istikşaf çalışması yapılmış ve istasyonlar ile lazer tarayıcının optimum olarak konumları belirlenmiştir. Bu işlemde hatanın en aza indirilmesi için referans küreler çalışma alanına homojen bir şekilde dağılmış olmasına dikkat edilmiştir.

Çalışma alanında taranacak objelerin, yapıların veya alanların konumlarından ve çevresel etkilerden dolayı yersel lazer tarama aletini kurmakta zorluklar ve kısıtlamalar olabilmektedir. Bu sorunların ortadan kaldırılması için yapının çevresine tesis edilecek istasyonların homojen olarak kurulması gerekmektedir.

Çalışmada ölçümü yapılan tarihi sismoloji binasının 3 cephesinin ölçümü için herhangi bir sorunla karşılaşılmazken arka cephenin ölçümünde kısıtlamalar ortaya çıkmıştır. Binanın ön, sağ ve sol cepheleri açık, geniş olup herhangi bir kısıtlayıcı nesne, yapı bulunmamaktadır ancak binanın arka cephesi depo bölümü ile birleşik olarak inşaa edildiğinden ölçümleri yapabilmek için depo bölümünün çatısına alet ve referans hedefler kurularak tarama işlemi gerçekleştirilmiştir. Şekil 6'ta çatıya kurulum yapıldıktan sonra elde edilen nokta bulutu görülmektedir.



Şekil 6. Nokta bulutlarından üretilmiş binanın kısıtlayıcı arka cephesi

17 adet istasyon kurulumu ile tamamlanmış olan tarama işlemi sırasında 276,512,777 adet nokta ölçülmüş olup bu noktalardan birbirlerinden bağımsız nokta bulutları elde edilmiştir. 17 adet istasyon kurulması ve tarama işlemi ardışık lazer taramasıdır ve bu tür lazer taramaları bindirmeli olup bindirme oranı % 30'tur (Altuntaş, 2017). Her bir bağımsız nokta bulutunun birleştirilmesi için minimum 3 adet referans kürenin ortak olması şartı ile FARO Scene yazılımda önce manuel olarak işaretlenen ortak hedefler ile iki bağımsız nokta bulutu birleştirilmiştir. İkinci adımda ise hassas dengeleme metodu ile Scene yazılımı otomatik olarak referans kürelerini tespit edip nokta bulutlarını birleştirmiştir. Daha sonra ise 17 adet bağımsız taramanın birleştirilmesi işlemi yapılmıştır. Böylelikle, bütün istasyonlardaki bağımsız nokta bulutları birbiri ile ortak referans küreleri ile jeoreferanslanarak tek bir nokta bulutu verisi elde edilmiştir (Şekil 7).

Tarihi eserlerin ve binaların, tarihi dokuya zarar vermeyecek şekilde tüm detaylarının alınması için yersel lazer tarama teknolojisi kullanılarak farklı noktalardan çok sayıda tarama yapılır. Her tarama sonucunda elde edilen nokta bulutlarının koordinatları, tarayıcı alet merkezli lokal koordinatlardır. Gerçekleştirilen bu çalışmada tarihi sismoloji binasının 3 Boyutlu dijital modelinin oluşturulması için 17 kez istasyon noktasına yersel lazer tarama aleti kurulmuş ve nokta bulutları elde edilmiştir. Elde edilen nokta bulutlarının koordinatları lokal koordinatlar olup bütün nokta bulutları lokal koordinat sisteminde birleştirilmiştir.



Şekil 7. Üretilen nokta bulutu

FARO Focus 350 S yersel lazer tarama aletinin içinde nesneyi tararken tarayıcıya entegre kamerası bulunmakta ve bu kamera ile tarama yapılırken aynı zamanda ölçülen nesnenin fotoğrafları da kaydedilmektedir. Yersel Lazer tarama uygulamalarında yer alan çözünürlük kavramı, ardarda gelen iki nokta arasındaki mesafedir (Gümüş, 2014). Bu sebeple gerçekleştirilen tarama işleminde, taranan objeye bağlı olarak uygun çözünürlük seçilmelidir. Düşük çözünürlük ile daha az nokta bulutu elde edilirken, yüksek çözünürlükte daha fazla detay ile daha fazla nokta bulutu elde edilmektedir. Uygulamada ilk olarak düşük çözünürlükte (1/8 oranında) tarama yapılmış ve tarama sırasında resim çekme özelliği kapatılmıştır. İkinci aşamada ise yüksek çözünürlükte (1/4 oranında) tarama yapılarak resim çekim modülü açılmış ve ayrıca binanın HDR formatında 70 megapiksel çözünürlüklü resimleri de alınıp kaydedilmiş ve renkli nokta bulutları üretilmiştir (Şekil 8).

Taramalar sonucu elde edilen nokta bulutlarının birleştirilmesi sonrasında taramaya esas olan Tarihi Sismoloji binasının dışında birçok fazla ve gereksiz nokta bulutları oluşmuştur. Üç boyutlu modellemede kullanılmayacak olan bu veriler Faro'nun Scene yazılımı yardımı ile temizlenmiştir. Temizleme işlemi manuel olarak yapılmış ve taranan bina çerçeve içine alınmış, çerçeve dışındaki nokta bulutları da silinmiştir. Birleştirilmiş ve temizlenmiş nokta bulutlarının dengelemesi Scene yazılımında gerçekleştirilmiştir. Scene yazılımında dengeleme için maksimum hata sınırı 20 mm. verilmiş ve istasyonların dengelenmesi sonucu yatayda 3.7 mm., düşeyde 1.5 mm. ortalama uzunlukta ise 4.1 mm. hata bulunmuş ve hata sınırları içinde kaldığı görülmüştür.



Şekil 8. Tarihi Sismoloji Binasının nokta bulutlarından oluşturulmuş 3 boyutlu görseli

5. Sonuçlar ve Bulgular

Günümüzde, deformasyon ölçmelerinden sinema endüstrisine kadar birçok alanda kendisine yeni uygulama alanları kazanan, ölçme işlemine yeni bir boyut katan yersel lazer tarayıcılar, birçok araştırmanın konusu olmaktadır. Yersel fotogrametri, yersel lazer tarama teknolojisi, mobil lazer tarama, LİDAR, modern metodlar olup çeşitli bilim insanlarının son yıllarda sıklıkla başvurdukları yöntemlerdir.

Gerçekleştirilen bu çalışmada İstanbul ili Boğaziçi Üniversitesi Kandilli Kampüsü sınırları içinde yer alan Tarihi sismoloji binasının Yersel Lazer teknolojisi kullanılarak yüksek çözünürlüklü 3 boyutlu dijital görüntüsü elde edilmiştir.

Tarihi, anıtsal ve kültürel eserlerin dökümantasyonu ve röleve çalışmaları uzun yıllardır klasik fotogrametrik yöntemlerle yapılmaktadır. Ancak gelişen teknoloji ile yersel lazer tarama teknolojisi, klasik yöntemlere göre kullanıcıya zaman, tasarruf, doğruluk olarak avantajlar sunmaktadır. Kültürel mirasın dökümantasyonu çalışmalarında, obje, yapı veya alanda meydana gelebilecek deformasyon, hasar veya eserin tümüyle yıkılması gibi hallerde dijital olarak eserlerin kayıt altına alınması yersel lazer tarama teknolojilerinin önemini göstermektedir.

Tarihi sismoloji binasının elde edilen sayısal 3 boyutlu, yüksek çözünürlüklü verilerinin multidisipliner çalışmalarda da kullanılmak üzere dökümantasyonunun yapılması ve saklanması önemli bir gelişmedir. Kampüsü sınırları dahilinde Tarihi Sismoloji binası dışında da eski ve tarihi binalar bulunmaktadır. Gelecek çalışmalarda ise bu binaların yersel lazer tarama teknolojisi ile yüksek çözünürlüklü ve 3 boyutlu nokta bulutları üretilerek sayısal formattaki hali dijital kütüphanede muhafaza edilmesi ve gerekli olması halinde ise multidisipliner çalışmalarda kullanılması amaçlanmaktadır.

Kaynaklar

- Altuntaş, C. (2017). Yersel lazer tarayıcı nokta bulutlarının birleştirilmesi ve jeodezik koordinat sistemine dönüştürülmesi: literatür araştırması, *Selçuk Teknik Dergisi*, 16(1), 12-43.
- Arca, D., Bayık, Ç., Acar, H., Alkan, M., & Şeker, D. Z. (2011, Nisan). Safranbolu Tarihi Kenti Örneğinde Dokümantasyon Çalışmalarında Fotogrametri ve CBS'nin Birlikte Kullanımı. *TMMOB Harita ve Kadastro Mühendisleri Odası*, 13, 18-22.
- Böge, S., (2013). Tarihi ve Kültürel Varlıkların Röleve Alımı İçin Farklı Yöntemlerin Birlikte Kullanılması, Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Boğaziçi Üniversitesi, (2019, Kasım 02). http://www.koeri.boun.edu.tr/new/tr/bilim_tarihi/
- Duran, Z. (2003). Tarihi Eserlerin Fotogrametrik Olarak Belgelenmesi ve Coğrafi Bilgi Sistemine Aktarılması. Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- FARO Bilgi Bankası, (2019a, Ekim 10). <https://www.faro.com/tr-tr/resources/makaleler/>
- FARO Bilgi Bankası, (2019b, Ekim 03), <https://www.faro.com/products/construction-bim/faro-focus/>
- Gümüş, K. (2014). Yersel Lazer Tarayıcıların Doğruluk Araştırması ve Mühendislik Yapılarında Kullanılabilirliği: Oymapınar Barajı Örneği. Doktora Tezi, Yıldız Teknik Üniversitesi, İstanbul.
- Grussenmeyer, P., Landes, T., Voegtler, T., & Ringle, K. (2008). Comparison methods of terrestrial laser scanning, photogrammetry and tacheometry data for recording of cultural heritage buildings. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37(B5), 213-218.
- Kersten, T., Mechelke, K., & Maziull, L. (2015). 3D model of al zubarah fortress in Qatar—Terrestrial laser scanning vs. dense image matching. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XL-5/W4, 1-8. doi:10.5194/isprsarchives-XL-5-W4-1-2015.
- Kıvanç, H., (2019). Kültürel Miras Belgeleme Çalışmalarında Fotogrametrik Yöntem ile Yersel Lazer Tarama Yönteminin Karşılaştırılması, Yüksek Lisans Tezi, Konya Teknik Üniversitesi, Konya, Türkiye.
- Korumaz, A. G., Dülgerler, O. N., & Yakar, M. (2011). Kültürel mirasın belgelenmesinde dijital yaklaşımlar. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 26(3), 67-83.
- Kuçak, R., (2013). Tarihi Eserlerin Dokümantasyonunda Çeşitli Veri Toplama Yöntemlerinin İncelenmesi, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Ulvi, A., Yakar, M., Yiğit, A. Y., & Kaya, Y. (2020). İHA ve Yersel Fotogrametrik Teknikler Kullanarak Aksaray Kızıl Kilise'nin 3 Boyutlu Nokta Bulutu ve Modelinin Üretilmesi, *Geomatik Dergisi*, 5(1), 22-30.

The Earth Surface Stability Observation by Satellite Radar Images Yer Yüzeyi Kararlılığının Radar Uydu Görüntüleriyle Gözlenmesi

Davod Poreh^{1*} 

¹ Università degli Studi di Napoli "Federico II", Napoli/Italy.

Abstract

ORIGINAL PAPER

*Corresponding author:

Davod Poreh
Davod.Poreh@unina.it

doi:

Article history

Received : 07.01.2020
Accepted : 18.03.2020
Published: 31.03.2020

Remote sensing is the art of acquisition of information about any objects (such as the Earth) without making any physical/close contact. Remote sensing has many vital civilian and non-civilian applications. Interferometric Synthetic Aperture Radar (InSAR) is a radar technique used in geoscience and remote sensing to measure the Earth surface deformation from 800 km above the Earth. In particular, Permanent/persistent/point-like Scatterer Interferometry (PSI) is a powerful remote sensing technique, which is able to measure the deformation on the Earth's surface over temporal baselines. This technique was developed to estimate the temporal characteristics of the Earth's deformation rates from multiple radar images acquired over time (series). This paper reviews InSAR and PSI techniques, and explains the current state of the art and potentials of the available radar remote sensing techniques. One case study is examined, pertaining to well-known deformation problem in the Mexico City area.

Keywords: Remote sensing, Mexico City, InSAR, PSI, ENVISAT-ASAR, GPS

Özet

Uzaktan algılama, yeryüzündeki objeler hakkında herhangi bir fiziksel temas olmaksızın bilgi elde etme sanatıdır. Uzaktan algılamanın birçok sivil ve resmi uygulama alanları vardır. Interferometrik Sentetik Açıklıklı Radar tekniği (InSAR) yer yüzeyi deformasyonlarının ölçülmesi amacıyla yer bilimleri ve uzaktan algılama alanlarında kullanılmaktadır. Özellikle, Sabit saçıcılar (Persistent Scatterers Interferometry: PSI) interferometri tekniği ise, yer yüzeyindeki deformasyonları zamansal bazda ölçme yeteneğine sahiptir. Bu teknik, çok zamanlı radar görüntülerinden yer yüzeyine ilişkin deformasyon oranlarının zamansal karakteristiklerinin belirlenmesi amacıyla geliştirilmiştir. Bu makalede, InSAR ve PSI teknikleri açıklanmakta ve en son geliştirilen/kullanılan tekniklerin kullanılabilirliği analiz edilmektedir. Makale kapsamında, Mexico City'ye ilişkin örnek bir çalışma incelenmiştir.

Anahtar kelimeler: Uzaktan algılama, Mexico City, InSAR, PSI, ENVISAT-ASAR, GPS

1. Introduction

Radar ElectroMagnetic (EM) waves are barely influenced by clouds and/or atmosphere, except for very heavy rain and/or tornados, etc.; therefore, radar remote sensing is known as a unique tool for monitoring the Earth's surface deformations in almost all conditions. The word Radar, an acronym for "RADio Detection And Ranging", refers to a specific band of EM waves as well as an engineering system. An engineering system has three functionalities: a transmitter, a receiver, and a processing system. In the radar system, antenna is a device for coupling energy between the outgoing and transmission lines. In remote sensing, different kinds of antennas exist such as disk like, spiral, or series of antennas etc. The Synthetic Aperture Radar (SAR) is a specific kind of side looking radars mounted on an aircraft, satellite, or even on the ground devices. EM signals are sent to the Earth's surface orthogonal to the orbit direction, and the backscattered EM waves are collected from the scatterers.

The SAR system was primarily tested for ocean studies on the Seasat satellite in June 1978. The SIR-A, SIR-B, Cosmos-1870, ALMAZ-1, ERS1&2, JERS, SIR-C/X-SAR, ENVISAT, RADARSAT1&2, ALOS, CosmoSkymed, TerraSAR-X, and Sentinel were the other SAR systems that launched one after another.

The launch of ERS-1 in July 1991 initiated a new era of Interferometric Synthetic Aperture Radar (InSAR) with which we are now acquainted. When the radar antenna moves forward in a specific trajectory, it allows to record the very high-resolution radar images with the help of advance signal processing. SAR interferometry has earned a considerable reputation in environmental science, oil and gas industries, engineering, and Earth surface deformation etc. Interferometry concepts, phase information, and tracking of transmitted and received EM waves are the fundamental concepts of the methodology. SAR data are acquired either by two antennas or by using repeated pass acquisition in the same orbit. Earth surface displacement monitoring with InSAR methodology is also possible with repeated pass arrangement. For deformation mapping of an area, two InSAR coherence images, one taken before and one taken after the deformation, would be suffice. It is enough to measure the phase attributes of the target during the time period. This approach works better for urban areas (man-made objects), as the backscattered EM signals are more stable during this period. Since the InSAR is a side-looking system, geometric distortion (such as layover, foreshortening, and shadows) of acquired images is one of the main limitations of the technique. The cost-effectiveness and availability of the InSAR data are two important advantages of these kinds of systems for monitoring the man-made targets.

Permanent Scatterer Interferometry (PSI) is one of the greatest inventions in the field of satellite remote sensing, which uses SAR image time series. This technique is a more advanced implementation of the well-known Differential Interferometric Synthetic Aperture Radar (DInSAR) approach, which has been employed for more than 20 years for monitoring the Earth's surface deformation and/or man-made structures. The InSAR time series methods work better on man-made structures or urban areas, where the radar backscatters are more abundant. In the original DInSAR approaches, radar coherency, geometrical decorrelation, and phase delay of the atmospheric effects on radar signals are three important limitations. Man-made targets such as, buildings, highways, railways, pipelines, etc. remain coherent for a long temporal baselines (Ferretti et al. 1999, 1999, 2000, 2001; Usai and Hanssen 1997). The PSI or PS (Permanent Scatterer) was developed to overcome the coherency problems of backscatterers in repeated pass (i.e. time series of) SAR interferometry.

The PSI technique was developed by some researchers in the university of Milan in Italy (Ferretti et al. 2000, 2001). A number of other similar methodologies have been developed as time passed. The Small Baseline Subset (SBAS) is another similar well-known time series radar interferometric approach (Berardino et al. 2004; Lanari et al. 2004; Pepe et al. 2005 and 2007). The difference between these two approaches is: in the PS approach, all InSAR coherence images are employed regardless of their spatial baseline variations; whereas in the SBAS methodology, some of them are ignored due to high spatial baseline arrangements. Geometric and temporal de-correlation errors of the InSAR approaches are more important in the SBAS, compared to the PS data analysis (Berardino et al. 2004; Lanari et al. 2004). The SBAS generates much more radar interferograms than the PS approaches. The SBAS and PS approaches also have different unwrapping procedures: the interferograms are unwrapped first spatially and then temporally in the SBAS, and the opposite is done in the PS data analysis. Disconnected clusters of generated interferograms may sometimes occur in the SBAS approaches. However, in the SBAS approaches, not only permanent scatterers can be used, but also distributed scatterers, with much moderate coherence, can be included in the analysis. For all of the abovementioned differences between SBAS and PSI techniques, a number of researches tried to proposed the innovative solutions in order to benefit from the advantages of both methods. The one great example for the minimization of the temporal baselines and employment of the InSAR coherence images with the SBAS approach was provided by Pepe et al. 2011. Mora et al. 2003 presents another similar approach. Hooper et al. 2004 gave a geophysical approach and Crosetto et al. 2005 discussed on a stepwise linear deformation with least square adjustment models. The Interferometric Point Target Analysis approach was given by Werner et al. 2003 and stable point networks approach was presented by Crosetto et al. 2008. In Ferretti et al. 2000, the PSI and small baseline analysis were combined heuristically: multiple imageries' pixels were employed within a certain radius to measure spatially correlated parameters. Ferretti et al. 2011 explained the SqueeSAR approach, which is capable of employing the PS and distributed scatterers approaches. This approach helped monitor rural areas where the coherency was limited. Contribution of fully polarimetric InSAR data was heuristically discussed by Navarro-Sanchez and Lopez-Sanchez 2013.

In PS technique, a large number of coherence images are used to estimate the changes on the Earth's surfaces in temporal domain. Historical deformation time series of the radar backscatterers, and the height of those scatterers are the results of PS techniques. In the PS approach, the pixels with high radar coherency during the temporal baseline are exploited. In general, more than 20 InSAR imageries are used to estimate and remove the atmospheric errors. In the PS data analysis, a master image is selected considering specific criteria (among K imageries), and $(K - 1)$ interferograms are produced with respect to the master image.

Then, with a number of different models, permanent scatterer candidates are selected. Final permanent scatterers can be produced through further refinements made on the selected permanent scatterer candidates (Kampes, 2005). Temporal changes in height for the Earth surface's, and the height of each PS with respect to a reference point, are the outputs. In man-made areas, the PS approaches can achieve an average of 100 PSs/ km² (points densities) with low resolution satellites such as ERS1/2 and ENVISAT-ASAR, and an average of a couple of thousands PSs/km² with high resolution sensors like TerraSAR-X and Cosmo-SkyMed data. Since the permanent radar scatterers are limited, the rural/vegetated areas might not be explored properly with the PS techniques. The PS approaches need a minimum amount of InSAR coherence images for phase unwrapping steps, which could severely influence the degree of correctness of the selected PS candidates. PS (and SBAS too) is basically a relative approach, which means all of the calculated time series for InSAR time series points are measured with respect to a pre-defined reference point; Continuous Global Positioning Systems (CGPS) or leveling methodologies can help rectify this problem (Kampes, 2005). Another drawback of the PS is the observation geometry of the satellite: PS deformation measurements are given along the satellite line of sight direction; therefore, the measured deformation rates are just the projection of the deformation vector onto the SAR look direction, not absolute deformation in vertical or horizontal directions.

2. Application of InSAR for the Earth surface monitoring review

In this section, we discuss some of the most essential applications of InSAR approaches in environmental science. Several important InSAR applications have been carried out by research communities, academic, and specialized companies; and have been reported in the scientific journals (see, for example www.npagroup.com, www.altamira-information.com, and www.gamma-rs.ch).

One of the most elegant and important applications of the radar monitoring is about man-made areas. Huge areas can be monitored through high-resolution InSAR coherence images with proper revisiting schedules. The estimation of the deformations on the Earth surface with InSAR data is currently done for several cities around the Earth. For example, in the PanGeo monitoring project (http://www.pangeoproject.eu/eng/project_overview), more than 52 European cities of the Europe in which 13% of these cities have a metropolitan population, were under this kind of monitoring continually.

PanGeo gives online deformation data based on the InSAR techniques for possible geohazard problems. However, PanGeo data are generated based on low-resolution InSAR coherence images, and no detail information in their area is given. For instance, these datasets might not be very helpful for studying a single building or a bridge. Dixon et al. 2006 presents a detailed study on a single target with InSAR coherence images of C-band. In Zerbini et al. (2007), the Bologna region and Po Plain (Italy) are the test sites for their InSAR work using the ERS and RADARSAT data. In Osmanoglu et al. 2011, deformation in Mexico City metropolitan area due to water extraction was investigated with the C-band ENVISAT data. Telerilevamento Europa (www.treuropa.com) runs a big program for monitoring the deformation that occurs due to oil and gas extractions.

Tectonic/Fault deformation surveillance based on InSAR coherence images is also one of the prominent uses of the the InSAR remote sensing approaches. Lyons and Sandwell (2003) show that fault creeping measurements based on ERS InSAR data might be translated to the fault's future activities.

Landslide surveillance is one of the most important subjects of the InSAR remote sensing studies (see some examples in Colesanti and Wasowski, 2006, and Kimura and Yamaguchi, 2000).

In the Netherlands, InSAR remote sensing monitoring of dikes and dams is a common task for water defense systems evaluation (see Hanssen et al. 2008).

In Lazecky et al. 2017, the bridge deformation was found with the use of very high resolution X-band imageries. In Hanssen et al. 2015, RADARSAT-2 images were employed to monitor the railway deformations in the entire Netherlands, for a temporal baseline between 2010 and 2015.

Finally, in Poreh et al. 2016, the bridge movements in Campania (Italy) area were studied with high (spatial) resolution X-band Italian CosmoSkyMed imageries. They concluded that most of the movements on the railways were related to periodical/temporal changes of the temperature, and that the bridge was safe to run the trains.

3. A case study: monitoring the subsidence in the Mexico City

In this section, subsidence of Mexico City area due to excessive water withdrawal is discussed. This study focuses on this problem utilizing the InSAR and Continuous Global Positioning Systems (CGPS). Fifty-two ENVISAT and nine permanent GPS stations from Mexico City area were used to monitor the subsidence of Mexico City's area. The radar data covers a time span of 2002-2010, and the GPS data covers a time span from 1998 to 2012. Based on the InSAR data, a maximum of 352 mm/yr deformation in LOS direction is measured.

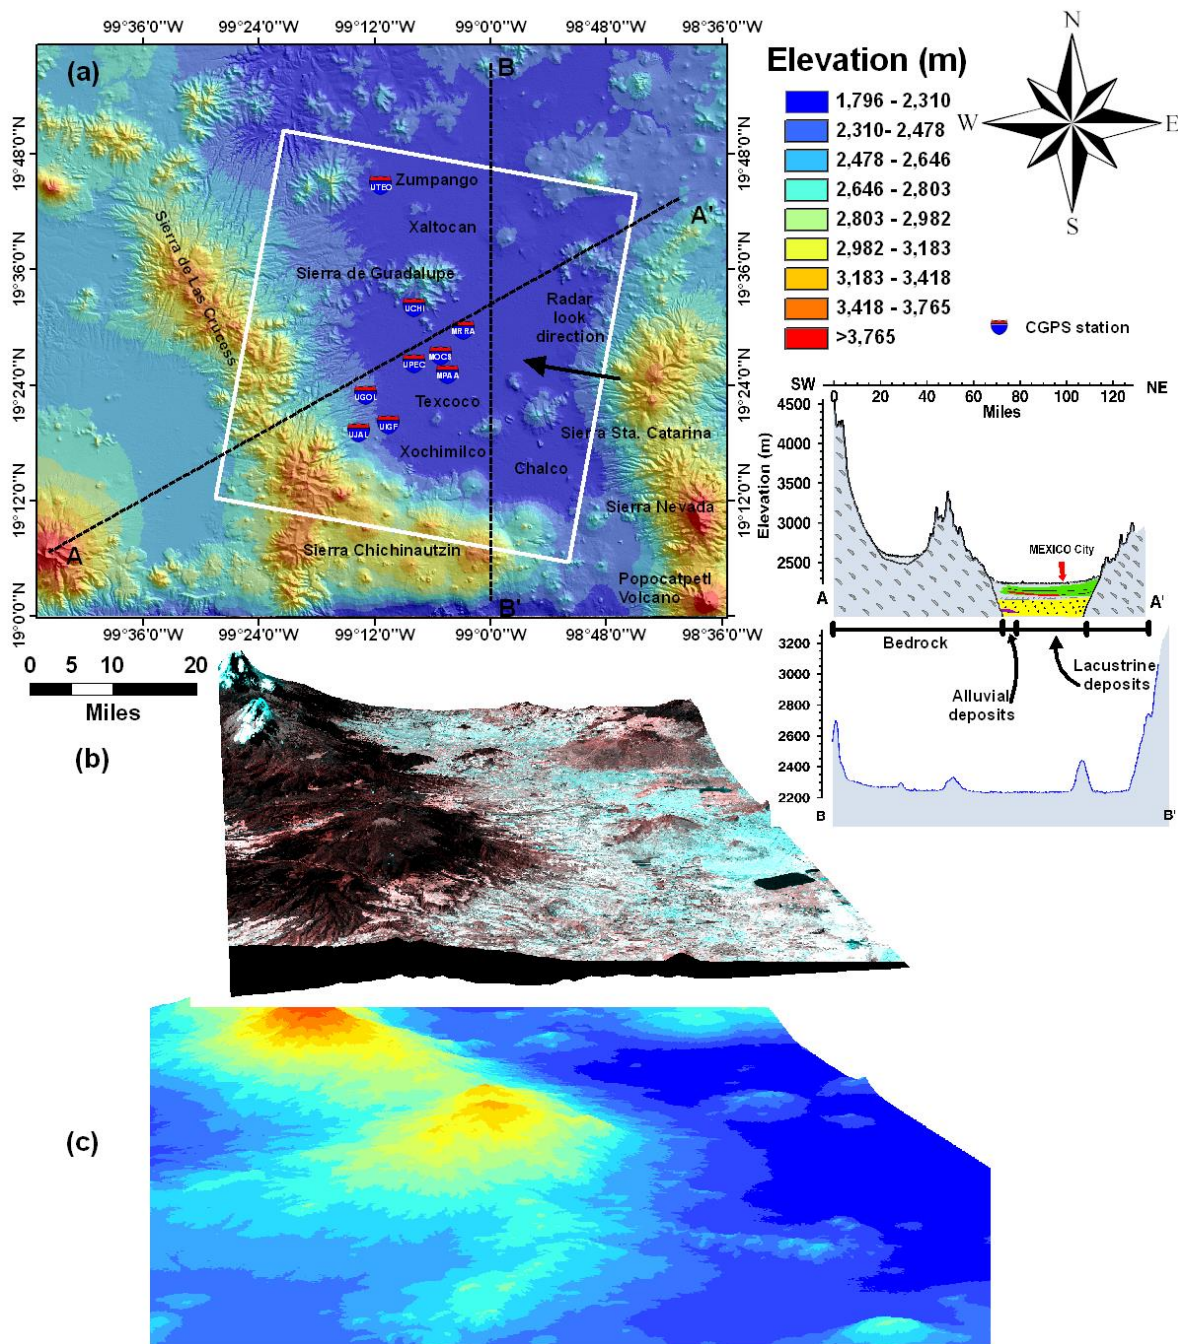


Figure 1. a) Mexico City topography map and installed CGPS stations in the metropolitan area. White rectangle shows the InSAR data coverage area in descending mode. b) 3D view of the study area with Landsat ETM+ imagery from 25/11/2005. c) 3D representation of Mexico City area (Poreh and Pirasteh, 2019)

Mexico City's (see Figure 1 and 2) subsidence began in the 1840s and expanded in the 1930s and 1950s. The Mexico City's soil comprise highly compressible clays, and the mechanism of the subsidence in Mexico City lacks enough natural water recharge, and consequently, compaction of the soil layers. The compaction of the overlying geological layers plays also a crucial role in the deformation mechanism.

Much of the deformation occurs in the irrecoverable, heavily pumped area, and results are loss of aquifer storage and damages on engineering structures. This subsidence accelerated since the 1950s, and several correlated structural damages were observed in the study area. More than 20 million (<http://www.unesco.org>) inhabitants in the Mexico City area are facing this extraordinary land subsidence problem (see Figure 2). For instance, in Mexico City's cathedral which took more than 250 years to build, one side is deformed nearly 2.44 meters deeper than the other side, and it is leaning to the left side.



Figure 2. Surface deformation in Mexico City area (The Geodesy Lab)

Figure 1 shows the study area with GPS station locations and InSAR data coverage. Nine GPS stations (Figure 4) and thousands of PSs from ENVISAT-ASAR imageries have been used. The GPS data are from the University of Mexico City, and employed as ground truth and/or calibration tool for the InSAR data. Given more than eight years of GPS and InSAR data overlap, the two independent methodologies provided a picture of deformation in the Mexico City and its surrounding area for the first decade of the 21st Century.

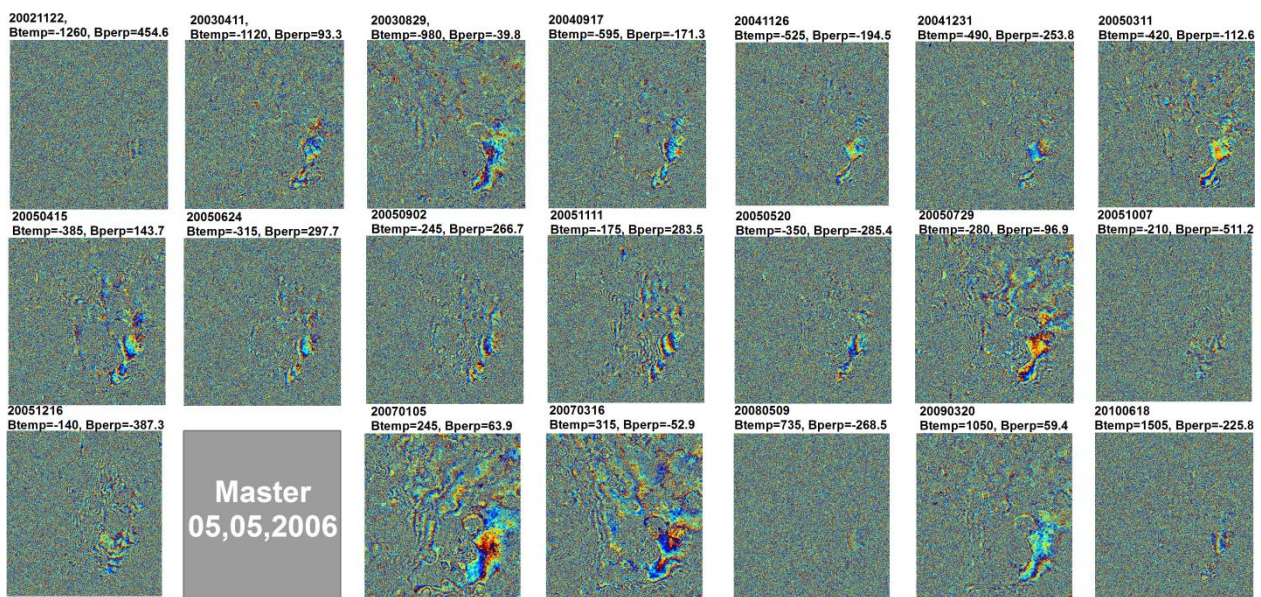


Figure 3. Some of the generated differential interferograms (from 51 interferograms) for Mexico City study area. Image 05.05.2006 is selected as the master image. Image acquisition time, temporal (Btemp), and perpendicular (Bperp) baselines are given on top of the interferograms

Image 05/05/2006 has been selected as the master image to minimize the effectiveness of the spatio-temporal baselines. The InSAR coherence images cover an area (Figure 1) of around 62 km×56 km and are centered over the Mexico City downtown. Some of the differential interferograms (from 51 interferograms) are given in Figure 3. Three well-known PSI/unwrapping approaches of ILS, bootstrapping, and periodogram results are given in Figure 5. As can be seen, there are not significant differences between the methodologies, and all of them presented similar results (sometimes the number of PSs (radar reflectors) are slightly different). Deformation rates and its extensions can be measured with the InSAR approaches. GPS data also can be used for calibration and InSAR data evaluation. If reference point of InSAR data is selected with the help of GPS measurements, then absolute deformation rates can be conducted over the study area.

Some of the widely used packages/software for InSAR and/or PSI processing are listed as: DORIS, ROI-PAC, ScatterersTM, GMTSAR, GAMMA, SARscape, PuSAR, DIAPASON, RAT (Radar Tools), StaMPS, MintPy-Miami InSAR time-series software, and SNAP ESA’s InSAR software.

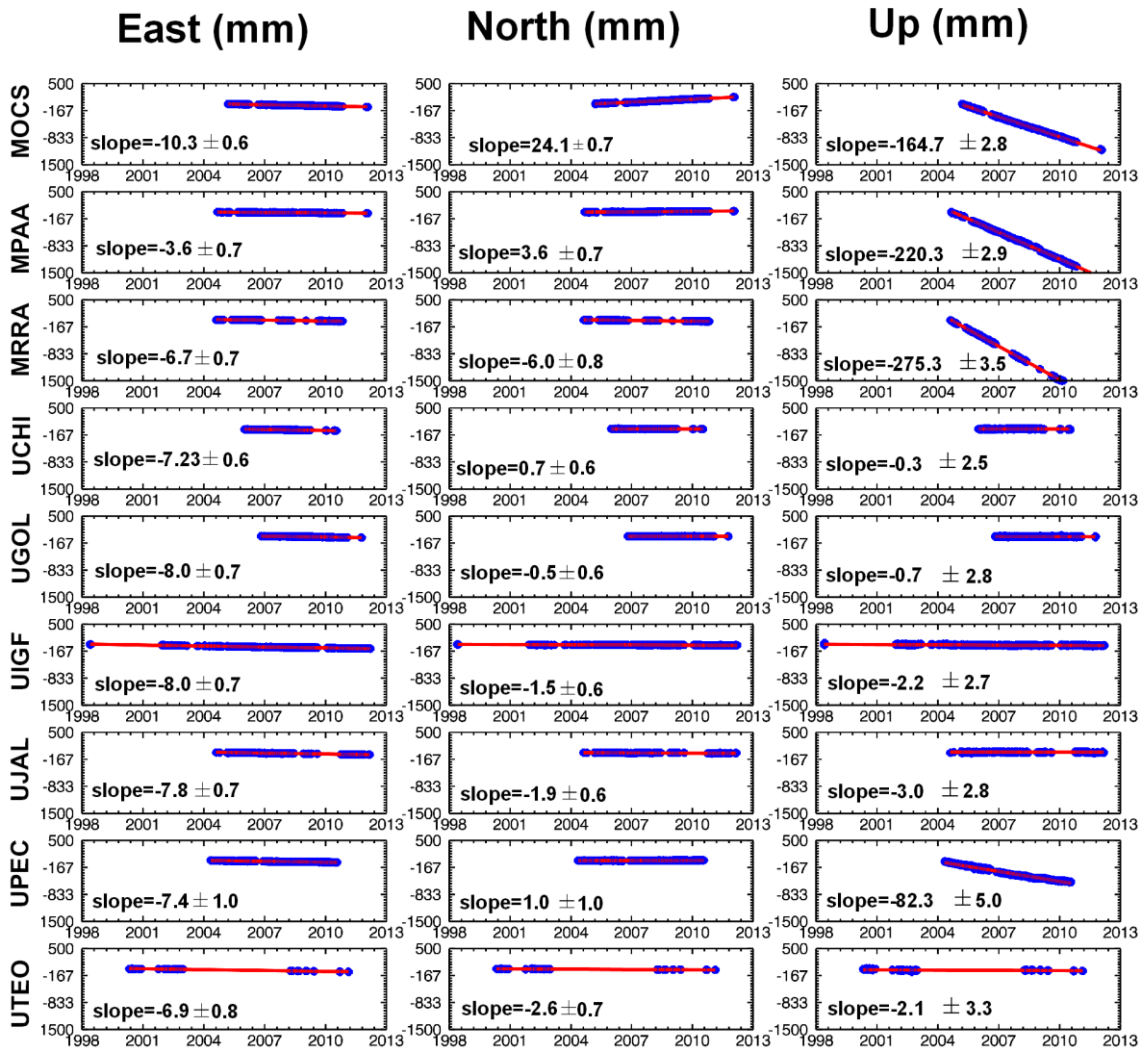


Figure 4. North, east, and vertical components of deformation based on GPS stations (Poreh and Pirasteh, 2019)

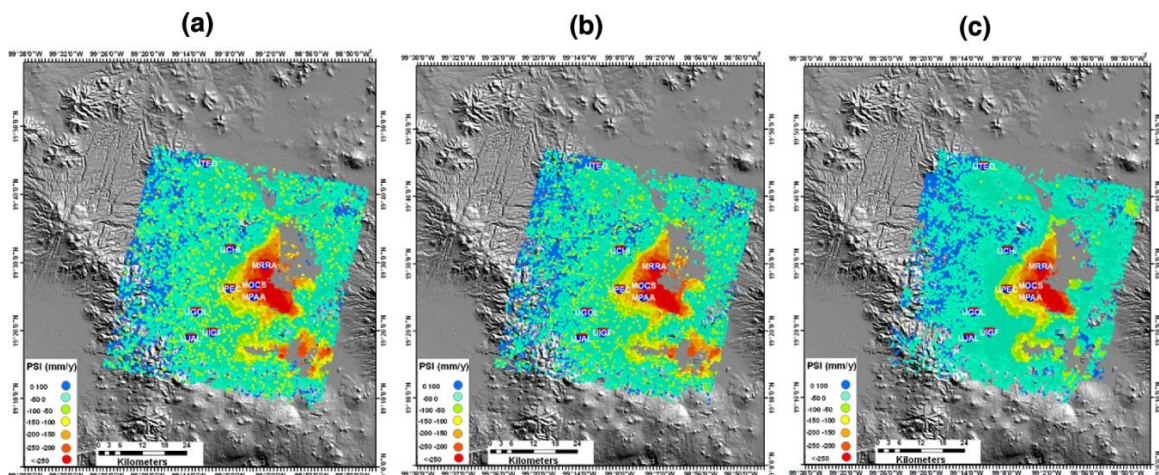


Figure 5. PSI deformation rates for Mexico City area for temporal baseline of 2002-2010 with a) Bootstrapping, b) ILS, and c) Periodogram approaches

4. Discussion and Conclusions

Monitoring the Earth surface based on radar remote sensing and InSAR time series is discussed in this study. The characteristics, benefits, and disadvantages of each InSAR time series techniques are highlighted. Since phase measurements are used in the InSAR systems, the wavelength characteristics of the radar systems are essential. L-band (24 cm), C-band (5.8 cm), and X-band (3 cm) are among the most common radar wavelengths. EM waves tend to interact with objects similar in size to the EM wavelengths. Meanwhile, surfaces appear rougher for shorter wavelengths. Compared to the shorter wavelengths (X-bands), longer EM waves (L-bands) are able to penetrate the vegetation, dry soils, and ice more deeply.

The most important practical point of InSAR data analysis is the availability of radar images for generation of interferograms. Given the limited re-visiting radar data and InSAR geometric problems, InSAR time series approach can not always be used for real-time monitoring purposes, and must be used parallel to the other surveillance methods.

In the case study, the deformation of Mexico City area is discussed. The extraction of groundwater from central part of Mexico City causes significant land deformation in the metropolitan area. We address the mechanism of this deformation based on GPS and InSAR coherence images. While several recent studies pointed out the potential of using InSAR data to assess the deformation rates in Mexico City area, we must stress that in some cases the unwrapping errors might cause significant errors in estimation of deformation rates; meanwhile, combination with other independent geodetic techniques such as GPS is essential. GPS stations were also used for calibration of InSAR time series. Three different InSAR unwrapping techniques show similarity on intensities and extension of the deformation rates. The combination of InSAR and GPS observations holds promise for high resolution mapping of Mexico City area deformation because of on groundwater depletion. GPS has a low resolution (only nine stations) data, but they measure the absolute deformation rates (i.e., absolute deformations in the north, east, and vertical); InSAR has high resolution, but not direct measurements: InSAR data is a relative method. The increasing coverage of the study area, high revisiting periods, and availability of InSAR data will encourage land subsidence/deformation mapping at InSAR scale of applications.

Acknowledgments

The author thanks ESA for providing the ENVISAT imageries downloaded from ESA's virtual web page (<http://eo-virtual-archive4.esa.int/>). The GPS data is from geophysical university of Mexico and UNAVCO organization.

References

- Berardino, P., Fornaro, G., Lanari, R., & Sansosti, E. (2002). A new algorithm for surface deformation monitoring based on small baseline differential SAR interferograms. *IEEE Transactions on geoscience and remote sensing*, 40(11), 2375-2383.
- Colesanti, C., & Wasowski, J. (2006). Investigating landslides with space-borne Synthetic Aperture Radar (SAR) interferometry. *Engineering geology*, 88(3-4), 173-199.
- Crosetto, M., Biescas, E., Duro, J., Closa, J., & Arnaud, A. (2008). Generation of advanced ERS and Envisat interferometric SAR products using the stable point network technique. *Photogrammetric Engineering & Remote Sensing*, 74(4), 443-450.
- Crosetto, M., Crippa, B., & Biescas, E. (2005). Early detection and in-depth analysis of deformation phenomena by radar interferometry. *Engineering Geology*, 79(1-2), 81-91.
- Dixon, T. H., Amelung, F., Ferretti, A., Novali, F., Rocca, F., Dokka, R., ... & Whitman, D. (2006). Subsidence and flooding in New Orleans. *Nature*, 441(7093), 587-588.
- Ferretti, A., Fumagalli, A., Novali, F., Prati, C., Rocca, F., & Rucci, A. (2011). A new algorithm for processing interferometric data-stacks: SqueeSAR. *IEEE transactions on geoscience and remote sensing*, 49(9), 3460-3470.
- Ferretti, A., Prati, C., & Rocca, F. (1999). Multibaseline InSAR DEM reconstruction: The wavelet approach. *IEEE Transactions on geoscience and remote sensing*, 37(2), 705-715.
- Ferretti, A., Prati, C., & Rocca, F. (2000). Nonlinear subsidence rate estimation using permanent scatterers in differential SAR interferometry. *IEEE Transactions on geoscience and remote sensing*, 38(5), 2202-2212.
- Ferretti, A., Prati, C., & Rocca, F. (1999). Non-uniform motion monitoring using the permanent scatterers technique. In: Second International Workshop on ERS SAR Interferometry, 'FRINGE99 conference', pp. 1-6, Liege, Belgium.
- Ferretti, A., Prati, C., & Rocca, F. (2001). Permanent scatterers in SAR interferometry. *IEEE Transactions on geoscience and remote sensing*, 39(1), 8-20.

- Hanssen, R., Chang, L. & Dollevoet, R.P.J. (2015, November). Automatic Railway Instability Detection Using Satellite SAR Interferometry, MUAS-2015, ESA Frascati.
- Hanssen, R. F., & van Leijen, F. J. (2008, May). Monitoring water defense structures using radar interferometry. In *2008 IEEE Radar Conference* (pp. 1-4). IEEE.
- Hooper, A., Zebker, H., Segall, P., & Kampes, B. (2004). A new method for measuring deformation on volcanoes and other natural terrains using InSAR persistent scatterers. *Geophysical research letters*, *31*(23), 1-5. doi: 10.1029/2004GL021737
- Kampes, B. (2005). *Displacement parameter estimation using permanent scatterer interferometry*. (Doctoral dissertation), Technische Universiteit Delft, Holland.
- Kimura, H., & Yamaguchi, Y. (2000). Detection of landslide areas using satellite radar interferometry. *Photogrammetric engineering and remote sensing*, *66*(3), 337-344.
- Lanari, R., Mora, O., Manunta, M., Mallorquí, J. J., Berardino, P., & Sansosti, E. (2004). A small-baseline approach for investigating deformations on full-resolution differential SAR interferograms. *IEEE Transactions on Geoscience and Remote Sensing*, *42*(7), 1377-1386.
- Lazecky, M., Hlavacova, I., Bakon, M., Sousa, J. J., Perissin, D., & Patricio, G. (2016). Bridge displacements monitoring using space-borne X-band SAR interferometry. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *10*(1), 205-210.
- Lyons, S., & Sandwell, D. (2003). Fault creep along the southern San Andreas from interferometric synthetic aperture radar, permanent scatterers, and stacking. *Journal of Geophysical Research: Solid Earth*, *108*(B1). doi: 10.1029/2002JB001831
- Mora, O., Mallorqui, J. J., & Broquetas, A. (2003). Linear and nonlinear terrain deformation maps from a reduced set of interferometric SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, *41*(10), 2243-2253.
- Navarro-Sanchez, V. D., & Lopez-Sanchez, J. M. (2013). Spatial adaptive speckle filtering driven by temporal polarimetric statistics and its application to PSI. *IEEE transactions on geoscience and remote sensing*, *52*(8), 4548-4557.
- Osmanoğlu, B., Dixon, T. H., Wdowinski, S., Cabral-Cano, E., & Jiang, Y. (2011). Mexico City subsidence observed with persistent scatterer InSAR. *International Journal of Applied Earth Observation and Geoinformation*, *13*(1), 1-12.
- Pepe, A., Berardino, P., Bonano, M., Euillades, L. D., Lanari, R., & Sansosti, E. (2011). SBAS-based satellite orbit correction for the generation of DInSAR time-series: Application to RADARSAT-1 data. *IEEE transactions on geoscience and remote sensing*, *49*(12), 5150-5165.
- Pepe, A., Manunta, M., Mazzarella, G., & Lanari, R. (2007, July). A space-time minimum cost flow phase unwrapping algorithm for the generation of persistent scatterers deformation time-series. In *2007 IEEE International Geoscience and Remote Sensing Symposium* (pp. 5285-5288). IEEE.
- Pepe, A., Sansosti, E., Berardino, P., & Lanari, R. (2005). On the generation of ERS/ENVISAT DInSAR time-series via the SBAS technique. *IEEE Geoscience and Remote Sensing Letters*, *2*(3), 265-269.
- Poreh, D., Iodice, A., Riccio, D., & Ruello, G. (2016). Railways' stability observed in Campania (Italy) by InSAR data. *European Journal of Remote Sensing*, *49*(1), 417-431.
- Poreh, D., & Pirasteh, S. (2019). InSAR and Landsat ETM+ incorporating with CGPS and SVM to Determine Subsidence Rates and Effects on Mexico City. Preprints 2019, 2019090082, doi: 10.20944/preprints201909.0082.v1.
- The Geodesy Lab, <http://geodesy.fiu.edu/MexSubsidence/index.html>
- Usai, S., & Hanssen, R. (1997). Long time scale INSAR by means of high coherence features. *European Space Agency-Publications-Esa Sp*, *414*, 225-228.
- Werner, C., Wegmuller, U., Strozzi, T., & Wiesmann, A. (2003, July). Interferometric point target analysis for deformation mapping. In *IGARSS 2003. 2003 IEEE International Geoscience and Remote Sensing Symposium. Proceedings (IEEE Cat. No. 03CH37477)* (Vol. 7, pp. 4362-4364). IEEE.
- Zerbini, S., Richter, B., Rocca, F., van Dam, T., & Matonti, F. (2007). A combination of space and terrestrial geodetic techniques to monitor land subsidence: case study, the Southeastern Po Plain, Italy. *Journal of Geophysical Research: Solid Earth*, *112*(B5).