

UZAKTAN ALGILAMA GÖRÜNTÜLERİNDE DERİN SİNİR AĞLARI KULLANARAK OTOMATİK DEĞİŞİM TESPİTİ

Fırat Erdem¹, Nuri Erkin Öçer², Dilek Küçük Matcı³, Resul Cömert³, Gordana Kaplan⁴, Uğur Avdan⁴

¹Doktora öğrencisi, Eskişehir Teknik Üniversitesi, Yer ve Uzak Bilimleri Enstitüsü, 26555, Tepebaşı, Eskişehir, firaterdem@eskisehir.edu.tr

²Arş. Gör. Dr., Eskişehir Teknik Üniversitesi, Yer ve Uzak Bilimleri Enstitüsü, 26555, Tepebaşı, Eskişehir, neocer@eskisehir.edu.tr

³Dr. Öğretim Üyesi, Eskişehir Teknik Üniversitesi, Yer ve Uzak Bilimleri Enstitüsü, 26555, Tepebaşı, Eskişehir, dkmatici/rcmert@eskisehir.edu.tr

⁴Doç. Dr., Eskişehir Teknik Üniversitesi, Yer ve Uzak Bilimleri Enstitüsü, 26555, Tepebaşı, Eskişehir, gkaplan/uavdan@eskisehir.edu.tr

ÖZET

Değişim tespiti için temel amacı, aynı bölgenin farklı zamanlarda çekilmiş görüntülerini karşılaştırarak her piksele değişim olan ve olmayan olmak üzere ikili kodlanmış etiketler atamaktır. Yüksek çözünürlüklü optik uzaktan algılama görüntülerine dayalı değişim tespiti çalışma alanında bulunan nesnelerin karmaşıklığı ve iki tarih arasındaki farklı görüntüleme koşulları nedeniyle zorlu bir görevdir. Bu çalışmada LEarning, Vision and Remote sensing (LEVIR)-CD veri seti ile eğitilmiş, derin sinir ağı temelli Bitemporal Görüntü Dönüştürücü (Bitemporal Image Transformer - BIT) ve STANet modellerinin farklı çalışma alanlarındaki performansının araştırılması amaçlanmıştır. Elde edilen sonuçlar LEVIR-CD veri seti ile eğitilmiş olan BIT ve STANet modellerinin yüksek doğruluk ile değişim tespiti gerçekleştirmesi için ek eğitim veri setine ihtiyaç duyduğunu göstermektedir.

Anahtar Sözcükler: bina tespiti, değişim tespiti, derin öğrenme, konvolüsyonel sinir ağları, uzaktan algılama.

ABSTRACT

AUTOMATIC CHANGE DETECTION IN REMOTE SENSING IMAGES USING DEEP NEURAL NETWORKS

The main purpose of change detection is to compare images taken at different times of the same region and assign binary coded labels to each pixel describing the areas with and without change. Change detection based on high resolution optical remote sensing images is a challenging task due to the complexity of the objects in the study area and the different viewing conditions between the two dates. In this study, it is aimed to investigate the performance of deep neural network-based Bitemporal Image Transformer (BIT) and STANet models trained with LEarning, Vision and Remote sensing (LEVIR)-CD, in different study areas. The outcomes demonstrate that the BIT and STANet models trained using the LEVIR-CD dataset requires an additional training dataset to carry out change detection with high accuracy.

Keywords: building detection, change detection, deep learning, convolutional neural networks, remote sensing.

1. GİRİŞ

Değişim analizi uzaktan algılamada önemli araştırma konularından biridir. Değişim tespiti için temel amacı, aynı bölgenin farklı zamanlarda çekilmiş görüntülerini karşılaştırarak her piksele değişim olan ve olmayan olmak üzere ikili kodlanmış etiketler atamaktır (Kennedy, vd., 2009). Değişim tespiti; kentsel büyüme (Chen ve Shi., 2020), ormansızlaşma (de Bem, vd., 2020), hasar tespiti (Xu, vd., 2019) gibi alanlarda sıklıkla kullanılmaktadır. Otomatik değişim tespiti, bilgi çıkarmada kullanılan manuel işlemlerin önüne geçerek işçilik maliyetini ve zaman tüketimini azaltmaktadır.

Yüksek çözünürlüklü uydu ve hava görüntülerinin varlığı, arazi örtüsünü ve arazi kullanımını lokal ölçekte izlemek için yeni araçlar sağlamaktadır. Ancak yüksek çözünürlüklü optik uzaktan algılama görüntülerine dayalı değişim analizi iki etken nedeniyle zorlu bir görevdir (Chen, vd., 2021). Bunlardan ilki çalışma alanında bulunan nesnelerin karmaşıklığıdır. Diğer etmen ise iki tarih arasındaki farklı görüntüleme koşullarıdır. Her iki etmen de aynı semantik konseptte sahip nesnelerin farklı zamanlarda ve farklı konumlarda farklı spektral özellikler göstermesine sebep olur. Bu nedenle karmaşık çalışma alanlarındaki değişimi tanımlamak için güçlü bir değişim tespiti modelinin bu etmenleri göz önünde bulunduracak kapasitede olması önemli bir araştırma konusudur.

Literatürde uzaktan algılama verilerinden otomatik değişim tespiti için geliştirilmiş farklı yöntemler bulunmaktadır. Bu yöntemler genel olarak görsel analiz, cebir tabanlı yöntemler, dönüşüm tabanlı yöntemler, sınıflandırma tabanlı yöntemler, gelişmiş yöntemler ve mekânsal istatistik tabanlı yöntemler olarak özetlenebilmektedir (Asokan ve Anitha, 2019; Shi vd., 2020). Cebir tabanlı yöntemlerde değişimi tespit edebilmek amacıyla her piksele görüntü farklılaştırma, görüntü oranlama, değişim vektör analizi gibi matematiksel yöntemler uygulanır (Ferraris vd., 2017; Ke vd., 2018). Dönüşüm tabanlı yöntemler, değişimi belirleyebilmek amacıyla pikseller üzerinde Taselled Cap dönüşümü, Gramm-


Schmidt dönüşümü, Temel Bileşen Analizi gibi dönüşüm yöntemlerinin uygulanmasını içerir (Massarelli, 2018; Zhuang vd., 2018). Sınıflandırma tabanlı yöntemler farklı tarihlere ait ait sınıflandırma sonuçlarını karşılaştırarak değişimi tespit etmeyi amaçlarken (Radhika ve Varadarajan, 2018) gelişmiş modeller farklı dönemlere ait görüntülerin farkını belirlemek amacıyla farklı yansıma modellerini ve spektral karışım modellerini içermektedir (Xu vd., 2017; Yan vd., 2018). Son yıllarda çalışma alanında bulunan nesnelerin karmaşıklığı ve aynı semantik konsepte sahip nesnelerin farklı zaman ve konumlarda farklı spektral özellikler göstermesi gibi problemler karşısında daha dayanıklı yöntemler üretmek amacıyla derin öğrenme temelli yeni yaklaşımlar geliştirilmiştir (Gong vd., 2015; Chen ve Shi, 2020; Fang vd., 2021). Bu yöntemler genel olarak değişim analizi yapılacak olan farklı tarihli görüntülerden anlamsal özellikler çıkarmak için Konvolüsyonel Sinir Ağı (Convolutional Neural Network – CNN) tabanlı derin sinir ağlarını kullanmaktadır (Chen vd., 2021).

Spatial–Temporal Attention Neural Network (STANet) (Chen ve Shi, 2020) ve Bitemporal Image Transformer (BIT) (Chen, vd., 2021) uzaktan algılama verilerinden otomatik değişim tespiti için geliştirilen derin sinir ağlarıdır. STANet modeli, kayıt hatalarının etkisini azaltıldığı ve pikseller arasındaki konum-zamansal ilişkileri daha güçlü ortaya çıkarttığı belirtilmektedir. Ayrıca diğer yöntemlerden farklı olarak, önerilen modülün uzun dönemde, zengin konum-zamansal ilişkileri yakalayabildiği ifade edilmiştir (Chen ve Shi, 2020). Değişim belirlemek amacıyla geliştirilmiş olan derin öğrenme temelli yaklaşımlardan biri diğeri BIT yöntemidir. Bu yöntem, mevcut derin öğrenme temelli yaklaşımlarda ortaya çıkan hesaplama karmaşıklığını azaltmak ve farklı tarihlerdeki pikseller arasındaki bağlantıyı oluşturmada ortaya çıkan problemlerin önüne geçmek amacıyla geliştirilmiştir. BIT yöntemi, üç farklı değişim analizi veri setinde test edilmiş ve mevcut yöntemlerden daha doğru bir sonucu üç kat daha hızlı bir şekilde verdiği belirtilmiştir. (Chen vd., 2021). Bu çalışmada önceden eğitilmiş BIT ve STANet modellerinin farklı çalışma alanlarında otomatik değişim tespitindeki performansının araştırılması amaçlanmıştır.

2. MATERYAL VE METOD


LEarning, VIsion and Remote sensing (LEVIR)-CD (Chen ve Shi, 2020), açık ve büyük ölçekli bir bina değişikliği algılama veri setidir. LEVIR-CD, villa konutları, yüksek apartmanlar, küçük garajlar ve büyük depolar gibi çeşitli bina türlerini kapsamaktadır. Veri setinde 1024×1024 boyutunda 637 çift yüksek çözünürlüklü (0.5 m) görüntü yer almaktadır. GPU bellek kapasitesinin sınırlandırılması için görüntüler 256×256 boyutunda küçük parçalara

bölünmüştür. Bu işlem sonucunda eğitim işlemi için toplam 7120 çift görüntü parçası elde edilmiştir. LEVIR-CD veri setinden örnekler Şekil 1’de gösterilmektedir.



Şekil 1. LEVIR-CD veri setinden örnekler


LEVIR-CD veri seti ile eğitilen BIT ve STANet derin öğrenme mimarileri ile Google Earth görüntüleri kullanılarak altı farklı çalışma alanı için bina değişim tespiti gerçekleştirilmiştir. Şekil 2’de test için kullanılan çalışma alanları gösterilmektedir.



Şekil 2. Test için kullanılan çalışma alanları


Bitemporal Görüntü Dönüştürücü (Bitemporal Image Transformer - BIT) modeli, konum-zamansal bilgileri verimli ve etkili bir şekilde modellemek için geliştirilmiştir (Chen, vd., 2022). Model, değişimin üst düzey kavramlarını birkaç görsel sözcükle yani anlamsal belirteçlerle temsil eder ve bir dönüştürücü kodlayıcı kullanır. Şekil 3’te BIT modeli gösterilmiştir. BIT modeli, her bir girdi görüntüsü için konvolüsyon bloklarını kullanarak özellik haritalarını elde ederek başlar. Daha sonra özellik haritaları, gelişmiş bitemporal özellikleri oluşturmak için Bitemporal Görüntü Dönüştürücü modülüne girdi olarak sağlanır. Son olarak ortaya çıkan özellik haritalarından tahmin modülü kullanılarak piksel düzeyinde tahminler üretilir. BIT modelinin temel anlayışı, üst düzey semantik konseptleri global

olarak öğrenmesi ve orijinal bitemporal özelliklerden yararlanacak şekilde modelin öğrenmesini sağlamaktır (Chen, vd., 2022).



Şekil 3. BIT modeli (Chen, vd., 2022)

Çalışma kapsamında kullanılan bir diğer model STANet modelidir. STANet, uzaktan algılama değişim tespiti için siyam (Siamese) tabanlı bir konum-zamansal dikkat (attention) sinir ağıdır. Model özellik çıkarımı, dikkat modülü ve metrik modülü olmak üzere üç ana bileşenden oluşur. Şekil 4'te STANet modeli gösterilmiştir. İlk aşamada değişim öncesi ve değişim sonrası içeren iki görüntü özellik çıkarımı modülüne girdi olarak sunulur ve her bir görüntü için özellik haritaları elde edilir (Chen ve Shi, 2020). İkinci aşamada, elde edilen özellik haritaları dikkat modülü kullanılarak güncellenir. Bu aşamada farklı zaman ve konumlardaki herhangi iki piksel arasındaki dikkat ağırlıklarını hesaplar ve bunları daha ayırt edici özellikler oluşturmak için kullanır. Bu modülde görüntüler nesnelerin farklı ölçeklere sahip olabileceğini göz önünde bulundurarak çok ölçekli alt bölgelere ayrılır ve her bir alt bölgeye self-attention işlemi uygulanır. Bu şekilde, çeşitli ölçeklerde konum-zamansal bağımlılıklar modellenebilmekte ve çeşitli boyutlardaki nesnelerin değişim tespiti için daha iyi temsiller üretilebilmektedir (Chen ve Shi, 2020). Üçüncü aşamada metrik modülü, güncellenen özellik haritalarını giriş görüntülerinin boyutuna göre yeniden boyutlandırdıktan sonra, iki özellik haritasındaki her piksel çifti arasındaki mesafeyi hesaplar ve bir mesafe haritası oluşturur (Chen ve Shi, 2020). Model, eğitim aşamasında değişim olan piksellerin mesafe değeri büyük, değişim olmayan piksellerin mesafe değeri küçük olacak şekilde kayıp fonksiyonunu minimize ederek optimize edilir.



Şekil 4. BIT modeli (Chen ve Shi, 2020)

Çalışmada değişim analizi sonuçları genel doğruluk (1), IoU (2), F1 skoru (3), kesinlik (precision) (4) ve duyarlılık (recall) (5) metrikleri ile değerlendirilmiştir. Yer gerçeği verisi için her bir test alanındaki değişen alanlar elle sayısallaştırılmış ve değişim olan ve olmayan alanları ifade eden ikili görüntüler elde edilmiştir.

$$\text{Genel doğruluk} = \frac{TP+TN}{TP+FP+FN+TN} \quad (1)$$

$$IoU = \frac{Prediction \cap Ground Truth}{Prediction \cup Ground Truth} \quad (2)$$

$$F1 \text{ skoru} = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (3)$$

$$Kesinlik = \frac{TP}{TP+FP} \quad (4)$$

$$Duyarlılık = \frac{TP}{TP+FN} \quad (5)$$

Burada TP, FP, TN ve FN sırasıyla gerçek pozitif, yanlış pozitif, gerçek negatif ve yanlış negatif ifade etmektedir.


3. BULGULAR

Test için kullanılan altı çalışma alanı için değişim analizi sonuçları Şekil 5'te verilmiştir. Altı test alanı arasında yer gerçeğine en yakın tahmin sonuçlarının üretildiği çalışma alanının Anadolu Üniversitesi Yunus Emre Kampüsü (Test-1) olduğu görülmektedir. Her iki derin öğrenme modeli de bu çalışma alanında yeni eklenen binaların tamamı için değişim tespit etmiştir. Bununla birlikte BIT modeli, yeni eklenen binaların geometrilerinin yansıtılması konusunda özellikle dikdörtgen olmayan bina tipleri için daha düşük doğrulukta tahmin sonucu üretmiştir. İkinci test görüntüsünde derin öğrenme modelleri Eskişehir Yunus Emre Devlet Hastanesi ve çevresindeki değişen binalar için tahmin sonucu üretmiştir. Bu test grubunda özellikle eski tarihli görüntüde bina bulunup yeni tarihli görüntüde bina bulunmayan alanlar için BIT modelinin bu değişimi tespit edemediği görülmektedir. STANet modeli, bu tip alanlar için tahmin sonucu üretmiş olsa da bu binaların geometrilerinin yansıtılması konusunda eksiklikleri mevcuttur.

Test için kullanılan bir diğer çalışma alanı (Test-3), eğitim görüntülerine göre farklı geometrik ve spektral karakteristiğe sahip binaların yer aldığı Eskişehir Teknik Üniversitesi İki Eylül Kampüsü'dür. Her iki model de bu çalışma alanı için gürültülü tahmin sonuçları üreterek binanın geometrisini yüksek doğruluk ile yansıtamamıştır. Bununla birlikte bu test grubunda BIT modeli, STANet modeline göre daha başarılı olmuştur. Dördüncü test grubu Eskişehir fuar alanını kapsamaktadır. Çalışma alanında yer alan dikdörtgen şeklinde beyaz çatılı binaların değişimi her iki model tarafından da tespit edilebilmiş olsa da diğer binaların tespitinde hatalar mevcuttur.

Beşinci çalışma alanı hem mevcut binaların silinmesi hem de yeni binaların eklenmesini içeren bir test alanıdır. Bu alanda yeni eklenen binalar modeller tarafından tespit edilebilmiştir. Bununla birlikte eski tarihli görüntüde yer alıp yeni tarihli görüntüde bulunmayan binaların tespiti konusunda STANet modeli BIT modeline göre daha başarılı olmuştur. Son test alanı yeni yapılaşan bir yerleşim alanı olup diğer test görüntülerine göre daha fazla sayıda bina

değişimi içermektedir. Çalışma alanında yer alan binaların çoğunluğu siyah çatılara sahiptir. Sonuçlar incelendiğinde STANet'in daha fazla sayıda bina değişimi tespit ettiği görülmektedir.



Şekil 5. Değişim analizi sonuçları

Doğruluk analizi sonuçları Çizelge 1’de verilmiştir. Her iki model için de en yüksek doğruluk analizi skorları Anadolu Üniversitesi Yunus Emre Kampüsü (Test-1) için elde etmiştir. Bu test alanında derin öğrenme modelleri yaklaşık %86 F1 skoru ve %76 IoU skoru ile birbirine yakın doğruluk analizi sonuçları elde etmiştir. İkinci test grubunda elde edilen doğruluk metrikleri ilk test grubuna göre düşük olduğu ve modellerin yine birbirine yakın sonuçlar ürettiği görülmektedir. Her iki derin öğrenme modeli de tüm test alanları içerisinde en düşük doğruluk metriklerini Eskişehir Teknik Üniversitesi İki Eylül Kampüsü (Test-3) için elde etmiştir. Dördüncü test grubunda BIT modeli tüm metriklerde STANet modeline göre daha yüksek skorlar elde etmiştir. Beşinci test alanı birinci test alanının ardından en yüksek skorların elde edildiği çalışma alanıdır. Her iki model de bu çalışma alanı için yaklaşık %94 genel doğruluk elde etmiştir. Son çalışma alanında (Test-6) BIT modeli, yeni yapılan binalardan birçoğunu tespit edememesi nedeniyle %47 IoU skoru elde ederken STANet modeli bu binaları daha doğru tespit ederek %72 IoU skoru elde etmiştir.

Çizelge 1. Doğruluk analizi sonuçları

Çalışma Alanı	Model	Genel Doğruluk	IoU	F1	Kesinlik	Duyarlılık
Test 1	BIT	0.955	0.752	0.858	0.902	0.819
	STANet	0.955	0.761	0.864	0.875	0.854
Test 2	BIT	0.872	0.605	0.754	0.928	0.635
	STANet	0.877	0.623	0.768	0.925	0.656
Test 3	BIT	0.830	0.427	0.598	0.946	0.437

	STANet	0.751	0.143	0.251	0.953	0.144
Test 4	BIT	0.914	0.613	0.760	0.930	0.642
	STANet	0.889	0.513	0.678	0.879	0.551
Test 5	BIT	0.944	0.646	0.785	0.941	0.673
	STANet	0.943	0.649	0.787	0.909	0.694
Test 6	BIT	0.845	0.461	0.631	0.904	0.485
	STANet	0.918	0.726	0.841	0.895	0.794

4. SONUÇLAR

Yüksek çözünürlüklü optik uzaktan algılama görüntülerine dayalı değişim analizi çalışma alanında bulunan nesnelerin karmaşıklığı ve iki tarih arasındaki farklı görüntüleme koşulları nedeniyle zorlu bir görevdir. Karmaşık çalışma alanlarındaki değişimi tanımlamak için güçlü bir değişim tespiti modelinin bu etmenleri göz önünde bulunduracak kapasitede olması önemli bir araştırma konusudur. Bu çalışmada önceden eğitilmiş, derin sinir ağı temelli BIT ve STANet modellerinin farklı çalışma alanları için otomatik değişim tespitindeki performanslarının araştırılması amaçlanmıştır. Modellerin performansı altı çalışma alanı için test edilmiş ve sonuçlar görsel değerlendirme ve doğruluk analizi metrikleri ile analiz edilmiştir. Sonuçlar incelendiğinde modellerin özellikle eski tarihte mevcut olup yeni tarihte mevcut olmayan binaları düşük doğruluk ile tespit ettiği görülmektedir. Her iki model de yeni inşa edilen binaların tespit edilmesi konusunda daha başarılı olmuştur. Bununla birlikte binaların geometrilerinin yansıtılması konusunda her iki modelin de eksiklikleri bulunmaktadır. Elde edilen sonuçlar LEVIR-CD veri seti ile eğitilmiş olan BIT ve STANet modellerinin değişim tespiti için ek eğitim veri setine ihtiyaç duyduğunu göstermektedir. Çalışmanın bir sonraki aşamasında derin öğrenme modellerinin daha yüksek doğrulukta sonuçlar üretmesi için LEVIR-CD veri seti yeni görüntüler ile genişletilecek ve eğitim işlemi genişletilmiş veri seti kullanılarak gerçekleştirilecektir.

KAYNAKLAR

- Asokan, A. ve Anitha, J.**, 2019. Change detection techniques for remote sensing applications: a survey. *Earth Science Informatics*, 12(2), 143-160.
- Chen, H ve Shi, Z.** 2020. A spatial-temporal attention-based method and a new dataset for remote sensing image change detection. *Remote Sensing*, 12(10), 1662.
- Chen, H., Qi, Z. ve Shi, Z.** 2021. Remote sensing image change detection with transformers. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-14.
- de Bem, P., de Carvalho Junior, O., Guimarães, R. F. ve Gomes, R. T.** 2020. Change detection of deforestation in the Brazilian Amazon using landsat data and convolutional neural networks, *Remote Sensing*, 12(6), 901.
- Fang, S., Li, K., Shao, J. ve Li, Z.**, 2021. SNUNet-CD: A densely connected Siamese network for change detection of VHR images. *IEEE Geoscience and Remote Sensing Letters*, 19, 1-5.
- Ferraris, V., Dobigeon, N., Wei, Q. ve Chabert, M.**, 2017. Detecting changes between optical images of different spatial and spectral resolutions: A fusion-based approach. *IEEE Transactions on Geoscience and Remote Sensing*, 56(3), 1566-1578.
- Gong, M., Zhao, J., Liu, J., Miao, Q. ve Jiao, L.**, 2015. Change detection in synthetic aperture radar images based on deep neural networks. *IEEE Transactions on Neural Networks and Learning Systems*, 27(1), 125-138.
- Ke, L., Lin, Y., Zeng, Z., Zhang, L. ve Meng, L.**, 2018. Adaptive change detection with significance test. *IEEE Access*, 6, 27442-27450.
- Kennedy, R. E., Townsend, P. A., Gross, J. E., Cohen, W. B., Bolstad, P., Wang, Y. Q. ve Adams, P.** 2009. Remote sensing change detection tools for natural resource managers: Understanding concepts and tradeoffs in the design of landscape monitoring projects. *Remote Sensing of Environment*, 113(7), 1382-1396.
- Massarelli, C.**, 2018. Fast detection of significantly transformed areas due to illegal waste burial with a procedure applicable to landsat images. *International Journal of Remote Sensing*, 39(3), 754-769.

- Radhika, K. ve Varadarajan, S.**, 2018. A neural network based classification of satellite images for change detection applications. *Cogent Engineering*, 5(1), 1484587.
- Shi, W., Zhang, M., Zhang, R., Chen, S. ve Zhan, Z.**, 2020. Change detection based on artificial intelligence: State-of-the-art and challenges. *Remote Sensing*, 12(10): 1688.
- Xu, D., Chen, R., Xing, X. ve Lin, W.**, 2017. Detection of decreasing vegetation cover based on empirical orthogonal function and temporal unmixing analysis. *Mathematical Problems in Engineering*, 2017, 5032091.
- Xu, J. Z., Lu, W., Li, Z., Khaitan, P. ve Zaytseva, V.** 2019. Building damage detection in satellite imagery using convolutional neural networks. *arXiv preprint*, arXiv:1910.06444.
- Yan, L., Xia, W., Zhao, Z. ve Wang, Y.**, 2018. A novel approach to unsupervised change detection based on hybrid spectral difference. *Remote Sensing*, 10(6), 841.
- Zhuang, H., Fan, H., Deng, K. ve Yao, G.**, 2018. A spatial-temporal adaptive neighborhood-based ratio approach for change detection in SAR images. *Remote Sensing*, 10(8), 1295.