

Impervious Soil Surface Mapping, Recent Developments and New Opportunities for Utilization

Muhammed GÜNDOĞAN^{1,a,*}, Recep GÜNDOĞAN^{2,b}

¹Politecnico Di Milano University, School of Architecture Urban Planning Construction Engineering, Milano, Italy

²Prof. Dr., Harran University, Faculty of Agriculture, Department of Soil Science and Plant Nutrition, Şanlıurfa Türkiye

*Corresponding author

Research Article

Acknowledgment

History

Received: 00/00/0000

Accepted: 25/02/2024



Copyright

This is an Open Access article distributed under the terms of the Creative Commons Attribution Licence (CC BY 4.0), which permits copying, adaptation and redistribution, provided the original work is properly cited.

ABSTRACT

Impervious soil surfaces have negative impacts on both rural areas and cities by disrupting the hydrological cycle, increasing runoff and reducing infiltration. Mitigating the negative impacts of impervious surfaces is crucial in stimulating resilient and liveable environments for both rural and urban areas. The aim of this study is to review the recent advances in impervious soil surface mapping in urban areas by integrating remote sensing data and artificial intelligence applications based on the research on impervious soil surface monitoring and the opportunities for its use in land degradation studies. According to the literature, it is seen that the studies on the identification and digital mapping of impermeable soil surfaces have gained momentum both with the increase in high-resolution data sources in remote sensing and the assessment of large volumes of data in a short time and with high accuracy by artificial intelligence. New indices specific to impervious soil surfaces have been proposed, especially with remote sensing indices created with the synergy of multiple bands of optical satellite imagery, allowing spectral errors to be reduced. In addition, with the widespread use of deep learning algorithms, high accuracy predictive impervious surface inventory maps have been obtained. Future research should focus on integrating different types of remote sensing data, developing feature or covariate selection methods for prediction algorithms, and developing new deep learning models to create more successful impervious surface maps. In this way, stakeholders such as decision makers and planners in the landscape can be provided with spatial data for sustainable land planning more quickly and accurately.

Keywords: Impervious soil surfaces, remote sensing, mapping, artificial intelligence

Geçirimsiz Toprak Yüzeyi Haritalaması, Son Gelişmeler ve Yeni Kullanım Olanakları

Bilgi

Süreç

Geliş: 00/00/0000

Kabul: 25/02/2024



Copyright

Bu, orijinal çalışmaya uygun şekilde atıfta bulunulması koşuluyla kopyalamaya, uyarlamaya ve yeniden dağıtmaya izin veren Creative Commons Atıf Lisansı (CC BY 4.0) koşulları altında dağıtılan bir Açık Erişim makalesidir.

ÖZ

Geçirimsiz toprak yüzeylerinin hem kırsal alanlar hem de şehirler üzerinde hidrolojik döngüyü bozarak yüzey akışının artmasına ve infiltrasyonun azalması gibi olumsuz etkileri vardır. Geçirimsiz toprak yüzeylerinin olumsuz etkilerinin azaltılması kırsal ve kentsel alanlar için esnek ve yaşanabilir ortamların sağlanmasında çok önemlidir. Bu çalışmanın amacı, geçirimsiz toprak yüzeyinin izlenmesi konusunda yapılmış olan araştırmalara dayanarak uzaktan algılama verileri ve yapay zekâ uygulamalarının entegrasyonu ile kentsel alanlarda geçirimsiz toprak yüzey haritalamasındaki son gelişmeleri ve arazi bozulması çalışmalarında kullanım olanaklarını ortaya koymaktır. Literatüre göre, geçirimsiz toprak yüzeylerin belirlenmesi ve sayısal olarak haritalanması çalışmaları hem uzaktan algılamadaki yüksek çözünürlüklü veri kaynaklarının artması hem de yapay zekânın büyük hacimli verileri kısa sürede ve yüksek doğrulukta değerlendirmesi ile ivme kazandığı görülmektedir. Özellikle optik uydu görüntülerinin birden çok bandının ortak kullanımı ile oluşturulan uzaktan algılama indeksleri ile spektral hataların azaltılmasına olanak tanınmasıyla, geçirimsiz toprak yüzeylere özel olan yeni indeksler önerilmiştir. Bunun yanı sıra, derin öğrenme algoritmalarının yaygınlaşması ile yüksek doğruluğa sahip tahmini geçirimsiz yüzey envanter haritalarının elde edildiği görülmüştür. Gelecekte yapılacak olan araştırmalar, farklı türdeki uzaktan algılama verilerin entegrasyonu, tahmin algoritmaları için özellik veya ortak değişken seçim yöntemlerinin geliştirilmesi ve yeni derin öğrenme modelleri geliştirilmesi ile daha başarılı geçirimsiz yüzey haritaları elde etmeye odaklanmalıdır. Böylelikle arazi peyzajında karar vericiler ve planlamacılar gibi paydaşlara sürdürülebilir arazi planlaması için mekânsal veriler daha hızlı ve doğru bir şekilde sağlanabilecektir.

Anahtar Kelimeler: Geçirimsiz toprak yüzeyi, uzaktan algılama, haritalama, yapay zekâ



muhammed.gundogan@mail.polimi.it



<https://orcid.org/0000-0002-5448-4173>



rgundogan@harran.edu.tr



<https://orcid.org/0000-0001-8877-1130>

1. Giriş

Geçirimsiz toprak yüzeyi haritalaması (GTYH), bir bölgedeki su geçirmez yüzeylerin belirlenmesi ve bu yüzeylerin oranlarının ölçülmesi işlemidir (Sun ve ark., 2017). Bu teknik genellikle uydu görüntüleri, hava fotoğrafları veya LIDAR (Işınım Ölçümü ve Algılama) verileri gibi sayısal veriler kullanılarak gerçekleştirilir (Weng, 2007a). Noktasal olmayan kaynaklı kirliliğin kontrolünde ortaya çıkan bilimsel ilgi alanlarından birisi su havzalarındaki geçirimsiz yüzeylerin tespiti ve analizidir. Belirli bir su havzasındaki geçirimsiz yüzey yüzdesi, yüzeysel akış etkilerinin ve gelecekteki su ve ekosistem kalitesinin önemli bir göstergesi olarak kabul edilmiştir (Arnold and Gibbons, 1996). Çünkü, büyük miktarda geçirimsiz yüzey bulunan su havzalarında taban suyu akışında genel bir azalma ve yüzeysel akışta ve sel sıklığında bir artış yaşanabilir (Brun and Band, 2000). Dahası, geçirimsizlik, bir drenaj havzasında rezervuar olan göllerin ve göletlerin su kalitesiyle ilgilidir. Geçirimsiz örtü ve yüzey akışındaki artış, patojenler, besin maddeleri, toksik kirleticiler ve sedimentler dahil olmak üzere noktasal olmayan kaynaklı kirleticilerin taşınmasını doğrudan etkilemektedir (Hurd and Civco, 2004).

Geçirimsiz toprak yüzeyi, yağmur sularının yeraltı su kaynaklarına sızmasını engeller, bu da yeraltı su kaynaklarının azalmasına ve kurumasına neden olabilir. Bu da toprağın verimliliğini azaltır ve bitkilerin büyümesini engeller. Bu nedenle, bir su havzasında geçirimsiz yüzey arttıkça bitki örtüsü azalacaktır bir başka deyişle geçirimsiz yüzey, bitki örtüsü ile ters orantılıdır (Dutta et al., 2021). Dolayısıyla, geçirimsiz yüzeylerle kaplı arazinin yüzdesi, arazi kullanım kategorileri ve alt kategorilerine göre önemli ölçüde değişmektedir (Chang et al., 2022). Bu nedenle, geçirimsiz yüzeyin tahmin edilmesi ve haritalanması (tespit edilmesi, izlenmesi ve analiz edilmesi) sadece su kalitesi değerlendirmesi değil, aynı zamanda arazi bozulması için de önemlidir. Çünkü, geçirimsiz yüzey artışı, doğal habitatların, toprağın ve su kaynaklarının azalmasına, erozyona, su kirliliğine ve biyolojik çeşitliliğin kaybına neden olabilir (Mu et al., 2022).

Genellikle yağışın düşük olduğu ve suyun yavaş sızdığı yarı kurak ve kurak bölgelerde toprak oluşumunu kil zengini ana materyaller oldukça etkilediğinden dolayı, bu topraklar genellikle geçirimsiz yüzey alanlarına sahiptir (Schoonover and Crim, 2015; Shahrokh et al., 2023). Çünkü, kil partikülleri su ve hava hareketini sınırlandırarak toprağın geçirimsizliğini azaltmakta ve bu durum, özellikle yağmur sularının yavaş sızmasına ve suyun toprak yüzeyinde birikmesine neden olmaktadır (Ostovari et al., 2019). Böylece, yağmur suyu ve diğer yüzey sularının toprağı sızdırmadan akmasına yani yüzeysel akışa neden olmaktadır (Valentin et al., 2004). Bu nedenle, geçirimsiz toprak yüzeyi, su erozyonuna neden olabilir veya artırabilir. Bu olgu, geçirimsiz toprak yüzeyinin, yarı kurak ve kurak koşullarda, arazi bozulma sürecindeki değişikliklerin belirlenmesinde ve bu değişiklikleri önlemek için uygun tedbirler alınmasında önemli bir unsur olarak karşımıza çıkmaktadır.

Geçirimsiz yüzeyin kırsal alanlarda yukarıda değinilen olumsuz etkilerinin yanı sıra kentsel alanlarda da olumsuz etkileri vardır. Literatürde birçok çalışma tarafından geçirimsiz yüzeylerin çevre ve kent iklimi üzerinde olumsuz etkileri ortaya konulmuştur. Simwanda et al. (2019), Lagos (Nijerya), Nairobi (Kenya), Addis Ababa (Etiyopya) ve Lusaka (Zambiya) olmak üzere dört Afrika kentinde geçirimsiz yüzey yoğunluğu ile kentsel ısı adaları arasında güçlü bir pozitif korelasyon bulmuştur. Benzer şekilde, Wang et al. (2017), Şangay'da tarım arazilerinin ve bitki örtüsünün geçirimsiz yüzeylerle değiştirilmesinin yoğun bir kentsel ısı adaları etkisine yol açtığını bulmuştur. Li et al., (2018), geçirimsiz yüzeylerin zayıf su depolama kapasitesine sahip olduğunu ve hava akımı iletimini engellediğini, bunun da kentsel arazi yüzeyi hidrolojik döngüsü, noktasal olmayan kaynak kirliliği ve biyoçeşitlilik gibi önemli eko-çevresel unsur etkilerine yol açtığını belirtmiştir. Long et al. (2020), geçirimsiz yüzeylerin mekânsal dağılımı ve dinamiklerinin, kentleşmenin ve bunun bölgesel veya kentsel hidrolojik çevre, yüzey sıcaklığı dengesi ve biyolojik çeşitlilik üzerindeki etkilerinin daha iyi anlaşılmasına katkıda bulunduğunu vurgulamıştır. Ayrıca, geçirimsiz yüzeylerin kentsel ısı adası etkisini artırdığı, yağışı ve yüzey akış hacmini artırdığı ve kentsel sel potansiyelinin yükselmesine yol açtığı bu çalışmaların ortak bulguları arasındadır. Song et al. (2015), geçirimsiz yüzeylerin hava ve toprak sıcaklığını artırdığını; hava ve toprak nem içeriğinin azalttığını bulmuştur. Genel olarak, bu çalışmalar ile geçirimsiz yüzeylerin kentler ve çevre üzerindeki olumsuz etkileri ortaya koyulmuştur.

Sonuç olarak, geçirimsiz toprak yüzeylerinin hem kırsal alanlar hem de şehirler üzerinde önemli olumsuz etkileri vardır. Kırsal alanlarda, doğal arazinin betonlaşma ile geçirimsiz yüzeylere dönüştürülmesi hidrolojik döngüyü bozarak yüzey akışının artmasına ve infiltrasyonun azalmasına neden olur. Bu durum toprak erozyonuna, su kirliliğine ve yeraltı sularının yeniden dolmasına neden olarak tarımsal verimliliği ve genel ekosistem sağlığını tehdit edebilir. Şehirlerde, geçirimsiz yüzeylerin çoğalması kentsel ısı adası etkisine katkıda bulunarak aşırı sıcaklıklara neden olmakta, hava kirliliğini ve enerji tüketimini daha da artırmaktadır. Ayrıca, geçirimsiz yüzeyler doğal drenaj düzenini bozarak sellere ve su kalitesinin bozulmasına yol açmaktadır. Bu zararlı etkilerin farkında olan sürdürülebilir arazi yönetimi uygulamaları ve yeşil altyapı çözümleri, geçirimsiz yüzeylerin etkilerinin azaltılmasında ve hem kırsal hem de kentsel alanlar için esnek ve yaşanabilir ortamların teşvik edilmesinde çok önemlidir.

2. Geçirimsiz Toprak Yüzeyi Haritalamada Uzaktan Algılama Verileri

Uydu görüntüleri, geçirimsiz yüzeylerin belirlenmesi için kullanılan en popüler uzaktan algılama kaynağıdır. Uydu görüntüleri, geniş bir yüzey alanını kaplayabilmesi, farklı spektral bantlarda yüksek çözünürlüklü veriler sağlayabilmesi ve kolayca erişilebilir olması nedeniyle geçirimsiz toprak yüzeyinin belirlenmesi için tercih edilmektedir (Weng, 2007b). Uzaktan algılama indeksleri kullanılarak geçirimsiz yüzey haritalama çalışmaları Landsat TM/ETM, MODIS, Hyperion, AVHRR ve DMSP/OLS gibi orta/kaba mekânsal çözünürlükte çeşitli uydu uzaktan algılama verileri kullanılarak gerçekleştirilmiştir (Shao et al., 2016).

Özellikle orta ve yüksek çözünürlüklü optik uydu görüntüleri, yeryüzü özelliklerini yüksek hassasiyetle belirlemek için kullanılan birçok özellik ve indeks sağlamaktadır. GTYH'de daha doğru sonuçlar elde etmek uzaktan algılama indeksleri kullanılmaktadır. Bu indekslerin kombinasyonu farklı özellikleri ölçerek GTYH için farklı yaklaşımlar sunmaktadırlar (Tian et al., 2018). Genellikle kullanılan indeksler: (I). Normalized Difference Built-up Index (NDBI): Bina ve yapıların yer aldığı alanlardaki yüzey sıcaklığı ile bitki örtüsüne sahip alanlardaki yüzey sıcaklığı arasındaki farkı ölçmektedir (Zha et al., 2003). (II). Normalized Difference Vegetation Index (NDVI): Bitki örtüsünün varlığını ve sağlığı hakkında bilgi vermektedir. GTYH'de, NDVI değerleri düşük olan alanlar (yani bitki örtüsü olmayan alanlar) geçirimsiz toprak yüzeyi olarak tanımlanabilmektedir (Li et al., 2019). (III). Normalized Difference Water Index (NDWI): Suyun varlığını ve yayılımını belirlemektedir. GTYH için, NDWI değerleri düşük olan alanlar (yani su bulunmayan alanlar) geçirimsiz toprak yüzeyi olarak tanımlanabilir (Liu et al., 2015). (IV). Soil Adjusted Vegetation Index (SAVI): NDVI'ye benzer bir indekstir ancak toprak yüzeyi ile bitki örtüsü arasındaki etkileşimi de hesaba katar (Sekertekin and Zadbagher, 2021) (V). Modified Normalized Difference Water Index (MNDWI): NDWI'ye benzer bir indekstir ancak sadece kısa dalga uzunluğundaki infrared bantları kullanır (Sun et al., 2016).

Farklı çalışmalar geçirimsiz yüzey çıkarımı için çeşitli uzaktan algılama indekslerini karşılaştırmış ve değerlendirmiştir. Örneğin, Chen ve ark. (2020), Sentinel-2 görüntülerini kullanarak NDBI, IBI (index-based built-up index), BCI (biophysical composition index), CBI (combinational build-up index), CBCI (combinational biophysical composition index) ve ENDISI (enhanced normalized difference impervious surfaces index) dahil olmak üzere altı geçirimsiz yüzey çıkarma indeksini karşılaştırmıştır. Benzer şekilde, Tang ve Xu (2017), geçirimsiz yüzey ile bitki örtüsü arasındaki negatif korelasyona dayanarak NDISI (normalized difference impervious surface index) ve BCI (biophysical composition index) vb. dahil olmak üzere uzaktan algılama spektral indekslerinin GTYH'de kullanışlı bir veri kaynağı olduğunu belirtmiştir. Ek olarak, Su ve ark (2022), görünür ve yakın kızılötesi bantlara dayalı yeni bir Normalized Impervious Surface Index (NISI) ismiyle geçirimsiz yüzey spektral indeksi önermiştir. Ayrıca, Fang ve ark (2019), Landsat 8 multispektral uzaktan algılama görüntülerinden geçirimsiz yüzey dağılımını çıkarmak için Kıyı / Aerosol bandına (0,433 ila 0,453 um dalga boyu aralığında) ve normalleştirilmiş fark bitki örtüsü indeksine dayalı yeni bir uzaktan algılama indeksi önermiştir (a ratio-based impervious surface index, RISI).

Sonuç olarak, yukarıda değinilen çalışmaların ortak noktaları: (I) uzaktan algılama indekslerinin GTYH için oldukça kullanışlı ve gerekli veri kaynağı olduğudur, (II) uzaktan algılama indeksleri seçiminin ise veri türüne, uzamsal çözünürlüğe ve çalışma alanına bağlı olduğudur.

3. Geçirimsiz Toprak Yüzey Haritalamada Modelleme Çalışmaları

Modelleme çalışmaları, geçirimsiz toprak yüzeylerinin doğru bir şekilde haritalanmasında önemli bir rol oynamaktadır. Bu çalışmalar, toprak yüzeyindeki geçirimsiz alanların dağılımını ve kapsamını tahmin etmek için çeşitli teknikler ve algoritmalar kullanır. Arazi kullanımı, topografya ve uzaktan algılama verileri gibi faktörleri bir araya getiren modelleme çalışmaları, geçirimsiz toprak yüzeylerinin daha iyi anlaşılmasına ve yönetilmesine katkıda bulunarak kentsel planlama, çevresel izleme ve afet yönetimi çabalarına yardımcı olmaktadır.

4. Uzaktan Algılama ile Geçirimsiz Toprak Yüzeyi Haritalaması

Uydu görüntüleri kullanılarak GTYH için, önce görüntülerin ön işleme adımları gerçekleştirilir. Bu adımlar, atmosferik düzeltme, geometrik düzeltme, spektral kalibrasyon ve görüntü uyumsuzluklarının düzeltilmesi gibi işlemleri içermektedir (Sekertekin et al., 2018). Ardından, uydu görüntüsüne özgü özellikler ve indeksler kullanılarak geçirimsiz toprak yüzeylerin belirlenmesi için bir sınıflandırma algoritması uygulanmaktadır. Uydu görüntülerinden geçirimsiz yüzey haritalaması yapılırken, genellikle görüntü sınıflandırma yöntemleri kullanılmaktadır. Bu yöntemler, denetimli (supervised) ve denetimsiz (unsupervised) sınıflandırma olarak ikiye ayrılmaktadır (Powell et al., 2007). Denetimsiz sınıflandırmada, algoritma uydu görüntüsündeki doğal gruplamaları otomatik olarak belirlerken; denetimli sınıflandırmada, önceden belirlenmiş eğitim verileri kullanılmaktadır. Genellikle bunlar arasında, karar ağaçları, destek vektör makineleri (SVM) ve yapay sinir ağları (ANN) gibi yöntemler yer almaktadır (Mohapatra and Wu, 2007; Sun, 2011; Xian, 2007). Bu yöntemler, geçirimsiz toprak yüzeylerin belirlenmesi için farklı doğruluk oranlarına sahiptir ve çalışma amaçlarına bağlı olarak tercih edilebilir iken makine öğrenme algoritmalarında yaşanan gelişmelere bağlı olarak, gün geçtikçe literatürde yeni yapay zekâ modelleri kullanan araştırmaların sayıları giderek artmaktadır.

Son zamanlarda yapılan bazı önemli çalışmalar: Huang et al. (2019): Bu çalışmada, yüksek çözünürlüklü uydu görüntüleri ve derin öğrenme teknikleri kullanılarak GTYH gerçekleştirilmiştir. Çalışma, doğruluk oranlarını artırmak için yüksek çözünürlüklü uzaktan algılama görüntülerinden kentsel geçirimsiz yüzeylerin çıkarılmasında, piksel tabanlı ve nesne tabanlı sınıflandırmayı kapsamlı bir şekilde ele alan ve piksel komşuluk özelliklerinin ve piksellerin ait olduğu nesnelerin şekil özelliklerini bir araya getiren, yüksek çözünürlüklü uzaktan algılama görüntülerine dayalı Evrimsel Sinir Ağı (CNN) önermiştir. Zheng et al. (2023), kentsel alanlarda geçirimsiz yüzeyin Landsat uydu görüntüsü kullanılarak belirlenmesi için en uygun makine öğrenme modelini ve geçirimsiz yüzey değişiklikleri ile kentsel su baskınları arasındaki korelasyonu araştırmıştır. Bu çalışmada, optimal modeli elde etmek için Naive Bayes (NB), CNN, SVM, Capsules Network (CapsNet) ve Random Forest (RF) gibi beş farklı makine öğrenimi ve derin öğrenme algoritmasını kentsel geçirimsiz yüzeyi çıkarmak için kullanılmıştır. CNN'in kentsel geçirimsiz yüzeyini çıkarmak için en iyi seçenek olduğunu bildirmiştir. Buna ek olarak, geçirimsiz yüzeyi çıkarmak için kullanılmış olan en uygun modele dayanarak, çalışma alanındaki su baskınları ve kentsel geçirimsiz arasında kısmi bir korelasyon analizi yapılmış, ikisi arasında 0.979 kısmi korelasyon katsayısı ile pozitif bir korelasyon olduğu sonucuna varılmıştır. Chang ve ark. (2023), Birleşmiş Milletler Sürdürülebilir Kalkınma Hedefi 11-Sürdürülebilir Şehirler ve Topluluklar hedeflerine katkıda bulunmak için geçirimsiz yüzeylerin alanında meydana gelen artışların, kentsel genişlemenin ve doğal çevrenin bozulma göstergesi olarak ele aldıkları araştırmada: kentsel alanlarda, geçirimsiz toprak yüzeyini yüksek doğrulukta ve otomatik olarak belirlediği için Small Attention Hybrid Unet (SAH-Unet) derin öğrenme modelini önermiştir. SAH-Unet ağı diğer klasik segmentasyon ağlarıyla karşılaştırıldığında Accuracy = 0.91, F-score = 0.91, Recall = 0.91 ve Precision = 0.90 doğruluk değerleri elde etmişlerdir ve bu modelin üstün hassasiyet ve doğruluğa sahip olduğunu bildirmişlerdir. Sonuç olarak, bu çalışmaların ortak vurgusu: yapay zekâ algoritmalarının ve uzaktan algılama teknolojisinin sürekli gelişmesiyle, derin öğrenme yoluyla kentsel geçirimsiz yüzey verilerinin çıkarılmasında daha fazla ilerleme kaydedileceği olmasıdır.

5. Sonuç

Geçirimsiz toprak yüzeyi haritalaması (GTYH), su geçirmez yüzeylerin belirlenmesi ve oranlarının ölçülmesi işlemidir. Bu çalışmada, uydu görüntüleri, hava fotoğrafları veya LIDAR verileri gibi sayısal veriler kullanılarak GTYH yöntemleri incelenmiştir. Bu teknik, su havzalarındaki geçirimsiz yüzeylerin tespiti ve analizi için önemlidir, çünkü geçirimsiz yüzey yüzdesi, su akışı ve ekosistem kalitesi açısından bir gösterge olarak kabul edilir. Geçirimsiz yüzeylerin artması, taban suyu akışında azalmaya ve yüzey akışında artışa neden olabilir. Ayrıca, geçirimsizlik, drenaj havzasındaki göllerin ve göletlerin su kalitesiyle ilgilidir. Geçirimsizlik, kirleticilerin taşınmasını etkileyerek su kaynaklarının kalitesini olumsuz etkileyebilir.

Son zamanlarda yapılan önemli çalışmalardan biri, yüksek çözünürlüklü uydu görüntüleri ve derin öğrenme tekniklerine odaklanmıştır. Piksel komşuluk özelliklerini ve nesnelerin şekil özelliklerini birleştirme gibi hibrit yaklaşımların tahmin sonuçlarını iyileştirdiği görülmüştür. Öte yandan, yüksek doğrulukta ve otomatik olarak geçirimsiz toprak yüzeyini belirleme yeteneğine sahip derin öğrenme modellerinin gittikçe geliştiği gözlemlenmiştir. Bu çalışmaların ortak vurgusu, yapay zekâ algoritmalarının ve uzaktan algılama teknolojisinin gelişmesiyle kentsel geçirimsiz yüzeylerin verilerinin çıkarılmasında ilerleme kaydedileceğidir.

Yapay zekâ ve uzaktan algılama kullanarak geçirimsiz yüzeyleri daha doğru bir şekilde tahmin etmek için gelecek araştırmalar aşağıdaki alanlara odaklanmalıdır:

- Çoklu kaynaklı uzaktan algılamadan elde edilen görüntülerin entegrasyonu: Önceki çalışmalar, çoklu kaynaklı uzaktan algılamadan elde edilen görüntülerin birleştirilmesinin büyük alanlarda geçirimsiz yüzey tahmininin doğruluğunu artırabileceğini göstermiştir. Bu nedenle, gelecek araştırmalar farklı türdeki uzaktan algılama verilerini, optik ve SAR verilerini entegre etmeye odaklanmalı ve geçirimsiz yüzey tahmininin doğruluğunu artırmalıdır.

- Özellik seçimi: Geçirimsiz yüzeylerin doğru bir şekilde tahmin edilmesi, kentsel arazi örtüsünün çeşitliliği nedeniyle hala zorlu bir görevdir. Bu nedenle, gelecek araştırmalar, geçirimsiz yüzeyleri diğer arazi örtülerinden etkili bir şekilde ayırt edebilen yeni özellik seçimi yöntemleri geliştirmeye odaklanmalıdır.

- Derin öğrenme: Derin öğrenme, uzaktan algılama verilerinden geçirimsiz yüzeyleri doğru bir şekilde tespit etmede büyük potansiyele sahiptir. Bu nedenle, gelecek araştırmalar, uzaktan algılama verilerinden geçirimsiz yüzeyleri doğru bir şekilde tahmin edebilen yeni derin öğrenme modelleri geliştirmeye odaklanmalıdır.

- Mekânsal çözünürlük: Uzaktan algılama verilerinin mekânsal çözünürlüğü, geçirimsiz yüzey tahmininin doğruluğu üzerinde önemli bir etkiye sahiptir. Bu nedenle, gelecek araştırmalar, yüksek mekânsal çözünürlükte geçirimsiz yüzeyleri doğru bir şekilde tahmin edebilen yeni yöntemler geliştirmeye odaklanmalıdır.

References

- Arnold, C.L., Gibbons, C.J., 1996. Impervious Surface Coverage: The Emergence of a Key Environmental Indicator. *Journal of the American Planning Association* 62, 243–258. <https://doi.org/10.1080/01944369608975688>
- Brun, S., Band, L., 2000. Simulating runoff behavior in an urbanizing watershed. *Computers, Environment and Urban Systems* 24, 5–22. [https://doi.org/10.1016/S0198-9715\(99\)00040-X](https://doi.org/10.1016/S0198-9715(99)00040-X)
- Chang, M., Luo, X., Zhang, Y., Pang, Y., Li, M., Liu, J., Da, L., Song, K., 2022. Land-use diversity can better predict urban spontaneous plant richness than impervious surface coverage at finer spatial scales. *Journal of Environmental Management* 323, 116205. <https://doi.org/10.1016/j.jenvman.2022.116205>
- Chang, R., Hou, D., Chen, Z., Chen, L., 2023. Automatic Extraction of Urban Impervious Surface Based on SAH-U-net. *Remote Sensing* 15, 1042. <https://doi.org/10.3390/rs15041042>

- Chen, J., Chen, S., Yang, C., He, L., Hou, M., Shi, T., 2020. A comparative study of impervious surface extraction using Sentinel-2 imagery. *European Journal of Remote Sensing* 53, 274–292. <https://doi.org/10.1080/22797254.2020.1820383>
- Dutta, D., Rahman, A., Paul, S.K., Kundu, A., 2021. Impervious surface growth and its inter-relationship with vegetation cover and land surface temperature in peri-urban areas of Delhi. *Urban Climate* 37, 100799. <https://doi.org/10.1016/j.uclim.2021.100799>
- Fang, H., Wei, Y., Dai, Q., 2019. A novel remote sensing index for extracting impervious surface distribution from Landsat 8 OLI imagery. *Applied Sciences (Switzerland)* 9. <https://doi.org/10.3390/app9132631>
- Huang, F., Yu, Y., Feng, T., 2019. Automatic extraction of impervious surfaces from high resolution remote sensing images based on deep learning. *Journal of Visual Communication and Image Representation* 58, 453–461. <https://doi.org/10.1016/j.jvcir.2018.11.041>
- Hurd, J.D., Civco, D.L., 2004. Temporal Characterization of impervious surfaces for the State of Connecticut, in: *ASPRS Annual Conference Proceedings*. p. Unpaginated CD ROM.
- Li, C., Liu, M., Hu, Y., Zong, M., Zhao, M., Todd Walter, M., 2019. Characteristics of impervious surface and its effect on direct runoff: a case study in a rapidly urbanized area. *Water Supply* 19, 1885–1891. <https://doi.org/10.2166/ws.2019.064>
- Li, M., Zang, S., Wu, C., Na, X., 2018. Spatial and temporal variation of the urban impervious surface and its driving forces in the central city of Harbin. *Journal of Geographical Sciences* 28, 323–336. <https://doi.org/10.1007/s11442-018-1475-z>
- Liu, X., Hu, G., Ai, B., Li, X., Shi, Q., 2015. A Normalized Urban Areas Composite Index (NUACI) Based on Combination of DMSP-OLS and MODIS for Mapping Impervious Surface Area. *Remote Sensing* 7, 17168–17189. <https://doi.org/10.3390/rs71215863>
- Long, X.Y., Shao, Z.F., Feng, X.X., 2020. URBAN IMPERVIOUS SURFACE EXTRACTION BASED on REMOTE SENSING IMAGES. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives* 42, 357–360. <https://doi.org/10.5194/isprs-archives-XLII-3-W10-357-2020>
- Mohapatra, R.P., Wu, C., 2007. Subpixel imperviousness estimation with IKONOS imagery: An artificial neural network approach, in: *Remote Sensing of Impervious Surfaces*. pp. 21–37.
- Mu, X., Qiu, J., Cao, B., Cai, S., Niu, K., Yang, X., 2022. Mapping Soil Erosion Dynamics (1990–2020) in the Pearl River Basin. *Remote Sensing* 14, 5949. <https://doi.org/10.3390/rs14235949>
- Ostovari, Y., Ghorbani-Dashtaki, S., Kumar, L., Shabani, F., 2019. Soil erodibility and its prediction in semi-arid regions. *Archives of Agronomy and Soil Science* 65, 1688–1703. <https://doi.org/10.1080/03650340.2019.1575509>
- Powell, S., Cohen, W., Yang, Z., Pierce, J., Alberti, M., 2007. Quantification of impervious surface in the Snohomish Water Resources Inventory Area of Western Washington from 1972-2006. *Remote Sensing of Environment*. <https://doi.org/10.1016/j.rse.2007.09.010>
- Schoonover, J.E., Crim, J.F., 2015. An Introduction to Soil Concepts and the Role of Soils in Watershed Management. *Journal of Contemporary Water Research & Education* 154, 21–47. <https://doi.org/10.1111/j.1936-704x.2015.03186.x>
- Sekertekin, A., Abdikan, S., Marangoz, A.M., 2018. The acquisition of impervious surface area from LANDSAT 8 satellite sensor data using urban indices: a comparative analysis. *Environmental Monitoring and Assessment* 190. <https://doi.org/10.1007/s10661-018-6767-3>
- Sekertekin, A., Zadbagher, E., 2021. Simulation of future land surface temperature distribution and evaluating surface urban heat island based on impervious surface area. *Ecological Indicators* 122, 107230. <https://doi.org/10.1016/j.ecolind.2020.107230>
- Shahrokh, V., Khademi, H., Zeraatpisheh, M., 2023. Mapping clay mineral types using easily accessible data and machine learning techniques in a scarce data region: A case study in a semi-arid area in Iran. *CATENA* 223, 106932. <https://doi.org/10.1016/j.catena.2023.106932>
- Shao, Z., Fu, H., Fu, P., Yin, L., 2016. Mapping urban impervious surface by fusing optical and SAR data at the decision level. *Remote Sensing* 8. <https://doi.org/10.3390/rs8110945>

- Simwanda, M., Ranagalage, M., Estoque, R.C., Murayama, Y., 2019. Spatial analysis of surface urban heat Islands in four rapidly growing african cities. *Remote Sensing* 11. <https://doi.org/10.3390/rs11141645>
- Song, Y., Li, F., Wang, X., Xu, C., Zhang, J., Liu, X., Zhang, H., 2015. The effects of urban impervious surfaces on eco-physiological characteristics of Ginkgo biloba: A case study from Beijing, China. *Urban Forestry and Urban Greening* 14, 1102–1109. <https://doi.org/10.1016/j.ufug.2015.10.008>
- Su, S., Tian, J., Dong, X., Tian, Q., Wang, N., Xi, Y., 2022. An Impervious Surface Spectral Index on Multispectral Imagery Using Visible and Near-Infrared Bands. *Remote Sensing* 14. <https://doi.org/10.3390/rs14143391>
- Sun, G., Chen, X., Jia, X., Yao, Y., Wang, Z., 2016. Combinational Build-Up Index (CBI) for Effective Impervious Surface Mapping in Urban Areas. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9, 2081–2092. <https://doi.org/10.1109/JSTARS.2015.2478914>
- Sun, G., Chen, X., Ren, J., Zhang, A., Jia, X., 2017. Stratified spectral mixture analysis of medium resolution imagery for impervious surface mapping. *International Journal of Applied Earth Observation and Geoinformation* 60, 38–48. <https://doi.org/10.1016/j.jag.2017.04.006>
- Sun, Z., 2011. Estimating urban impervious surfaces from Landsat-5 TM imagery using multilayer perceptron neural network and support vector machine. *Journal of Applied Remote Sensing* 5, 053501. <https://doi.org/10.1117/1.3539767>
- Tang, F., Xu, H., 2017. Impervious surface information extraction based on hyperspectral remote sensing imagery. *Remote Sensing* 9. <https://doi.org/10.3390/rs9060550>
- Tian, Y., Chen, H., Song, Q., Zheng, K., 2018. A Novel Index for Impervious Surface Area Mapping: Development and Validation. *Remote Sensing* 10, 1521. <https://doi.org/10.3390/rs10101521>
- Valentin, C., Rajot, J.-L., Mitja, D., 2004. Responses of soil crusting, runoff and erosion to fallowing in the sub-humid and semi-arid regions of West Africa. *Agriculture, Ecosystems & Environment* 104, 287–302. <https://doi.org/10.1016/j.agee.2004.01.035>
- Wang, H., Zhang, Y., Tsou, J.Y., Li, Y., 2017. Surface urban heat island analysis of shanghai (China) based on the change of land use and land cover. *Sustainability (Switzerland)* 9. <https://doi.org/10.3390/su9091538>
- Weng, Q., 2007a. Remote Sensing of Impervious Surfaces, *Remote Sensing of Impervious Surfaces*. <https://doi.org/10.1201/9781420043754.fmatt>
- Weng, Q., 2007b. Remote sensing of impervious surfaces: An overview, in: *Remote Sensing of Impervious Surfaces*. pp. xv–xxvii.
- Xian, G., 2007. Mapping impervious surfaces using classification and regression tree algorithm, in: *Remote Sensing of Impervious Surfaces*. pp. 39–58. <https://doi.org/10.1201/9781420043754.ch3>
- Zha, Y., Gao, J., Ni, S., 2003. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing* 24, 583–594. <https://doi.org/10.1080/01431160304987>
- Zheng, Z., Yang, B., Liu, S., Xia, J., Zhang, X., 2023. Extraction of impervious surface with Landsat based on machine learning in Chengdu urban, China. *Remote Sensing Applications: Society and Environment* 30, 100974. <https://doi.org/https://doi.org/10.1016/j.rsase.2023.100974>