

MAKİNE ÖĞRENİMİ VE UZAKTAN ALGILAMA VERİLERİ İLE ARAZİ KULLANIMINDAKİ DEĞİŞİKLİKLERİN ANALİZİ: ANKARA İLİ YENİMAHALLE İLÇESİ ARAZİ KULLANIMINDAKİ DEĞİŞİM

Mithat Emre KIBRIS¹

Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Jeoloji Mühendisliği Anabilim Dalı, Beytepe, Ankara, emrekibris@hacettepe.edu.tr

ÖZET

Afet, savaş, kuraklık ve pandemi gibi durumlarda ülkelerin gıda stoklarının hazır ve yeterli olmaması geniş bir coğrafyayı etkileyebilecek bir krize dönüşebilmektedir. Bu yüzden ülkeler bu gibi durumlara hazırlıklı olmalı ve gerekli önlemleri almalıdır. Tarım alanlarındaki değişimi ortaya koyan arazi kullanımı değişimleri bu konuda veri sunması açısından önlemlerin alınmasında ve stratejik planlamaların yapılmasında yol gösterici olmaktadır. Günümüzde arazi örtüsü/arazi kullanım değişimlerinin tespitinde uzaktan algılama (UA) ve coğrafi bilgi sistemlerinden (CBS) yararlanılmakta olup arazi örtüsü/arazi kullanımı değişimlerinin belirlenmesinde başvurulan en etkili yöntemlerdendir.

Bu çalışmada temel jeo-uzamsal veri/GIS/Uzaktan Algılama kapsamında, çeşitli veriler kullanılarak, nesne tabanlı görüntü analizi ve makine öğreniminin algoritmaları uygulanarak gelişmiş jeo-uzamsal analiz yapılmıştır. Makine öğrenimi yapay zeka kavramının alt kümelerinden biri olup bilgisayarlara karmaşık örüntüleri algılama ve veriye dayalı akılcı kararlar verebilme becerisi kazandırma prensibine dayanmaktadır. Günümüzün makine öğreniminin iki amacı vardır, biri verileri geliştirilen modellere göre sınıflandırmak, diğeri ise bu modellere dayalı olarak gelecekteki sonuçlar için tahminler yapmaktır. Çalışmada uydu görüntüleri kullanılarak LULC (Arazi Kullanımı ve Arazi Örtüsü) haritası elde edilmiş, uzaktan algılama haritasının doğruluğu değerlendirilmiş ve makine öğrenimi algoritmaları ile çalışma alanı olarak belirlenen Ankara ili Yenimahalle ilçesindeki arazi kullanımındaki 2004-2022 yılları arasındaki değişim ortaya konularak tarım alanlarındaki azalış hakkında bilgi elde edilmeye çalışılmıştır.

Anahtar Sözcükler: Uzaktan algılama, makine öğrenimi, yapay zeka, arazi kullanımı değişimi, CBS

ABSTRACT

ANALYSIS OF IN LAND USE WITH MACHINE LEARNING AND REMOTE SENSING DATA: CHANGE IN LAND USE IN YENİMAHALLE DISTRICT, ANKARA

In cases such as disasters, wars, droughts and pandemics, the fact that the food stocks of the countries are not ready and sufficient can turn into a crisis that can affect a wide geography. Therefore, countries should be prepared for such situations and take the necessary precautions. Land use changes, which reveal the change in agricultural areas, are guiding in taking precautions and making strategic plans in terms of providing data on this issue. Today, remote sensing (UA) and geographic information systems (GIS) are used in the determination of land cover and land use changes, and they are the most effective methods used in determining land cover and land use changes.

In this study, advanced geospatial analysis was performed by applying object-based image analysis and machine learning algorithms using various data within the scope of basic geospatial data/GIS/Remote Sensing. Machine learning is one of the subsets of the concept of artificial intelligence and is based on the principle of giving computers the ability to detect complex patterns and make rational decisions based on data. Today's machine learning has two purposes, one is to classify data according to the models developed and the other is to make predictions for future results based on these models. In the study, LULC (Land Use and Land Cover) map was obtained by using satellite images, the accuracy of the remote sensing map was evaluated, and the change in land use in Yenimahalle district of Ankara province, which was determined as the study area by machine learning algorithms, between the years 2004-2022, and information about the decrease in agricultural areas was obtained.

Keywords: Remote sensing, machine learning, artificial intelligence, land use change, GIS

1. GİRİŞ

Arazi örtüsünün meydana gelen afetlerle değişmesi veya insan eliyle kontrolsüz bir şekilde değiştirilmesi sonucu yaşanan kayıplar, küresel biyoçeşitlilik krizinde önemli bir rol oynamaktadır. Arazi örtündeki değişimler ve toprak kayıpları, biyojeokimyasal döngülerin değişmesine neden olmaktadır. Ekosistemlerin yapısı ve işleyişindeki bu değişimler, ve böylece insan ihtiyaçlarını karşılamada yetersiz kalınmasının temel etkenlerinden biri olarak değerlendirilmektedir. 1990 yılında 0,76 ha olan kişi başına toplam tarım alanı miktarı, 2018 yılında 0,46 ha alana kadar gerilemiştir. Günümüze kadar geçen sürede tarım alanlarının daha da azaldığı düşünüldüğünde olağanüstü dönemlerin içerdiği yüksek risk dolayısıyla, tarımsal açıdan dışarıya bağımlı olmak hiçbir ülke için istenen bir durum değildir. Bu yüzden ülkeler afet, savaş, kuraklık ve pandemi gibi durumlarda ihtiyaç duyabilecekleri gıda stoklarını hazır durumda bulundurmak zorundadırlar.

Uzaktan Algılama (UA) ve Coğrafi Bilgi Sistemler (CBS), arazi örtüsü ve arazi kullanımı değişimlerinin gözlemlenmesinde başvurulan en etkili yöntemlerdendir. UA ve CBS'nin birlikte entegrasyonu, birçok yer bilimi çalışmalarına kaynak sağlayan arazi örtüsü/arazi kullanımlarının tespiti, zamansal ve mekansal değişikliklerin gözlemlenmesi, planlanması ve yönetiminde de büyük kolaylıklar sağlamaktadır.

Afet, savaş, kuraklık ve pandemi gibi durumlarda ülkelerin gıda stoklarının hazır ve yeterli olmaması geniş bir coğrafyayı etkileyebilecek küresel bir krize dönüşebilmektedir. Bu yüzden ülkeler bu gibi durumlara hazırlıklı olmalı ve gerekli önlemleri almalıdır. Tarım alanlarındaki değişimi ortaya koyan arazi kullanımı değişimleri bu konuda veri sunması açısından önlemlerin alınmasında ve stratejik planlamaların yapılmasında yol gösterici olmaktadır. Günümüzde arazi örtüsü ve arazi kullanım değişimlerinin tespitinde uzaktan algılama (UA) ve coğrafi bilgi sistemlerinden (CBS) yararlanılmaktadır.

Hızlı kentleşme süreçleri, özellikle kıyı arazi ıslahı süreci, LULC haritasındaki değişikliklerden tanınabilir. Bu ilerleme, gelecekte arazi yönetimi, tehlike azaltma, acil durum müdahalesi ve çevre yönetimi için kentsel bölgede hızlı değişiklik tespiti gerçekleştirmek için daha fazla uygulanabilir. Çalışmada uydu verileri kullanılarak (Arazi Örtüsü ve Arazi Örtüsü) LULC haritası elde edilmiş ve uzaktan algılama haritasının doğruluğu değerlendirilmiş ve farklı makine öğrenimi algoritmaları ile çalışma alanının olarak belirlenen Ankara ili Yenimahalle ilçesindeki arazi kullanımındaki 2004-2022 yılları arasındaki değişim ortaya konularak yapılaşmanın tarım alaları üzerindeki baskısı ortaya konulmaya çalışılmıştır.

1.1 Çalışma Alanı


İnceleme alanı Ankara ili, Yenimahalle ilçesinde yer almaktadır. İnceleme alanının merkeze uzaklığı 12 km dir. İnceleme alanı Ankara ilinde yer almakta olup, Yenimahalle Merkez Yenimahalle ilçesine bağlıdır. Kentsel yayılımın tarımsal alanlara baskısı üzerine bilgi edinmek için ilçenin kentleşme ve yapılaşma hızının daha yoğun olduğu batı tarafında yer alan Yeni Batı, Susuz ,Kardelen, Turgut Özal, Ostim, Serhat ve Yuva Köy Mahallerinden oluşan alan çalışma alanı olarak seçilmiştir

Yenimahalle Merkez semtinin Ankara şehir merkezine mesafesi ise yaklaşık 14 kilometredir. Yenimahalle Merkez rakımı 831 metredir (ortalama deniz seviyesine göre yüksekliği). İlçe doğu yönünde Mira dağı, batı yönünde Ayaş dağları, kuzey yönünde Ova Çayı'nın vadilerle ayırdığı Kızılcahamam dağlarının tepeleri ve güney yönünde ise Polatlı-Haymana Ovası'nı kapsayan geniş bir alana sahiptir, ilçe içinde yer alan en büyük akarsu Ankara Çayı'dır. İç Anadolu Bölgesi'nde Ankara İline bağlı olan Yenimahalle kuzeybatısında Kazan, güneybatısında Etimesgut, güneydoğusunda Çankaya ve kuzeydoğusunda Keçiören ilçeleri bulunmaktadır. İlçenin bu yollarla bağlantısı bulunmaktadır. Ankara İli, 39°57' kuzey enlemi ile 32°53' doğu boylamları arasında, iki ayrı coğrafi bölge içinde kalmaktadır. Ankara ilinin Güney kısmında Tuz Gölü çanağı, Kepez Ovaları ve Hacıbekirözü gibi düzlükleri bulunur. Kuzeyde, Çubuk ve Kızılcahamam ilçelerinde yer yer sarp görünüşlü Yıldırım, Işık ve Yakut dağları, Batıda Ayaş, Beypazarı ve Nallıhan ilçelerinin kuzey sınırları Karakiriş, Kartal ve Manastır dağları ile çevrilmiştir. **Şekil 1.**'de çalışma alanının yer bulduru haritası yer almaktadır.


2.3 Makine Öğrenmesi ve Çalışmada Kullanılan Makine Öğrenmesi Yöntemleri

Makine öğrenimi, bilgisayarların, açıkça programlanmadan görevleri nasıl yerine getirebileceklerini keşfetmelerini içerir. Belirli görevleri yerine getirmeleri için sağlanan verilerden öğrenen bilgisayarları kapsar. Bilgisayarlara atanan basit görevler için, makineye eldeki sorunu çözmek için gereken tüm adımları nasıl uygulayacağını bildiren algoritmalar programlamak mümkündür.

Uygulamada, programcıların gerekli her adımı belirlemesinden ziyade, makinenin kendi algoritmasını geliştirmesine yardımcı olmak daha etkili olabilir. Günümüzün modern makine öğreniminin iki amacı vardır, biri verileri geliştirilen modellere göre sınıflandırmak, diğer amaç ise bu modellere dayalı olarak gelecekteki sonuçlar için tahminler yapmaktır (Kıbrıs, 2022). Makine öğrenimi, uzaktan algılanan görüntülerin etkili ve verimli bir şekilde sınıflandırılması için potansiyel sunar. Makine öğreniminin güçlü yönleri, yüksek boyutlu verileri işleme ve çok karmaşık özelliklere sahip sınıfları haritalama kapasitesini içerir. Bununla birlikte, bir makine öğrenimi sınıflandırmasının uygulanması kolay değildir ve literatür, birçok önemli konu hakkında çelişkili tavsiyeler sunmaktadır. (Maxwell vd., 2018)




Şekil 2. Yapay zeka, makine öğrenimi ve derin öğrenme arasındaki ilişki.



Şekil 3. Makine öğrenmesindeki öğrenme çeşitleri.


Makine öğrenimi (ML) tekniği, uzaktan algılama veri analizi için yaygın olarak kullanılmaktadır. Geleneksel denetimli veri sınıflandırma görevini bir regresyon problemi olarak ele alırsak, popüler yöntemler arasında Yapay Sinir Ağı (YSA), Lojistik Regresyon (LR) ve Destek Vektör Makinesi (SVM) bulunur. Destek vektör makinesi makine öğreniminde, SVM'ler, sınıflandırma ve regresyon analizi için kullanılan denetimli öğrenme modelidir (Liu vd., 2016). Makine öğrenimi algoritmaları kullanarak performanslarını artırabilir. Sınıflandırmanın amacı, girdi verilerine dayalı olarak ayrık değerleri tahmin etmektir. Makine öğrenimi türlerinin sınıflandırılması için farklı yaklaşımlar vardır. Bunlar denetimli öğrenme, denetimsiz öğrenme ve yarı denetimli öğrenmedir. Denetimli öğrenmede uzmanlar bir öğretmen olarak hareket eder, bilgisayarı girdi tahmin edicilerinde bulunan eğitim verileriyle besler ve cevaplar, çıktı ve veriden doğruluğu gösterir. Bu algoritmalar, uzmanın verilerde ne arayacağını bilmediği durumlarda özellikle yararlıdır. Denetimli öğrenme, rastgele orman sınıflandırması kullanıp ve etiket verilerine göre eğitiliyorsa, yarı denetimli öğrenme algoritması kullanılıyor demektir. Bu yöntem, grup üyeliklerine rağmen etiketlenmemiş verilerinin bilinmeyen olduğu fikrinden yararlanır. Bu veriler, grup parametreleri hakkında önemli bilgiler taşır.



Şekil 4. Denetimli, yarı denetimli ve denetimsiz algoritmalar.

Denetimsiz öğrenme makinelerin ve yazılım araçlarının belirli bir bağlamda ideal davranışı otomatik olarak belirlemesine olanak tanır. Denetimli öğrenme yaygın olarak özel analizler için, özellikle denetimli öğrenmede uydu görüntüsü sınıflandırması için kullanılır. Denetimsiz öğrenme kavramı, denetimli öğrenme kadar yaygın değildir ve sıklıkla kullanılmamaktadır. Sınıflandırma problemini ve ayrıca şekil ve renk farkını tanımak için kendi başına çalışan bir sistemdir. Denetimsiz öğrenme sistemi eldeki problemle ilgili bilgileri tanıyacak ve daha sonra tüm benzer nesneleri birlikte gruplayacaktır. Bu nesneye vereceği etiketler makinenin kendisi tarafından tasarlanacaktır. Denetimsiz öğrenmede, etiketler makineler tarafından, makinenin kendisi tarafından çözülür. Bu da denetimli öğrenmeye göre büyük bir dezavantajdır çünkü denetimli öğrenmede sınıflandırılan nesnelere verilen etiketler analist veya uzman tarafından sağlanır. Denetimsiz öğrenme algoritmalarının ana türleri, kümeleme ALGOL algoritmalarını ve ilişkilendirmeyi içerir. K- Means clustering , ISODATA, Association Rules bu algoritmalara örnek olarak verilebilir.

Makine öğrenimi sınıflandırıcıları, ideal olarak optimize edilmesi gereken parametrelere sahiptir. Ancak, varsayılan parametre değerleri, proje gereksinimlerini karşılayacak kadar doğru bir çıktı sağlayabilir. Bazı algoritmaların, RF gibi parametre ayarlarına karşı sağlam olduğu bildirilmiştir ve makine öğrenimi, optimizasyon olmadan bile ML gibi parametrik sınıflandırıcılardan daha iyi performans gösterebilir. Bununla birlikte, mümkünse, en iyi sınıflandırma performansını elde etmek için parametre optimizasyonu yapılmalıdır. Değişken sayısı için varsayılan parametrenin kullanılması ve çok sayıda ağaç seçilmesi (örneğin 500), optimizasyon yoluyla elde edilebilecekler yakın bir sınıflandırma doğruluğu ürettiği gibi görünmektedir. Genel olarak, makine öğrenme yöntemleri ve özellikle SVM, RF ve güçlendirilmiş DT' lerin, parametrik yöntemlere kıyasla büyük veya karmaşık özellik uzaylarına karşı daha sağlam olduğu gösterilmiştir. SVM ve RF, birçok çalışmada hiperspektral verileri sınıflandırmak için değerli bulunmuştur. Öte yandan, k-NN genellikle karmaşık öznelik uzaylarında iyi performans göstermez. (Maxwell vd., 2018)



Şekil 5. Makine öğrenimi hiyerarşisi

Denetimli öğrenme, veri toplanmasına veya önceki deneyimden bir veri çıktısı üretilmesine olanak tanır. Ayrıca, önceki deneyimleri kullanarak performans kriterlerini optimize etmeye yardımcı olur. Denetimli öğrenmedeki yaygın algoritmalar arasında lojistik regresyon, karar ağaçları veya destek vektör makineleri (SVM), yapay sinir ağları (ANN) ve rastgele orman (RF) bulunur. Denetimli öğrenme, bir girdi verisine sahip olduğunda, sistem eldeki bilgilerden öğrenebileceği her şeyi öğrenir.

Bu çalışmada verileri kullanarak makine eğitilmiştir. Bu, denetimli öğrenme algoritmaları etiketlenmiş eğitim verilerinden öğrendiği için bazı verilerin zaten doğru yanıtla izlendiği anlamına gelir, bu da öngörülemez verilerin sonuçlarını tahmin etmeye yardımcı olur. Arazi kullanımındaki değişimlerin belirlenmesi için sırasıyla RF, SVM, OBIA yöntemleri kullanılmıştır.

2.3.1 Random Forest

RF ağaç tabanlı bir makine öğrenimi sınıflandırma algoritmasıdır. Rastgele ormanlar olarak bilinen teknik, girdi değişkenlerinin rastgele seçilmiş bir alt kümesine ve ayrıca rastgele seçilmiş bir veri vakası alt kümesine dayalı olarak ağaçları öğrenerek temel öğrenenleri ilişkilendirmeye çalışır (Breiman, 2001). Bu tür modeller genellikle çok iyi tahmin doğruluğuna sahiptir (Caruana vd., 2006).

$$f(x) = \sum_{m=1}^M \frac{1}{M} f_m(x)$$


Bir tahminin varyansını azaltmanın bir yolu, birçok tahminin ortalamasını almaktır. Örneğin, değiştirme ile rastgele seçilen verilerin farklı alt kümeleri üzerinde M farklı ağacı eğitebilir ve ardından f_m'nin m'inci ağaç olduğu topluluğu hesaplayabiliriz (Murphy, 2012). Bu tekniğe "önyükleme toplama" anlamına gelen torbalama denir (Breiman, 1996). RF sınıflandırması, bir dizi karar ağacı sınıflandırıcısından ve geliştirilmiş önyükleme

yönteminden oluşan bir topluluk sınıflandırma yöntemini kullanır (Gislason, 2006). RF, nesne tabanlı sınıflandırmada en iyi performansı sergilemektedir ve son yıllarda büyük ilgi görmektedir onun sonrasında SVM gelmektedir ve onu en kötü performansı ile MLC izlemektedir (Ma, 2017). Çalışma alanlarının arazi örtüsü türü ile ilgili olarak, nesne tabanlı sınıflandırma, tarım çalışma alanlarının arazi örtüsü haritalaması için daha avantajlıdır (Ma, 2017).

2.3.2 Destek Vektör Makineleri (SVM)

Destek Vektör Makineleri (SVM) temel istatistiksel öğrenme teorisine açık bağlantılarla örüntü tanıma sorununa yeni bir yaklaşım sağlar. Sinir ağları gibi karşılaştırılabilir yaklaşımlardan farklıdır: SVM eğitimi her zaman küresel bir minimum bulur ve basit geometrik yorumları, daha fazla araştırma için verimli bir zemin sağlar (Borges, 1998). SVM diğer geleneksel yöntemlerden çok daha etkilidir (Melgani, 2004). Destek vektör makinesi (SVM), regresyon ve sınıflandırma sorunlarını çözmek için kullanılan bir tür denetimli öğrenme algoritmasıdır (Shang, 2013). SVM sınıflandırıcıları, eğitim aşamasında birden çok sınıfı en az yanlış sınıflandırılmış pikselle ayıran ideal bir hiper düzlem oluşturur (Shang, 2013).

Liu vd., 2017 yapmış olduğu çalışmada, DL' nin hiperspektral verilerin sınıflandırılması için SVM'den daha iyi performans gösterip gösteremeyeceğini ortaya koymaya çalışmıştır. Bu bağlamda, DL algoritmalarının varyantlarından biri olan derin seyrek otomatik kodlayıcı (SAE) SVM'ye karşı uygulanmıştır. SVM'nin genellikle SAE'den daha iyi performans gösterdiği sonucuna varılmıştır. Ayrıca, ana hatlarıyla belirttikleri gibi, SAE tarafından üretilen en iyi doğruluklar, SVM'ninkilere yakındır (Jozdani vd., 2019). SVM'ler, uzaktan algılama uygulamaları için ortak bir sınırlama olan sınırlı eğitim örnekleriyle bile iyi bir şekilde genelleme yapabilme yetenekleri nedeniyle uzaktan algılama alanında ilgi çekicidir. Ancak, elde edilen sonuçları önemli ölçüde etkileyebilecek parametre atama sorunlarından da muzdariptirler (Jozdani vd., 2019). Orijinal formülasyonunda (Vapnik, 1979) yöntem, bir dizi etiketli veri örneği ile sunulur ve SVM eğitim algoritması, veri kümesini eğitim örnekleriyle tutarlı bir şekilde önceden tanımlanmış ayrı bir sayıda sınıfa ayıran bir hiper düzlem bulmayı amaçlar (Mountrakis vd., 2010). Basit olarak SVM, belirli bir test örneğine iki olası etiketten birinden bir sınıf atayan doğrusal ikili sınıflandırıcıdır. SVM'lerin önemli bir genelleme yönü, genellikle mevcut eğitim örneklerinin tamamının ayırma hiperdüzleminin tanımında ve belirtiminde kullanılmamasıdır. Kenar boşluğunda yer alan noktaların alt kümesi (destek vektörleri olarak adlandırılır), maksimum kenar boşluğunun hiper düzlemini tanımlayan yegane noktalar. SVM'ler, genellikle geleneksel yöntemlerden daha yüksek sınıflandırma doğruluğu üreten, küçük eğitim veri setlerini başarılı bir şekilde işleme yetenekleri nedeniyle uzaktan algılama alanında özellikle ilgi çekicidir (Mantero vd., 2005).




Şekil 6. SVM prensibi.

SVM'nin en önemli özelliği, sınırlı miktarda ve/veya kalitede eğitim verisinden iyi genelleme yapabilme yeteneğidir. Geri yayılım sinir ağları gibi alternatif yöntemlerle karşılaştırıldığında, SVM'ler çok daha küçük bir eğitim örneği boyutu kullanarak karşılaştırılabilir doğruluk sağlayabilir. Kendi kendine uyarlanabilirlik, hızlı öğrenme hızı ve eğitim boyutuyla ilgili sınırlı gereksinimler ile karakterize edilen SVM sınıflandırıcılarının, uzaktan algılama yoluyla elde edilen verilerin akıllı işlenmesinde oldukça güvenilir bir metodoloji olduğu sonucuna varılabilir (Mountrakis vd., 2010).

2.3.3 Nesne Tabanlı Sınıflandırma için Makine Öğrenimi Sınıflandırıcıları (OBIA)


Sınıflandırma için temel birimlerin (pikseller veya görüntü bölümleri) yanı sıra, uygun bir sınıflandırıcının seçimi de kentsel LULC haritalaması için kritik öneme sahiptir (Jozdani vd., 2019). Son derece karmaşık verilerin sınıflandırılmasında makine öğrenimi (ML) algoritmalarının başarısı, RS analizi uygulamalarını önemli ölçüde artırmıştır ve geçmiş RS çalışmalarında parametrik yöntemlerden önemli ölçüde daha iyi performans gösterdiği bulunmuştur (Yu vd., 2014). GEOBIA tabanlı kentsel LULC sınıflandırması için en yaygın olarak kullanılanlar arasındadır (Ma vd., 2017) RF, nesne tabanlı sınıflandırmada en iyi performansı sergilemektedir ve son yıllarda büyük ilgi görmektedir (Ma, 2017) Çalışma alanlarının arazi örtüsü türü ile ilgili olarak, nesne tabanlı sınıflandırma, tarım çalışma alanlarının arazi örtüsü haritalaması için daha avantajlıdır. Ayrıca, kentsel alanlara uygulanabilen nesne tabanlı sınıflandırma yöntemlerini keşfetmek önemlidir (Ma, 2017). LULC türünün ana kategorileriyle su kütleleri, ormanlar, otlaklar, çıplak alanlar, binalar ve yollar, kentsel yayılma nedeniyle otlakların çok zamanlı varyasyonları, kıyı arazi ıslahından kaynaklanan alanların değişimleri, nüfus artışı ve göç, kentleşme sürecinin ana yönünü ve bağlantısını yansıtabilir. Başlıca zorluklar, bu altı LULC sınıfının bazılarında dikkate değer benzerlik ve çeşitlerin mevcut olması ve bu bozulmaların sınıflandırıcının nihai performansını etkileyebilmesidir (Chang vd., 2010).



Şekil 7. RF, SVM ve OBIA yöntemleriyle çalışma alanının 2004 ve 2022 yıllarındaki arazi kullanımı haritaları.

Çizelge 1. Kentsel LULC modellerinin alt sınıfları

Temel LULC Tipi	Alt Tip
Tarım Alanı	Ekili Tarım Alanı
	Sürülü Tarım Alanı
Yeşil Alan	Yeşil Alan
Yapı	Beyaz Çatılı Yapılar
	Turuncu-Kırmızı Çatılı Yapılar
Çorak Alan	Çorak Alan



Şekil 8. RF ile 2004-2022 yılları yapılaşma kaynaklı arazi kullanımındaki değişim haritası.

Çizelge 2. Kentsel LULC modellerinin alt sınıfları

Temel LULC Tipi	Alt Tip	Açıklama
Tarım Alanı	Tarım 1	Ekili Tarım Alanı
	Tarım 2	Ekili Tarım Alanı 2
	Tarım 3	Sürülü Tarım Alanı
	Tarım 4	Yeşil-Ağaçlık Alan
Yapı	Yeni Yapı	Beyaz -Tururuncu Çatılı Sonradan Yapılmış Yapılar, Yollar, Kentsel Çalışma Yapılmış Alanlar
	Eski Yapı	Beyaz -Tururuncu Çatılı Var Olan Yapılar, Yollar, Çorak Alanlar.

Hızlı kentleşme süreçleri, belirgin bir şekilde iki LULC haritasındaki değişikliklerden tanınabilir. Bu ilerleme, gelecekte arazi yönetimi, tehlike azaltma, acil durum müdahalesi ve çevre yönetimi için kentsel bölgede hızlı değişiklik tespiti gerçekleştirmek için daha fazla uygulanabilir. Sınıflandırıcı ne kadar iyi eğitilirse, sınıflandırıcı aynı kategoriler içinde ayırt etmek ve ayırt etmek için benzer nesnelerle karşılaştığında başarı şansı o kadar yüksek olur (Chang vd., 2010).

Bu çalışmada çalışma alanı olarak belirlenen bölgenin 2004 ve 2022 yıllarındaki uydu görüntülerinden Google Earth aracılığıyla faydalanılarak kentleşme süreçlerindeki değişim belirlenmeye çalışılmış ve yapılaşmanın tarım alanları üzerindeki baskısı ortaya konulmaya çalışılmıştır. 2004 ve 2022 yıllarındaki görüntüler RF, SVM ve OBIA yöntemleriyle sınıflandırılarak yapılaşma artışına yönelik fikir elde edilmeye çalışılmıştır. Bu aşamada LULC **Çizelge 1'** de belirtildiği şekilde sınıf ve alt sınıflara ayrılmıştır. 2004 ve 2022 yıllarına ait görüntülerin sınıflandırılmasında bu 3 yöntem arasından OBIA daha sağlıklı veriler elde edilmesine olanak sağlamıştır (**Şekil 7**). Sonraki aşamada 2004 ve 2022 yıllarına ait nesne tabanlı görüntü analizi (OBIA) haritaları karşılaştırılmış ve tarım alanı ve yapı olarak 2 kategoriye ayrılmıştır. Tarım alanı kendi içerisinde 4, yapı ise kendi içinde 2 alt kategoriye ayrılmıştır (**Çizelge 2**). RF ile tekrardan sınıflandırılmıştır. Böylelikle yeni yapıların ve eski yapıların belirlenebildiği 2004 ve 2022 yılları arasındaki yapılaşma kaynaklı arazi kullanımındaki değişiklikler belirlenmiştir (**Şekil 8**).

3. SONUÇLAR

Bu çalışmada uydu verileri kullanılarak (Arazi Örtüsü ve Arazi Örtüsü) LULC haritası elde edilmiş ve uzaktan algılama haritasının doğruluğu değerlendirilmiş harita doğruluğunun tatmin edici düzeyde olduğu belirlenmiştir. Makine öğrenimi algoritmaları ile çalışma alanının olarak belirlenen Ankara ili Yenimahalle ilçesindeki arazi kullanımındaki 2004-2022 yılları arasındaki değişim belirlenmiştir. Tarım alanların günümüze kadar gelen sürede giderek azaldığı, yapılaşmanın tarım alanları üzerinde baskı oluşturduğu ortaya konulmuştur. SVM ve RF, birçok çalışmada hiperspektral verileri sınıflandırmak için değerli bulunmuştur. RF, nesne tabanlı sınıflandırmada en iyi performansı sergilemektedir ve son yıllarda büyük ilgi görmektedir onun sonrasında SVM gelmektedir. Çalışma alanlarının arazi örtüsü türü ile ilgili olarak, nesne tabanlı sınıflandırma, tarım çalışma alanlarının arazi örtüsü haritalaması için daha avantajlıdır. Bu çalışmada, RF, SVM ve OBIA yöntemleriyle çalışma alanının 2004 ve 2022 yıllarındaki arazi kullanımı haritaları oluşturulmuştur. Bu çalışmada en sağlıklı yöntem OBIA olmuştur. Daha sonra SVM ve RF gelmektedir. 2004 yılındaki görüntüye ait sınıflandırmada RF ile SVM arasında fark kolayca belli olurken 2022 yılına yönelik görüntülerde bu fark daha zor tespit edilmektedir. Nesne tabanlı sınıflandırma yapmada RF SVM'den daha başarılı bir veri sunmuştur. 2004 ve 2022 yılları arasındaki yapılaşma kaynaklı arazi kullanımındaki değişiklikler belirlenmiştir. Yeni yapıların ve varolan yapıların tespiti yapılmıştır. Yapılaşmanın çalışma alanının orta bölgesinde bulunan Yeni Batı mahallesinde daha yoğun olduğu tespit edilmiştir. Bu çalışmada

kullanılan yöntemler su kütleleri, ormanlar, otlaklar, çıplak alanlar, binalar ve yollar, kentsel yayılma nedeniyle otlakların çok zamanlı varyasyonları, kıyı arazi ıslahından kaynaklanan alanların değişimleri, nüfus artışı ve göç, kentleşme sürecinin ana yönü ve bağlantısını belirlemede veri sunar. Afet, savaş, kuraklık ve pandemi gibi durumlarda ülkelerin gıda stoklarının hazır ve yeterli olmaması geniş bir coğrafyayı etkileyebilecek bir krize dönüşebilmektedir. Bu yüzden ülkeler bu gibi durumlara hazırlıklı olmalı ve gerekli önlemleri almalıdır. Tarım alanlarındaki değişimi ortaya koyan arazi kullanımı değişimleri bu konuda veri sunması açısından önlemlerin alınmasında ve stratejik planlamaların yapılmasında yol gösterici olmaktadır.

KAYNAKLAR

Alpaydin, E., (2020). *Introduction to Machine Learning* (Fourth bas.). MIT. ss. xix, 1-3, 13-18. ISBN 978-0262043793.

Breiman, L., “Random forests,” *Machine Learning*, vol. 45, pp. 5–32, 2001.

Burges, C.J.C., 1998, A Tutorial on Support Vector Machines for Pattern Recognition, Data Mining and Knowledge Discovery, 2, 121–167.

Caruana, R. and A. Niculescu-Mizil, 2006, An empirical comparison of supervised learning algorithms. In *Intl. Conf. on Machine Learning*.

Cortes, C.; Vapnik, V., 1995 Support-vector Networks. *Mach. Learn.*, 20, 273–297.

Chang, N., Han, M, Yao, W., Chen, L., Xu, S., 2010, *Change Detection of Land Use and Land Cover in an Urban Region With SPOT-5 Images and Partial Lanczos Extreme Learning Machine*, *Journal of Applied Remote Sensing*, Vol. 4, 043551.

Doğan, A., 2007, “*Ekonomik Gelişme Sürecinde Tarımın Katkısı: Türkiye Örneği*” SÜ İİBF Sosyal ve Ekonomik Araştırmalar Dergisi, 365-392.

Pielke, P.A., Marland, S.G., Betts, R.A., Chase, T.N., Eastman, J.L., Niles, J.O., Niyogi, D.D.S., Running, S.W. 2002, *The influence of land-use change and landscape dynamics on the climate system: Relevance to climate change policy beyond the radiative effect of greenhouse gases*. *Phil. Trans. R. Soc. Lond. A*. 360: 1705-1719.

Gibbard, S., Caldeira, K., Bala G., Phillips, T.J., Wickett, M. 2005. *Climate effects of global land cover change*. *Geophysical Research Letters*, (32):23705.

Sala, O.E., III Chapin, F.S., Armesto, J.J., Berlow, E.L., Bloomfield, J., Huenneke, L., Jackson, R.B., Kinzig, A., Leemans, R., Lodge, D.M., Mooney, H.A., Oesterheld, M., Poff, N.L., Sykes, M.T., Walker, B., Walker, M., Wall, D.H. 2000, *Biodiversity: global biodiversity scenarios for the year 2100*, *Science*. 287(5459):1770-1774.

Maxwell, A.E., Warner, T.A., Fang, F., 2018, *Implementation of machine-learning classification in remote sensing: an applied review*, *International Journal of Remote Sensing*, 39:9, 2784-2817

Pimm, S.L., Raven, P., 2000, *Biodiversity - Extinction by numbers*, *Nature*. 403(6772): 843-5.

Foley, J.A., Defries, R.S., Asner, G.P., Barford, C.C., Bonan, G., Carpenter, S.R., Chapin III, F.S., Coe, M.T., Daily, G.C., Gibbs, H., Helkowski, J.H., Holloway, T., Howard, E.A., Kucharik, C.J., Monfreda, C., Patz, J., Prentice, I.C., Ramankutty, N., Snyder, P.K. 2005, *Global Consequences of Land Use*, *Science*. 309(5734):570-4.

Gislason, P.O., et al., 2006, “*Random forests for land cover classification*,” *Pattern Recognit. Lett.*, vol. 27, pp. 294–300.

Jozdani, S.E., Johnson, B.A., Chen, D., 2019, *Comparing Deep Neural Networks, Ensemble Classifiers, and Support Vector Machine Algorithms for Object-Based Urban Land Use/Land Cover Classification*, *Remote Sensing*.

- Yu, L.; Liang, L.; Wang, J.; Zhao, Y.; Cheng, Q.; Hu, L.; Liu, S.; Yu, L.; Wang, X.; Zhu, P.; et al.**, 2014, Meta-discoveries from a synthesis of satellite-based land-cover mapping research. *Int. J. Remote Sens.*, 35, 4573–4588.
- Liu, P.; Choo, K.-K.R.; Wang, L.; Huang, F.**, 2017, *SVM or Deep Learning? A Comparative Study on Remote Sensing Image Classification*, *Soft Comput.*, 21, 7053–7065.
- Ma, L.; Li, M.; Ma, X.; Cheng, L.; Du, P.; Liu, Y.**, 2017, *A Review of Supervised Object-Based Land-Cover Image Classification*. *ISPRS J. Photogramm. Remote Sens.*, 130, 277–293.
- Mantero, P.; Moser, G.; Serpico, S.B.**, 2005. *Partially Supervised Classification of Remote Sensing Images Through SVM-Based Probability Density Estimation*, *IEEE Transactions on Geoscience and Remote Sensing* 43 (3), 559–570.
- Melgani, F.; Bruzzone, L.**, 2004, *Classification of Hyperspectral Remote Sensing Images with Support Vector Machines*. *IEEE Trans. Geosci. Remote Sens.*, 42, 1778–1790.
- Murphy, K.P.**, 2012 *Machine Learning: A Probabilistic Perspective*, Massachusetts Institute of Technology, 550-551. ISBN 978-0-262-01802-9.
- Shang, X.; Chisholm, L. A.**, 2013, *IEEE Journal Of Selected Topics In Applied Earth Observation And Remote Sensing*.
- Turan, İ.A.; Dengiz, O.; Kaya S.N.**, 2021, *Arazi Örtüsü/Arazi Kullanım Değişimlerinin Farklı Zamanlı Landsat Uydu Görüntüleri ile Belirlenmesi: Çarşamba Delta Ovası Örneği*, *ÇOMÜ Zir. Fak. Derg.* ISSN: 2147–8384 / e-ISSN: 2564–6826.
- Thomas, L.; Ralph, W.; Kiefer, J.C.**, 2004, *Remote Sensing and Image Interpretation* (Fifth Edition). *Geogr. J.*, 146, 448–449.
- Vapnik, V.**, 1979, *Estimation of Dependences Based on Empirical Data*. Nauka, Moscow, pp. 5165–5184, 27 (in Russian) (English translation: Springer Verlag, New York, 1982).