



Comparison of fuzzy logic and machine learning methods in the production of object-based land use and land cover (LULC) maps using very high resolution aerial imagery

Tolga Kaynak^{1*}, Coşkun Özkan²

¹Department of Geomatics Engineering, Faculty of Engineering, Niğde Ömer Halisdemir University, 51240, Niğde, Türkiye

²Department of Geomatics Engineering, Faculty of Engineering, Erciyes University, 38030, Kayseri, Türkiye

Highlights:

- Superiority of multiresolution segmentation over other object formation methods
- Evaluation of the performance of four methods for land use and land cover classification
- Producing the most accurate LULC map to support management strategies

Keywords:

- Object-based classification
- Segmentation
- k-nearest neighbor
- Random forest
- Support vector machines
- Fuzzy logic

Article Info:

Research Article

Received: 18.11.2024

Accepted: 15.07.2025

DOI:

10.17341/gazimmfd.1585980

Correspondence:

Author: Tolga Kaynak

e-mail:

tolgakaynak@ohu.edu.tr

phone: +90 531 237 77 45

Graphical/Tabular Abstract

This study used very high-resolution aerial photographs to produce the most realistic land use and land cover (LULC) map of the study area. As shown in Figure A, segmentation and several classification algorithms were utilized to generate this map. The performance of these algorithms was then compared, and the method providing the highest accuracy, along with its optimal parameter settings, was determined.




Figure A. The methodological framework of the study

Purpose: The purpose of this study is to produce the most accurate LULC map by utilizing very high-resolution aerial photographs through object-based image analysis. This was accomplished using multiresolution segmentation and four classification methods named as k-Nearest Neighbor (kNN), Random Forest (RF), Support Vector Machine (SVM), and Fuzzy Logic (FL). Each classifier was optimized with different parameter settings to ensure the best possible accuracy. The study also aims to statistically compare the best maps obtained from this process.

Theory and Methods: This study's methodological framework is based on an object-based image analysis approach. First, the multiresolution algorithm divided the very high-resolution aerial photographs into objects. During segmentation, parameters such as scale, shape, and compactness were iteratively adjusted to generate optimal objects. A set of features was extracted from each object to characterize land patterns. These features were then used as inputs for four different classifiers. Training samples were selected for each class. Several parameter combinations were tested to determine the most suitable configuration for each classifier. The performance of the algorithms was assessed using Overall Accuracy (OA) and Kappa statistics. The McNemar's test was used to determine whether there was a statistically significant difference between the best method-based maps.

Results: The classification results revealed that the SVM algorithm produced the most accurate LULC map. McNemar's statistical test confirmed that the differences in the classification results were significant at the 0.05 confidence level. The final LULC map derived from the SVM algorithm effectively represented the spatial distribution of the classes, aligning closely with ground observations.

Conclusion: The findings of this study highlight that the integration of optimized segmentation parameters, appropriate feature selection, and systematic comparison of classifiers significantly improves classification reliability. The most accurate LULC map derived from the SVM algorithm can serve as a valuable reference for environmental monitoring, land management, and spatial planning studies requiring detailed, up-to-date LULC information.



Mühendislik Mimarlık Fakültesi Dergisi

Journal of The Faculty of Engineering
and Architecture of Gazi University

Elektronik / Online ISSN : 1304 - 4915
Basılı / Printed ISSN : 1300 - 1884

Çok yüksek çözünürlüklü hava fotoğrafları ile nesne tabanlı arazi kullanım ve arazi örtüsü (LULC) haritalarının üretiminde bulanık mantık ve makine öğrenme yöntemlerinin karşılaştırılması

Tolga Kaynak^{1*}, Coşkun Özkan²

¹Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 51240, Niğde, Türkiye

²Erciyes Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 38280, Kayseri, Türkiye

Ö N E Ç İ K A N L A R

- Superiority of multiresolution segmentation over other object formation methods
- Evaluation of the performance of four methods for land use and land cover classification
- Producing the most accurate LULC map to support management strategies

Makale Bilgileri

Araştırma Makalesi

Geliş: 18.11.2024

Kabul: 15.07.2025

DOI:

10.17341/gazimmfd.1585980

Anahtar Kelimeler:

Nesne tabanlı sınıflandırma, segmentasyon, k-en yakın komşu, rastgele orman, destek vektör makineleri, bulanık mantık

ÖZ

Belirli bir bölgedeki arazi kullanım biçimlerini (tarım, yerleşim, sanayi, orman vb.) ve arazinin mevcut örtüsünü (ormanlar, su kütleleri, çıplak araziler vb.) gösteren arazi kullanımı ve arazi örtüsü (LULC) haritaları doğal kaynakların yönetimi, çevresel planlama, doğal afet yönetimi ve biyoçeşitlilik gibi etmenlerde kullanıldığı için büyük önem taşımaktadır. LULC haritaları uzaktan algılama ile elde edilen görüntüden sınıflandırılmak istenen sınıfların her biri için ayrı piksel topluluğu veya obje topluluğu seçilerek ve görüntünün bu sınıfları içeren tematik haritasının üretilmesiyle elde edilmektedir. Bu makale kapsamında çalışma alanının LULC haritaları nesne tabanlı sınıflandırma yaklaşımına bağlı olarak oluşturulmuştur. Bu yöntemin segmentasyon, sınıflandırma ve doğruluk değerlendirmesi aşamaları eCognition yazılımında yapılmıştır. LULC haritaları nesne tabanlı sınıflandırmanın ilk aşaması olan segmentasyon aşamasında tespit edilen objelerin k-en yakın komşu (kNN), rastgele orman (RF) destek vektör makineleri (SVM) ve bulanık mantık (FL) yöntemleri kullanılarak sınıflandırılmasıyla elde edilmiştir. Doğruluk değerlendirmesi aşamasında ise kNN, RF, SVM ve FL yöntemleri karşılaştırılmıştır. Segmentasyon parametrelerinin (ölçek, şekil ve bütünlük) optimum değerleri deneme yanılma yöntemiyle belirlenmiştir. Ayrıca sınıflandırmada kullanılacak özellikler seçilirken de her bir sınıf ayrı ayrı analiz edilerek karar verilmiştir. Doğruluk analizi aşamasında yapılan istatistiksel analizlere göre SVM yönteminin en iyi sonucu verdiği tespit edilmiştir.

Comparison of fuzzy logic and machine learning methods in the production of object-based land use and land cover (LULC) maps using very high resolution aerial imagery

H I G H L I G H T S

- The design and optimization of an input shaper capable of attenuating specific vibration frequencies for flexible systems is presented
- The proposed approaches eliminate the need for impulse sequences
- The effectiveness of the approaches has been experimentally validated on a crane system

Article Info

Research Article

Received: 18.11.2024

Accepted: 15.07.2025

DOI:

10.17341/gazimmfd.1585980

Keywords:

Object-based classification, Segmentation, k-nearest neighbor, random forest, support vector machines, fuzzy logic

ABSTRACT

Land use and land cover (LULC) maps, which show land use patterns (agriculture, settlement, industry, forest, etc.) and current land cover (forests, water bodies, bare land, etc.) in a given region, are of great importance as they are used in factors such as natural resource management, environmental planning, natural disaster management and biodiversity. LULC maps are obtained by selecting distinct groups of pixels or objects for each of the classes to be classified from the remotely sensed image and creating a thematic map of the image containing these classes. In this paper, LULC maps of the study area were produced using object-based classification approach. The segmentation, classification and accuracy assessment stages of this method were carried out in the eCognition software. LULC maps were obtained by classifying the objects detected in the segmentation stage, which is the first stage of object-based classification, using k-nearest neighbor (kNN), random forest (RF), support vector machines (SVM) and fuzzy logic (FL) methods. In the accuracy analysis assessment, the kNN, RF, SVM and FL methods were compared. The optimal values for the segmentation parameters (scale, shape and compactness) were determined by trial and error. In addition, when selecting the features to be used in the classification, the decision was made by analyzing each class separately. According to the statistical analyses performed during the accuracy assessment phase, the SVM method was found to give the best result.

1. Giriş (Introduction)

20. yüzyılın başlarında balonlarla veya uçaklarla çekilen hava fotoğrafları, özellikle savaş dönemlerinde stratejik bilgi toplama, harita yapımı ve arazi gözlemi için önemli bir kaynak olmuştur. Daha sonra özellikle su, tarım ve orman yönetimi planlanmasında kullanılmaya başlanmıştır. Gelişen teknoloji ile birlikte, hava fotoğraflarının kalitesi ve erişilebilirliği artmaktadır. İnsansız hava araçları sayesinde, daha önce ulaşılması zor olan bölgelere dair yüksek çözünürlüklü görüntüler elde edilebilmektedir. Bu durum, hem bilimsel araştırmalara hem de ticari uygulamalara büyük katkı sağlamaktadır. Örneğin, tarım sektöründe çiftçiler, hava fotoğraflarını kullanarak mahsul sağlık durumunu izleyebilir, sulama gereksinimlerini belirleyebilir ve kaynak kullanımını optimize edebilir. Ayrıca şehirlerin yeni politikalarının geliştirilmesinde, planlama ve yönetim süreçlerinde karar vericilere LULC haritaları yardımcı olmaktadır.

Piksel tabanlı ve nesne tabanlı sınıflandırma LULC haritalarının üretilmesinde en sık kullanılan yöntemlerdir. Piksel tabanlı sınıflandırma, her pikseli bağımsız bir birim olarak ele alır ve yalnızca spektral özellikleri göz önünde bulundurarak sınıflandırma yapar. Bu yüzden piksel tabanlı yöntemler, özellikle heterojen yapıları alanlarda tuz-biber (salt-and-pepper) etkisine yol açarak sınıflandırma sonucunu olumsuz etkileyebilmektedir. Literatürde yapılan çalışmalarda, piksel tabanlı sınıflandırmanın homojen alanlarda daha yüksek doğruluk sağladığı, ancak karmaşık alanlarda doğruluğun azaldığı belirtilmiştir [1].

Nesne tabanlı sınıflandırma yöntemi ise yalnızca piksellerin spektral özelliklerini değil, aynı zamanda doku, şekil ve komşuluk gibi mekânsal ilişkileri de dikkate almaktadır. Bu yöntemin ilk aşaması olan segmentasyon aşamasında benzer özelliklere sahip komşu pikseller bir araya getirilerek nesne veya obje olarak adlandırılan daha büyük birimler oluşturmaktadır. Daha sonra üretilen bu nesneler sınıflandırılmaktadır. Böylece sınıflandırma sonuçları daha homojen bir yapıya sahip olmaktadır. Bu durumda sınıf sınırlarının daha doğal bir şekilde oluşmasını sağlamaktadır [2]. Nesne tabanlı yöntemler, özellikle yüksek çözünürlüklü uydur görüntülerinde başarılı sonuçlar vermektedir. Ancak daha karmaşık bir işlem süreci gerektirmesi ve daha yüksek hesaplama gücü ihtiyacı bu yöntemin sınırlamalarıdır [3].

Literatürde piksel tabanlı ve nesne tabanlı sınıflandırma yöntemlerinin karşılaştırıldığı birçok çalışma bulunmaktadır. Matejickova vd. [4] ölü ladin ağaçlarının tespiti için bu yöntemleri karşılaştırmıştır. Yer kontrol noktaları ile yapılan karşılaştırma sonucunda hava görüntülerinden elde edilen nesne tabanlı sınıflandırma doğruluğunun piksel tabanlı yöntemle göre üstün olduğunu bulmuşlardır. Nasiri vd. [5] orman örtüsünün doğru bir biçimde haritalanabilmesi için piksel tabanlı ve nesne tabanlı sınıflandırma yöntemlerini araştırmışlardır. Bölgenin yüksek çözünürlüklü görüntü ile orman örtüsünün tespitinde nesne tabanlı yöntem kullanmanın daha mantıklı olacağını bulmuşlardır. Jovanović vd. [6] çalışmalarında yapı değişimini tespit eden, yapı envanterini güncel tutan ve değişiklikleri kayda alan bir yöntem geliştirmeyi amaçlamıştır. Yapı değişikliklerini yüksek doğrulukla tanımlayabilen yöntemin nesne tabanlı yöntem olduğuna keşfetmişlerdir. Bu tür çalışmaların yanında piksel tabanlı ve nesne tabanlı sınıflandırma yöntemleri LULC haritalarının üretiminde de karşılaştırılmıştır. Riggan vd. [7] nesne tabanlı sınıflandırma ile daha yüksek doğruluk oranları elde edildiğini, özellikle şekil ve mekânsal bağlamın sınıflandırma doğruluğunu artırdığını göstermişlerdir. Buna karşın, piksel tabanlı yöntemler tek tek pikselleri ele aldığından doğruluk oranlarının daha düşük olduğunu tespit etmişlerdir. Li vd. [8]

Amerika'nın Orta Batı bölgesindeki bir ilçenin yüksek çözünürlüklü hava fotoğrafıyla LULC haritalarının doğruluğunu araştırmışlardır. Çalışma kapsamında, nesne tabanlı sınıflandırmanın mekânsal ve spektral özellikleri dikkate alması sayesinde, piksel tabanlı yöntemlere göre özellikle tarım ve ormanlık alanlar gibi karmaşık arazilerde benzer nesneler arasında bile daha yüksek benzerlik oranları sağladığı bulunmuştur. Qu vd. [9] Yangtze Nehri Deltası'nda üzerinde yapılan LULC sınıflandırmasında, nesne tabanlı modelin %96,01 doğruluk oranına ulaştığı gözlenmiş ve özellikle topografik özelliklerin model doğruluğunu artırdığı belirlenmiştir. Piksel tabanlı yaklaşımla kıyaslandığında, nesne tabanlı yöntem, ek veri kaynaklarıyla birleştirildiğinde daha küçük nesneleri tanımlamada ve daha yüksek doğruluk sağlamada etkili olmuştur.

Literatürde yer alan çalışmalar incelendiğinde, çoğu çalışmanın yalnızca sınıflandırma algoritmalarını karşılaştırmakla sınırlı kaldığı görülmektedir. Bununla birlikte, bu çalışmalarda segmentasyon parametrelerinin optimizasyonu ve sınıflandırma algoritmaların ayar parametrelerinin seçimi gibi unsurlar çoğunlukla göz ardı edilmektedir. Ayrıca, McNemar's testi gibi ileri düzey istatistiksel yöntemlerle sınıflandırma haritalarının anlamlılık düzeyinde karşılaştırıldığı çalışmalara da oldukça nadir rastlanmaktadır. Tassi ve Vizzari [10] ve Kasahun ve Legesse [11] çalışmalarında diğer unsurları göz ardı ederek yalnızca sınıflandırma yöntemlerinin doğrulukları üzerine çalışma yapmışlardır. Balha vd. [12] ve Selvaraj vd. [13] ise sınıflandırma performanslarının yanında segmentasyon parametrelerinin uygun değerlerini bulmaya odaklanmıştır. Fakat McNemar's ile karşılaştırma yapmamışlardır. Luo vd. [14] ise McNemar's ile sınıflandırma sonuçları arasındaki anlamlılığı test etmiştir.

Geçmiş çalışmalarda elde edilen bulgulara göre çalışma alanının LULC haritasının elde edilmesinde nesne tabanlı sınıflandırma yöntemlerinin kullanılmasına karar verilmiştir. Bu bağlamda gerçeğe en çok benzeyen haritayı elde etmek için kNN, RF, SVM ve FL sınıflandırma yöntemleri karşılaştırılmıştır. Çalışma kapsamında üretilcek sınıflara karar verildikten sonra segmentasyon aşaması gerçekleştirilmiştir. Bu aşamada objelerin doğru bir biçimde oluşturan uygun yöntemi bulmak için eCognition programında üç farklı segmentasyon yöntemi denenmiştir. Bu işlemler tarım alanları ve ağaç gibi birbirine karışması muhtemel bazı objeler incelenerek gerçekleştirilmiş ve en iyi nesne oluşumlarını multiresolution yönteminin ürettiği görülmüştür. Bu yöntemin uygun parametrelerini bulmak için birçok deneme yapılmıştır. Uygun parametreler kullanılarak elde edilen objelerden eğitim ve test alanları seçilmiştir. Daha sonra sınıfların optimum ayırt edilebilmesi için gerekli olan açık alan endeksi (BAI), normalleştirilmiş fark bitki örtüsü endeksi (NDVI), normalleştirilmiş fark su endeksi (NDWI) gibi özellikler belirlenmiştir. Bu işlemlerden sonra üretilen objeler kNN, RF, SVM ve FL yöntemlerine göre sınıflandırılarak her yöntemin LULC haritaları elde edilmiştir. Bu LULC haritalarının test verileri ile karşılaştırılması ile oluşturulan hata matrislerinin istatistiksel analizi ile doğruluk analizleri yapılmıştır. Ayrıca, sınıflandırma haritaları yalnızca doğruluk oranlarıyla değil, aynı zamanda McNemar's testi ile istatistiksel anlamlılık açısından da değerlendirilmiştir. Bu yönüyle çalışma, hem yöntemsel derinlik hem de uygulama bütünlüğü açısından literatürdeki benzerlerinden ayrılmaktadır.

2. Materyal ve Yöntemler (Material and Methods)

2.1. Çalışma Alanı (Study Area)

Çalışmada arazi detaylarını en kapsamlı bir biçimde gösterebilmek için sınıf çeşitliğinin en fazla olduğu Kayseri İlinin Kocasinan İlçesindeki Zümrüt, Hoca Ahmet Yesevi ve Saray Bosna Mahallelerinin kesişiminde yaklaşık 2,56 kilometrekarelik alan

çalışma bölgesi olarak seçilmiştir. 30 cm yersel çözünürlüğe ve 8 bit radyometrik çözünürlüğe sahip, mavi, yeşil, kırmızı ve yakın kızılötesi olmak üzere 4 bantlı hava fotoğrafı araştırma alanının LULC haritasını çıkarmak için nesne tabanlı sınıflandırma yöntemlerinin kullanımında girdi verisi olarak kullanılmıştır (Şekil 1).

2.2. Görüntü Segmentasyonu (Image Segmentation)

Nesne tabanlı sınıflandırma çalışmalarında chessboard, quadtree ve multiresolution gibi birçok yaklaşım kullanılmıştır. Chessboard bunlar arasında matematik hesabına dayalı olmayan en basit yöntemdir. Bu yöntemde sol üst köşe referans alınarak girilen parametre değerine göre eşit karelerden oluşan objeler elde edilir [10]. Quadtree segmentasyon yöntemi sonucunda da kare şeklinde objeler oluşur. Fakat oluşan büyüklükleri ölçek parametresine bağlı olmasından dolayı farklı olabilmektedir. Bu aşamada oluşan objeler homojenlik şartı sağlanana kadar kendi içerisinde 4 küçük kareye bölünür [11]. Multiresolution yönteminde ise objeler karenin yanında çok farklı geometrik şekillerde de oluşabilmektedir. Bu nedenle multiresolution, segmentasyon teknikleri arasında en çok kullanılan yöntem olmuştur. Bu yöntemde objeler girilmesi zorunlu 3 parametre ve 1 tanede isteğe bağlı olmak üzere toplam 4 parametreye verilen değerlere göre üretilmektedir [12]. Bu parametrelerden ölçek, şekil ve bütünlük zorunlu parametrelerdir. Zorunlu olmayan bantların ağırlığı ise herhangi bir değer girilmediğinde bütün bantları eşit ağırlık alarak işlemi gerçekleştirmektedir. Bu parametreler belirlenirken nicel bir ölçüt bulunmamasından dolayı, görsel yorumlama ile bulunurlar. Ölçek parametresi objelerin boyutunu belirlemektedir. Bu parametre büyük seçilirse oluşan objelerin birden fazla sınıf içerebileceği veya küçük seçilirse de fazla sayıda obje oluşturabileceği için ölçek parametresi seçilirken ne büyük olmasına ne küçük olmasına dikkat edilmelidir. Şekil parametresi ile birbirini 1'e tamamlayan renk parametresi komşu piksellerin yansıtım değerlerinin benzerliğine dikkate alırken, bu parametrenin azalması şekil parametresinin etkisini artırmaktadır. Bu parametrenin yüksek seçilmesi, az yansıtım farkları bile dikkate alır ve homojen obje sayısını artırır. Birbirlerini 1'e tamamlayan diğer parametreler bütünlük ve pürüzsüzlüktür. Bütünlük arttıkça daha bütün nesneler oluşmaktadır. Pürüzsüzlük artırıldığında ise oluşan objelerin sınırları daha düzgün bir biçimde belirlenmektedir.

2.3. Sınıflandırıcılar (Classifiers)

2.3.1. K-en yakın komşuluk (K-nearest neighbour)


K en yakın komşuluk (kNN) yöntemi, T. M. Cover ve P. E. Hart [13] tarafından sunulmuştur. kNN basit, etkili ve parametrik olmayan bir makine öğrenme yöntemidir [14]. Bu yöntemin temel prensibi, sınıfı bilinmeyen bir pikselin sınıfını belirlemek için, en yakın komşularının sınıfını inceleyerek karar vermektedir. Bunu veri kümesindeki piksellerin benzerliklerine dayanarak gerçekleştirmektedir. Öğrenme aşamasında model eğitilmez; bunun yerine, piksellerin doğrudan karar aşamasında belirlenmektedir. kNN, tüm veri setini hafızada tutar, bu da büyük veri kümelerinde yüksek bellek tüketimine neden olabilmektedir. Ayrıca özellikle büyük veri kümelerinde her tahmin işlemi için tüm veri piksellerine olan mesafelerin hesaplanması gerekir, bu da tahmin sürecini yavaşlatmaktadır [15].

kNN yönteminin ilk adım, K değerinin belirlenmesidir. K, modelin sınıflandırma yaparken kaç komşunun dikkate alınacağını belirtmektedir. K değerinin küçük seçilmesi, modelin daha ayrıntılı ve hassas sonuçlar vermesine neden olabilir, ancak bu durum aşırı öğrenmeye (overfitting) yol açabilir. Çok büyük K değerleri ise modelin genelleme yeteneğini artırsa da düşük performansa ve aşırı basitleştirmeye (underfitting) neden olabilir. kNN yönteminin ikinci adımında sınıfı belirlenmek istenen pikselin komşularıyla olan mesafeleri Eş. 1'de verilen öklid mesafesi ile hesaplanmaktadır [16]. Bu işlem sonucunda bulunan değerler küçükten büyüğe sıralanır. Daha sonra sınıflandırılacak pikselin en yakın K komşu bulunur ve en yakın K komşu arasında en çok hangi sınıfa sahip olan komşu varsa, pikselin tahmin edilen sınıfı da o olur [17].

$$dis(x^i, y^i) = \sqrt{\sum_{i=1}^n (x^i - y^i)^2} \quad (1)$$

2.3.2. Rasgele orman (Random forest)

Rastgele Orman (RF) yöntemi, büyük veri kümelerinde yüksek doğruluk sağlama yeteneği ve genellemeye karşı dayanıklılığı ile öne çıkan bir makine öğrenimi algoritması olarak Breiman [18] tarafından bulunmuştur.



Şekil 1. Çalışma alanının hava fotoğrafı (Aerial photo of study area)

Özellikle sınıflandırma ve regresyon problemlerinde kullanılan RF, çok sayıda karar ağaçlarından oluşan bir topluluk öğrenme (ensemble learning) yöntemidir [19]. RF'nin temel mantığı, çok sayıda farklı karar ağacını eğitmek ve ardından her birinin verdiği sonuçları birleştirilerek daha genel bir sonuca ulaşmaktır. Ayrıca RF, her bir özneliliğin önem derecesini belirleyebilmektedir [20].

RF yönteminde, her bir karar ağacı, bootstrap örnekleme adı verilen bir işlemle eğitim veri setinden rastgele örneklenmiş bir alt küme ile eğitilir. Bootstrap örnekleme, aynı örneğin tekrar seçilebildiği bir rastgele seçim sürecidir. Bu sayede her bir ağaç, veri setinin farklı bir varyasyonu ile eğitilir, bu da ağaçların çeşitliliğini artırır ve aşırı öğrenmeyi azaltır. RF yönteminin diğer bir önemli bileşeni, her bir düğümde yapılacak özellik seçimidir. Karar ağaçlarında, her düğümde veriyi bölebilecek en iyi özelliği bulmak için genellikle tüm özellikler analiz edilir. Ancak RF'de her bir düğümde yalnızca belirli sayıda rastgele seçilmiş özellik arasından seçim yapılır. Bu yöntem, her bir ağacın farklı bir yapı kazanmasını sağlar ve modelin çeşitliliğini artırır. Her düğümde toplam özellik sayısının karekökü kadar özellik seçilir. Derinlik ise her ağacın ne kadar derine kadar büyüyebileceğini sınırlamaktadır. Maksimum ağaç sayısı kadar oluşturulan karar ağaçlarının düğüm bölme işlemleri yaprak düğümler elde edilene kadar devam eder. Bu işlemler sonucunda her bir karar ağacının bulunduğu sınıflar bulunmaktadır. Bu sınıfların içerisinde en fazla olanı RF'ye göre sınıflandırılmak istenen sınıfı olarak atanır.

2.3.3. Destek vektör makineleri (Support vector machine)

Destek Vektör Makineleri (SVM), yüksek boyutlu verilerde sınıflandırma görevini etkili bir şekilde gerçekleştirebilen, kontrollü sınıflandırma algoritmaları arasında öne çıkan bir yaklaşımdır. Ayrıca verilerin dağılımı konusunda herhangi bir ön bilgi veya varsayım gerektirmediği için parametrik olmayan bir yöntemlerden biridir [21]. SVM'nin temel amacı, destek vektörleri adı verilen veri noktaları arasındaki mesafe olarak adlandırılan marjın maksimum olabilmesini sağlayan optimal bir karar sınırını bulmaktır. Hiper düzlem adı verilen bu sınır sınıflandırma hatalarını minimize eder [22]. Verilerin doğrusal olarak ayırt edilebildiği durumlarda SVM'nin matematiksel gösterimi aşağıdaki Eş. 2'de verilmiştir.

$$f(x) = \text{sign}(\sum \alpha_i y_i x_i + b) \quad (2)$$

Geniş spektral varyansa sahip veri kümelerinde, sınıfların doğrusal ayrılması mümkün olmamaktadır. Bu nedenle SVM verilerin doğrusal ayrılabilir hale getirilmesi amacıyla kernel fonksiyonlarını kullanılmaktadır. Kernel fonksiyonları, verilerin orijinal uzaydan daha yüksek boyutlu bir uzaya taşınmasını sağlayarak sınıfların doğrusal bir şekilde ayrılmasına yardımcı olmaktadır. Bu durumda SVM'nin matematiksel gösterimi aşağıda verilen Eş. 3'e dönüşmektedir.

$$f(x) = \text{sign}(\sum \alpha_i y_i \phi(x_i) \phi(x_j) + b) \quad (3)$$

SVM yöntemi birçok avantajlara sahip olmasına rağmen RBF gibi kernel türünün seçimi ve seçilen türün gamma gibi parametrelerinin seçimi problemlerine sahiptir. RBF ince ayrıntıları yakalayarak benzer spektral özelliklere sahip sınıfları ayırt etmede oldukça başarılı bulunmuştur.

2.3.4. Bulanık mantık (Fuzzy logic)

Zadeh [23], iki değerli olması gereken geleneksel mantığın (sıcak veya soğuk, yavaş veya hızlı, yanlış veya doğru gibi) insan düşünme biçimlerini ve dilsel kavramları modellemek için yetersiz kaldığını fark etti. Ayrıca gerçek dünya, bu kadar kesin doğruluk veya yanlışlık içermez. Bu bağlamda bulanık mantık (FL), belirsiz ve keskin sınırları

olmayan insana özgü düşünme biçimini bilgisayar sistemlerine ve matematiksel modellere daha iyi aktarma amacıyla Zadeh tarafından geliştirilmiştir.

FL, bulanık kümelerle dayanmaktadır. Bulanık kümeler, bir öğenin kısmi üyeliğini ifade etmektedir. Klasik küme teorisinde bir öğe bir kümeye ya aittir ya da değildir; ancak bulanık kümelerde bir öğenin kümeye ait olma derecesi vardır. Bu derecelendirme genellikle 0 ile 1 arasında bir değerle ifade edilmektedir. Örneğin, klasik bir mantık sisteminde bir kişinin 50 yaşında olması orta yaşlı veya yaşlı şeklinde ifade edilirken, bulanık bir sistem "bu kişi belirli oranda orta yaşlı ve belirli oranda yaşlı olabilir" diyebilir ve bir üyelik derecesi verir. Üyelik derecesini belirlemek için üçgen, yamuk, çan ve sigmoid gibi üyelik fonksiyonları kullanılmaktadır [24]. Üçgen, yamuk ve çan bu fonksiyonlardan en sık kullanılanları olup formülleri sırasıyla aşağıdaki Eş. 4-6'da verilmiştir.

1 değeri objenin o sınıfa ait tam üyeliği temsil ederken, 0 değeri hiçbir üyeliğin olmadığı durumu temsil eder. Bu iki değer dışında kalan diğer değerler ise büyüklükleri oranında üyeliğin olacağını gösterir. Bu durumda obje, hangi sınıf için en yüksek üyelik değerine sahipse o sınıfa dâhil edilebilir.

$$\mu_A(x) = \begin{cases} 0, & x \leq a \text{ veya } x \geq c \\ \frac{x-a}{b-a}, & x \in (a, b] \\ \frac{c-x}{c-b}, & x \in (b, c) \end{cases} \quad (4)$$

Burada a , b ve c üçgenin köşe noktalarıdır.

$$\mu_A(x) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & x \in (a, b] \\ 1, & x \in (b, c] \\ \frac{d-x}{d-y}, & x \in (c, d) \\ 0, & x \geq d \end{cases} \quad (5)$$

Burada a , b , c ve d yamuğun köşe noktalarıdır.

$$\mu_A(x) = \left\{ e^{-\frac{(x-c)^2}{2\sigma^2}} \right\} \quad (6)$$

Burada c fonksiyonun merkezini ve σ ise standart sapmadır. FL yöntemi sonucunda bulunan 1 değeri objenin o sınıfa kesin olarak ait olduğunu gösterirken, 0 değeri ise objenin hiçbir o sınıfa ait olmadığını göstermektedir. Bu iki değer dışında bulunan değerlerden en yüksek üyelik değerine sahip sınıfa obje dâhil edilmektedir.

2.4. Doğruluk Değerlendirmesi (Accuracy Assessment)

Yapılan çalışmalarda tek bir sonuç elde ediliyorsa bu sonucun doğruluğu veya birden sonuç fazla sonuç elde ediliyorsa hangi sonucun en yüksek doğruluğa sahip olduğu hata matrisi gibi doğruluk belirleme yöntemleriyle elde edilir. Bu yöntem referans veri ile sınıflandırılmış görüntünün karşılaştırılması esasına dayanmaktadır. Hata matrisi kullanılarak genel doğruluk (OA), kappa, üretici ve kullanıcı doğruluğu metrikleri hesaplanmaktadır.

OA doğru olarak sınıflandırılan piksel veya obje sayısının toplam piksel veya obje sayısına oranıdır. Kappa referans veri ile sonuç haritası arasındaki uyumu ölçer. Kappa değeri 1'e yaklaştıkça uyumun arttığını, 0'a yaklaştıkça ise uyumun azaldığını gösterir. Üretici doğruluğu, her sınıf içinde doğru olarak sınıflandırılmış piksellerin veya objelerin sayısının, her sınıf için kullanılan referans veri setindeki toplam piksel veya obje sayısına bölerek bulunurken

kullanıcı doğruluğu ise her sınıf içinde doğru sınıflandırılmış piksel veya obje sayısını, ilgili kategori içinde sınıflandırılan piksellerin toplam sayısına bölünmesiyle bulunur.

2.5. McNemar's testi (McNemar's test)

McNemar's testi, sonuçları olan eşleştirilmiş verileri karşılaştırmak için kullanılan parametrik olmayan bir testtir. Bu test, özellikle aynı deneklerin farklı yöntemlerle test edildiği durumlarda, sonuçların anlamlı bir şekilde farklılık gösterip göstermediğini belirlemek amacıyla kullanılmaktadır. LULC haritalarının üretiminde, farklı sınıflandırma algoritmalarının sonuçlarını karşılaştırırken de bu test oldukça faydalı olabilmektedir. Bu noktada, McNemar's testi, iki veya daha fazla algoritmanın ürettiği LULC haritalarının benzerlik ve farklılıklarını değerlendirerek, sonuçların anlamlı olup olmadığını göstermektedir.

McNemar's testi, iki sınıflandırmanın karşılaştırıldığı durumlarda, örneğin bir pikselin SVM tarafından tarım alanları olarak, RF tarafından ise orman alanları olarak sınıflandırılması gibi uyumsuz eşleşmeleri ortaya çıkarır. Bu tür uyumsuzluklar uyumsuz çiftler (discordant pairs) olarak adlandırılır ve McNemar's testi bu çiftlerin sayısını kullanarak sonuçların farkını belirler. Uyumsuz çiftlerin sayısı, b ve c ile ifade edilir ve testin formülü Eş. 7'de verilmektedir.

$$\chi^2 = (b - c)^2 / (b + c) \quad (7)$$

Eş. 7'ye göre elde edilen χ^2 değeri, anlamlılık seviyesine (örneğin, $\alpha=0,05$) karşılık gelen tablo değeriyle kıyaslanır. Eğer bu değer tablo değerinden büyük ise iki yöntem arasındaki farkın istatistiksel olarak anlamlı olduğunu gösterir.

3. Sonuçlar ve Tartışmalar (Results and Discussions)

3.1. Segmentasyon (Segmentation)

Nesne tabanlı sınıflandırmanın ilk ve en önemli kısmı olan segmentasyon aşaması birbirleriyle homojen özellik gösteren piksellerin birleştirilerek objeler elde etme işlemidir. Bu objeler oluşturulurken chessboard, quadtree ve multiresolution gibi segmentasyon çeşitlerinden faydalanılır. Bu segmentasyon çeşitleri farklı parametre değerleriyle ayrı ayrı denenmiş ve bölgedeki sınıflar düzenli bir şekle sahip olmadıkları için çalışma kapsamında multiresolution segmentasyonun kullanılmasının uygun olduğu görülmüştür.

Çalışma kapsamında segmentasyon aşamasında bitki örtüsü yoğun olan ağaç, yeşil alanlar ve tarım alanları sınıflarının diğer sınıflardan

daha rahat bir biçimde ayırt edilebilmesi için bant ağırlığı kırmızı, yeşil ve mavi bantları için 1 girilirken yakın kızılötesi bant için ise 2 girilmiştir.

Multiresolution segmentasyonunda objelerin minimum boyutunu tayin eden ölçek parametresi en önemli parametredir. Fakat bu parametre seçilirken değerin gereğinden küçük girilmesi gereksiz obje oluşmasına, gereğinden büyük girilmesi de detay kaybına sebep olabilmektedir. Uygun ölçek parametre değerini bulmak için şekil ve bütünlük parametreleri sabit tutulmuş ve bu parametreye birçok farklı değer verilerek denenmiştir. Şekil 2, ölçek değerlerinin değişimine bağlı olarak obje sınırlarında meydana gelen farklılıkları görsel olarak ortaya koymuştur. Bu figür üzerinden, ölçek parametresinin objelerin görsel sınırlarını nasıl etkilediği açık bir şekilde izlenebilmektedir. Şekil 2a, Şekil 2b ve Şekil 2c'de, farklı ölçek değerleriyle (sırasıyla 10, 20 ve 50) elde edilen objelere ait örnekler sunulmuştur. Bu ölçek seviyelerinin sınıflandırmada uygun olup olmadığını değerlendirmek için sınıf başına 20 farklı nesne, seçilen ölçek düzeylerinde görsel olarak kontrol edilmiştir. Ölçek parametresi 10 verildiğinde Şekil 2a'da gösterilen objelerin tek bir obje olmasının hem gereksiz obje oluşumunu engelleyebileceği hem de sınıflandırma sırasında eğitim aşamasını hızlandırabileceği gözlemlenmiştir. Şekil 2b'de de ölçek parametresi 20 olarak seçilmiş ve oluşan objelerin gerçekte benzerlik gösterdiği tespit edilmiştir. Şekil 2c'de ise ölçek parametresi 50 girildiğinde de detay kaybı olduğunun farkına varılmıştır. Yapılan birçok karşılaştırılma sonucunda uygun ölçek parametresinin 20 alınmasına karar verilmiştir.

Renk parametresi komşu piksellerin yansıtım değerlerindeki benzerliği dikkate almaktadır. Birbirlerini 1'e tamamladıkları için şekil parametresi renk parametresi ile doğrudan ilişkilidir. Ölçek ve bütünlük parametreleri sabit tutularak denenilen birçok şekil parametre değerlerinden 0,1, 0,3, 0,5 için elde edilen örnek objeler Şekil 3a, Şekil 3b ve Şekil 3c'de gösterilmiştir. Bu çalışma kapsamında, ölçek ve bütünlük parametreleri sabit tutularak yalnızca şekil parametresine odaklanılmış ve birçok şekil parametreleri denenmiştir. Denenen şekil parametre değerlerinden Şekil 3a, 3b ve 3c, sırasıyla 0,1, 0,3 ve 0,5 şekil parametresi ile oluşturulan segmentasyon sonuçlarının obje sınırlarına etkisini görsel olarak karşılaştırmalı şekilde sunmuştur. Bu şekiller üzerinden şekil parametresi arttıkça renk parametresinin etkisi azalacağından dolayı, oluşan objelerin birden fazla sınıf içerdiği görülmüştür. Bu gözlemler doğrultusunda, görsel bütünlük ve sınıf temsiliyeti açısından optimum şekil parametresinin 0,1 olduğu sonucuna varılmıştır.

Çalışma kapsamında multiresolution yönteminin son seçim aşaması olan bütünlük parametresi de oluşturulan objelerin sınırlarının ve şekillerinin daha düzgün olabilmesinde rol oynamaktadır. Bu parametreye ilişkin denenilen birçok bütünlük değerinden bazılarının




Şekil 2. Multiresolution segmentasyon parametrelerinden ölçek parametresinin değişimine bağlı olarak obje sınırlarının nasıl farklılaştığı: a) 10, b) 20, c) 50

(How the object boundaries differ depending on the change of scale parameter from the multiresolution segmentation parameters: a) 10, b) 20, c) 50)


görsel analiz sonuçları Şekil 4'te detaylı şekilde sunulmuştur. Şekil 4a, Şekil 4b ve Şekil 4c, sırasıyla 0,1, 0,3 ve 0,5 bütünlük parametresi değerleri ile elde edilen obje yapılarının görsel karşılaştırmalarını içermektedir. Bu şekillerden bütünlük parametresi arttıkça segmentasyon sonucu oluşan objelerin sınırlarının gereğinden fazla keskinleşerek doğal yapıyı bozduğu, parametrenin düşük olması durumunda ise objeler arasındaki fiziksel ayrımın zayıfladığı ve gereksiz nesne oluşumuna neden olduğu net bir şekilde

gözlemlenmiştir. Bu nedenle en uygun bütünlük parametre değeri 0,5 değeri olarak kabul edilmiştir. Yukarıda verilen multiresolution segmentasyonunun parametrelerinin en uygun değerlerinin belirlenebilmesi için yapılan görsel yorumlamalar dikkate alındığında ölçek parametresi 20, şekil parametresi 0,1 ve bütünlük parametresi 0,5 değeri olarak belirlenmiştir. Bu parametre kombinasyonu kullanılarak gerçekleştirilen segmentasyon işlemi sonucunda yaklaşık 144000 adet obje oluşturulmuştur (Şekil 5).




Şekil 3. Multiresolution segmentasyon parametrelerinden şekil parametresinin değişimine bağlı olarak obje sınırlarının nasıl farklılaştığı: a) 0,1, b) 0,3, c) 0,5

(How the object boundaries differ depending on the change of shape parameter from the multiresolution segmentation parameters: a) 0.1, b) 0.3, c) 0.5)



Şekil 4. Multiresolution segmentasyon parametrelerinden bütünlük parametresinin değişimine bağlı olarak obje sınırlarının nasıl farklılaştığı: a) 0,1, b) 0,3, c) 0,5

(How the object boundaries differ depending on the change of compactness parameter from the multiresolution segmentation parameters: a) 0.1, b) 0.3, c) 0.5)



Şekil 5. Multiresolution segmentasyonunun ölçek, şekil ve bütünlük parametreleri doğru ayarlandığında oluşan objelerin görsel temsili (Visual representation of objects formed when the scale, shape and compactness parameters of multiresolution segmentation are set correctly)

3.2. Sınıflandırma (Classification)

Çalışma yapılan bölgede sınıflandırma işleminde su kanalı, tarım alanları, ağaç, yeşil alanlar, gölge, toprak yollar, bina, çatı, kaldırım, yollar ve çıplak alanlar sınıflarının kullanılmasına karar verilmiştir. Daha sonra su kanalı hariç bu sınıfların her biri için 200 obje seçilmiş ve bu objelerin %70'i eğitim ve kalan %30'u ise test olmak üzere rastgele ayrılmıştır. Daha sonra sınıflandırmada kullanılmak üzere toplam 15 adet özellik seçilmiştir.

BAI çıplak alanları yani bitki örtüsünün bulunmadığı veya çok az olduğu alanları tespit etmek için geliştirilmiştir. BAI görüntünün mavi (BLUE) ve yakın kızılötesi (NIR) bantlarının Eş. 8'de kullanılmasıyla elde edilmektedir.

$$BAI = (BLUE - NIR) / (BLUE + NIR) \quad (8)$$

Çıplak alanlarda, NIR değerlerinin düşük olması ve BLUE değerlerinin nispeten daha yüksek olması, çıplak alanların daha yüksek BAI değerlerine sahip olmasına neden olmaktadır. Bitki örtüsü yoğun olan bölgelerde ise, NIR değeri daha yüksek olduğundan, bu da bu tür alanlarda BAI'nin düşük olmasına neden olmaktadır.

NDVI, bitki örtüsünün yoğunluğunu ve sağlığını ölçmek için yaygın olarak kullanılan bir endekstir. Eş. 9'da verilen görüntünün kırmızı (RED) ve yakın kızılötesi (NIR) bantlarının kombinasyonu ile elde edilmektedir.

$$NDVI = (NIR - RED) / (NIR + RED) \quad (9)$$

Bitkilerin sağlıklı yaprakları, NIR bölgesinde yüksek yansıma gösterir. Ayrıca bitkiler, fotosentez yapmak için kırmızı ışığı soğurur. Bu nedenle NDVI bitki örtüsü yoğunluğu ile doğru orantılı olmaktadır.

NDWI, su varlığını belirlemek ve izlemek için kullanılan bir endekstir. Yeşil (GREEN) ve yakın kızılötesi (NIR) bantları kullanılarak elde NDWI formülü Eş. 10'da verilmiştir.

$$NDWI = (GREEN - NIR) / (GREEN + NIR) \quad (10)$$

Bant oranı 1, elektromanyetik spektrumun mavi (BLUE) ve kırmızı (RED) bantları arasındaki oranı ile oluşturulmaktadır (Eş. 11).

$$Bant\ oranı\ 1 = BLUE / RED \quad (11)$$

Bu oran özellikle yolların ve binaların ayırt edilmesinde kullanılmaktadır.

Bant oranı 2 ise özellikle kaldırımların ayırt edilmesinde kullanılmaktadır (Eş. 12).

$$Bant\ oranı\ 2 = BLUE / GREEN \quad (12)$$

Mean (RED, GREEN, BLUE, NIR), segmentasyon sonucunda oluşan her bir nesnenin bu dört bant için ortalama yansıma değerlerini hesaplamak için kullanılmaktadır.

Brightness (Parlaklık), genellikle bir objenin her bant için ortalama yansıma değerlerinin hesaplanıp bu değerlerin ortalamasının alınmasıyla elde edilmektedir. Bir objenin parlaklığı Eş. 13'te gibi hesaplanmaktadır.

$$\frac{1}{n} \sum_{i=1}^n Band_i \quad (13)$$

Burada, n kullanılan bantların sayısını, $Band_i$ her bir banttaki yansıma değerlerini ifade etmektedir.

Length/Width oranı, objelerin geometrik özelliklerini tanımlamak için kullanılan bir ölçüdür. Bu oran, bir objenin en uzun ekseninin (Length) en kısa eksenine (Width) olan oranını ifade eder ve bir nesnenin ne kadar uzun ya da geniş olduğunu değerlendirmeye yardımcı olur. Özellikle yolların ayırt edilmesinde büyük öneme sahiptir.

Asymmetry objeyi kapsayan bir elips bulunduktan sonra elipsin ana eksenlerinden büyük olanın uzunluğunun küçük olanın uzunluğuna oranıyla hesaplanmaktadır.

Rectangular fit, bir objenin ideal bir dikdörtgene ne kadar yakın olduğunu ölçen önemli bir geometrik ölçüttür. Özellikle düzenli yapılar ile düzensiz yapılar arasındaki farkı anlamak ve objelerin geometrik yapılarını analiz etmek için kullanılmaktadır.

Roundness, bir objenin elipsle ne kadar benzer olduğunu belirleyen bir geometrik ölçüttür. Bu özelliğin yüksek olduğu objeler, belirli bir merkez etrafında simetrik ve düzenli bir şekilde dağılım gösterirken, daha az olduğu objeler ise daha düzensiz bir şekle sahip olabilmektedir.

Shape index, objenin kenarlığının yumuşaklığını gösteren geometrik ölçüttür. Objenin kenarlığı ne kadar yumuşak olursa, şekil indeksi o kadar düşük olur. Özellikle çatı gibi yumuşak sınıfların ayırt edilmesinde büyük öneme sahiptir.

Belirlenen özellikler esas alınarak ve seçilen eğitim alanları sisteme öğretilerek sınıflandırma işlemleri kNN, FL, RF ve SVM için ayrı ayrı gerçekleştirilmiştir. Aynı zamanda bu yöntemlerde kullanılan parametrelerin en uygun değerlerini belirleyebilmek için farklı kombinasyonlar ayrı ayrı denenmiştir. kNN yönteminde kullanılan k komşuluk parametresi için 1'den 20'ye kadar olan sayılar denenmiştir. k değerinin bu aralıkta kademeli olarak artırılması, algoritmanın düşük k değerlerinde gösterdiği detay hassasiyeti ile yüksek k değerlerinde sergilediği genelleme kabiliyetinin sistematik biçimde değerlendirilmesini sağlamak amacıyla tercih edilmiştir. RF yönteminde kullanılan maksimum derinlik parametresi için 1-10, 20, 50, 100, 200, 300, 400, 500, 600, 700, 800, 900 ve 1000 olmak üzere 22 farklı değer ve maksimum ağaç sayısı parametresi için ise 50,100,200,300,400,500,600,700,800,900 ve 1000 değerleri olmak üzere 14 farklı değer alınarak toplam 308 farklı kombinasyon denenmiştir. Bu geniş aralıklar, modelin hem düşük karmaşıklıkta (örneğin: sığ ağaç yapıları, az sayıda ağaç) hem de yüksek karmaşıklıkta (örneğin: derin ağaç yapıları, yoğun ormanlar) nasıl performans gösterdiğini ortaya koymak amacıyla tercih edilmiştir. Bu çalışmada literatüre uygun olarak SVM yönteminde ise diğer kernellere göre daha etkili olan RBF kernel fonksiyonu kullanılmıştır [25-28]. RBF kernel fonksiyonunun C parametresi için 10^{-1} 'den 10^4 'e kadar artırılarak 10^8 'e kadar 10 tane değer, gamma parametresi için 10^{-5} 'ten 10^4 'e kadar artırılarak 10^4 'e kadar 10 tane değer alınmış ve toplamda 100 farklı kombinasyon denenmiştir. C parametresi küçük seçildiğinde daha esnek, büyük seçildiğinde ise daha katı karar sınırları oluşturduğu; gamma değerinin ise küçük olduğunda daha genel, büyük olduğunda ise daha karmaşık sınıflama sınırları ürettiği ifade edilmektedir [34, 35]. Bu nedenle geniş parametre aralığı, modelin hem düşük hem yüksek karmaşıklıkta performansını incelemek için uygun bir temel sunacağı için seçilmiştir.

FL sınıflandırma uygulamasında her bir özellik için hangi üyelik fonksiyonunun kullanılacağına her bir sınıf bazında ayrı ayrı karar verilmiştir. Bu işlemde, her bir sınıf için toplanan eğitim verilerinden hesaplanan özellik değerlerine en iyi uyan üyelik fonksiyonları seçilmiştir. Toplamda 165 adet (11 sınıf x 15 özellik) üyelik fonksiyonu belirlenmiş ve her birinin parametreleri, eCognition yazılımı üzerinde otomatik optimizasyon süreçleri ile hassas bir

şekilde ayarlanmıştır. Örneğin, tarım alanları, ağaç ve yeşil alan sınıflarının NDVI değerleri incelendiğinde, orta kısımlarda belirgin bir yoğunlaşma gözlemlenmiş, uç değerlere doğru ise yumuşak geçişler tespit edilmiştir. Bu nedenle yamuk üyelik fonksiyonu seçilmiştir. Toprak sınıfının NDVI değerlerinin çan eğrisine yakın olduğu için bu üyelik fonksiyonu seçilmiştir. Öte yandan, yol ve toprak yol sınıflarında, asymmetry ve length/width değerleri düşükten yükseğe doğru geçiş göstermiştir. Bu nedenle, bu özellikler sigmoid ile modellenmiştir. Bina sınıfının brightness değerleri analiz edildiğinde, belirli bir aralıkta yoğunlaşma gösterdiği, bu aralığın dışında ise hızla azaldığı bulunmuştur. Bu yapı, yamuk üyelik fonksiyonu ile başarılı bir şekilde modellenmiştir. Gölge alanları, güneş ışığını minimum düzeyde yansıttıkları için brightness değerleri düşük ve belirli bir aralıkta yoğunlaşmıştır. Bu dağılım yapısına göre gölge sınıfında bu özelliğin modellenmesinde çan üyelik fonksiyonu seçilmiştir.


3.3. Doğruluk Değerlendirmesi (Accuracy Assessment)

Sınıflandırma doğruluğu, toplanan eğitim alanları vasıtasıyla üretilen sınıflandırma haritasının test verileri ile karşılaştırılması sonucunda elde edilen hata matrisi kullanılarak belirlenmiştir. Şekil 6, farklı k değerlerinin sınıflandırma başarısı üzerindeki etkilerini grafiksel olarak ortaya koymaktadır. Bu şekilde, kNN yöntemi kullanılarak elde edilen LULC haritalarının test verilerine karşılık gelen OA değerleri görsel olarak sunulmuştur. Grafikte net bir eğilim olarak, k değeri arttıkça sınıflandırma doğruluğunun azaldığı ve en iyi sonucun k = 1 değeriyle elde edildiği görülmüştür. Test verileri kullanılarak, RF sınıflandırıcısına ait maksimum derinlik ve maksimum ağaç sayısı parametrelerinin farklı kombinasyonları denenmiş ve her kombinasyona karşılık gelen OA değerleri hesaplanmıştır. Tablo 1, bu farklı parametre ayarlarının RF'nin sınıflandırma başarısı üzerindeki etkilerini sistematik olarak ortaya koymuştur. Bu tabloda maksimum derinlik değerinin genellikle 8'e kadar genel doğruluğunu olumlu etkilediği fakat 9'dan sonra ise olumsuz etkilediği tespit edilmiştir. Ayrıca buna bağlı olarak maksimum ağaç sayısı değerindeki artışın RF'nin performansını olumsuz etkilediği bulunmuştur. Bunun sonucunda RF'ye göre maksimum derinlik için 8 ve maksimum ağaç sayısı için 50 değerlerinin en yüksek performansı verdikleri görülmüştür. SVM sınıflandırıcısının başarısı, modelin iki

parametresi olan C ve gamma değerlerine bağlı olarak önemli ölçüde değişiklik göstermektedir. Bu kapsamda, farklı C ve gamma kombinasyonları denenmiş ve her kombinasyona karşılık gelen OA değerleri hesaplanmıştır. Tablo 2, bu kombinasyonların sınıflandırma doğruluğu üzerindeki etkilerini sistematik biçimde sunmakta ve modelin parametrik hassasiyetini göstermiştir. Bu tabloya göre genel doğruluğu kabul edilebilir düzeydeki haritaların C parametresinin yüksek olduğu ve buna bağlı olarak gamma parametresinin düşük olduğu sonucuna varılmıştır. C için 10^5 ve gamma için 10^{-4} değerlerinin en iyi sonucu vermesi bu durumla tutarlılık göstermiştir. FL yönteminde ise her bir özellik için sınıf bazında ayrı ayrı seçilen üyelik fonksiyonları ve bu fonksiyonların en uygun parametre değerlerine göre sınıflandırma genel doğruluğu %84,81 olarak bulunmuştur.

Şekil 6'daki grafik, Tablo 1 ve Tablo 2'deki parametre kombinasyonlarının doğruluk üzerindeki etkilerini gösteren değerler ve FL yönteminin genel doğruluğu (%84,81) birlikte incelendiğinde, SVM yönteminin ($C=10^5$ ve $\gamma=10^{-4}$ e göre) diğer sınıflandırıcılara kıyasla daha yüksek performans gösterdiği belirlenmiştir. Bu yöntemin doğrulukları değerleri ile FL ve diğer kullanılan sınıflandırma algoritmalarının her birinin kendi içindeki en yüksek doğrulukları arasında fark olup olmadığı, istatistiksel olarak McNemar's testi kullanılarak karşılaştırılmıştır. Tablo 3, bu karşılaştırmalara ilişkin istatistiksel test sonuçlarını detaylı biçimde sunmuştur. Buradaki sonuçlar incelendiğinde tüm karşılaştırma değerlerinin %95 güven aralığındaki kritik tablo değeri olan $\chi^2 = 3,841$ değerinden büyük olduğu tespit edilmiştir. Buradan doğruluk değerleri arasındaki farklılığın istatistiksel olarak anlamlı olduğu bulunmuştur.

Çalışma kapsamında yapılan parametre optimizasyonu sonucunda en yüksek genel doğruluk değerine sahip olan $C = 10^5$ ve $\gamma = 10^{-4}$ parametreleri ile oluşturulan SVM tabanlı LULC haritası, görsel olarak Şekil 7'de sunulmuştur. Şekil 7, sınıfların sınırlarının gerçek arazi örtüsüyle yüksek düzeyde uyum sağladığını göstermiştir. Bu nedenle Şekil 7, yalnızca sınıflandırma sonucunu değil, aynı zamanda SVM yönteminin yüksek ayırt ediciliğe sahip olduğunu görsel düzlemde doğrulayan önemli bir çıktıdır. Ek olarak, aynı modele ait doğruluk metrikleri ise Tablo 4'te sayısal olarak sunulmuştur.



Şekil 6. kNN yönteminde kullanılan farklı k değerlerinin OA üzerindeki etkisi
(The effect of different k values used in kNN method on OA)

Tablo 1. RF'nin farklı parametre kombinasyonları ile elde edilen OA değerleri
(OA values obtained with different parameter combinations of RF)

Maksimum ağaç sayısı												
	50	100	200	300	400	500	600	700	800	900	1000	
Maksimum derinlik	1	0,11	0,07	0,38	0,09	0,09	0,38	0,07	0,12	0,09	0,40	0,09
	2	0,19	0,19	0,34	0,20	0,20	0,32	0,28	0,25	0,19	0,22	0,34
	3	0,44	0,31	0,42	0,33	0,45	0,45	0,38	0,44	0,31	0,45	0,45
	4	0,64	0,60	0,59	0,59	0,50	0,51	0,52	0,52	0,51	0,51	0,50
	5	0,68	0,67	0,68	0,69	0,68	0,68	0,68	0,68	0,68	0,68	0,68
	6	0,70	0,70	0,70	0,70	0,70	0,70	0,71	0,71	0,71	0,70	0,70
	7	0,69	0,70	0,70	0,69	0,69	0,70	0,71	0,71	0,71	0,71	0,70
	8	0,88	0,72	0,70	0,70	0,71	0,71	0,71	0,71	0,70	0,71	0,71
	9	0,81	0,81	0,81	0,81	0,80	0,70	0,71	0,71	0,71	0,71	0,71
	10	0,81	0,81	0,78	0,72	0,72	0,70	0,71	0,71	0,71	0,71	0,71
	20	0,69	0,70	0,70	0,70	0,70	0,69	0,70	0,69	0,69	0,69	0,71
	50	0,69	0,70	0,70	0,70	0,69	0,70	0,70	0,68	0,68	0,69	0,71
	100	0,69	0,70	0,70	0,70	0,71	0,70	0,70	0,69	0,70	0,69	0,70
	200	0,69	0,70	0,70	0,70	0,70	0,71	0,69	0,68	0,68	0,70	0,71
	300	0,69	0,70	0,70	0,70	0,69	0,70	0,70	0,69	0,68	0,69	0,71
	400	0,69	0,70	0,70	0,70	0,69	0,69	0,71	0,68	0,69	0,70	0,71
	500	0,69	0,70	0,70	0,70	0,71	0,70	0,69	0,69	0,69	0,69	0,71
600	0,69	0,70	0,70	0,70	0,71	0,69	0,71	0,68	0,68	0,69	0,71	
700	0,69	0,70	0,70	0,70	0,70	0,69	0,70	0,69	0,69	0,69	0,71	
800	0,69	0,70	0,70	0,70	0,70	0,71	0,70	0,69	0,68	0,69	0,71	
900	0,69	0,70	0,70	0,70	0,71	0,69	0,70	0,69	0,69	0,70	0,71	
1000	0,69	0,70	0,70	0,70	0,70	0,71	0,70	0,69	0,68	0,71	0,72	

Tablo 2. SVM'nin farklı gamma ve C parametre kombinasyonlarıyla bulunan OA değerleri
(OA values found with different gamma and C parameter combinations of SVM)

		gamma									
		10 ⁻⁵	10 ⁻⁴	10 ⁻³	10 ⁻²	10 ⁻¹	1	10	10 ²	10 ³	10 ⁴
C	10 ⁻¹	0,08	0,08	0,08	0,08	0,08	0,08	0,08	0,08	0,08	0,08
	1	0,15	0,27	0,53	0,12	0,08	0,08	0,08	0,08	0,08	0,08
	10 ¹	0,33	0,61	0,71	0,66	0,19	0,08	0,08	0,08	0,08	0,08
	10 ²	0,63	0,70	0,70	0,85	0,27	0,10	0,09	0,09	0,09	0,09
	10 ³	0,70	0,72	0,88	0,76	0,27	0,10	0,09	0,09	0,09	0,09
	10 ⁴	0,73	0,73	0,82	0,77	0,27	0,10	0,09	0,09	0,09	0,09
	10 ⁵	0,72	0,93	0,82	0,77	0,27	0,10	0,09	0,09	0,09	0,09
	10 ⁶	0,75	0,71	0,81	0,77	0,27	0,10	0,09	0,09	0,09	0,09
	10 ⁷	0,88	0,71	0,81	0,76	0,27	0,10	0,09	0,09	0,09	0,09
	10 ⁸	0,88	0,71	0,81	0,77	0,27	0,10	0,09	0,09	0,09	0,09

Tablo 3. Ayar parametrelerine göre optimum kNN, RF, SVM ile FL tarafından üretilen haritaların sınıflandırma performanslarına ilişkin McNemar's istatistiksel test sonuçları
(McNemar's statistical test results on the classification performance of maps produced by optimal kNN, RF, SVM and FL according to the tuning parameters)


	KNN	RF	FL
SVM	180,958	165,816	51,541

Tablo 4'teki OA ve kappa değerleri uygun parametreler kullanıldığında SVM'nin mükemmel performansa sahip olduğunu göstermiştir. Bu doğrultuda yöntemin alandaki detayları neredeyse gerçeğe yakın çıkardığı görülmüştür. Özellikle su kanalının hem üretici hem de kullanıcı doğruluğunun %100 bulunması bu sınıfın tamamının doğru tespit edildiğini göstermiştir. Çıplak alanlar haricindeki diğer sınıfların ise üretici doğrulukları oldukça yüksek

(%91 ve %99 arasında) bulunmuştur. Bu durumda bu sınıflardaki test verilerinin neredeyse tamamının doğru sınıfa atandığı sonucuna varılmıştır. Ayrıca çalışma alanında en fazla yer kaplayan çıplak alanlar sınıfının ayırt edilmesinde SVM çok yüksek olmasa da yüksek (yaklaşık %89) bir performans göstermiştir. Farklı spektral özellik göstermesinden dolayı, en fazla sınıf karışıklığı bu sınıfta tespit edilmiştir. Kullanıcı doğruluğu bakımından ise gölge, su kanalı, tarım alanları, çıplak alanlar, toprak yollar ve yollar sınıfları çok iyi performans göstermiştir. Kalan sınıfların kullanıcı doğruluğu aralığı %87 ve %89 arasında bulunmuştur.

3.4. Tartışmalar (Discussions)

Dünyada doğal kaynakların en verimli ve sürdürülebilir biçimde yönetilmesinde LULC haritalarının aktif ve güncel olarak kullanılması oldukça önemlidir. Nüfus artışının takip edilmesinin yanında tarım ve orman alanlarının plansız kentsel sonucunda kentsel alanlara dönüştürülmesi oldukça tehlikelidir ve takip edilmesi



Şekil 7. SVM yönteminin en iyi sonuçları verdiği C ve gamma parametreleriyle üretilen LULC haritası (LULC map generated with C and gamma parameters, where the SVM method gives the best results)

Tablo 4. Optimum SVM ayar parametreleriyle oluşturulan LULC haritasının sınıflandırma doğruluk metrikleri (Classification accuracy metrics of LULC map generated with the optimal SVM tuning parameters)

Sınıf	Kullanıcı doğruluğu	Üretici doğruluğu
Ağaç	0,8857	0,9506
Bina	0,8690	0,9749
Çatı	0,8768	0,9457
Gölge	0,9783	0,9914
Kaldırım	0,8912	0,9208
Su kanalı	1,0000	1,0000
Tarım alanları	0,9859	0,9291
Çıplak alanlar	0,9245	0,8868
Toprak yollar	0,9958	0,9122
Yeşil alanlar	0,8759	0,9455
Yollar	0,9739	0,9307
OA	%93,01	
Kappa	0,9162	

gerekir. Bunların takibi ve planlamalar yapılırken LULC kavramının ele alınması, doğal zenginliklerin, biyoçeşitlilikteki zenginliğin korunması açısından da büyük önem arz etmektedir.

Teknolojideki gelişmeler yüksek mekansal çözünürlüğe sahip hava fotoğraflarının artmasına neden olmuştur. Literatüre göz atıldığında, yüksek mekansal çözünürlüğe sahip görüntülerden LULC tespitinde nesne tabanlı sınıflandırma yaklaşımının piksel tabanlı yöntemlere göre daha iyi sonuç verdiği görülmüştür. Bu durum da nesne tabanlı sınıflandırma yaklaşımlarına olan ilgiyi de artırmıştır. Bu nedenle çalışma bölgesinin LULC'nın tespiti için nesne tabanlı sınıflandırma kullanılmıştır.

LULC sınıflandırılması hakkında incelenen birçok çalışmada her durumda en iyi sonucu veren bir yöntem hakkında fikir birliğine varılamamıştır. Bu durum, farklı bölgelere ait değişik kaynaklardan gelen her bir veri türü için hangi yöntemin daha iyi çalışacağı konusunda bir anlayış geliştirmenin akıllıca olabileceğini düşündürmektedir. Hem kNN, RF, SVM ve FL sınıflandırma yöntemlerinin hem de bu yöntemlerin (FL hariç) ayar parametrelerine olan tepkisinin karşılaştırıldığı bu çalışma, bu araştırmaya bir katkı

olarak düşünülebilir. Bir sınıflandırma algoritmasının etkinliği örnek sayısına, eğitim ve test verilerini seçmek için kullanılan stratejiye, çalışma alanının büyüklüğüne ve heterojenliğine ve girdi faktörlerinin sayısına bağlı olmuştur. Objektif bir karşılaştırma yapabilmek için her yöntemde aynı eğitim ve test verileriyle aynı faktörler kullanılmıştır. Ayrıca uygun yöntemin dışında nesne tabanlı sınıflandırmanın ilk aşaması olan segmentasyon aşamasında gerçeğe en yakın olarak elde edilen nesnelerin literature katkı sağlaması beklenmektedir.

kNN yönteminde kullanılan k parametresinin değeri arttıkça sınıflandırma doğruluğu üzerinde olumsuz etki yaptığı tespit edilmiş ve bu sebeple k 1 için en iyi sonucu verdiği gözlemlenmiştir. Ayrıca, hesaplama zamanı açısından kNN yöntemi diğer yöntemlerden daha az zaman almasına rağmen, OA bakımından incelendiğinde kNN'nin diğer yöntemlerden daha düşük doğruluğa sahip olduğu bulunmuştur. Fakat farklı k parametre değerlerindeki değişime karşı duyarlılığı %11,34 değeri ile en düşük olmuştur. RF yöntemi ayar parametrelerindeki değişimlere göre %81,10 çok yüksek duyarlılık göstermiştir. Parametre değerlerine göre RF yönteminden elde edilen OA değerlerindeki değişkenliğin yüksek olması bu yöntem için parametre seçiminin daha önemli olduğunu göstermektedir. RF için

parametreler incelendiğinde maksimum ağaç sayısı değeri ne olursa olsun derinlik değerinin 8'den küçük ve 10'dan büyük olduğu durumlarda iyi sonuçlar vermediği (%80'den düşük) gözlemlenmiştir. RF yöntemi için yüksek doğruluk değerine (%80 ve daha fazla) ulaşabilen parametreler derinlik için 8, 9 ve 10 ve maksimum ağaç sayısı için 50, 100, 200, 300 ve 400 olarak tespit edilmiştir. Bu yöntem için optimum parametre seti derinlik 8 ve maksimum ağaç sayısı 50 olarak bulunmuştur. Farklı C ve gamma değerlerinin SVM yöntemi için sınıflandırma doğruluklarını nasıl etkilediği incelendiğinde gamma değeri 0,1'den büyük olduğunda, sınıflandırma doğrulukları, C parametresinin değeri ne olursa olsun, %7,66 ile %26,85 arasında düşük olduğu ve bu sonuç gamma değerinin 0,1'den fazla olmaması gerektiğini gösterdi. Bu bulgu, benzer özelliklere sahip farklı çalışmalarla desteklenmektedir. Qian vd. [29], farklı gamma ve C değerlerinin SVM sınıflandırıcısının doğrulukları üzerindeki etkisini araştırmış ve C değerine bakmaksızın gamma değerinin 10^{-1} 'den büyük olduğunda sınıflandırma doğruluklarının %20-74 arasında değiştiğini bulmuşlardır. Ayrıca yüksek doğruluklara (%80 ve daha fazla) ulaşılabilen C değerleri 10^2 ile 10^8 arasında ve gamma 10^{-5} ile 10^{-2} arasındadır. SVM yöntemi için optimum parametre seti C için 10^5 ve 10^{-4} olarak tespit edilmiştir. Bu durum, yüksek C ve düşük gammaların SVM sınıflandırıcısı için en yüksek genel doğruluğu ürettiğini gösteren çalışmayla tutarlılık göstermiştir [30]. SVM'nin genel doğruluğunun model parametrelerine diğer üç sınıflandırıcıdakinden daha duyarlı olmasından dolayı SVM'nin performansını optimize etmek için geniş bir parametre alanında etkili bir şekilde arama yapılması gereklidir.

Sınıflandırma doğruluklarının karşılaştırılması ile ilgili olarak, en yüksek OA SVM (%93,06) tarafından üretilmiştir ve bunu RF (%87,91) ve FL (%84,81) ve son olarak kNN (%82,56) takip etmiştir. Çalışmadaki LULC türlerinin sınıflandırma doğruluğu için, SVM diğer sınıflandırma algoritmalarından daha doğru olduğu bulunmuştur. Ayrıca SVM diğer 3 yöntem ile McNemar's testi ile karşılaştırıldığında istatistiksel olarak anlamlı bir fark bulunmuştur. Bu sonuç birçok benzer çalışma ile tutarlılık göstermiştir. Thanh Noi ve Kappas [30], LULC üretiminde sınıflandırma algoritmaları olarak kNN, SVM ve RF'nin performanslarını karşılaştırmış ve SVM'nin diğer iki yöntemden daha iyi olduğunu bulmuştur. Keshtkar vd. [31], SVM sınıflandırmasının, heterojen bir peyzajın arazi örtüsü türlerinin sınıflandırılması için RF'den genellikle daha doğru olduğunu öne sürmüştür. Birçok parametre kombinasyonları kullanılarak elde edilen LULC haritalarının sonuçları incelendiğinde dört yöntem arasında performans açısından farklılıklar bulunmuştur. SVM yönteminin diğer yöntemlerden daha iyi sonuç ürettiği tespit edilmiştir. Fakat bu çalışmanın literatüre katkısı, yalnızca farklı sınıflandırma algoritmalarının karşılaştırılmasıyla sınırlı değildir. Segmentasyon parametrelerinin çok sayıda deneme ile optimize edilmesi, nesne oluşturma sürecinin sınıflandırma başarısı üzerindeki etkisini açıkça ortaya koymaktadır. Ayrıca, kNN, RF, SVM ve FL yöntemlerinin sınıflandırma performansları yalnızca doğruluk metrikleri ile değil, aynı zamanda istatistiksel olarak anlamlılık düzeyinde de karşılaştırılmıştır. Literatürde nadiren kullanılan McNemar's testi, bu farklılıkların tesadüfi olup olmadığını göstermek açısından önemli bir araç olarak kullanılmıştır. FL yönteminde her sınıf için ayrı üyelik fonksiyonları tanımlanması ve bu fonksiyonların veriye özgü belirlenmesi, bulanık mantığın uygulanmasında özgün bir yaklaşım sunmuştur. Böylece çalışmanın yöntembilimsel derinliği artırılmış ve yüksek çözünürlüklü hava fotoğraflarının sınıflandırmasında daha güçlü bir modelleme yapılmıştır.

4. Sonuçlar (Conclusions)

Bu çalışmada, çok yüksek çözünürlüklü görüntüye sahip Kayseri ilinin sınıf çeşitliliği fazla olan bir bölgesinin LULC haritasını elde etmek amacıyla öncelikle objeleri elde etmede kullanılan

multiresolution segmentasyon yönteminin optimum ayar parametreleri (ölçek, şekil, bütünlük) belirlenmiştir. Bu işlem birçok farklı parametre kombinasyonu gerçekte karşılaştırılarak gerçekleştirilmiştir. Daha sonra oluşturulan objeler kNN, RF ve SVM ve FL yöntemleri kullanılarak sınıflandırıldı ve yöntemlerin performansları sınıflandırma doğrulukları baz alınarak karşılaştırıldı. Burada (FL hariç) her yöntemin optimal parametreleri çeşitli parametre kombinasyonlarının sınıflandırma sonuçları üzerindeki etkileri incelenerek bulunmuştur. Sınıflandırıcıların ayar parametrelerinin sınıflandırma doğruluğu üzerindeki etkisi ele alındığında SVM'nin bu etkiye karşı çok fazla duyarlı olduğu ve bunu RF'nin izlediği görülmüştür. Ancak kNN ise bu duruma karşı SVM ve RF'ye göre nispeten çok az duyarlılık göstermiştir. SVM'de C 100000 ve gamma 0,0001 değerlerini aldığında, RF'de maksimum derinlik 8 ve maksimum ağaç sayısı 50 değerlerini aldığında ve kNN'de k 1 değerini aldığında, bu yöntemler kendi içlerinde maksimum performans göstermiştir. SVM yöntemi optimal C ve gamma parametresi kullanıldığında diğer 3 yöntemden daha üstün performans göstermiştir. Bu yöntemle göre çalışma alanının çok küçük bir kısmını su kanalı (yaklaşık %0,085) oluştururken en büyük kısmını ise (yaklaşık %28) çıplak alanlar sınıfı oluşturmuştur. Çıplak alanlar sınıfı bazı sınıflarla benzer özellik göstermesine rağmen SVM bu sınıfı diğer sınıflardan çok iyi derecede ayırmıştır. Ayrıca birbirine çok yakın spektral özelliğe sahip ağaç, yeşil alanlar ve tarım alanlarını da çok iyi kategorize ettiği tespit edilmiştir. Bu çalışma, yüksek çözünürlüklü görüntüyle herhangi bir bölgenin yönetiminde ve planlanmasında kullanılan LULC haritası oluşturulurken nesne tabanlı sınıflandırma yöntemlerinin karşılaştırılması üzerine kapsamlı bir araştırma sunmuştur. Burada elde edilen sonuçlar, araştırmacılara hangi yöntemleri kullanacaklarını ve bu yöntemleri kullandıklarında nasıl en iyi sonuçları elde edeceklerini belirlemeleri konusunda rehberlik sağlamaktadır. Ayrıca, bu çalışmanın, nesne tabanlı sınıflandırma yöntemlerinin geliştirilmesi ve iyileştirilmesi için ileriye yönelik çalışmaların temelini oluşturması da beklenmektedir.

Bu çalışmada elde edilen detaylı LULC haritaları, çevresel planlama ve arazi yönetimi gibi alanlarda etkili karar destek sistemleri oluşturulmasına olanak tanımaktadır. Tarım alanlarının doğru şekilde belirlenmesi, hassas tarım uygulamalarında su yönetimi, mahsul planlaması ve gübreleme stratejilerinin optimize edilmesine yardımcı olabilir. Benzer şekilde, çıplak arazi ve orman sınıflarının yüksek doğrulukla tespit edilmesi, toprak koruma stratejilerinin geliştirilmesi ve orman yönetimi planlamalarında etkili bir araç olarak kullanılabilir. Ayrıca, yol ve bina sınıflarının doğru bir şekilde sınıflandırılması, kentsel planlama, altyapı geliştirme ve yeni yerleşim yerlerinin belirlenmesinde yerel yönetimler için önemli bir veri kaynağı sağlamaktadır.

Endüstriyel ve uygulamalı alanlarda, bu sınıflandırma yaklaşımı özellikle madencilik, enerji üretimi ve su yönetimi gibi sektörlerde mekânsal karar destek sistemlerinin doğruluğunu artırabilir. Örneğin, madencilik sahalarının doğru bir şekilde tespiti, rehabilitasyon süreçlerinin daha verimli yürütülmesine katkı sağlar. Benzer şekilde, enerji santralleri ve su kaynaklarının çevresel etkilerinin izlenmesinde LULC haritaları, arazi kullanımı değişikliklerinin analiz edilmesini mümkün kılmaktadır. Ayrıca, altyapı projelerinde, yol ağlarının doğru bir şekilde belirlenmesi, lojistik planlamalarda zaman ve maliyet tasarrufu sağlamaktadır.

Sonuç olarak, bu çalışma, sadece sınıflandırma yöntemlerinin doğruluğunu ortaya koymakla kalmamış, üretilen haritaların çevresel planlama, arazi yönetimi ve endüstriyel uygulamalar için geniş bir kullanım potansiyeline sahip olduğunu göstermiştir. Bu doğrultuda, gelecekteki araştırmalarda nesne tabanlı sınıflandırma yöntemlerinin daha geniş alanlarda uygulanabilirliği araştırılabilir ve karar destek sistemleriyle entegrasyonu sağlanabilir.

Kaynaklar (References)

1. Lu, D., Weng, Q., A survey of image classification methods and techniques for improving classification performance, *Int. J. Remote Sens.*, 28 (5), 823-870, 2007.
2. Blaschke, T., Object based image analysis for remote sensing, *ISPRS J. Photogramm. Remote Sens.*, 65 (1), 2-16, 2010.
3. Myint, S. W., Gober, P., Brazel, A., Grossman-Clarke, S., Weng, Q., Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery, *Remote Sens. Environ.*, 115 (5), 1145-1161, 2011.
4. Matejčíková, J., Věbová, D., Surový, P., Comparative Analysis of Machine Learning Techniques and Data Sources for Dead Tree Detection: What Is the Best Way to Go?, *Remote Sensing*, 16 (16), 3086, 2024.
5. Nasiri, V., Hawrylo, P., Janiec, P., Socha, J., Comparing object-based and pixel-based machine learning models for tree-cutting detection with planetscope satellite images: exploring model generalization, *Int. J. Appl. Earth Obs. Geoinf.*, 125, 103555, 2023.
6. Jovanović, D., Gavrilović, M., Sladić, D., Radulović, A., Govedarica, M., Building change detection method to support register of identified changes on buildings, *Remote Sensing*, 13 (16), 3150, 2021.
7. Riggan Jr, N., Weih Jr, R. C., Comparison of pixel-based versus object-based land use/land cover classification methodologies, *Journal of the Arkansas Academy of Science*, 63 (1), 145-152, 2009.
8. Li, X., Shao, G., Object-based land-cover mapping with high resolution aerial photography at a county scale in midwestern USA, *Remote Sensing*, 6 (11), 11372-11390, 2014.
9. Qu, L. a., Chen, Z., Li, M., Zhi, J., Wang, H., Accuracy improvements to pixel-based and object-based LULC classification with auxiliary datasets from Google Earth Engine, *Remote Sensing*, 13 (3), 453, 2021.
10. Tassi, A., & Vizzari, M., Object-oriented LULC classification in google earth engine combining snic, glcm, and machine learning algorithms, *Remote Sensing*, 12 (22), 3776, 2020.
11. Kasahun, M., & Legesse, A., Machine learning for urban land use/cover mapping: Comparison of artificial neural network, random forest and support vector machine, a case study of Dilla town, *Heliyon*, 10(20), 2024.
12. Balha, A., Mallick, J., Pandey, S., Gupta, S., & Singh, C. K., A comparative analysis of different pixel and object-based classification algorithms using multi-source high spatial resolution satellite data for LULC mapping, *Earth Science Informatics*, 14 (4), 2231-2247, 2021.
13. Selvaraj, R., Amali, D., & Bessie, G., Assessment of object-based classification for mapping land use and land cover using google earth, *Global Nest Journal*, 25 (7), 131-138, 2023.
14. Luo, X., Tong, X., & Pan, H., Integrating multiresolution and multitemporal Sentinel-2 imagery for land-cover mapping in the Xiongan New Area, China, *IEEE Transactions on Geoscience and Remote Sensing*, 59 (2), 1029-1040, 2020.
15. Li, M., Ao, Y., Peng, W., He, J., Research of status recognition of fiber transfer box based on machine vision and deep learning, *Multimedia Tools Appl.*, 79 (39), 28695-28709, 2020.
16. Peyvandí, K., Yaghmaee, F., Improving image inpainting based on structure and texture information using quadtree, *Int. J. Eng.*, 33 (5), 940-948, 2020.
17. Jawak, S. D., Wankhede, S. F., Luis, A. J., Balakrishna, K., Multispectral characteristics of glacier surface facies (Chandra-Bhaga Basin, Himalaya, and Ny-Ålesund, Svalbard) through investigations of pixel and object-based mapping using variable processing routines, *Remote Sensing*, 14 (24), 6311, 2022.
18. Cover, T., Hart, P., Nearest neighbor pattern classification, *IEEE Trans. Inf. Theory*, 13 (1), 21-27, 1967.
19. Cunningham, P., Delany, S. J., k-Neighbour classifiers, Technical Report UCD-CSI-2007-4, School of Computer Science & Informatics, University College Dublin, 2007.
20. Liu, H., Zhang, S., Noisy data elimination using mutual k-nearest neighbor for classification mining, *J. Syst. Software*, 85 (5), 1067-1074, 2012.
21. Weinberger, K. Q., Saul, L. K., Distance metric learning for large margin nearest neighbor classification, *J. Mach. Learn. Res.*, 10 (2), 207-244 2009.
22. Haapanen, R., Ek, A. R., Bauer, M. E., Finley, A. O., Delineation of forest/nonforest land use classes using nearest neighbor methods, *Remote Sens. Environ.*, 89 (3), 265-271, 2004.
23. Breiman, L., Random forests, *Mach. Learn.*, 45, 5-32, 2001.
24. Belgiu, M., Drăguț, L., Random forest in remote sensing: A review of applications and future directions, *ISPRS J. Photogramm. Remote Sens.*, 114, 24-31, 2016.
25. Melville, B., Lucieer, A., Aryal, J., Object-based random forest classification of Landsat ETM+ and WorldView-2 satellite imagery for mapping lowland native grassland communities in Tasmania, Australia, *Int. J. Appl. Earth Obs. Geoinf.*, 66, 46-55, 2018.
26. Ding, S., Hua, X., Recursive least squares projection twin support vector machines for nonlinear classification, *Neurocomputing*, 130, 3-9, 2014.
27. Liu, T., Chen, J., Kong, L., Li, X., Chen, X., Utilization of a portable Raman spectrometer combined with a PCA-SVM model for starch type differentiation, *Food Biosci.*, 57, 103465, 2024.
28. Zadeh, L. A., Fuzzy sets, *Information and Control*, 8, 338-353, 1965.
29. Özdemir, O., Kalınkara, Y., Bulanık mantık: 2000-2020 yılları arası tez ve makale çalışmalarına yönelik bir içerik analizi, *Acta Infologica*, 4 (2), 155-174, 2020.
30. Mountrakis, G., Im, J., Ogole, C., Support vector machines in remote sensing: A review, *ISPRS J. Photogramm. Remote Sens.*, 66 (3), 247-259, 2011.
31. Kavitha, K., Arivazhagan, S., Kanaga Sangeetha, I., Hyperspectral image classification using support vector machine in Ridgelet domain, *Natl. Acad. Sci. Lett.*, 38, 475-478, 2015.
32. Jozdani, S. E., Johnson, B. A., Chen, D., Comparing deep neural networks, ensemble classifiers, and support vector machine algorithms for object-based urban land use/land cover classification, *Remote Sensing*, 11 (14), 1713, 2019.
33. Arfa, A., Minaci, M., Utilizing multitemporal indices and spectral bands of Sentinel-2 to enhance land use and land cover classification with random forest and support vector machine, *Adv. Space Res.*, 2024.
34. Huang, C. L., & Wang, C. J., A GA-based feature selection and parameters optimization for support vector machines, *Expert Systems with applications*, 31 (2), 231-240, 2006.
35. Kavitha, K., Arivazhagan, S., & Kanaga Sangeetha, I., Hyperspectral image classification using support vector machine in Ridgelet domain, *National Academy Science Letters*, 38, 475-478, 2015.
36. Qian, Y., Zhou, W., Yan, J., Li, W., & Han, L., Comparing machine learning classifiers for object-based land cover classification using very high resolution imagery, *Remote Sensing*, 7 (1), 153-168, 2014.
37. Thanh Noi, P., Kappas, M., Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery, *Sensors*, 18 (1), 18, 2017.
38. Keshtkar, H., Voigt, W., Alizadeh, E., Land-cover classification and analysis of change using machine-learning classifiers and multi-temporal remote sensing imagery, *Arabian J. Geosci.*, 10, 1-15, 2017.

