

YÜKSEK ÇÖZÜNÜRLÜKLÜ OPTİK GÖRÜNTÜLER VE SAYISAL YÜZEY MODELİ İLE DERİN ÖĞRENME TABANLI BİNA ÇATILARININ TESPİTİ

Mehmet Akif GÜNEN¹, Enes Reha MUTLU², Erkan BEŞDOK³

¹Doç. Dr., Gümüşhane Üniversitesi, Harita Mühendisliği Bölümü, Gümüşhane, aktif@gumushane.edu.tr

²Yüksek Lisans Öğrencisi, Erciyes Üniversitesi, FBE Enstitüsü, Harita Mühendisliği Bölümü, Kayseri, ensmutlu@gmail.com

³Prof. Dr., Erciyes Üniversitesi, Harita Mühendisliği Bölümü, Kayseri, ebesdok@erciyes.edu.tr

ÖZET

Bu çalışmada, yüksek çözünürlüklü optik görüntü görünür bantları (KYM) ve sayısal yüzey modeli (SYM) kullanılarak bina çatılarının otomatik olarak tespiti için bir yöntem önerilmektedir. Önerilen yöntem, çok kaynaklı veri füzyonu ve derin öğrenme tekniklerini kullanmaktadır. Farklı kaynaklardan elde edilen veriler; bina çatılarının tespit performansını artırmak için kaynaştırılmıştır. Derin öğrenme yöntemi olarak ise DeepLabv3+ modelinin MobileNetV2 omurgası kullanılmıştır. Eğitim ve test verisi olarak, Elbistan, Kahramanmaraş'a ait yüksek çözünürlüklü ortofoto, KYM, SYM, görünür bant farkı bitki örtüsü indeksi (VDVI) ve topografik konum indeksi (TKI) kullanılmıştır. Elde edilen sonuçlar; önerilen yöntemin farklı geometri ve tipteki bina çatılarının tespitinde oldukça başarılı olduğunu göstermektedir. Sadece KYM verisi kullanılarak elde edilen doğruluk, geri çağırma, prezisyon, F_Skor ve geometrik ortalama değerleri sırasıyla %79.04, %55.39, %86.87, %67.65 ve %72.36'dır. Tüm verilerin kullanılmasıyla bu değerler sırasıyla %97.34, %95.40, %97.82, %96.66 ve %96.99'a yükselmiştir. Sonuçlar; bina tespitinde derin öğrenme yöntemlerinin yüksek doğruluk ve hassasiyetle çalışabildiğini ve farklı veri kaynaklarının entegrasyonunun performansı artırdığını ortaya koymaktadır.

Anahtar Kelimeler: Çatı tespiti, DeepLabv3+, ortofoto, sayısal yüzey modeli.

1. GİRİŞ

Günümüzde yüksek çözünürlüklü optik görüntülerinden bina tespiti (Günen, 2024), şehir planlaması (Dhanaraj ve Angadi, 2021), afet yönetimi (Kucharczyk ve Hugenholtz, 2021) ve çevresel izleme (Günen ve Atasever, 2024) gibi çeşitli alanlarda hayati öneme sahip bir araştırma konusu haline gelmiştir. Yüksek çözünürlüklü uydu ve hava görüntüleri, binaların detaylı ve doğru bir şekilde belirlenmesine olanak tanır, ancak bu sürecin otomatikleştirilmesi ve doğruluğunun artırılması hâla birçok zorluğu beraberinde getirir. Yüksek çözünürlüklü optik görüntülerinin kullanımı, büyük veri miktarlarının işlenmesi ve yüksek hesaplama gücü gerektirmesi nedeniyle teknik zorluklar içerir. Bu görüntülerin işlenmesi, geleneksel fiziksel kurallara dayalı yöntemler, görüntü segmentasyonu tabanlı yöntemler ve gelişmiş makine öğrenmesi teknikleri (özellikle derin öğrenme) gibi çeşitli yöntemlerle gerçekleştirilebilir. Geleneksel yöntemler genellikle daha az karmaşıklığa sahip olup belirli koşullarda etkili olabilirken, derin öğrenme tabanlı yöntemler daha yüksek doğruluk oranları sunmaktadır ancak daha fazla veri ve işlem gücü gerektirir (J. Li vd., 2022; Q. Li vd., 2024; Wierzbicki vd., 2021).

Son yıllarda, binaların tespitinde çok kaynaklı veri füzyonu, özellikle optik görüntüler ile LiDAR (Light Detection and Ranging) (Touzani ve Granderson, 2021; Ullo vd., 2020) ve sentetik açıklıklı radar (SAR) verilerinin birleşimi (Ayala vd., 2021; Baydogan ve Sarp, 2022), önemli bir araştırma alanı haline gelmiştir. LiDAR verileri, binaların yüksekliği ve üç boyutlu yapısı hakkında bilgi sağlarken, optik görüntüler detaylı yüzey bilgilerini sunar. Ancak bu verilerin elde edilmesi görece daha pahalı ve işlem yükü fazladır. Bina tespitine yönelik araştırmalar, bina poligonlarının belirlenmesi, bina türlerinin morfoloji ve fonksiyonlarına göre sınıflandırılması, tek gözlü görüntülerden bina yüksekliği çıkarımı ve bina değişim tespiti gibi alanlarda yoğunlaşmaktadır. Optik görüntüler, insan gözüne doğal görünen renkler üretir. Bu özellik, kullanıcıların görüntüleri yorumlamasını ve analiz etmesini kolaylaştırır. Uydu ve hava platformlarından elde edilen optik görüntüler, geniş alanların hızlı ve etkili bir şekilde görüntülenmesine olanak tanır ve çeşitli spektral bantlarda veri toplayabilir. Bu, bitki örtüsü, su kütleleri ve farklı yüzey malzemelerinin ayırt edilmesinde faydalıdır. Farklı spektral bantların kullanımı, özellikle çevresel izleme ve doğal kaynak yönetimi gibi alanlarda daha detaylı analizler yapılmasına olanak tanır. Ayrıca diğer görüntüleme yöntemlerine göre daha düşük maliyetli, erişilebilir ve işlenmesi ve analiz edilmesi, genellikle daha az karmaşıklık gerektirir. Bu sebeplerden dolayı bina çatılarının tespitinde günümüzde sıklıkla kullanılmaktadır. Bina tipleri genellikle oldukça değişkendir. İç tonları ve dokuları farklılık gösterir ve çeşitli uzamsal ölçeklere sahiptirler. Ayrıca şekilleri ve renkleri binadan farklılık gösterebilir. Binalar genellikle yollar gibi benzer malzemelere sahip özelliklerin yakınında dururlar ve diğer elementlerle kolayca karıştırılabilirler. Bu nedenle özellikle sınır konturlarının segmentasyon kalitesi önemlidir. Gölgeler, yapay mimari olmayan özellikler ve bina yüzeylerinin heterojenliği gibi çeşitli karmaşık faktörlerin ön planı gizlemesine neden olabileceğinden, binalar ile çevre nesnelere

arasındaki uzak mesafeli ilişki önemli bir husustur. Binaların şekilleri ise doğal nesnelere göre daha düzenli ve belirgindir, bu da sınır sorunlarını kritik hale getirir (Civicioglu ve Besdok, 2024; Günen, 2024; J. Li vd., 2022; Q. Li vd., 2024; Luo vd., 2021).

Derin öğrenme modelleri, büyük veri kümeleri üzerinde eğitilerek yüksek doğruluk ve hassasiyetle bina çatılarını tespit edebilir. Bu modeller, görüntülerdeki ince ayrıntıları ve karmaşık desenleri tanımlamada son derece etkilidir. Geleneksel yöntemler, manuel müdahale ve uzun işlem süreleri gerektirirken, derin öğrenme tabanlı yaklaşımlar otomatik ve hızlı bir şekilde çalışır. Bu, büyük ölçekli şehirler veya geniş alanlar için bina çatılarını hızlı ve etkili bir şekilde tespit etmeyi mümkün kılar. Özellikle afet durumlarında, hızlı değerlendirme ve müdahale için bu otomatik ve hızlı işleme kapasitesi hayati önem taşır. Derin öğrenme modelleri, büyük miktarda veri ile ölçeklenebilirlik sağlar. Uydu ve hava görüntülerinden elde edilen büyük veri setleri, derin öğrenme modelleri için daha fazla eğitim verisi anlamına gelir ve bu da modelin genel performansını artırır. Büyük veri setleri üzerinde eğitilmiş modeller, farklı coğrafi bölgelerde ve çeşitli çevresel koşullarda daha yüksek genelleme yeteneğine sahip olur. Derin öğrenme yöntemleri, optik görüntülerin diğer veri kaynakları ile (örneğin; Hiperspektral görüntü, LiDAR, SAR) entegre edilerek daha zengin ve doğru bilgi çıkarımı yapabilir. Derin öğrenme, bina çatılarını sadece tespit etmekle kalmaz, aynı zamanda çatının malzemesi, eğimi, hasar durumu gibi detaylı özelliklerini de çıkarabilir (Guo vd., 2021; Günen vd., 2020; Rastogi vd., 2022)

HRNet, tekrarlanan çok ölçekli birleştirme tekniğini kullanarak, semantik segmentasyon alanında öne çıkan bir mimari haline gelmiştir. Bu teknik sayesinde, HRNet binaları yüksek bir hassasiyetle belirleyebilmektedir (Zhu vd., 2020). Mask RCNN, binaları tek tek nesne olarak ele alarak, yüksek seviyeli anlamsal bilgiyi çıkarmak ve bina konumlarını belirlemek için nesne tespiti ve ardından her pikselin sınıf etiketini belirlemek için maske segmentasyonundan oluşan iki aşamalı bir mimaridir. Mask RCNN, bina ayıklamada her bir binanın ayrıntılı analizini ve sınırlarının net bir şekilde belirlenmesini sağlayan yöntemlerden birisidir (Han vd., 2021; Liu vd., 2020). Chen ve arkadaşları (Chen vd., 2020) çatı kenarlarının düz çizgiler ve keskin köşelerle oluşturulmasını sağlamak için, manuel çatı çizim sürecini taklit eden bir konvolüsyon tekrarlayan sinir ağı (CRNN) kullanmıştır. Wierzbicki ve arkadaşları yüksek çözünürlüklü görüntüler LiDAR verilerini kullanarak eğitilen U-Net mimarisi, binaları %89,5 genel doğruluk ve %80,7 geri çağırma oranıyla başarıyla tanımlanmasını sağlamıştır (Wierzbicki vd., 2021). Bir başka çalışmadaki DeepLab v3 modeli, Nanjing çatıları üzerinde güneş paneli kurulumuna uygun alanları belirlemede oldukça başarılı sonuçlar vermiştir (Zhong vd., 2021). Boonpook ve arkadaşları (Boonpook vd., 2021) insansız hava araçları görüntülerinden binaları tespit etmek için derin öğrenme tabanlı bir sistem geliştirmişlerdir. Araştırmanın sonuçlarına göre, kullanılan özellik sayısının artırılması sınıflandırma doğruluğunu yükseltmektedir. Thottolil ve arkadaşları (Thottolil ve Kumar) tarafından yapılan çalışmada, kentsel alanlarda bina ayak izlerini tespit etmek için Google Earth görüntüleri ve çeşitli özellikler (KYM, SYM, VDVI) kullanılmıştır. Bulguları, bu ek özelliklerin dahil edilmesinin test alanlarında F-Skorunu önemli ölçüde iyileştirdiğini göstermektedir. Bu, sadece KYM görüntülerinin ötesinde daha geniş bir veri yelpazesi kullanmanın, özellikle kentsel ortamlarda bina ayak izi tespitinin doğruluğunu önemli ölçüde artırabileceğini göstermektedir. Ksenia Bittner ve ekibi yüksek çözünürlüklü uydu görüntülerinden otomatik bina çıkarma ve sınırlarını belirleme için yenilikçi bir yaklaşım geliştirdi. Önerilen mimari, farklı veri kaynaklarından spektral ve yükseklik bilgilerini birleştiren üç paralel ağdan oluşan Fused-FCN4s'yi içerir. Fused-FCN4s, daha doğru bina sınırları için daha ince detaylı bilgilerin yüksek seviyelere aktarılmasına yardımcı olan geç bir aşamada birleştirilen üç paralel ağdan oluşmaktadır (Bittner vd., 2018).

Bu çalışmada DeepLabv3+'ün MobileNetV2 omurgası kullanılarak bina çatılarının belirlenmesi gerçekleştirilmiştir. Bu kapsamda profesyonel uçaklarla elde edilen görüntülerden fotogrametrik olarak üretilen gerçek ortofotonun yanı sıra, bu ortofotodan üretilen görünür bant farkı bitki örtüsü indeksi (VDVI), 30 cm çözünürlüklü stereo hava fotoğraflarından otomatik haritalama ile üretilen 5 m uzamsal çözünürlüğe sahip dijital yüzey modeli (DSM) kullanılmıştır.

2. MATERYAL VE METOT

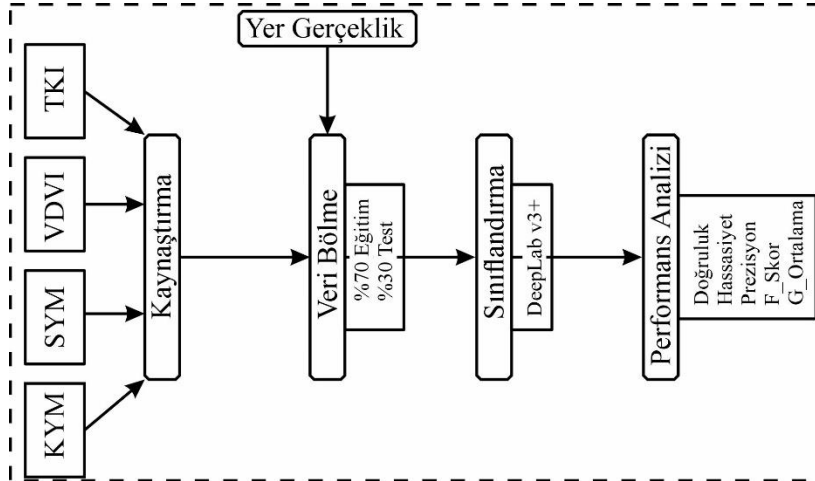
Bu çalışma, Kahramanmaraş'ın Elbistan ilçesinde yürütülmüştür. Şehrin yer gösterir haritası Şekil 1'de gösterilmiştir. Elbistan, Türkiye'nin dördüncü büyük ovası ve üçüncü büyük linyit termik santraline ev sahipliği yapmaktadır. Bu durum, şehrin hızla büyüyerek hem yeni hem de tarihi yapılara ev sahipliği yapmasına yol açmaktadır. Elbistan'ın araştırma alanı olarak seçilmesinin birden fazla önemli sebebi bulunmaktadır. Bunlardan ilki, şehrin kaçak yapı tespitinde önemli bir rol oynayabilecek potansiyele sahip olmasıdır. Farklı kaynaklardan

elde edilen verilerin ve derin öğrenme teknikleri kullanılarak, bu tür yapılar etkin bir şekilde belirlenebilir. Bu sayede şehir planlaması daha sağlıklı bir şekilde gerçekleştirilebilir ve kentin çarpık gelişmesi önenebilir. Ayrıca 2023 yılında meydana gelen deprem (Mw=7.6) öncesi ve sonrası durumun tespit edilebilmesi için örnek alandır. Son olarak, Elbistan'ın planlama için gerekli olan temel haritasının oluşturulması konusunda da önemli bir rol oynayabileceği düşünülmektedir. Farklı kaynaklardan elde edilen veriler kaynaştırılıp kullanılarak şehrin güncel ve detaylı haritaları üretilebilir ve bu haritalar altyapı yatırımlarında, afet risklerinin değerlendirilmesinde ve kentsel dönüşüm projelerinde kullanılabilir.



Şekil 1. Elbistan'ın yer gösterir haritası.

Çok yüksek çözünürlüklü görüntülerden elde edilen çeşitli özellikler, bina çatı tespit performansını artırır. Bu çalışma, karmaşık geometri ve dokuya sahip binaları tespit etmek için yüksek çözünürlüklü görüntünün renkli bantları (KYM), sayısal yüzey modeli (SYM), görünür bant farkı bitki örtüsü indeksi (VDVI) ve topografik konum indeksini (TKI) içeren bir özellik seti kullanılmıştır. 25 cm'lik uzamsal çözünürlüğe sahip ortofotoların KYM bantları ECW formatında verilmiştir ve WGS84 coğrafi koordinat sistemini kullanarak coğrafi olarak referanslandırılmıştır. 5 metre grid aralıklı SYM, 30 cm çözünürlüğe sahip stereo hava fotoğraflarından otomatik eşleştirme yöntemiyle oluşturulmuştur. Seviye-0 verilerinden yeniden örneklenen veriler, arazi topografyasında insan yapısı ve bitki örtüsü gibi tüm detayları kapsayan %90 güven aralığında 3 metrelik düşey doğruluğa sahiptir. Önerilen yöntemle ait iş akış şeması Şekil 2'de sunulmuştur (URL, 2024).



Şekil 2. Önerilen yöntemin iş akış şeması.

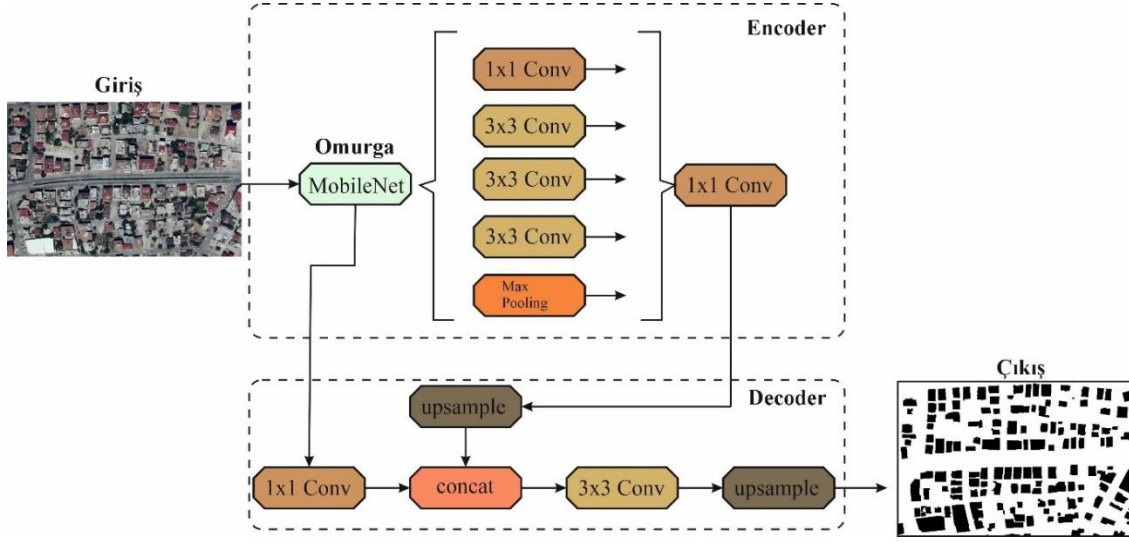
VDVI uzaktan algılamada bitki örtüsünün yoğunluğunu ve durumunu değerlendirmek için kullanılan bir indekstir. Hesaplanması için iki farklı görünür banttan (Kırmızı ve Yeşil bantlar) gelen veriler kullanılır. Bu bantlardaki fark, bitki örtüsünün fotosentez yeteneğini ve klorofil içeriğini gösteren bir değer üretir. Farklı bitki türleri, VDVI değerlerinde farklılık gösterir. Sağlıklı bitkiler, genellikle yüksek VDVI değerlerine sahipken, stresli veya hastalıklı bitkiler daha düşük VDVI değerlerine sahip olma eğilimindedir (Boonpook vd., 2021; Günen, 2024). Eşitlik 1 ile VDVI hesaplaması yapılmıştır.

$$VDVI = \frac{2 \times \text{Yeşil} - \text{Kırmızı} - \text{Mavi}}{2 \times \text{Yeşil} + \text{Kırmızı} + \text{Mavi}} \quad (1)$$

TKI, arazi yüzeyinin topografik konumunu ve eğimini karakterize etmek için kullanılan bir jeomorfolojik indekstir. Hesaplanması için arazi yüksekliği verileri ve bir pencere boyutu kullanılır. Pencere boyutu, TKI değerinin hesaplanacağı alanın boyutunu temsil eder. TKI haritaları, genellikle vadi tabanları, yamaçlar, sırtlar ve platolar gibi farklı arazi formlarını ayırt etmek için kullanılırken bu çalışmada bina çatılarının tespitine yardımcı olması için kullanılmıştır (De Reu vd., 2013; Weiss, 2001). Z_0 sorgu yapılan pikselin yüksekliğini, $Z_{ortalama}$ ve Z_{std} ise sırasıyla Z_0 etrafındaki yükseklik değişiminin ortalamasını ve standart sapmasını ifade etmek üzere Eşitlik 2 ile TKI hesaplanmaktadır.

$$TKI = \left(\frac{Z_0 - Z_{ortalama}}{Z_{std}} \right) * 100 + 0.5 \quad (2)$$

Derin öğrenme yöntemi ile veri sınıflandırması yapmak üzere dört farklı veri kaynaştırılmıştır. Daha sonra bu veriler eğitim ve test verisi olarak ayrılmış. Yer gerçeklik verisi manuel olarak yaklaşık 500 bina için gerçekleştirilmiştir. Verilen sınıflandırılması için DeepLabv3+ yapısı tercih edilmiştir. Bu yöntem görüntü segmentasyonu için geliştirilmiş bir derin öğrenme modelidir. Google tarafından geliştirilen bu model, özellikle nesne tespiti ve görüntüdeki her bir pikselin sınıflandırılması gibi görevlerde kullanılır. Bu yöntemde kullanılan delikli evrişim filtreleri düzenli aralıklarla uygulayan geleneksel konvolüsyonel katmanların aksine daha geniş aralıklarla uygulayarak, daha geniş bir algılama alanı sağlar böylece görüntü çözünürlüğünü koruyarak daha fazla bağlam bilgisi elde etmeye yardımcı olur. Encoder kısmı, giriş görüntüsünden özellikleri çıkarır ve düşük çözünürlüklü bir özellik haritası üretir. Decoder kısmı ise, bu düşük çözünürlüklü özellik haritasını yüksek çözünürlüklü bir segmentasyon haritasına dönüştürür. Genişletilmiş evrişimler, daha geniş bir algılama alanı sağlayarak daha fazla bağlam bilgisi yakalamaya yardımcı olur. Bu, özellikle küçük nesnelerin segmentasyonu için faydalıdır. DeepLabv3+'ın omurgasında kullanılan MobileNet, mobil ve gömülü cihazlar gibi sınırlı kaynaklara sahip ortamlarda çalışmak üzere optimize edilmiş bir sinir ağı mimarisidir. Bu yapı geleneksel evrişimlerin hesaplama yükünü azaltarak ve standart evrişimler derinlik ayrışmalı evrişim ve noktaya ayrışmalı evrişim olarak iki ayrı işleme bölünür. Böylece parametre sayısını ve hesaplama maliyetini önemli ölçüde azaltır, dolayısıyla modelin daha hızlı ve daha verimli çalışmasını sağlar (Z. Li ve Dong, 2022; Wang vd., 2024). Şekil 3'de omurganın MobileNetV2 olduğu DeepLabv3+ ağ mimarisi gösterilmiştir.



Şekil 3. Omurganın MobileNetV2 olduğu Deeplabv3+ ağ mimarisi.

Eğitim süreci bittikten sonra test ve eğitim veri setlerinin tahmin edilen sonuçları yer gerçeklik verisine göre performans karşılaştırılması yapılmıştır. Bu kapsam kullanılan metrikler Eşitlik 3-7’de verilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

$$\text{Geri Çağırma} = \frac{TP}{TP + FN} \quad (4)$$

$$\text{Prezisyon} = \frac{TP}{TP + FP} \quad (5)$$


$$F_Skor = \frac{2 \times \frac{TP}{TP + FN} \times \frac{TP}{TP + FP}}{\frac{TP}{TP + FN} + \frac{TP}{TP + FP}} \quad (6)$$

$$G_Ortalama = \sqrt{\frac{TP}{TP + FN} \times \frac{TN}{TP + FP}} \quad (7)$$

Burada doğru pozitif (TP), yanlış negatif (FN), yanlış pozitif (FP) ve doğru negatif (TN) karışıklık matrisinin elemanlarını ifade etmektedir.


3. DENEYLER

Farklı çatı tiplerinin belirlenmesi, özellikle uzaktan algılama ve görüntü işleme teknikleri kullanılarak bina analizi yapılırken çeşitli zorluklar içermektedir. Bu zorluklar, teknik sınırlamalar, veri kalitesi, çevresel koşullar ve çatı tiplerinin çeşitliliğinden kaynaklanmaktadır. Yüksek çözünürlüklü görüntülerde bile, gölgeler, yansımalar ve atmosferik etkiler nedeniyle çatı detaylarının yeterince belirgin olmaması zorluk yaratır. Çatı tiplerini ayırt etmek için gereken ince detaylar, düşük çözünürlüklü görüntülerde kaybolabilir, bu da çatı türlerinin doğru sınıflandırılmasını zorlaştırır. Farklı çatı malzemeleri (örneğin, metal, kiremit, asfalt) optik görüntülerde benzer yansımalar yapabilir, bu da malzeme bazlı sınıflandırmayı zorlaştırır. Çatılar, düz, eğimli, kırma veya mansard gibi çeşitli şekillere sahip olabilir ve bu geometrik çeşitlilik doğru sınıflandırmayı zorlaştırır. Bir binada birden fazla çatı tipi ve katman bulunabilir, bu da tespit ve sınıflandırma sürecini daha da karmaşık hale getirir. Çatılarda yetişen bitkiler veya çevredeki ağaçların gölgeleri, çatıların doğru tespit edilmesini zorlaştırabilir. Bu çalışmada çeşitli çatı tiplerinin otomatik tespit edilmesi sağlanmıştır. Çeşitli çatı tiplerine ait görseller Şekil 4’de sunulmuştur.



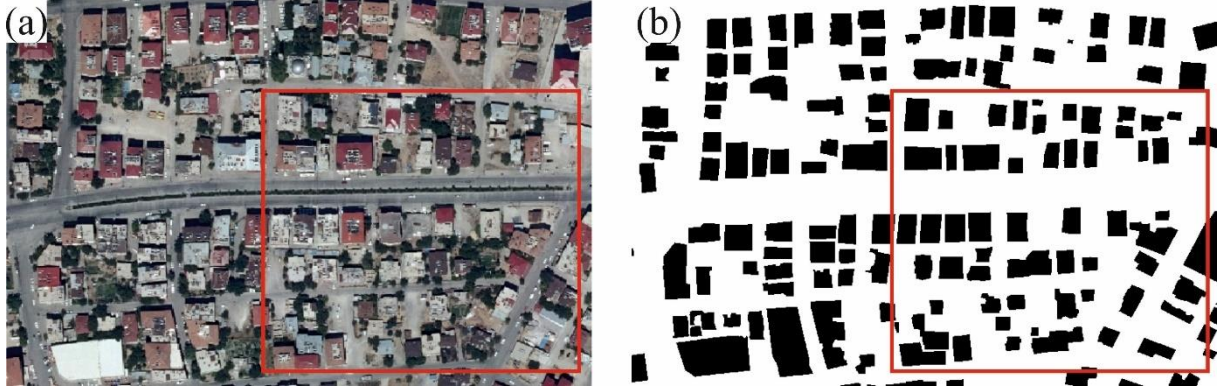
Şekil 4. Farklı çatı tiplerinin gösterimi.

Türkiye Cumhuriyeti Millî Savunma Bakanlığı Harita Genel Müdürlüğü tarafından sağlanan yüksek çözünürlüklü ortofotonun çalışma alanına kapsayacak şekilde kesilmiş hali Şekil 5.a'da SYM Şekil 5.b'de, hesaplanan ve görsel olarak algılanması kolaylaştırmak için gölgelendirilerek hazırlanan VDVI Şekil 5.c'de ve hesaplanan TKI Şekil 5.d'de sunulmuştur.



Şekil 5. Çalışma bölgesini gösterir a) Ortofoto, b) SYM, c) VDVI ve d) TKI.

Coğrafi Bilgi Sistemleri'nde farklı kaynaklardan gelen verilerin bir araya getirilmesi ve analiz edilmesi çok önemlidir. Ancak, bu veriler her zaman aynı uzamsal çözünürlüğe sahip olmayabilir. Bu, farklı piksel boyutları ve ayrıntı seviyeleri anlamına gelir. Kullanılan verilerin uzamsal çözünürlüğü değişiklik gösterir ve bunların birleştirilip kaynaştırılması için aynı mekânsal çözünürlükte ifade edilmesi gerekmektedir. Aslında amaç, düşük çözünürlüklü görüntü ızgaralarını küçülterek verinin uzamsal çözünürlüğünün aynı kalmasını sağlamaktır. SYM ve ortofoto görüntüsünün yukarı örnekleme için bi-kübik enterpolasyon tekniği kullanıldı. Kaynaştırma işleminden sonra veriler 256x256 boyutlarında 500 görüntü oluşturacak şekilde parçalara ayrılmıştır. Şekil 6'da eğitim için kullanılan alan bölge, çalışma alanı ve bu bölgeye karşılık gelen yer gerçeklik verisi gösterilmiştir. Test verisi kırmızı alana denk gelen bölge olarak seçilmiştir.




Şekil 6. a) Çalışma bölgesi ve b) çalışma bölgesinin yer gerçeklik verisi.

Çalışmada KYM verisi ve kaynaştırılmış bütün veriler (KYM, VDVI, SYM ve TKI) elde edilerek eğitim işlemi gerçekleştirilmiştir. Elde edilen istatistiksel sonuçlar Tablo 1’de sunulmuştur.


Tablo 1. Eğitim ve test verilerinin sınıflandırma metrikleri

	Veri Türü	Doğruluk	Geri çağırma	Prezisyon	F Skor	G Ortalama
Test	KYM	79.04	55.39	86.87	67.65	72.36
	Bütün Veri	97.34	95.40	97.82	96.660	96.99
Eğitim	KYM	84.04	54.25	85.51	66.39	72.26
	Bütün Veri	98.35	96.48	97.80	97.13	97.79

Sadece KYM verisi kullanılarak elde edilen sonuçların ortofoto üzerinde ve siyah beyaz sunumu Şekil 7’de bütün verinin kullanılması sonucu elde edilen sonuçlar Şekil 8’de sunulmuştur.



Şekil 7. KYM verisi kullanılarak elde edilen sonuçlar.



Şekil 8. KYM, VDVI, SYM ve TKI kullanılarak elde edilen sonuçlar.

Eğitim verisinde hem KYM hem de bütün veri için metrikler genellikle test verisinden daha yüksektir. Bu, modelin eğitim verisinde daha iyi performans gösterdiğini ancak test verisinde bu performansın bir miktar düştüğünü gösterebilir. KYM kullanıldığında, doğruluk, geri çağırma, presizyon, F_Skor ve geometrik ortalama değerleri genel olarak daha düşük. Geri çağırma özellikle düşük, bu da modelin doğru pozitif oranını düşük tuttuğunu gösterir. Bu durum, modelin pozitif sınıfları tanımlamada zorlandığını işaret eder. Preziyon değerinin nispeten yüksek olması, modelin tahmin ettiği pozitif sınıfların doğru olma olasılığının yüksek olduğunu gösterir. Tüm metrikler için daha yüksek değerler elde edilmiştir. Sonuç olarak, KYM kullanıldığında modelin performansı daha düşük olmasına rağmen, bütün veri kullanıldığında model çok daha yüksek performans sergiliyor. Bu, daha fazla veri ve bütün veri setlerinin modelin genel doğruluğunu ve güvenilirliğini önemli ölçüde artırabileceğini gösteriyor.

4. SONUÇLAR

Bu çalışmada, yüksek çözünürlüklü optik görüntülerden bina çatılarının otomatik olarak tespiti için bir yöntem önerilmiştir. Önerilen yöntem, çok kaynaklı veri füzyonu ve derin öğrenme tekniklerini kullanmaktadır. Farklı kaynaklardan elde edilen veriler, bina çatılarının tespit performansını artırmak için birleştirilir. Derin öğrenme yöntemi olarak ise DeepLabv3+ modeli kullanılmıştır. Model, MobileNetV2 omurgası kullanılarak tasarlanmıştır. Eğitim ve test verisi olarak, Elbistan'dan yüksek çözünürlüklü ortofoto, SYM, VDVI ve TKI kullanılmıştır. Elde edilen sonuçlar, önerilen yöntemin bina çatılarının tespitinde oldukça başarılı olduğunu göstermektedir. Sadece KYM verisi kullanılarak elde edilen başarı tüm verilerin kullanılmasıyla elde edilen başarıdan daha yüksektir. Derin öğrenme algoritmaları, büyük veri setleri üzerinde eğitilerek karmaşık ve değişken yapıya sahip bina çatılarının tespitinde başarılı sonuçlar elde edilmesini sağlar. Ancak, bu algoritmaların etkinliği, veri kalitesi, etiketleme doğruluğu ve eğitim sürecindeki dikkatli optimizasyonlarla doğrudan ilişkilidir. Gelecekteki araştırmalar, daha geniş ve çeşitli veri setleri üzerinde yapılan deneylerle bu algoritmaların genelleme yeteneklerini artırmayı amaçlamalıdır. Ayrıca, bu çalışma sadece bina çatılarının tespiti için değil, aynı zamanda diğer nesne tespiti ve sınıflandırma problemleri için de bir model oluşturma potansiyeline sahiptir. Önerilen yöntem, çeşitli uygulama alanlarında kullanılabilir ve coğrafi olarak da geniş bir kapsama sahiptir. Örneğin, şehir planlaması, tarım izleme, orman yönetimi ve arazi kullanımı gibi alanlarda, benzer yöntemlerin kullanılmasıyla verimlilik ve doğruluk artırılabilir.

KAYNAKLAR

Ayala, C., Sesma, R., Aranda, C. ve Galar, M., 2021. A deep learning approach to an enhanced building footprint and road detection in high-resolution satellite imagery, *Remote Sensing*, 13,16, 3135.

Baydoğan, E. ve Sarp, G., 2022. Urban footprint detection from night light, optical and SAR imageries: A comparison study, *Remote Sensing Applications: Society and Environment*, 27, 100775.

- Bittner, K., Adam, F., Cui, S., Körner, M. ve Reinartz, P.**, 2018. Building footprint extraction from VHR remote sensing images combined with normalized DSMs using fused fully convolutional networks, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11,8, 2615-2629.
- Boonpook, W., Tan, Y. ve Xu, B.**, 2021. Deep learning-based multi-feature semantic segmentation in building extraction from images of UAV photogrammetry, *International Journal of Remote Sensing*, 42,1, 1-19.
- Chen, Q., Wang, L., Waslander, S. L. ve Liu, X.**, 2020. An end-to-end shape modeling framework for vectorized building outline generation from aerial images, *ISPRS Journal of Photogrammetry and Remote Sensing*, 170, 114-126.
- Civicioglu, P. ve Besdok, E.**, 2024. Pansharpening of remote sensing images using dominant pixels, *Expert Systems with Applications*, 242, 122783.
- De Reu, J., Bourgeois, J., Bats, M., Zwertvaegher, A., Gelorini, V., De Smedt, P., Chu, W., Antrop, M., De Maeyer, P. ve Finke, P.**, 2013. Application of the topographic position index to heterogeneous landscapes, *Geomorphology*, 186, 39-49.
- Dhanaraj, K. ve Angadi, D. P.**, 2021. Urban expansion quantification from remote sensing data for sustainable land-use planning in Mangaluru, India, *Remote Sensing Applications: Society and Environment*, 23, 100602.
- Guo, H., Shi, Q., Marinoni, A., Du, B. ve Zhang, L.**, 2021. Deep building footprint update network: A semi-supervised method for updating existing building footprint from bi-temporal remote sensing images, *Remote Sensing of Environment*, 264, 112589.
- Günen, M. A.**, 2024. Fast building detection using new feature sets derived from a very high-resolution image, digital elevation and surface model, *International Journal of Remote Sensing*, 45,5, 1477-1497.
- Günen, M. A. ve Atasever, U. H.**, 2024. Remote sensing and monitoring of water resources: A comparative study of different indices and thresholding methods, *Science of The Total Environment*, 926, 172117.
- Günen, M. A., Atasever, U. H. ve Besdok, E.**, 2020. Analyzing the contribution of training algorithms on deep neural networks for hyperspectral image classification, *Photogrammetric Engineering & Remote Sensing*, 86,9, 581-588.
- Han, Q., Yin, Q., Zheng, X. ve Chen, Z.**, 2021. Remote sensing image building detection method based on Mask R-CNN, *Complex & Intelligent Systems*, 1-9.
- Kucharczyk, M. ve Hugenholtz, C. H.**, 2021. Remote sensing of natural hazard-related disasters with small drones: Global trends, biases, and research opportunities, *Remote Sensing of Environment*, 264, 112577.
- Li, J., Huang, X., Tu, L., Zhang, T. ve Wang, L.**, 2022. A review of building detection from very high resolution optical remote sensing images, *GIScience & Remote Sensing*, 59,1, 1199-1225.
- Li, Q., Mou, L., Sun, Y., Hua, Y., Shi, Y. ve Zhu, X. X.**, 2024. A Review of Building Extraction from Remote Sensing Imagery: Geometrical Structures and Semantic Attributes, *IEEE Transactions on Geoscience and Remote Sensing*.
- Li, Z. ve Dong, J.**, 2022. A framework integrating deeplabV3+, transfer learning, active learning, and incremental learning for mapping building footprints, *Remote Sensing*, 14,19, 4738.
- Liu, Y., Chen, D., Ma, A., Zhong, Y., Fang, F. ve Xu, K.**, 2020. Multiscale U-shaped CNN building instance extraction framework with edge constraint for high-spatial-resolution remote sensing imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 59,7, 6106-6120.
- Luo, L., Li, P. ve Yan, X.**, 2021. Deep learning-based building extraction from remote sensing images: A comprehensive review, *Energies*, 14,23, 7982.
- Rastogi, K., Bodani, P. ve Sharma, S. A.**, 2022. Automatic building footprint extraction from very high-resolution imagery using deep learning techniques, *Geocarto International*, 37,5, 1501-1513.

Thottolil, R. ve Kumar, U., 2022, Automatic Building Footprint Extraction using Random Forest Algorithm from High Resolution Google Earth Images: A Feature-Based Approach, *IEEE International Conference on Electronics, Computing and Communication Technologies*, Hindistan, 1-6.

Touzani, S. ve Granderson, J., 2021. Open data and deep semantic segmentation for automated extraction of building footprints, *Remote Sensing*, 13,13, 2578.

Ullo, S. L., Zarro, C., Wojtowicz, K., Meoli, G. ve Focareta, M., 2020. LiDAR-based system and optical VHR data for building detection and mapping, *Sensors*, 20,5, 1285.

URL, <https://www.harita.gov.tr/urun/sayisal-yuzey-modeli-5-m-seviye-0-sym5-10-1>. (2024).

Wang, Y., Yang, L., Liu, X. ve Yan, P., 2024. An improved semantic segmentation algorithm for high-resolution remote sensing images based on DeepLabv3+, *Scientific Reports*, 14,1, 9716.

Weiss, A., 2001, Topographic position and landforms analysis, *ESRI kullanıcı konferansı poster sunumu*, Amerika.

Wierzbicki, D., Matuk, O. ve Bielecka, E., 2021. Polish cadastre modernization with remotely extracted buildings from high-resolution aerial orthoimagery and airborne LiDAR, *Remote Sensing*, 13,4, 611.

Zhong, T., Zhang, Z., Chen, M., Zhang, K., Zhou, Z., Zhu, R., Wang, Y., Lü, G. ve Yan, J., 2021. A city-scale estimation of rooftop solar photovoltaic potential based on deep learning, *Applied Energy*, 298, 117132.

Zhu, Q., Liao, C., Hu, H., Mei, X. ve Li, H., 2020. MAP-Net: Multiple attending path neural network for building footprint extraction from remote sensed imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 59,7, 6169-6181.