



MOLUSCE EKLENTİSİNİN KURAMSAL MİMARİSİ VE ARAZI ÖRTÜSÜ DEĞİŞİMİ KESTİRİMİNDE UYGULAMA SONUÇLARININ DEĞERLENDİRİLMESİ

(THE THEORETICAL ARCHITECTURE OF THE MOLUSCE PLUGIN AND AN ASSESSMENT OF APPLICATION RESULTS IN LAND COVER CHANGE PREDICTION)

İlksen ÇELİKOĞLU¹, Ömer K. ÖRÜCÜ²

¹Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Peyzaj Mimarlığı Anabilim Dalı ISPARTA/Türkiye
ilksencelikoglu@hotmail.com, ORCID: 0009-0001-3110-7201

²Süleyman Demirel Üniversitesi, Mimarlık Fakültesi Peyzaj Mimarlığı Bölümü ISPARTA/Türkiye
omerorucu@sdu.edu.tr, ORCID: 0000-0002-2162-7553

Doi: <https://doi.org/10.53463/ecopers.20240468>

Corresponding Author/İletişim yazarı: İlksen Çelikoğlu

E-mail: ilksencelikoglu@hotmail.com



ÖZET

Arazi örtüsü ve kullanımı değişiminin kestirimi, peyzaj planlaması ve doğal kaynak yönetiminde merkezî bir konuma yerleşmiştir. MOLUSCE (Modules for Land Use Change Simulations), Markov zinciri, hücresel otomata ve makine öğrenmesi tabanlı geçiş potansiyeli modellerini tek bir açık kaynaklı QGIS eklentisinde birleştirir. Bu çalışma önce eklentinin kuramsal mimarisini çözümlemekte, ardından dokuz ülkede yürütülmüş 28 uygulamayı karşılaştırmalı olarak tartışmaktadır. Eklentinin sunduğu dört yöntem, yapay sinir ağı, lojistik regresyon, kanıt ağırlıkları ve çok ölçütlü değerlendirme, uygulamalardan derlenen doğruluk değerleri üzerinden karşılaştırılmıştır. Yapay sinir ağı ile hücresel otomata birleşimi en sık başvuru kurgudur; denetimli karşılaştırmalar ise melez kurguların daha yüksek doğruluk sağladığına işaret etmektedir. Uygulamaların çoğu 0,70-0,95 aralığında Kappa değerleri üretmekle birlikte, eğitimde başarılı bir modelin doğrulamada belirgin biçimde gerileyebildiği örnekler vardır. Kestirimler hemen her coğrafyada yapı alanların genişlemesini, doğal örtünün gerilemesini öngörmektedir. MOLUSCE güvenilir bir karar destek aracıdır; ancak başarısı araçtan çok girdi verisinin kalitesi ile sürücü değişken ve parametre tercihlerine bağlıdır.

Anahtar Kelimeler: MOLUSCE, arazi kullanımı/örtüsü değişimi, hücresel otomata, yapay sinir ağı, coğrafi bilgi sistemleri, kestirim modeli

ABSTRACT

Projecting land use and land cover change is central to landscape planning and natural resource management. MOLUSCE (Modules for Land Use Change Simulations) combines Markov chain, cellular automata and machine learning based transition potential models in one open source QGIS plugin. This study dissects the theoretical architecture of the plugin, then comparatively discusses 28 applications from nine countries. Its four transition potential methods (neural network, logistic regression, weights of evidence, multi-criteria evaluation) are compared through the reported accuracy figures. The neural network-cellular automata combination is the most frequently adopted configuration, while controlled comparisons show hybrid configurations achieving higher accuracy. Although most applications report Kappa values of 0.70-0.95, a model performing well in training may decline markedly at validation. Predictions consistently indicate expanding built-up areas and retreating natural cover. MOLUSCE is a reliable decision support tool, but its success depends less on the tool than on input data quality and the choice of driver variables and parameters.

Key words: MOLUSCE, land use/cover change, cellular automata, artificial neural network, geographic information systems, predictive modelling

1. GİRİŞ

Arazi yüzeyinin dönüşümü, ekosistem hizmetlerinin sürekliliğinden taşkın rejimine, biyoçeşitlilikten kentsel yaşam kalitesine kadar geniş bir etkiler zincirinin başlangıç noktasıdır. Bu nedenle arazi örtüsü ve arazi kullanımı değişiminin yalnızca geçmişe dönük haritalanması yeterli görülmemekte, mevcut eğilimlerin gelecekte hangi mekânsal örüntülere yol açacağının da öngörülmesi beklenmektedir. Planlama süreçlerinde yararlanılan bilgi türlerinden biri de bir havzanın ya da kentin yirmi otuz yıl sonra alabileceği biçime ilişkin nicel senaryolardır; çünkü koruma, altyapı ve arazi tahsis kararlarının çoğu, bugünden gelecek için verilir.

Bu öngörü ihtiyacı, geçmiş dönemlerin değişim örüntüsünü öğrenip geleceğe taşıyan mekânsal simülasyon modellerini ön plana çıkarmıştır. Söz konusu modellerin büyük bölümü iki temel bileşen üzerine kuruludur. Birincisi, sınıflar arası dönüşümlerin ne oranda gerçekleşeceğini olasılıksal olarak kestiren Markov zinciridir; ikincisi ise bu dönüşümlerin mekânda nereye yerleşeceğini komşuluk ilişkileri üzerinden çözen hücresel otomatadır. Ne var ki Markov zinciri dönüşümün miktarını verirken yerini belirleyemez, hücresel otomata ise tek başına dönüşümü yöneten çevresel etkenleri içselleştiremez. İşte bu boşluk, geçiş potansiyelini çevresel sürücülerden öğrenen istatistiksel ve makine öğrenmesi tabanlı modellerle doldurulur. Türkiye'de de bu yaklaşımlar erken tarihlerden itibaren uygulanmıştır; Yiğit (2018) Hatay-Samandağ bölgesindeki peyzaj değişimini peyzaj metrikleri üzerinden değerlendirmiş, Aldoğan (2019) ise İstanbul'un 2023 yılı arazi örtüsü/kullanımını yapay sinir ağları ve lojistik regresyon yöntemleriyle modellemiştir. Bu çalışmalar, eklenti tabanlı bütünsel çözümler yaygınlaşmadan önce izlenen yolu göstermesi bakımından derlemenin ulusal bağlamını oluşturmaktadır.

MOLUSCE eklentisinin literatürde hızla benimsenmesinin temelinde, sayılan bileşenlerin tümünü açık kaynaklı ve ücretsiz bir QGIS ara yüzünde bir araya getirmesi yatar. Bu çalışmanın amacı, eklentiye kullanan yayınları yüzeysel biçimde sıralamak değil, önce eklentinin iç yapısını ayrıntılı biçimde çözümlemek, sonra da farklı coğrafyalarda elde edilen sonuçları karşılaştırmalı ve eleştirel biçimde tartışmaktır. Böylece hem eklentinin yöntemsel olanakları hem de uygulamada ortaya çıkan güçlü yönleri ve sınırlılıkları bütüncül bir çerçevede ele alınmaktadır.

2. MATERYAL VE YÖNTEM

Bu derleme, MOLUSCE eklentisinin kuramsal yapısını ve uygulama sonuçlarını bir arada değerlendirmeyi amaçlayan tanımlayıcı bir literatür incelemesi olarak kurgulanmıştır. Eklentinin kuramsal mimarisinin çözümlendiği bölüm, geliştiricinin resmî belgelerine (Asia Air Survey ve NextGIS, 2024; NextGIS, 2024) dayandırılmıştır. Uygulama sonuçlarının değerlendirildiği bölümler ise sistematik bir tarama sonucunda belirlenen çalışma kümesi üzerinden yürütülmüştür.

Tarama, Web of Science, Scopus ve Google Akademik (Google Scholar) veri tabanlarında; Türkçe lisansüstü tezler için ayrıca YÖK Ulusal Tez Merkezi üzerinde gerçekleştirilmiştir. Arama terimi olarak "MOLUSCE", "MOLUSCE QGIS", "MOLUSCE land use change", "MOLUSCE cellular automata" ve "MOLUSCE arazi örtüsü değişimi" ifadeleri ile bunların bileşimleri kullanılmıştır. Tarama, eklentinin tanıtıldığı 2013 yılı ile Temmuz 2026 arasındaki yayınları kapsayacak biçimde tarih sınırı konulmaksızın yapılmış; erişilen kayıtlar başlık, özet ve tam metin düzeyinde sırasıyla değerlendirilmiştir.

Dâhil etme ölçütleri şu şekilde belirlenmiştir: (i) çalışmanın MOLUSCE eklentisini arazi örtüsü/arazi kullanımı değişiminin çözümlenmesinde ya da geleceğe yönelik kestiriminde fiilen uygulamış olması, (ii) kullanılan geçiş potansiyeli yönteminin ve/veya doğrulama sonucunun raporlanmış olması, (iii) tam metnin erişilebilir olması. Eklentiye yalnızca değinen ancak uygulama içermeyen kayıtlar, mükerrer yayınlar ve tam metnine ulaşılamayan kayıtlar kümeden çıkarılmıştır. Bu süreç sonunda dokuz ülkede yürütülmüş 26 MOLUSCE uygulaması belirlenmiştir. Bunlara ek olarak, eklentinin yaygınlaşmasından

önce benzer kestirim yaklaşımlarını Türkiye'de uygulayan iki lisansüstü tez (Yiğit, 2018; Aldoğan, 2019) ulusal bağlamı temsil etmek üzere kümede tutulmuş ve değerlendirmeye alınan toplam çalışma sayısı 28 olarak belirlenmiştir.

Kümedeki her çalışma; çalışma alanı ve ülkesi, veri kaynağı ve dönemi, kullanılan sürücü değişkenler, tercih edilen geçiş potansiyeli yöntemi, ağ parametreleri, doğrulama ölçütleri ve raporlanan doğruluk değerleri bakımından ortak bir çizelgeye işlenmiştir. Karşılaştırmalı değerlendirme, izleyen bölümlerde bu çizelge üzerinden yürütülmüştür. Doğruluk değerleri, çalışmaların kendi raporladıkları biçimde (genel Kappa ve/veya doğru yüzdesi) aktarılmış; farklı doğrulama ölçütlerinin birbirine dönüştürülmesinden kaçınılmıştır.

3. MOLUSCE EKLENTİSİNİN MİMARİSİ VE ÇALIŞMA İLKESİ

MOLUSCE, Asia Air Survey (AAS) tarafından geliştirilerek 2013 yılındaki FOSS4G konferansında tanıtılmış, günümüzde ise NextGIS tarafından sürdürülen açık kaynaklı bir QGIS eklentisidir (Asia Air Survey ve NextGIS, 2024; NextGIS, 2024). Kısaltmanın açılımı resmî belgelerde iki farklı biçimde geçmektedir: eklentinin Hızlı Yardım kılavuzu adı Modules for Land Use Change Evaluation olarak verirken, NextGIS'in güncel tanıtımı Modules for Land Use Change Simulations biçimini kullanmaktadır; literatürdeki çalışmalar da bu iki açılımı dönüşümlü olarak benimsemiştir. Eklenti GNU GPL v2 ve sonrası lisansı ile dağıtılır; güncel sürümleri Qt6 tabanlı yeni QGIS ortamlarında çalışır ve eğitilmiş modelin kaydedilip sonradan yeniden yüklenerek başka bir simülasyonda kullanılabilmesi ile raster ve vektör verilerini iş akışına hazırlayan yerleşik araç kutusu araçları gibi yeniliklerle genişletilmiştir (NextGIS, 2024).

Eklentinin kullanıcı ara yüzü, birbirini besleyen altı sekme üzerinden ilerler: Girdiler (Inputs), Korelasyon Değerlendirmesi (Evaluating correlation), Alan Değişimleri (Area changes), Geçiş Potansiyeli Modellemesi (Transition potential modelling), Hücresel Otomata Simülasyonu (Cellular Automata Simulation) ve Doğrulama (Validation) (NextGIS, 2024). Girdiler sekmesinde en az iki farklı tarihe ait sınıflandırılmış arazi örtüsü haritası ile dönüşümü yönlendiren sürücü değişken katmanları yüklenir. Alan Değişimleri sekmesi iki tarih arasındaki geçişleri bir değişim haritasına ve sınıflar arası geçiş matrisine dönüştürür; bu matris esasen bir Markov zinciri kurgusudur ve her sınıfın hangi olasılıkla başka bir sınıfa dönüşeceğini nicel olarak ifade eder. Geçiş Potansiyeli Modellemesi sekmesinde seçilen algoritma, sürücüler ile gözlenen dönüşümler arasındaki ilişkiyi öğrenerek mekânın her noktası için bir dönüşme eğilimi yüzeyi üretir. Hücresel Otomata Simülasyonu bu yüzeyi komşuluk kuralları çerçevesinde işleyerek gelecek tarihli haritayı oluşturur, Doğrulama sekmesi ise kestirimi gerçek harita ile karşılaştırır. Bu aşamalı akış, Şekil 1'de bütüncül biçimde gösterilmektedir.



Şekil 1. MOLUSCE eklentisinin altı sekmeli resmi iş akışı ve her aşamada kullanılan başlıca işlevler.

Modelleme öncesinde sürücü değişkenler arasındaki ilişkinin denetlenmesi önemlidir; bu nedenle Korelasyon Değerlendirmesi sekmesi, sürekli değişkenler için Pearson korelasyon katsayısını, nominal değişkenler için ise Cramér katsayısını veya ortak bilgi belirsizliğini (joint information uncertainty) hesaplar ve tüm rasterların topluca sınanmasına olanak tanır (NextGIS, 2024). Model kurulurken kategorik olan başlangıç durumu ve değişim haritaları, sözde değişken kodlaması (dummy coding) yoluyla N düzeyli bir değişkeni N-1 bağımsız değişkene ayırarak sayısallaştırılır; sürekli değişkenler ise normalleştirilir. Örneklem aşamasında kullanıcı, tüm pikselleri kullanan (all), rastgele (random) ya da büyük sınıfları azaltıp küçük sınıfları çoğaltarak dengeyi gözetken katmanlı (stratified) örneklem kiplerinden birini seçer (Asia Air Survey ve NextGIS, 2024).

Geçiş potansiyelinin modellenmesinde dört yöntem sunulur ve her biri farklı bir istatistiksel mantığa dayanır. En sık kullanılanı, girdi katmanını sürücülerin, çıktı katmanını olası dönüşüm sınıflarının oluşturduğu çok katmanlı algılayıcı yapay sinir ağıdır (MLP-ANN); aradaki gizli katman, geri yayılım (back-propagation) yoluyla sürücüler ile dönüşümler arasındaki doğrusal olmayan ilişkileri öğrenir. Kullanıcı bu yöntemde komşuluk yarıçapını (genellikle 0 ya da 1), öğrenme oranını, gizli katman sayısını ve en yüksek yineleme sayısını belirler. Öğrenme oranının düşük tutulması modeli daha temkinli kılarken, yineleme sayısının aşırı yüksek olması aşırı öğrenmeye (overfitting) yol açabilir; eğitim sırasında hem öğrenme hem de doğrulama hata eğrilerinin birlikte ve düzgün biçimde azalması ve güncel

doğrulama Kappa değerinin 0,8 dolayına ulaşması, sağlıklı bir eğitimin göstergesi olarak sunulur (NextGIS, 2024). İncelenen uygulamalarda bu parametreler belirli bir aralıkta yoğunlaşmıştır: yineleme sayısı çoğunlukla 1000, gizli katman nöron sayısı 10 ile 12 arasında, öğrenme oranı 0,001 ile 0,100 arasında ve momentum 0,05 dolayındadır (Amgoth vd., 2023; Baghel vd., 2024; Kamaraj ve Rangarajan, 2022). İkinci yöntem olan lojistik regresyon, her dönüşümü bağımsız bir olasılık fonksiyonu olarak modelleyerek daha yorumlanabilir bir yapı sunar. Üçüncü yöntem kanıt ağırlıkları, Bayesçi bir çerçevede her sürücünün dönüşüme katkısını ağırlıklandırarak sürücü öneminin sıralanmasına imkân verir. Dördüncü yöntem çok ölçütlü değerlendirme ise sürücülerini Saaty'nin ikili karşılaştırma ölçeği üzerinden uzman görüşüne dayalı ağırlıklarla birleştiren daha kural tabanlı bir seçenektir (Asia Air Survey ve NextGIS, 2024).

Hücrel otomata simülasyonunda kullanıcı, kestirimin kaç zaman dönemi için yapılacağını belirleyen yineleme sayısını tanımlar; bu değer varsayılan olarak birdir ve her yineleme bir dönem ilerlemeyi temsil eder. Simülasyon yalnızca gelecek tarihli arazi örtüsü haritasını değil, aynı zamanda 0 ile 100 arasında değişen bir geçiş potansiyeli haritasını ve kestirimin güvenilirlik derecesini yansıtan bir kesinlik fonksiyonunu da üretir (NextGIS, 2024). Sürücülerin zaman içinde değiştiği durumlarda, simülasyon için ayrı mekânsal değişken tanımlanabilen bir sürüm de kullanılabilir.

Doğrulama modülü, tek bir sayıya indirgenmeyen çok boyutlu bir değerlendirme sunar. Standart Kappa, histogram Kappa ve konum Kappa olmak üzere üç ayrı Kappa istatistiği hesaplanır; bu ayırım, modelin dönüşüm miktarını mı yoksa dönüşümün konumunu mu daha iyi kestirdiğini görmeyi sağlar (Asia Air Survey ve NextGIS, 2024). Bunun yanında bir hata bütçesi (error budget) çözümlemesi ile piksel bazında kalıcı, boş ve hatalı sınıflarını ayıran bir hata haritası üretilir; böylece modelin nerede yanlış olduğu mekânsal olarak görünür kılınır.

3.1. GEÇİŞ POTANSİYELİ ALGORİTMALARININ KARŞILAŞTIRMALI DEĞERLENDİRMESİ

İncelenen uygulamalarda açık bir yöntem tercihi öne çıkmaktadır: çalışmaların büyük çoğunluğu, doğrusal olmayan ilişkileri yakalama gücü nedeniyle yapay sinir ağını hücrel otomata ile eşleştiren CA-ANN kurgusunu benimsemiştir. Ancak bu baskın tercihin her koşulda en iyi seçenek olduğu, literatürdeki denetimli karşılaştırmalarla sınanmadan kabul edilmemelidir.

Bu noktada en açıklayıcı kanıt Tefera ve Thatiparthi (2026) sunar. Etiyopya'nın Gubalafto ilçesinde yürüttükleri çalışmada üç yöntemi aynı veri üzerinde ayrı ayrı çalıştırmış ve tek başına kanıt ağırlıklarının 0,629, lojistik regresyonun 0,609, çok katmanlı algılayıcının ise 0,617 Kappa ürettiğini raporlamışlardır. Buna karşılık kanıt ağırlıklarıyla sürücülerini sıralayıp en etkili beşini sinir ağına veren melez WoE-MLPNN-CA kurgusu, Kappa değerini 0,740'a yükseltmiştir. Bu sonuç, yöntemlerin tek başına birbirine yakın performans gösterdiğini, asıl kazanımın ise sürücü seçimi ile öğrenme aşamasını birbirini tamamlayacak biçimde bütünleştiren melez kurgudan kaynaklandığını göstermesi bakımından dikkate değerdir.

Yöntem tercihinin çalışma ölçeğine ve sürücü niteliğine göre değişebildiğine dair başka örnekler de vardır. Gao vd. (2023) Büyük Sarı Nehir bölgesi gibi çok geniş bir alanda lojistik regresyonu hücrel otomata ile birleştirerek 0,94 gibi yüksek bir doğru yüzdesine ulaşmış, böylece doğrusal yöntemlerin de büyük ölçekte etkin olabileceğini ortaya koymuştur. Şikel (2025) ise Almus Barajı çevresinde sürücülerini iki gruba ayırarak topografik değişkenleri yapay sinir ağıyla, iklimsel değişkenleri lojistik regresyonla modellemiş ve iklimsel değişkenlere dayalı lojistik regresyon modelinin topografik yapay sinir ağı modelinden daha yüksek başarı verdiğini bulmuştur. Bu bulgu, yöntem ile sürücü türü arasındaki uyumun tek başına yöntem seçiminden daha belirleyici olabileceğine işaret eder.

Eklentinin diğer simülasyon araçları karşısındaki konumunu doğrudan sınanan tek çalışma ise Ayalke (2025) tarafından yürütülmüştür. Samsun'da kentsel genişlemeyi modelleyen bu doktora çalışması,

MOLUSCE'nin CA-ANN kurgusunu TerrSet ortamındaki Arazi Değişim Modelleyici ile ve yama tabanlı PLUS modeliyle karşılaştırmıştır. Sonuçlar dikkat çekicidir: MOLUSCE, dönüşümün mekânsal yerleşimini yansıtan konum Kappa değerinde (0,8555) beş model arasında en yüksek başarıyı gösterirken, genel uyum ölçütünde (0,8202) TerrSet'in çok katmanlı algılayıcı temelli modelinin bir miktar gerisinde kalmıştır. Bu ayrışma, farklı Kappa türevlerinin farklı hikâyeler anlatabileceğini bir kez daha somutlaştırmaktadır.

3.2. SÜRÜCÜ DEĞİŞKENLER VE PARAMETRE DUYARLILIĞI

Geçiş potansiyeli modelinin kestirim gücünü belirleyen etkenlerin başında, kendisine sunulan sürücü değişkenlerin niteliği gelmektedir; bununla birlikte bölümün ilerleyen kısmında görüleceği üzere parametre ayarları ve modelleme sürecine ilişkin diğer tercihler de sonucu belirgin biçimde etkilemektedir. İncelenen çalışmalarda kullanılan sürücüler dört ana kümede toplanabilir. Topografik değişkenler yükseklik, eğim ve bakıdan oluşur ve neredeyse tüm uygulamalarda yer alır. Erişilebilirliği temsil eden mesafe değişkenleri yollara, akarsulara, yerleşimlere ve kent merkezine olan Öklit uzaklığını içerir. Sosyoekonomik değişkenler nüfus yoğunluğu, arazi değeri ve önemli noktalara yakınlık gibi katmanları kapsar. İklimsel değişkenler ise sıcaklık, yağış ve nem gibi süreçleri temsil eder ve özellikle su kaynakları ile hidroloji odaklı çalışmalarda öne çıkar (Rivera-Fernández vd., 2026; Şikel, 2025; Tefera ve Thatiparthi, 2026).


Sürücü setinin çalışma alanının karakterine göre biçimlendiği açıkça görülmektedir. Engebeli Purwokerto kentinde Ramadan ve Hidayati (2022) yükseklik ile eğimi öne çıkarırken, düz ova karakterli Jember sulama alanında Kartikasari vd. (2025) tek sürücü olarak yol ağını seçmiş ve düşük eğimli arazide değişimin yol erişilebilirliğiyle yönlendiğini gerekçe göstermiştir. En zengin sürücü setlerinden birini oluşturan Ayalke (2025), on iki kentsel sürücüye ilaveten koruma alanlarını temsil eden bir kısıtlayıcı katmanı da modele katarak, dönüşümün belirli alanlarda engellenmesini sağlamıştır.

Sürücü bileşiminin doğruluğa etkisi denetimli biçimde de gösterilmiştir. Amgoth vd. (2023) farklı değişken kombinasyonlarını sınamış ve yalnızca yükseklik ile eğim kullanıldığında 0,62 olan Kappa değerinin, bakı ve yola uzaklık eklendiğinde 0,78'e çıktığını raporlamıştır. Benzer biçimde Kamaraj ve Rangarajan (2022) en yüksek uyumu yükseklik, yola uzaklık ve yapılı alana uzaklık üçlüsüyle elde etmiştir. Öte yandan doğruluğu belirleyen yalnızca sürücüler değildir; Iskandar vd. (2024), Kappa değerinin komşuluk yarıçapı, öğrenme oranı, yineleme sayısı, gizli katman sayısı ve momentum gibi ağ parametrelerine de duyarlı olduğunu vurgulayarak, sonuçların hem veriye hem de parametre ayarına bağlı olduğunu hatırlatmıştır.

Son yıllardaki belirgin bir eğilim, sınıflandırma ile modelleme aşamalarının iş bölümüne tabi tutulmasıdır. Çalışmaların önemli bir bölümü arazi örtüsü sınıflandırmasını Google Earth Engine ortamında Rastgele Orman algoritmasıyla yüksek doğrulukla gerçekleştirmiş, MOLUSCE'yi yalnızca değişim ve kestirim aşaması için kullanmıştır (Bathe ve Patil, 2024; Gündüz, 2025; Gupta, 2026). Bu iş bölümü, girdi haritalarının doğruluğunu yükselterek modelleme hatasının kaynağını daraltan pratik bir çözüm olarak yerleşmiştir.

3.3. DOĞRULUK, MODEL GÜVENİLİRLİĞİ VE BİR BAŞARISIZLIK ÖRNEĞİ

İncelenen uygulamalarda elde edilen doğrulama değerleri geniş bir aralığa yayılmakla birlikte, büyük çoğunluğun kabul edilebilir sayılan 0,80 eşiğinin çevresinde ya da üzerinde yoğunlaştığı görülmektedir. En yüksek uyum değerlerine Jahdi (2023) yüzde 97,2 doğruluk ve 0,95 Kappa ile, Bathe ve Patil (2024) yüzde 98,2 doğruluk ve 0,97 Kappa ile, Bramantio vd. (2024) ise 0,98 Kappa ile ulaşmıştır. Büyük ölçekli bir uygulamada Gao vd. (2023) yüzde 96,4 doğru yüzdesiyle eklentinin bölgesel ölçekte de etkin biçimde çalıştığını göstermiştir. Bu değerlerin dağılımı Şekil 2'de seçili çalışmalar üzerinden görselleştirilmiştir.




Şekil 2. Seçili çalışmalarda MOLUSCE modelinin genel Kappa doğrulama değerleri. Kesikli çizgi 0,80 kabul eşiğini göstermektedir.

Bu iyimser tabloyu dengeleyen ve belki de derlemenin en öğretici bulgusu, Santoso vd. (2025) çalışmasıdır. Yogyakarta kentsel yığılma alanında yürütülen bu araştırmada, geçiş potansiyeli modellemesi eğitim aşamasında 0,96 gibi yüksek bir Kappa değeri üretmiş, ancak nihai model doğrulamasında Kappa 0,009'a, doğru yüzdesi ise yüzde 35'e gerilemiştir. Yazarlar bu sonucu açık yüreklilikle raporlayarak sonuçların güvenilir olmadığını belirtmiş ve nedenini sürücü değişkenlerdeki hatalara ya da sinir ağının yakınsayamamasına bağlamıştır. Bu örnek, eğitim başarısının tek başına aldatıcı olabileceğini ve bağımsız doğrulamanın vazgeçilmezliğini çarpıcı biçimde ortaya koyar; yüksek eğitim Kappa'sına bakıp modeli güvenilir saymak, ciddi bir yorum hatasıdır.

Doğrulamanın yalnızca tek bir Kappa değerine indirgenmesinin sakıncaları da tartışılmaya başlanmıştır. Tefera ve Thatiparthi (2026), Kappa istatistiğinin sınıf yaygınlığı ve yanlılık sorunlarına duyarlı olduğunu hatırlatarak, tek bir uyum değerine güvenmek yerine sınıf bazlı F1 ölçütleri ile miktar ve konum uyumsuzluğunun ayrıştırıldığı bir değerlendirme eklemiştir. Bu yaklaşım, modelin nerede ve hangi sınıfta yanıldığını görünür kılması bakımından, geleneksel tek değerli raporlamaya göre belirgin bir ilerleme sunar.

4. TEMATİK UYGULAMALAR VE BULGULARIN TARTIŞILMASI

İncelenen literatürün coğrafi dağılımı, eklentinin özellikle Güney ve Güneydoğu Asya'da güçlü bir kullanıcı tabanı bulduğunu ortaya koymaktadır. Dokuz çalışma Hindistan'da, yedi çalışma Endonezya'da, beş çalışma Türkiye'de yürütülmüş; geri kalanı Çin, İran, Irak, Etiyopya, Peru ve Amerika Birleşik Devletleri'ne dağılmıştır. Bu dağılım Şekil 3'te özetlenmektedir ve hızlı kentleşme yaşayan, açık kaynaklı araçlara yönelen ülkelerin eklentiyi bir maliyet avantajı olarak benimsediğine işaret eder.



Şekil 3. İncelenen 28 çalışmanın ülkelere göre dağılımı.

Tematik olarak çalışmaların çarpıcı bir ortaklığı vardır: coğrafya ve iklim ne olursa olsun, kestirimlerin neredeyse tamamı yapıli alanların genişlemesini ve doğal örtünün gerilemesini öngörmektedir. Ahmedabad metropoliten bölgesinde Gupta (2026) yapıli alanın 2045 yılına kadar 2000 yılına göre yaklaşık iki katına çıkacağını, bitki örtüsünün ise yüzde 85 oranında azalacağını kestirmiştir. Berhampore'da Roy ve Kumar (2025) 1991 ile 2021 arasında yapıli alanın yüzde 7'den yüzde 38'e yükseldiğini belgeleyip bu eğilimin 2051'e dek süreceğini öngörmüş, Bhavani havzasında Kamaraj ve Rangarajan (2022) orman ve tarım alanlarının yapıli alana dönüşümünü nüfus artışıyla ilişkilendirmiştir. Bu tekrar eden örüntü, eklentinin farklı ellerde tutarlı bir sinyal ürettiğini, dolayısıyla bulgunun araçtan çok gerçek dünyadaki kentleşme baskısını yansıttığını düşündürmektedir.

Orman ve biyoçeşitlilik ekseninde eklentinin kırılgan ekosistemlerde erken uyarı işlevi gördüğü örnekler vardır. Kumari ve Roy (2025) Batı Himalaya'nın ekolojik açıdan hassas biyocoğrafik kuşağında 2055 yılına kadar mera alanlarında yüzde 37'ye varan bir kayıp öngörerek çalışmalarını hassas bölgelerde jeouzamsal araçların önemini vurgulayan bir örnek olarak sunmuştur. Iskandar vd. (2024) Orta Kalimantan'daki bir orman işletme biriminde bataklık ormanlarının tarıma dönüşüm baskısını modellemiş, Bramantio vd. (2024) ise Parangtritis kum tepelerinin korunmasına yönelik senaryoları eklenti aracılığıyla değerlendirmiştir.

Eklentinin en ileri kullanımlarından biri, çıktısının süreç tabanlı modellere girdi olarak bağlanmasıdır. Rivera-Fernández vd. (2026), MOLUSCE ile ürettikleri gelecek arazi örtüsü senaryolarını SWAT hidrolojik modeline besleyerek Yüksek And havzalarında akım rejimindeki değişimi kestirmiş ve 2050 yılına kadar ortalama yıllık akışta yüzde 8 ile yüzde 13 arasında bir azalma öngörmüştür. Bu bağlaşım, arazi örtüsü kestiriminin tek başına bir amaç değil, daha geniş çevresel modellemelerin bir bileşeni olabileceğini göstermesi bakımından önemlidir. Benzer biçimde Singha vd. (2022) ve Singha vd. (2026) eklentiye yüzey sıcaklığı, NDBI ve NDVI kestirimine genişleterek Kolkata havzasında kentsel ısı adası etkisini modellemiş; Lufira vd. (2026) hibrit kurguyu kentsel havza dayanıklılığı bağlaşımına oturtturarak Semarang'daki bir sel kanalı havzasında geçirimsiz yüzey artışının taşkın riskine etkisini tartışmıştır. Su kaynaklarına odaklanan bir başka örnekte Şikel (2025), Almus Barajı çevresindeki su alanlarının daralma eğilimini 2028 ve 2032 yıllarına yönelik olarak modellemiştir.

Yukarıda tematik ekseninde ele alınan uygulamaların yöntem tercihleri ile ulaştıkları doğruluk düzeyleri, bir arada görüldüğünde daha kolay karşılaştırılabilir. Bu amaçla Tablo 1, incelenen çalışmalar arasından yöntem kurgusunu açıkça belirten ve doğrulama sonucunu raporlayan çalışmaları; çalışma

alanı, ülke, geçiş potansiyeli yöntemi ve doğrulama değeri bakımından bir arada sunmaktadır. Tabloya alınacak çalışmalar seçilirken farklı ülke, ölçek ve yöntem bileşimlerinin temsil edilmesi gözetilmiş; doğrulama bilgisi vermeyen ya da eklentiye yalnızca ara adım olarak kullanan çalışmalar tabloya dâhil edilmemiştir. Böylece tablo, önceki bölümlerde tematik olarak tartışılan bulguların yöntem ve doğruluk boyutundaki karşılığını topluca göstermektedir.

Tablo 1. İncelenen çalışmalardan seçilenlerin çalışma alanı, ülke, geçiş potansiyeli yöntemi ve doğrulama sonucu bakımından karşılaştırmalı özeti.

Çalışma	Alan / Ülke	Yöntem	Doğrulama
Ramadan ve Hidayati (2022)	Purwokerto / Endonezya	ANN-CA	Kappa 0,63; %75,3
Kamaraj ve Rangarajan (2022)	Bhavani havzası / Hindistan	MLP-ANN + CA	Kappa 0,69; %76,3
Muhammad vd. (2022)	Linyi / Çin	ANN-CA	Yeterli düzey
Gao vd. (2023)	Sarı Nehir bölgesi / Çin	LR + CA	Kappa 0,94; %96,4
Amgoth vd. (2023)	Pakhal Gölü / Hindistan	MLP-ANN + CA	Kappa 0,78; %78,2
Baghel vd. (2024)	Mand havzası / Hindistan	MLP-ANN + CA	Kappa 0,87; %84,3
Bathe ve Patil (2024)	Jagatsinghpur / Hindistan	ANN-CA	Kappa 0,97; %98,2
Bramantio vd. (2024)	Parangtritis / Endonezya	ANN-MLP + CA	Kappa 0,98; %92
Sabri ve Khayyun (2024)	Kuzey Irak	CA-ANN	Kappa 0,83; %93
Jahdi (2023)	Siahkal / İran	Geçiş matrisi + CA	Kappa 0,95; %97,2
Gündüz (2025)	Manisa / Türkiye	CA-ANN	Kappa 0,88; %92
Santoso vd. (2025)	Yogyakarta / Endonezya	ANN-CA	Kappa 0,009; %35
Roy ve Kumar (2025)	Berhampore / Hindistan	CA-ANN	Kappa 0,87; %84
Tefera ve Thatiparthi (2026)	Gubalafto / Etiyopya	WoE-MLPNN-CA	Kappa 0,74; %82,1
Dadzie vd. (2026)	Baton Rouge / ABD	Markov + MLP + CA	Kappa > 0,94
Ayalke (2025)	Samsun / Türkiye	ANN-CA	Kappa 0,82

5. GÜÇLÜ YÖNLER, SINIRLILIKLAR VE GELECEK YÖNELİMLERİ

İncelenen literatür, eklentinin benimsenmesinde birkaç ortak gerekçeyi tekrar tekrar öne çıkarmaktadır. Bunların başında açık kaynaklı ve ücretsiz olması gelir; Şikel (2025) bu yapının farklı makine öğrenmesi tekniklerini hücrel otomata simülasyonlarıyla bütünleştirmeye olanak tanıdığını vurgulamıştır. İkinci güçlü yön, tüm modelleme sürecini tek bir ara yüzde toplamasıdır; Baghel vd. (2024) ara yüzü girdi, değişim analizi, modelleme, kestirim ve doğrulama modülleriyle sezgisel ve kullanıcı dostu bulmuş, Wanggai vd. (2026) ise eklentiye kestirim modellemesinin tüm aşamaları için tek bir araç olarak nitelemiştir. Üçüncü ayırt edici özellik, çok sayıda geçiş potansiyeli algoritmasını aynı çatı altında sunması ve bunlar üzerine melez kurgular inşa edilebilmesidir; Tefera ve Thatiparthi (2026) eklentiye tam da istatistiksel, makine öğrenmesi ve hücrel otomata yaklaşımlarını tek bir açık kaynaklı ortamda birleştirdiği için seçtiklerini belirtmiştir.

Bu güçlü yönlerin yanında belirgin sınırlılıklar da vardır. Sık dile getirilen bir teknik güçlük sürüm uyumluluğudur; incelenen çalışmaların önemli bir bölümü eklentiye QGIS'in eski 2.18 sürümünde çalıştırmış, hatta Bramantio vd. (2024) ön işlemeyi QGIS 3.16 ile, modellemeyi ise QGIS 2.18 ile yürütmek gibi iki sürümü birlikte kullanan pratik bir çözüme başvurmuştur. Bununla birlikte bu güçlüğün büyük ölçüde geride kaldığını belirtmek gerekir; eklentinin NextGIS tarafından sürdürülen güncel sürümleri Qt6 tabanlı yeni QGIS ortamlarında çalıştığından, eski 2.18 bağımlılığı esasen daha erken tarihli çalışmaların

bir kısıtı olarak kalmaktadır (NextGIS, 2024). Daha yapısal bir eleştiri ise yöntemsel şeffaflık ve yinelenebilirlik konusundadır. Lufira vd. (2026), mevcut uygulamaların çoğunun sürücü seçimini, parametre kalibrasyonunu ve doğruluk eşiklerini sistematik biçimde belgelemeden eklentiye çalıştırdığını, bunun da yinelenebilirliği kısıtladığını belirtmiştir. Gupta (2026) ise modelin girdi verisinin mekânsal çözünürlüğü ve sosyoekonomik değişkenlerin dışlanması nedeniyle sınırlandığını açıkça kaydetmiştir. Bu eleştiriler birlikte okunduğunda, sorunun aracın kendisinden çok, araca yüklenen verinin ve seçilen ayarların yeterince gerekçelendirilmemesinden kaynaklandığı anlaşılır.

Bu değerlendirmeden birkaç gelecek yönelimi türetilebilir. Sosyoekonomik ve iklimsel sürücülerin daha sistematik biçimde modele katılması, tek bir Kappa değerine dayanmak yerine sınıf bazlı ölçütler ve uyumsuzluk ayrıştırmasının benimsenmesi, kestirim belirsizliğinin nicel olarak ifade edilmesi ve sonuçların kesin bir gerçeklik değil bir senaryo olarak yorumlanması, bu araca dayalı araştırmaların niteliğini yükseltecek başlıca alanlardır. Nitekim Dadzie vd. (2026) kendi çıktısını bir garanti değil bir senaryo olarak sunarak bu olgun yorumlama tutumunun iyi bir örneğini vermiştir.

6. SONUÇ

Bu çalışmada MOLUSCE eklentisi, önce kuramsal mimarisi bakımından modül modül çözümlenmiş, ardından dokuz ülkede yürütülmüş 28 uygulamanın sonuçları karşılaştırmalı biçimde tartışılmıştır. Değerlendirme, eklentinin arazi örtüsü değişimi kestiriminde olgunlaşmış ve güvenilir bir araç hâline geldiğini göstermektedir. Markov zinciri, hücresel otomata ve dört ayrı geçiş potansiyeli yöntemini açık kaynaklı bir QGIS ara yüzünde birleştirmesi, yerleşik doğrulama modülüyle desteklenmesi ve melez kurgulara açık olması, onu özellikle kaynak kısıtı altındaki araştırma ortamlarında güçlü bir seçenek kılmaktadır.

Bununla birlikte literatürden süzülen en temel çıkarım, kestirim başarısının tek bir etkene indirgenemeyeceğidir; girdi verisinin kalitesi, sürücü değişkenlerin seçimi, model parametrelerinin kalibrasyonu ve benimsenen doğrulama yaklaşımı birlikte belirleyici olmaktadır. Sürücü değişkenlerin özenle seçildiği, çok bağlantılılığın denetlendiği ve parametrelerin bilinçli biçimde ayarlandığı çalışmalar 0,90'ın üzerinde doğrulama değerlerine ulaşırken, bu özenin gösterilmediği durumlarda eğitimdeki yüksek başarının doğrulama aşamasında belirgin biçimde gerileyebildiği görülmüştür. Bu nedenle eklentiye kullanan araştırmacıların sürücü seçim gerekçelerini, parametre değerlerini ve çok boyutlu doğrulama sonuçlarını şeffaf biçimde belgelemesi, hem bilimsel güvenilirlik hem de yinelenebilirlik açısından zorunludur. Bu koşul yerine getirildiğinde MOLUSCE, arazi değişimi kestiriminde planlamaya dönük karar destek işlevini güçlü biçimde yerine getirebilecek bir konumdadır.

KAYNAKLAR

- Aldoğan, C. F. (2019). *İstanbul 2023 yılı arazi örtüsü/kullanım tahmininin yapay sinir ağıları ve mantıksal regresyon metotları ile modellenmesi* (Yüksek lisans tezi). İstanbul Teknik Üniversitesi, Bilişim Enstitüsü, İstanbul.
- Amgoth, A., Rani, H. P., & Jayakumar, K. V. (2023). Exploring LULC changes in Pakhal Lake area, Telangana, India using QGIS MOLUSCE plugin. *Spatial Information Research*, 31(4), 429–438. <https://doi.org/10.1007/s41324-023-00509-1>
- Asia Air Survey, & NextGIS. (2024). *MOLUSCE: Modules for Land Use Change Evaluation, Quick help* [QGIS eklentisi kullanım kılavuzu]. https://github.com/nextgis/qgis_molusce
- Ayalke, Z. G. (2025). *Kentsel genişlemenin makine öğrenmesi yöntemleri ile irdelenmesi* (Doktora tezi). Ondokuz Mayıs Üniversitesi, Lisansüstü Eğitim Enstitüsü, Samsun.
- Baghel, S., Kothari, M. K., Tripathi, M. P., Singh, P. K., Bhakar, S. R., Dave, V., & Jain, S. K. (2024). Spatiotemporal LULC change detection and future prediction for the Mand catchment using MOLUSCE tool. *Environmental Earth Sciences*, 83(3), 66. <https://doi.org/10.1007/s12665-023-11381-5>

- Bathe, K. D., & Patil, N. S. (2024). Assessment of land use-land cover dynamics and its future projection through Google Earth Engine, machine learning and QGIS-MOLUSCE: A case study in Jagatsinghpur district, Odisha, India. *Journal of Earth System Science*, 133(2), 111. <https://doi.org/10.1007/s12040-024-02305-3>
- Bramantio, B., Hizbaron, D. R., & Khakhim, N. (2024). Prediction of the future landuse and land cover changes in the Parangtritis sand dune: A spatio-temporal analysis using QGIS MOLUSCE. *IOP Conference Series: Earth and Environmental Science*, 1313, 012014. <https://doi.org/10.1088/1755-1315/1313/1/012014>
- Dadzie, E., Twumasi, Y. A., Ning, Z. H., Osei, J. D., Gyan, D. T., Annan, K. K., & Loh, P. M. (2026). Integrating remote sensing and MOLUSCE to map and predict land degradation in Baton Rouge. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLVIII-M-10-2025, 107–112. <https://doi.org/10.5194/isprs-archives-XLVIII-M-10-2025-107-2026>
- Gao, C., Cheng, D., Iqbal, J., & Yao, S. (2023). Spatiotemporal change analysis and prediction of future land cover changes using QGIS MOLUSCE plugin on a large regional scale and the relationship analysis with mountain hazards: A case study of the Great Yellow River Region (GYRR), China. *Land*, 12(2), 340. <https://doi.org/10.3390/land12020340>
- Gündüz, H. İ. (2025). Land-use land-cover dynamics and future projections using GEE, ML, and QGIS-MOLUSCE: A case study in Manisa. *Sustainability*, 17(4), 1363. <https://doi.org/10.3390/su17041363>
- Gupta, R. K. (2026). Integrating GEE, machine learning, and MOLUSCE for predicting urban LULC dynamics of Ahmedabad Metropolitan Region, India. *International Journal of Engineering and Geosciences*, 11(3), 666–684. <https://doi.org/10.26833/ijeg.1828589>
- Iskandar, B., Saidah, Kurnia, A. A., Jauhari, A., & Zannah, F. (2024). Modeling land cover change using MOLUSCE in Kahayan Tengah Forest Management Unit, Kalimantan Tengah. *Jurnal Sylva Lestari*, 12(2), 242–257. <https://doi.org/10.23960/jsl.v12i2.865>
- Jahdi, R. (2023). Land use changes analysis and prediction using remote sensing and QGIS MOLUSCE plugin in the Siahkal County. *Systems of Watershed Management*, 10(4), 29–42.
- Kamaraj, M., & Rangarajan, S. (2022). Predicting the future land use and land cover changes for Bhavani basin, Tamil Nadu, India, using QGIS MOLUSCE plugin. *Environmental Science and Pollution Research*, 29(63), 86337–86348. <https://doi.org/10.1007/s11356-021-17904-6>
- Kartikasari, A. N. I., Prasajo, S. I. L., Kaffa, N. S., & Robbani, H. W. (2025). Land cover projection of Jember irrigation area using MOLUSCE QGIS. *Geoid*, 20(2), 35–44.
- Kumari, S., & Roy, A. (2025). Simulation of land use and land cover using the MOLUSCE plugin integrated with QGIS for the Western Himalayan region of India. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLVIII-M-5-2024, 81–85. <https://doi.org/10.5194/isprs-archives-XLVIII-M-5-2024-81-2025>
- Lufira, R. D., Andawayanti, U., Asmaranto, R., Suhartanto, E., Azzahra, A., Utami, R. T., & Rahmawan, I. T. (2026). Hybrid cellular automata-artificial neural network land use change QGIS-MOLUSCE for urban watershed resilience. *Journal of Water and Land Development*, 69, 15–23. <https://doi.org/10.24425/jwld.2026.157847>
- Muhammad, R., Zhang, W., Abbas, Z., Guo, F., & Gwiazdzinski, L. (2022). Spatiotemporal change analysis and prediction of future land use and land cover changes using QGIS MOLUSCE plugin and remote sensing big data: A case study of Linyi, China. *Land*, 11(3), 419. <https://doi.org/10.3390/land11030419>
- NextGIS. (2024). *MOLUSCE: Modules for Land Use Change Simulations* [QGIS eklentisi kullanıcı belgesi]. https://docs.nextgis.com/docs_ngqgis/source/molusce.html
- Ramadan, G. F., & Hidayati, I. N. (2022). Prediction and simulation of land use and land cover changes using open source QGIS: A case study of Purwokerto, Central Java, Indonesia. *Indonesian Journal of Geography*, 54(3), 344–351. <https://doi.org/10.22146/ijg.68702>
- Rivera-Fernández, A. S., Zabaleta-Santisteban, J. A., Medina-Medina, A. J., Tuesta-Trauco, K. M., Silva-Meléndez, T. B., Grandez-Alberca, M. A., Salas López, R., Oliva-Cruz, M., Portocarrero, C., Rojas-Briceño, N. B., Barboza, E., & Silva-López, J. O. (2026). Hydrological impacts of LULC change in high-Andean basins: An integrated SWAT-MOLUSCE modeling approach. *Water*, 18(3), 365. <https://doi.org/10.3390/w18030365>

- Roy, S. K., & Kumar, A. (2025). Monitoring the LULC changes in the rural region of Berhampore Municipality using MOLUSCE plugin of QGIS. *Proceedings of the Indian National Science Academy*. <https://doi.org/10.1007/s43538-025-00628-3>
- Sabri, N. Q., & Khayyun, T. S. (2024). Spatiotemporal prediction of future LULC changes, northern and northeastern parts of Iraq with MOLUSCE. *Journal of Ecohumanism*, 3(7), 2417–2433. <https://doi.org/10.62754/joe.v3i7.4647>
- Santoso, D. H., Puryani, Algary, T. A., Chaeron, M., & Hilmi, I. K. (2025). Land use change analysis using plugin MOLUSCE in Yogyakarta urban agglomeration area. *INSOLOGI: Jurnal Sains dan Teknologi*, 4(2), 160–169. <https://doi.org/10.55123/insologi.v4i2.5032>
- Şikel, Y. S. (2025). *Uzaktan algılama verileri ile makine öğrenmesi algoritmaları kullanılarak Almus Barajı su alanlarının zamansal değişiminin analizi ve geleceğe yönelik mekânsal projeksiyonları* (Yüksek lisans tezi). Sivas Cumhuriyet Üniversitesi, Fen Bilimleri Enstitüsü, Sivas.
- Singha, C., Sahoo, S., Singh, S. P., & Chowdhuri, B. R. (2022). *Predicting the relationship between LULC changes and their impact on LST by MOLUSCE and GEE environment in urban catchment of Kolkata city* [Ön baskı]. SSRN. <https://ssrn.com/abstract=4272465>
- Singha, C., Sahoo, S., Swain, K. C., Govind, A., Al-Quraishi, A. M. F., & Singh, S. P. (2026). Utilization of MOLUSCE tool and GEE cloud to predict the variation of LST through LULC, NDBI and NDVI in Tollygunge-Panchannagram Basin of Kolkata. *Discover Environment*, 4, 2. <https://doi.org/10.1007/s44274-025-00474-6>
- Tefera, S. A., & Thatiparthi, V. L. (2026). Optimizing land use and land cover prediction using an integrated MOLUSCE framework in Gubalafto district, Ethiopia. *Discover Sustainability*, 7, 958. <https://doi.org/10.1007/s43621-026-03283-w>
- Wanggai, C. B., Supardi, Sari, C. F. K., Mardiyadi, Z., & Putri, E. F. S. (2026). Analysis and prediction of land cover change in Palangka Raya City using a cellular automata–neural network model based on MOLUSCE. *Jurnal Teknologi Informasi dan Pendidikan*, 19(2), 1479–1499. <https://doi.org/10.24036/jtip.v19i2.1117>
- Yiğit, Ş. (2018). *Peyzaj metrikleri kullanılarak Hatay-Samandağ bölgesi peyzaj değişimlerinin değerlendirilmesi* (Yüksek lisans tezi). Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Antalya.