

Sistem Klasifikasi Penggunaan Lahan Berbasis Data Spasial Dalam Penilaian Massal

Edwardo Krisna Sembiring^{a,1*}, Aga Sri Dharmestha^{b,2}

^aUniversitas Gadjah Mada, Yogyakarta, Indonesia

^bInstitut Teknologi Bandung, Bandung, Indonesia

Email : ^{1*}edwardokrisnasembiring@mail.ugm.ac.id, ²agadharmestha@gmail.com

*Corresponding Author

Abstrak

Penelitian ini berfokus pada masalah yang dihadapi dalam penilaian massal properti di Indonesia yang memiliki lanskap perkotaan heterogen, sehingga diperlukan sistem klasifikasi lahan yang terstandarisasi untuk menggambarkan perubahan nilai properti dengan tepat. Tujuan dari studi ini adalah untuk menciptakan model otomatis untuk klasifikasi penggunaan lahan dengan memanfaatkan arsitektur deep learning ResNet-50. Metode yang digunakan dalam penelitian ini mencakup pengambilan fitur dari citra satelit berkualitas tinggi untuk mengidentifikasi enam jenis penggunaan lahan, yaitu area hijau, kawasan permukiman kumuh-padatan, permukiman menengah hingga atas, kawasan premium, industri, dan komersial sebagai objek penilaian. Temuan penelitian ini menunjukkan bahwa penggunaan ResNet-50 sangat efektif dalam melakukan segmentasi daerah perkotaan dengan akurasi tinggi, yang secara signifikan meningkatkan efisiensi waktu dan sumber daya dibandingkan dengan teknik tradisional. Penerapan model ini menyediakan basis data spasial yang objektif dan terukur, sehingga membantu dalam mengidentifikasi wilayah nilai tanah yang penting untuk dinamika pasar properti. Pendekatan ini mendukung upaya digitalisasi dalam sektor penilaian aset serta memperkuat pengambilan keputusan yang berlandaskan data dalam konteks pembangunan berkelanjutan di Indonesia.

©2025 the author(s)

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



Riwayat Artikel

Diterima 2025-12-05

Revisi 2026-05-09

Disetujui 2026-05-24

Kata Kunci

Citra Satelit

Klasifikasi Penggunaan Lahan

Pembelajaran Mesin

Penilaian Massal

Resnet-50

Klasifikasi JEL*:

R32,R52,C88

Pendahuluan

Klasifikasi penggunaan lahan merupakan aspek penting dalam memahami karakteristik suatu wilayah. Dalam praktik penilaian, klasifikasi penggunaan lahan tersebut dapat menjadi dasar sistematis dalam memahami pola spasial sehingga dapat mendukung justifikasi empiris terhadap variasi valuasi (Zheng & Wang, 2024). Dalam praktik penilaian, klasifikasi penggunaan lahan diperlukan untuk dapat meninjau karakteristik wilayah yang umumnya dapat diklasifikasikan menjadi kategori seperti komersial, residensial, industri, dan lainnya. Tinjauan ini berperan dalam

penentuan *highest and best use* (HBU) yang dapat memengaruhi persepsi penilai dalam melakukan pendekatan penilaian. Salah satu contoh penerapan dari tinjauan ini adalah penilai dapat memilih data pembanding yang sejenis dan sebanding dalam pendekatan perbandingan data pasar.

Seiring dengan perkembangan teknologi, praktik penilaian aset perlu untuk mengikuti alur yang lebih cepat untuk dapat memangkas waktu evaluasi dan efisiensi operasional, terutama pada penilaian massa yang menilai sekelompok aset dalam jumlah banyak. Praktik penilaian konvensional yang dilakukan selama ini perlu untuk dipadukan dengan otomatisasi sehingga dapat meningkatkan efisiensi kerja, termasuk dalam hal pengklasifikasian penggunaan lahan (Jahanshiri et al., 2011; Siewert & Kroszczyński, 2023). Dalam praktik penilaian massal. Di Indonesia, skema klasifikasi masih cenderung rumit karena belum adanya dukungan sistem klasifikasi yang dapat dilakukan secara digital. Digitalisasi klasifikasi penggunaan lahan ini diperlukan dalam praktik penilaian untuk dapat meningkatkan kecepatan penyediaan informasi secara akurat dan informatif dan meningkatkan akuntabilitas penentuan informasi sesuai dengan data masukan dan parameter yang ditentukan (Bergadano et al., 2021). Berdasarkan hal tersebut, pengembangan teknologi identifikasi klasifikasi penggunaan lahan ini jika dapat membantu proses penilaian, maka dapat meminimalisir kesalahan manusia dalam proses identifikasi data dan meningkatkan efisiensi proses analisis penilaian.

Seiring dengan perkembangan teknologi, proses klasifikasi penggunaan lahan dapat dilakukan secara digital dengan menerapkan *remote sensing*. *Remote sensing* tersebut dapat mendeteksi variasi spektral di permukaan bumi sehingga dapat memetakan dan memantau perubahan tutupan lahan (Lillesand et al., 2015). *Remote sensing* sebagai teknologi untuk perolehan informasi ini menghasilkan citra satelit yang dapat dijadikan sebagai basis dapat mengklasifikasikan penggunaan lahan. Pemanfaatan citra satelit ini dapat mendukung proses klasifikasi agar lebih akurat dan efisien, termasuk dalam wilayah yang memiliki karakteristik beragam (Helber et al., 2017).

Perkembangan teknologi pemrosesan data spasial mendorong penerapan *deep learning* dalam melakukan analisis dan klasifikasi penggunaan lahan. *Deep learning* dapat melakukan ekstraksi hingga penggabungan fitur penting secara otomatis melalui proses hierarkis pada data berukuran besar, termasuk citra satelit. *Deep learning* ini memanfaatkan Artificial Neural Network (ANN) untuk dapat mempelajari hubungan non-linear yang kompleks dalam mengenali pola spektral dan spasial yang dapat digunakan untuk klasifikasi penggunaan lahan. ANN tersebut kemudian dikembangkan menjadi Convolutional Neural Network (CNN) yang dirancang untuk dapat mengolah data berbentuk citra dan mengenali pola spasial, mulai dari fitur sederhana hingga kompleks. CNN ini dapat mengintegrasikan informasi spasial dan spektral secara bersamaan sehingga dapat melakukan pemrosesan spasial dengan baik dengan tingkat akurasi mencapai lebih dari 95 persen (Zhang et al., 2018).

Salah satu pengembangan dari Convolutional Neural Network (CNN) adalah Residual Network (ResNet). ResNet memungkinkan adanya proses pelatihan yang cukup dalam tanpa mengalami penurunan akurasi karena tetap menjaga dan mengombinasikan fitur awal. ResNet dapat melakukan ekstraksi terhadap fitur spasial dari citra multispektral yang dapat mengatasi permasalahan terkait pola spasial yang kompleks dan variasi dalam spektral citra lahan. Dengan kemampuan tersebut, ResNet dapat meningkatkan akurasi analisis spasial (Abbas et al., 2024).

Penerapan ResNet dapat mempercepat proses analisis dalam penilaian. Penerapan ResNet ini diharapkan dapat menghasilkan peta klasifikasi penggunaan lahan yang andal, terukur, dan dapat direproduksi sehingga mengatasi tantangan pola persebaran lahan yang heterogen di Indonesia (Pamungkas et al., 2025). Model klasifikasi tersebut tidak hanya membantu dalam mengidentifikasi berbagai pola penggunaan lahan, tetapi juga berkontribusi pada pemahaman komprehensif tentang dinamika sosial ekonomi sebagai salah satu komponen penting yang berpengaruh terhadap nilai properti (Li et al., 2021). Penerapan teknologi ini juga dapat membantu proses penilaian karena mengurangi waktu proses klasifikasi penggunaan lahan. Dalam studi yang pernah dilakukan di

Guangdong, China, teknologi ini terbukti berhasil untuk memetakan penggunaan lahan dengan akurasi 81,52% dalam waktu 13 jam untuk area seluas 179.700 km² (Wang et al., 2019).

Meskipun penelitian terkait klasifikasi penggunaan lahan berbasis citra satelit dan *deep learning* telah berkembang pesat, masih terdapat beberapa kesenjangan penelitian (*research gap*) yang relevan dengan konteks penilaian properti. Pertama, gap teoritis, sebagian besar studi sebelumnya berfokus pada klasifikasi penggunaan lahan sebagai tujuan akhir, tanpa mengaitkannya secara konseptual dengan teori penilaian properti, seperti *highest and best use* (HBU) dan *market segmentation*. Padahal, dalam praktik penilaian, klasifikasi penggunaan lahan seharusnya menjadi variabel penting yang memengaruhi pembentukan nilai aset (Jafary et al., 2024)

Kedua, gap metodologis, penelitian terdahulu umumnya mengembangkan model klasifikasi berbasis CNN hanya untuk meningkatkan akurasi klasifikasi citra, tanpa merancang pipeline yang terintegrasi dengan kebutuhan penilaian massal. Belum banyak studi yang secara sistematis menggabungkan proses klasifikasi spasial, standardisasi data, hingga evaluasi berbasis kebutuhan praktis penilai (Zhou et al., 2019)

Ketiga, gap empiris, khususnya di Indonesia, implementasi sistem klasifikasi penggunaan lahan berbasis *deep learning* masih sangat terbatas, terutama dalam konteks penilaian massal properti di wilayah urban yang kompleks seperti DKI Jakarta. Praktik yang ada masih didominasi oleh pendekatan manual yang rentan terhadap subjektivitas dan inefisiensi waktu (Purnawan & Tarmaji, 2025). Oleh karena itu, penelitian ini berupaya mengisi kesenjangan tersebut dengan mengembangkan sistem klasifikasi penggunaan lahan berbasis *deep learning* yang tidak hanya berorientasi pada akurasi teknis, tetapi juga terintegrasi dengan kebutuhan konseptual dan praktis dalam penilaian aset.

Adopsi ResNet dalam praktik penilaian dapat menjadi solusi terutama terkait klasifikasi penggunaan lahan untuk mendukung praktik penilaian. Oleh karena itu, dilakukan penelitian penerapan ResNet untuk digitalisasi proses klasifikasi penggunaan lahan yang dapat mengintegrasikan data penginderaan jauh sehingga dapat mengatasi tantangan terkait kesenjangan interpretasi citra satelit beresolusi tinggi dan penilaian pasar properti di Indonesia. Berbeda dengan penelitian sebelumnya yang umumnya berhenti pada peningkatan akurasi klasifikasi, penelitian ini memposisikan output klasifikasi sebagai variabel yang memiliki implikasi langsung terhadap pembentukan nilai properti. Penelitian ini menawarkan beberapa kontribusi kebaruan utama. Pertama, penelitian ini mengembangkan pipeline klasifikasi spasial yang terstruktur, mulai dari segmentasi berbasis poligon, standardisasi citra resolusi tinggi, hingga implementasi model deep learning yang dioptimalkan untuk kebutuhan penilaian massal.

Kedua, penelitian ini mengembangkan pendekatan yang menghubungkan klasifikasi penggunaan lahan dengan konsep *highest and best use* (HBU) serta segmentasi pasar properti, sehingga hasil klasifikasi tidak hanya bersifat deskriptif, tetapi juga memiliki relevansi dalam analisis valuasi. Dalam konteks ini, setiap kategori penggunaan lahan yang dihasilkan model merepresentasikan karakteristik ekonomi dan spasial yang berbeda, yang secara teoritis memengaruhi variasi nilai aset.

Ketiga, penelitian ini menghadirkan pendekatan aplikatif dalam konteks penilaian massal di Indonesia, dengan studi kasus DKI Jakarta, sehingga memberikan kontribusi empiris pada literatur yang masih didominasi oleh studi di negara maju. Dengan adanya penelitian ini, proses penilaian diharapkan dapat menjadi lebih efektif dan efisien karena adaptasi otomatisasi proses analisis.

Selain itu, pemilihan wilayah studi di DKI Jakarta didasarkan pada tingkat kompleksitas penggunaan lahan yang sangat tinggi dibandingkan wilayah lain di Indonesia. DKI Jakarta sebagai pusat ekonomi nasional memiliki heterogenitas spasial yang mencakup kawasan komersial intensif, permukiman dengan berbagai kelas sosial ekonomi, hingga kawasan industri dalam skala besar. Menunjukkan bahwa nilai tanah di Jakarta dapat sangat bervariasi bahkan dalam satu wilayah yang sama, mencerminkan adanya campuran antara kawasan kumuh dan kawasan modern dalam satu ruang perkotaan (Savitri & Fransiska, 2022)

Selain itu, dinamika ekonomi perkotaan di Jakarta juga mendorong terbentuknya kluster-kluster penggunaan lahan yang memengaruhi nilai properti secara signifikan. Aglomerasi aktivitas ekonomi di Jakarta membentuk urban clusters yang berkorelasi positif dengan peningkatan nilai lahan (Januari et al., 2024). Di sisi lain, tingginya frekuensi transaksi properti dan kebutuhan penilaian massal di DKI Jakarta menjadikan wilayah ini sebagai tempat yang sempurna untuk menguji efektivitas sistem klasifikasi berbasis kecerdasan buatan. Transformasi lahan yang masif serta pertumbuhan kawasan terbangun yang cepat semakin memperkuat kompleksitas struktur spasial Jakarta sebagai kota metropolitan (Parhusip & Trihandaru, 2025). Oleh karena itu, penggunaan DKI Jakarta dalam penelitian ini tidak hanya bersifat kontekstual, tetapi juga strategis dalam merepresentasikan tantangan nyata dalam praktik penilaian aset di kawasan urban dengan kompleksitas tinggi.


Metode

Pembelajaran mesin atau *machine learning* merupakan sub bidang kecerdasan buatan yang menggunakan algoritma dan model matematis untuk mempelajari pola dari data, dengan tujuan membuat prediksi atau keputusan tanpa diprogram secara eksplisit untuk setiap tugas (Xie et al., 2022). Secara khusus, pembelajaran mesin spasial/*spatial machine learning* memperkuat metode pembelajaran mesin tradisional dengan mengintegrasikan informasi geografis dan spasial, yang memungkinkan model mempertimbangkan ketergantungan dan heterogenitas spasial. Sebagai contoh, mesin vektor pendukung telah diadaptasi secara khusus untuk menganalisis faktor-faktor spasial yang terlibat dalam perluasan perkotaan dan perubahan penggunaan lahan, dengan menetapkan korelasi antara faktor-faktor pendorong nonspasial dan distribusi spasial pertumbuhan perkotaan (Rienow, 2016).

Convolutional Neural Networks (CNN) merupakan jenis *deep neural network* yang khusus dirancang untuk memproses struktur data seperti kisi, termasuk citra atau gambar (Xie et al., 2022). Melalui pembelajaran representasi fitur hierarkis secara otomatis menggunakan filter konvolusi, CNN menunjukkan efektivitas yang tinggi untuk tugas klasifikasi citra, termasuk yang melibatkan citra satelit resolusi tinggi, dan telah menjadi fondasi bagi berbagai aplikasi penginderaan jauh dan *computer vision* (Wang et al., 2019). Operasi konvolusi dan *pooling* dalam CNN memfasilitasi ekstraksi fitur spasial yang sangat penting untuk mengidentifikasi objek dan pola dalam citra satelit (Wang et al., 2019).

Dalam lanskap pembelajaran mesin yang lebih luas, terdapat dua paradigma pembelajaran utama, pembelajaran terawasi/*supervised learning* dan pembelajaran tak terawasi/*unsupervised learning*. Pembelajaran terawasi melibatkan pelatihan model pada dataset di mana masukan dipasangkan dengan label atau hasil yang diketahui. Model mempelajari fungsi pemetaan sehingga ketika disajikan data baru, model dapat memprediksi keluaran yang sesuai. Sebaliknya, pembelajaran tak terawasi bertujuan mengungkap struktur atau pola tersembunyi dalam data tanpa label, memungkinkan tugas-tugas seperti pengelompokan dan deteksi anomali (Sarmast et al., 2023). Kedua pendekatan ini merepresentasikan kategorisasi teknik pembelajaran mesin yang paling umum dan sering dipilih berdasarkan ketersediaan data berlabel dan tujuan spesifik analisis.

ResNet (Residual Network) merupakan arsitektur CNN yang menggunakan pembelajaran residual melalui koneksi pintas, yang juga disebut koneksi lompatan, untuk mengatasi masalah gradien yang menghilang yang dapat terjadi pada *deep neural network* yang sangat dalam (Xie et al., 2022). Arsitektur ini memungkinkan lapisan-lapisan untuk mempelajari fungsi residual berkenaan dengan masukannya, bukan mempelajari fungsi tanpa referensi, sehingga memfasilitasi pembangunan jaringan yang jauh lebih dalam tanpa degradasi kinerja yang signifikan.




Gambar 1. Arsitektur ResNet-50

Sumber: towardsdatascience.com

ResNet-50 merupakan varian 50 lapisan dari keluarga ResNet yang banyak digunakan dalam tugas klasifikasi citra. Arsitekturnya biasanya terdiri dari lapisan konvolusi awal, diikuti oleh empat blok konvolusi yang menggabungkan struktur *bottleneck*, dan berakhir dengan lapisan pooling rata-rata serta lapisan klasifikasi yang terhubung penuh (Wang et al., 2019). Desain *bottleneck* dalam ResNet-50 mengurangi biaya komputasi sambil mempertahankan kedalaman, dan koneksi residual memastikan bahwa lapisan yang lebih dalam tidak menghambat pembelajaran dengan memfasilitasi aliran gradien. Konsekuensinya, ResNet-50 telah menunjukkan kinerja yang kuat dalam aplikasi seperti penginderaan jauh, di mana klasifikasi akurat pola spasial yang kompleks sangat penting (Wang et al., 2019).

Metode ini diharapkan mampu melakukan klasifikasi dalam beberapa kategori penggunaan lahan, termasuk di lingkungan perkotaan dan *peri-urban*. Dalam penelitian ini, dataset penelitian terdiri dari fitur poligon yang mewakili enam kategori penggunaan lahan yang dicirikan oleh tanda spektral, pola spasial, dan properti kontekstual yang dapat diamati melalui citra satelit. Kategori tersebut mencakup jenis penggunaan lahan utama yang umum ditemukan di daerah perkotaan dan dapat menunjukkan keragaman lanskap di wilayah metropolitan. Wilayah studi kasus dalam penelitian ini adalah DKI Jakarta karena dianggap memiliki guna lahan yang cukup kompleks. Pendefinisian dataset untuk daerah DKI Jakarta tersebut dapat dilihat pada lampiran.

Dalam penelitian ini, terdapat lima tahapan yang dilakukan. Tahapan tersebut terdiri atas akuisisi dan pra-pemrosesan data, pembuatan dan standarisasi gambar, arsitektur *deep learning*, pelatihan model, serta evaluasi model.



Gambar 2. Kerangka Penelitian

Sumber: Hasil Analisis Pribadi

Proses awal yang dilakukan adalah melakukan perolehan dan pra-proses data serta membangun dasar untuk pelatihan model. Data latih berasal dari kumpulan data poligon GeoJSON yang berisi kategori penggunaan lahan. Setiap poligon dalam data mewakili area geografis yang berbeda dengan klasifikasi yang terverifikasi. Poligon tersebut berfungsi sebagai dasar untuk pembelajaran terawasi/*supervised learning*.

Penyusunan sampel data label dilakukan melalui pendekatan interpretasi visual berbasis Sistem Informasi Geografis (SIG). Proses ini dimulai dengan menggunakan data poligon Wilayah

Administrasi Kelurahan/Desa (WADMKD) sebagai batas dasar analisis dalam wilayah DKI Jakarta. Menggunakan perangkat lunak QGIS, poligon WADMKD tersebut kemudian dipotong dan disegmentasi menjadi unit-unit yang lebih kecil berdasarkan homogenitas karakteristik penggunaan lahan yang diamati.

Proses klasifikasi manual dilakukan melalui interpretasi visual terhadap citra satelit resolusi tinggi dengan mengacu pada kriteria klasifikasi penggunaan lahan yang telah ditetapkan. Setiap segmen poligon yang dihasilkan dari proses pemotongan kemudian diberikan label kelas penggunaan lahan berdasarkan karakteristik dominan yang teramati dalam area tersebut. Validasi visual dilakukan untuk memastikan konsistensi dan akurasi pemberian label, dengan menggunakan pendekatan triangulasi data melalui perbandingan dengan sumber referensi tambahan.

Pengumpulan data citra satelit bersumber dari Google Maps API dengan menggunakan poligon yang telah diklasifikasi secara manual sebagai referensi geometri. Pemanfaatan Google Maps API bertujuan memastikan konsistensi resolusi spasial sebesar 0,6 meter pada seluruh sampel data. Resolusi tersebut tergolong dalam kategori resolusi sangat tinggi yang memungkinkan identifikasi detail penggunaan lahan dengan tingkat akurasi mencapai 79,40% (Zahidi et al., 2015).

Sistem referensi koordinat yang digunakan adalah WGS84 untuk menjamin keselarasan spasial yang tepat antara data vektor poligon dan data raster citra satelit. Validasi data dilakukan melalui eliminasi poligon yang tidak valid atau mengandung nilai yang hilang guna mempertahankan kualitas dataset pelatihan. Kontrol kualitas data meliputi verifikasi geometri poligon, konsistensi sistem koordinat, dan kelengkapan atribut klasifikasi untuk memastikan integritas dataset pelatihan.

Proses ini dilakukan dengan mengubah poligon menjadi gambar berukuran 640×640 piksel yang nantinya digunakan sebagai input untuk *deep learning*. Gambar tersebut juga ditransformasikan sesuai dengan sistem referensi koordinat yang digunakan serta disesuaikan dengan poligon batas dari area yang diinginkan. Dilakukan standarisasi gambar melalui operasi *padding* dengan *zero-fill* untuk mencapai dimensi 640×640 piksel yang konsisten. Standarisasi ini mencakup normalisasi nilai piksel menggunakan parameter ImageNet,

mean:[0.485, 0.456, 0.406] (1)

standar deviasi:[0.229, 0.224, 0.225] (2)

dan penerapan *masking* poligon untuk mengisolasi area penggunaan lahan dari background yang tidak relevan. Proses standarisasi ini memastikan format input yang seragam untuk arsitektur ResNet-50 dan meningkatkan kualitas pelatihan model.

Proses perancangan arsitektur *deep learning* yang akan digunakan dalam proses pemodelan dilakukan dengan ResNet-50 yang dapat mengklasifikasikan gambar dengan menyeimbangkan kompleksitas model. Dalam proses ini, ImageNet dimanfaatkan untuk dapat memberikan klasifikasi awal dalam melakukan generalisasi data masukan. Data tersebut kemudian melalui proses augmentasi untuk dapat memodifikasi gambar. Proses augmentasi data tersebut dapat meningkatkan akurasi pada proses *transfer learning* yang sebelumnya dilakukan (Shi et al., 2025).

Dalam proses perancangan, sistem yang digunakan adalah *supervised learning* yang nantinya akan melatih model dengan menggunakan data berlabel. Kinerja model nantinya dievaluasi melalui metrik klasifikasi standar termasuk akurasi, *precision*, *recall*, dan *F1-score*. Setelah melakukan pelatihan terhadap data, dilakukan pelatihan dengan mengonversi model PyTorch ke dalam format Open Neural Network Exchange (ONNX) untuk mendapatkan hasil yang optimal. Hal ini dilakukan untuk meningkatkan *deployment flexibility* dan *inference efficiency*. Proses konversi ONNX dapat menghilangkan ketergantungan terhadap satu kerangka kerja dengan tetap mempertahankan tingkat akurasi dan menghasilkan prediksi yang mendekati model aslinya. Dalam pelatihan, digunakan rasio antara data latih dan data uji sebesar 80:20 untuk memastikan bahwa model memiliki keseimbangan statistik dalam enam klasifikasi penggunaan lahan.

Pelatihan tersebut berlangsung selama 39 epoch dengan implementasi *early stopping mechanism* apabila terdapat stagnansi akurasi validasi selama 20 epoch berturut-turut. Mekanisme tersebut dapat menurunkan *validation loss* sehingga akurasi validasi meningkat. Hal tersebut menunjukkan bahwa *overfitting* dapat dicegah sebelum adanya generalisasi pada *validation set*. Proses optimalisasi model juga mencakup validasi model untuk memastikan konsistensi antara implementasi PyTorch dan ONNX yang dikonversi melalui pengujian inferensi komparatif pada sampel input yang identik. Hal pengujian tersebut akan menunjukkan *performance metrics* yang digunakan untuk mengevaluasi kinerja *machine learning* melalui tinjauan kesesuaian penerapan.

Proses evaluasi model dilakukan dengan melakukan pendekatan komprehensif dari data poligon GeoJSON. Evaluasi ini dilakukan dengan melakukan pengujian pada tiap data poligon melalui model ONNX yang telah dilatih untuk menghasilkan prediksi klasifikasi penggunaan lahan. Proses evaluasi memastikan bahwa kinerja model yang dihasilkan sesuai dengan kriteria yang ditentukan dan tetap relevan sehingga dapat menunjukkan akurasi dari hasil klasifikasi. Proses evaluasi dapat menghasilkan tingkat kepercayaan dari seluruh hasil klasifikasi. Tingkat kepercayaan tersebut dapat menunjukkan estimasi kebenaran dari hasil prediksi. Untuk memahami performa model secara mendalam, perlu dijelaskan tiga metrik penting, yaitu *precision*, *recall*, dan *F1-score*. *Precision* mengukur ketepatan prediksi model, yaitu dari seluruh area yang diprediksi sebagai kategori tertentu, berapa persen yang benar-benar sesuai kategori tersebut. Sementara *recall* mengukur kelengkapan deteksi model, yaitu dari seluruh area yang seharusnya masuk kategori tertentu, berapa persen yang berhasil teridentifikasi dengan benar oleh model.

F1-score merupakan harmonic mean antara *precision* dan *recall* yang memberikan nilai tunggal untuk mengevaluasi performa keseluruhan model pada setiap kategori. *F1-score* sangat berguna ketika terdapat trade-off antara *precision* dan *recall*, dimana peningkatan salah satu metrik dapat menurunkan metrik lainnya. Nilai *F1-score* mendekati 1.0 menunjukkan bahwa model memiliki keseimbangan optimal antara ketepatan dan kelengkapan klasifikasi. Dalam konteks penilaian properti, *precision* tinggi berarti sedikit kesalahan klasifikasi yang dapat menyesatkan penilai, *recall* tinggi berarti model tidak melewatkan banyak area yang seharusnya masuk kategori tersebut, dan *F1-score* tinggi menunjukkan model yang dapat diandalkan untuk kedua aspek tersebut. Proses evaluasi juga menghasilkan berupa hasil klasifikasi, *confusion matrix* dengan visualisasi *heatmap*, statistik kinerja, dan analisis terperinci pada tiap klasifikasinya untuk memastikan bahwa kinerja model termasuk dalam kategori baik.

Hasil dan Pembahasan

Dalam tahap akuisisi data, penelitian ini melakukan ekstraksi dengan menghasilkan 1506 poligon data yang terdistribusi dalam enam klasifikasi penggunaan lahan di DKI Jakarta. Data ini kemudian melalui proses pembersihan yang hasilnya dikonversi menjadi citra 640×640 piksel. Data kemudian dibagi menggunakan *stratified sampling* dengan rasio 80:20 yang menghasilkan 1.151 sampel untuk pelatihan dan 288 sampel untuk validasi dengan tetap mempertahankan proporsi setiap kategori dalam kedua subset. Berikut adalah hasil distribusi data pada tiap klasifikasi penggunaan lahan.

Tabel 1. Distribusi Data Berdasarkan Klasifikasi Penggunaan Lahan

Kategori	Jumlah
Hijau	83 (5,8%)
Kumuh-	562 (39,1%)
Menengah – Menengah Atas	270 (18,8%)
Premium	153 (10,6%)
Industri	122 (8,5%)
Komersial	249 (17,3%)




Gambar 3. Sampel Gambar untuk Setiap Kategori

Sebelum melakukan pelatihan model, dilakukan tinjauan terhadap ketidakseimbangan data pada tiap kelasnya sehingga dilakukan penerapan *Weighted Cross Entropy Loss* secara inversely proportional terhadap jumlah sampel. Klasifikasi dengan jumlah data paling sedikit, yaitu kelas 1 mendapatkan bobot tertinggi (2,91). Di sisi lain, kategori dengan data terbanyak, yaitu kelas 6 mendapatkan bobot terendah (0,50). Hasil dari pembobotan tersebut dapat menyeimbangkan distribusi bobot pada tiap kelas, yaitu kelas 3 (0,89), kelas 4 (1,57), kelas 5 (1,96), dan kelas 6 (0,96). Proses tersebut terbukti dapat meningkatkan performa model dengan distribusi yang kurang seimbang.

Setelah didapatkan distribusi data yang proporsional, maka selanjutnya dilakukan pelatihan model. Pelatihan model menghasilkan validasi akurasi tertinggi sebesar 87,15% yang menunjukkan kemampuan model dalam mengklasifikasikan penggunaan lahan dengan benar pada 87 dari setiap 100 area yang diuji. Akurasi akhir sebesar 84,72% mengindikasikan bahwa model dapat mempertahankan performa yang stabil dan konsisten dalam mengidentifikasi kategori penggunaan lahan.

Tingkat akurasi yang tinggi ini memiliki implikasi praktis yang signifikan bagi penilai properti, dimana model dapat memberikan klasifikasi awal yang reliabel untuk lebih dari 8 dari 10 area yang dinilai. Hal ini berarti penilai dapat mengandalkan prediksi sistem sebagai *foundation assessment* yang kuat, sehingga waktu dan tenaga dapat dialokasikan untuk verifikasi dan *fine-tuning* hasil klasifikasi daripada memulai proses identifikasi dari nol. Semakin tinggi akurasi model, semakin sedikit intervensi manual yang diperlukan dalam proses penilaian massal, yang berkontribusi pada efisiensi dan konsistensi hasil penilaian




Gambar 4. Kurva Hasil Pelatihan dan Validasi (Tingkat Akurasi dan Kesalahan)

Berdasarkan hasil model yang dilatih, didapatkan tingkat akurasi keseluruhan sebesar 92% dengan *F1-score* rata-rata sebesar 0.90. Nilai tersebut menunjukkan bahwa kemampuan model sudah baik dalam proses klasifikasi penggunaan lahan dengan tingkat akurasi yang konsisten. Hasil klasifikasi juga menunjukkan bahwa kategori permukiman kumuh mencapai *F1-score* tertinggi (0,96) dan kategori Menengah-Menengah Atas memiliki *F1-score* terendah (0,86). Nilai tersebut menunjukkan bahwa terdapat tingkat kompleksitas yang berbeda dalam mengidentifikasi karakteristik visual setiap kategori penggunaan lahan. Hasil klasifikasi juga menunjukkan bahwa untuk kategori Hijau, nilai *recall* didapatkan sangat tinggi, yaitu 0,97 dengan nilai *precision* yang lebih rendah yaitu 0,81. Nilai tersebut menunjukkan adanya kecenderungan model untuk mengklasifikasikan area lain sebagai hijau. Di sisi lain, kategori Industri dan Komersial menunjukkan keseimbangan yang baik antara *precision* dan *recall* dengan *F1-score* masing-masing 0,92 dan 0,90.

Secara keseluruhan, nilai Weighted Average pada model mencapai 0,92 untuk *precision*, *recall*, dan *F1-score*. Nilai tersebut mengonfirmasi konsistensi performa model meskipun terdapat ketidakseimbangan distribusi kelas dalam data. Selain itu, didapatkan *Macro Average* sebesar 0,90 yang menunjukkan bahwa model mampu mempertahankan performa yang relatif stabil di seluruh kategori tanpa bias yang signifikan terhadap kelas mayoritas.

Tabel 2. *Precision, Recall, F1-Score per Kategori*

	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>Support</i>
Hijau	0,81	0,97	0,89	80
Kumuh-	0,98	0,95	0,96	585
Menengah -	0,92	0,80	0,86	295
Menengah Atas				
Premium	0,87	0,89	0,88	157
Industri	0,89	0,95	0,92	132
Komersial	0,85	0,95	0,90	256
Akurasi			0,92	1505
<i>Macro Average</i>	0,89	0,92	0,90	1505
<i>Weighted Average</i>	0,92	0,92	0,92	1505



Gambar 5. *Confusion Matrix*

Setelah didapatkan kinerja model, dilakukan analisis *confusion matrix* untuk mengevaluasi hasil yang didapatkan. Analisis ini dapat menunjukkan pola kesalahan antar klasifikasi antar kategori. Berikut adalah hasil matriks tersebut.

Matriks di atas menunjukkan bahwa kesalahan paling umum terjadi pada kategori Menengah-Menengah Atas dengan total kasus kesalahan kalkulasi sebanyak 19,66% dari total data. Hal ini dapat

terjadi karena adanya kecenderungan kesamaan karakteristik spektral dan tekstural antara klasifikasi tersebut dengan yang lain. Untuk klasifikasi hijau, terdapat kecenderungan kesalahan kalkulasi akibat adanya tumpang tindih karakteristik visual pada area dengan vegetasi yang tersebar. Pada prediksi ini, performa dari klasifikasi kumuh dikategorikan dalam tingkat sangat baik dengan hanya 30 dari 615 prediksi yang salah. Untuk kategori premium dan industri, tingkat kesalahan prediksi juga rendah dengan Premium memiliki 139 prediksi benar dari 157 total dan Industri 125 prediksi benar dari 132 total. Hal ini menunjukkan bahwa kedua kategori memiliki karakteristik visual yang cukup unik untuk diidentifikasi dengan akurat oleh model.

Berdasarkan hasil prediksi, didapatkan bahwa tingkat kepercayaan rata-rata prediksi benar yang dihasilkan oleh model yaitu 0,918. Di sisi lain, untuk tingkat kepercayaan rata-rata prediksi yang salah sebesar 0,652. Perbedaan sebesar 0,266 tersebut menunjukkan bahwa model memiliki kemampuan *uncertainty estimation* yang baik. Model menunjukkan kemampuan yang konsisten dalam mengidentifikasi karakteristik visual penggunaan lahan dari citra satelit. Sebagai contoh, ketika model menganalisis citra area permukiman dengan tingkat kepercayaan 0,95, sistem dapat mengidentifikasi pola bangunan, kepadatan struktur, dan tata letak yang khas untuk kategori normal premium. Sebaliknya, pada area transisi antara zona industri dan komersial dengan *confidence score* 0,68, model menunjukkan ketidakpastian yang mencerminkan kompleksitas visual area tersebut.

Dalam konteks penilaian properti, kemampuan diskriminasi visual ini memungkinkan penilai untuk memahami dasar klasifikasi yang dihasilkan model. Area dengan kepercayaan tinggi ($>0,85$) umumnya memiliki karakteristik penggunaan lahan yang jelas dan homogen, sehingga dapat diterima dengan review minimal. Sementara area dengan kepercayaan rendah ($<0,75$) menunjukkan adanya ambiguitas visual yang memerlukan investigasi lapangan atau analisis tambahan dari penilai. Rata-rata tingkat kepercayaan secara keseluruhan yang dihasilkan adalah 0,896 yang menunjukkan bahwa hasil prediksi yang dibuat oleh model memiliki tingkat akurasi yang tinggi dengan kemungkinan benar sebesar 89,6%. Tingkat akurasi yang didapatkan oleh hasil prediksi memenuhi *threshold-based filtering* dengan nilai tingkat kepercayaan di atas *threshold*, yaitu 0,75-0,80. Hal ini menunjukkan bahwa hasil prediksi dapat diterima sehingga dianggap efektif dalam melakukan analisis spasial untuk mendapatkan klasifikasi penggunaan lahan menggunakan citra satelit, dengan reliabilitas yang memadai untuk mendukung proses penilaian properti profesional.

Pengembangan model klasifikasi penggunaan lahan melalui implementasi teknologi dapat mendukung praktik penilaian. Implementasi yang memanfaatkan kemampuan *deep learning* dalam melakukan otomatisasi proses identifikasi dan klasifikasi penggunaan lahan melalui analisis citra satelit resolusi tinggi dapat menggantikan metode penilaian manual yang memerlukan waktu dan sumber daya intensif. Dalam konteks penilaian aset, model ini memungkinkan pengguna untuk melakukan valuasi properti dan lahan secara objektif berdasarkan kategori penggunaan lahan yang teridentifikasi. Sistem dapat mengklasifikasikan area menjadi kategori hijau, kumuh-padat, menengah-menengah atas, premium, industri, dan komersial dengan tingkat akurasi tinggi sehingga dapat memberikan dasar yang solid untuk penentuan nilai aset berdasarkan karakteristik penggunaan lahan aktual. Berikut adalah contoh hasil klasifikasi penggunaan lahan.

Polygon 1: premium (98.6% confidence)



Polygon 2: komersial (98.2% confidence)



Gambar 6. Contoh Hasil Klasifikasi Penggunaan Lahan

Gambar di atas menunjukkan bahwa tingkat akurasi pada hasil klasifikasi berada pada nilai yang tinggi yang menunjukkan bahwa model sudah cukup andal. Area di Kelurahan Pondok Pinang, Kecamatan Kebayoran Lama dapat terbaca sebagai kawasan permukiman premium dengan kemungkinan akurasi hasil di angka 98,6%. Begitu pula untuk area SCBD di Kelurahan Senayan, Kecamatan Kebayoran Baru yang dibaca sebagai daerah komersial dengan kemungkinan akurasi hasil di angka 98,2%. Akurasi tersebut didapatkan dari pembacaan model terhadap pola spasial dan spektral data poligon yang ingin diprediksi. Implementasi teknologi ini memungkinkan dilakukannya analisis area dalam waktu singkat yaitu sekitar 1 detik untuk area kecil dan sekitar 5 detik untuk area yang luas. Selain itu, model yang sudah dioptimalkan dalam format ONNX tersebut dapat digunakan di berbagai platform sehingga proses penilaian digital lebih mudah diakses oleh pengguna. Model ini juga mendukung adanya masukan data seiring dengan penambahan data latih berdasarkan temuan secara kontinyu sehingga tingkat akurasi penilaian semakin baik seiring dengan meningkatnya akurasi model. Hal ini sejalan dengan tren digitalisasi pada sektor properti dan perencanaan kota yang memanfaatkan teknologi untuk meningkatkan akurasi dan efisiensi proses.

Penelitian ini memberikan kontribusi ilmiah dalam tiga dimensi utama. Pada aspek metodologis, penelitian ini mengembangkan pipeline klasifikasi penggunaan lahan berbasis citra satelit resolusi tinggi yang terstruktur, mulai dari proses labeling berbasis poligon, standarisasi citra, hingga implementasi model ResNet-50 yang dioptimalkan melalui teknik transfer learning dan konversi ONNX. Pendekatan ini menunjukkan keunggulan dalam hal efisiensi komputasi dan fleksibilitas implementasi dibandingkan metode konvensional.

Dalam hal kontribusi praktis, hasil penelitian menunjukkan bahwa model mampu mencapai akurasi hingga 92% dengan waktu inferensi yang sangat cepat ($\pm 1-5$ detik per area). Hal ini mengindikasikan potensi penghematan waktu yang signifikan dalam proses penilaian massal, serta pengurangan kesalahan akibat subjektivitas manusia dalam klasifikasi penggunaan lahan. Dari sudut pandang konseptual, penelitian ini mengembangkan hubungan antara klasifikasi penggunaan lahan dan penilaian properti dengan mengaitkan hasil klasifikasi terhadap konsep *highest and best use (HBU)* dan segmentasi pasar. Dengan demikian, klasifikasi tidak hanya berfungsi sebagai output teknis, tetapi sebagai variabel yang memiliki implikasi langsung terhadap pembentukan nilai

properti. Integrasi ketiga aspek tersebut menjadikan penelitian ini tidak hanya relevan dalam bidang kecerdasan buatan, tetapi juga memberikan kontribusi nyata dalam pengembangan ilmu penilaian aset.

Kesimpulan

Penelitian ini mengembangkan sistem klasifikasi penggunaan lahan otomatis berbasis deep learning yang memberikan solusi transformatif bagi praktik penilaian properti di Indonesia. Dengan mencapai akurasi 92%, sistem ini memungkinkan penilai untuk mengoptimalkan alur kerja penilaian melalui pendekatan hybrid yang menggabungkan kecerdasan buatan dengan pihak profesional penilai. Adanya implementasi teknologi ini secara signifikan mengubah peran penilai dari pelaksana klasifikasi manual menjadi reviewer yang memfokuskan keahliannya pada validasi dan interpretasi hasil. Penilai tidak lagi perlu memulai proses identifikasi penggunaan lahan dari nol, melainkan dapat langsung melakukan evaluasi verifikasi klasifikasi yang telah dihasilkan sistem. Dengan adanya penerapan teknologi ini, alokasi waktu dan tenaga dapat lebih efisien untuk digunakan aspek penilaian yang memerlukan pertimbangan profesional, seperti analisis faktor penyesuaian nilai dan interpretasi kondisi pasar lokal.

Penerapan teknologi ini memiliki peluang pengembangan yang luas. Meskipun data pelatihan terbatas pada wilayah DKI Jakarta, metodologi yang dikembangkan memiliki potensi adaptasi untuk region lain dengan karakteristik wilayah serupa. Seiring dengan perkembangan masukan data yang dapat ditambahkan, hasil prediksi yang dihasilkan dapat semakin efisien dan dapat mencakup wilayah yang lebih beragam. Penilai nantinya dapat memanfaatkan kerangka kerja ini sebagai sebuah landasan yang dapat disesuaikan dengan kondisi geografis dan karakteristik pasar lokal. Sistem yang digunakan dalam penelitian ini juga menggunakan analisis tingkat confidence score yang dapat memberikan mekanisme quality control sehingga membantu penilai untuk mengidentifikasi area yang memerlukan verifikasi lebih mendalam. Hasil akurasi 92% yang dicapai model, didukung oleh F1-score rata-rata 0,90 dan area-weighted accuracy 95,85%, menunjukkan tingkat reliabilitas yang sangat memadai untuk implementasi operasional dalam praktik penilaian properti. Konsistensi performa ini terbukti dari weighted average precision, recall, dan F1-score yang mencapai 0,92, mengkonfirmasi bahwa model dapat diandalkan meskipun menghadapi ketidakseimbangan data yang signifikan.

Tingkat akurasi yang tinggi ini memberikan kepercayaan bahwa sistem dapat menghasilkan klasifikasi awal yang reliabel untuk lebih dari 9 dari 10 area yang dinilai. Dengan tingkat confidence score yang menunjukkan perbedaan signifikan antara prediksi benar (0,918) dan salah (0,652), model membuktikan kemampuan untuk bekerja secara otomatis yang memungkinkan penilai untuk memprioritaskan review pada area dengan tingkat kompleksitas tinggi. Ke depannya, hasil akurasi dan reliabilitas model yang telah tervalidasi ini mendukung implementasi penilaian masal yang efisien dengan tetap mempertahankan standar akurasi profesional. Model yang terbukti dapat diandalkan ini sejalan dengan tuntutan digitalisasi sektor penilaian aset dalam mendukung pembangunan berkelanjutan yang berbasis data objektif dan terukur, memberikan pondasi teknologi yang solid untuk transformasi praktik penilaian properti di Indonesia.

Ucapan Terima Kasih

Kami mengucapkan terima kasih yang sebesar-besarnya kepada Fauzan Favian S.T., M.Sc. dan Indera Ihsan, S.Kom., atas masukan, dan dukungannya dalam menyelesaikan penelitian ini.

Daftar Pustaka

Abbas, S., Almadhor, A., Sampedro, G. A., Alsubai, S., Hejaili, A. A., Strážovská, L., & Zaidi, M. M. (2024). Efficient geospatial mapping of buildings, woodlands, water and roads from aerial imagery

- using deep learning. *PeerJ Computer Science*, 10, e2039. <https://doi.org/10.7717/peerj-cs.2039>
- Purnawan, A., & Tamaji, M. . (2025). Penerapan Metode Deep Learning Mask R-Cnn Untuk Identifikasi Bangunan Baru Sebagai Objek Pajak Di Desa. *Jurnal Sistem Cerdas Dan Rekayasa (JSCR)*, 7(2), 1–8. <https://doi.org/https://doi.org/10.61293/jscr.v7i2.857>
- Bergadano, F., Bertilone, R., Paolotti, D., & Ruffo, G. (2021). Learning Real Estate Automated Valuation Models from Heterogeneous Data Sources. *International Journal of Real Estate Studies*, 15(1), 72–85. <https://doi.org/10.11113/intrest.v15n1.10>
- Helber, P., Bischke, B., Dengel, A., & Borth, D. (2019). EuroSAT: A Novel Data and Deep Learning Benchmark for Land Use and Land Cover Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(7), 2217–2226. <https://doi.org/10.1109/JSTARS.2019.2918242>
- Jafary, P., Shojaei, D., Rajabifard, A., & Ngo, T. (2024). Automated land valuation models : A comparative study of four machine learning and deep learning methods based on a comprehensive range of influential factors. *Cities*, 151, 105115. <https://doi.org/10.1016/j.cities.2024.105115>
- Jahanshiri, E., Buyong, T., & Shariff, A. R. M. (2011). A Review of Property Mass Valuation Models. *Pertanika Journal of Science and Technology*, 19(S), 23–30.
- Januari, A. D. W. I., Rusdayanti, N., Kardian, S., & Shara, S. (2024). Sustainable Transportation and Urban Mobility Urbanisasi Jakarta dan dampaknya terhadap sosial ekonomi dan lingkungan. *STUM Sustainable Transportation and Urban Mobility*, 1(1), 21–37.
- Zhou, K., Ming, D., Xianwei, J. F. & Wang, M. (2019). CNN-Based Land Cover Classification Combining Stratified Segmentation and Fusion of Point Cloud and Very High-Spatial Resolution Remote Sensing Image Data. *Remote Sensing*, 11(17), 1–28. <https://doi.org/https://doi.org/10.3390/rs11172065>
- Li, R., Zheng, S., Duan, C., Wang, L., & Zhang, C. (2022). Land cover classification from remote sensing images based on multi-scale fully convolutional network. *Geo-Spatial Information Science*, 25(2), 278–294. <https://doi.org/10.1080/10095020.2021.2017237>
- Lillesand, T., Kiefer, R. W., & Chipman, J. (2015). *Remote Sensing and Image Interpretation*. John Wiley & Sons.
- Pamungkas, G. B., Firmansyah, M. R., Sari, R., Tamara, A. P., & Zainul, R. (2025). Land Cover Classification of Indonesian Archipelago Using Digital Spectroscopy to Support Spatial Planning in Indonesia. *Geoplanning: Journal of Geomatics and Planning*, 12(1), 57–68. <https://doi.org/10.14710/geoplanning.12.1.57-68>
- Parhusip, H. A., & Trihandaru, S. (2025). Automated Property Valuation with Multi-Hazard Risk : Jakarta Metropolitan Area Study. *Jurnal Teknik Informatika*, 6(5), 3136–3152. <https://doi.org/https://doi.org/10.52436/1.jutif.2025.6.5.5236>
- Rienow, A. (2016). *The future of central european cities – optimization of a cellular automaton for the spatially explicit prediction of urban sprawl*. <https://doi.org/10.5772/62424>
- Sarmast, Z., Shokouhyar, S., Ghanadpour, S., & Shokoohyar, S. (2023). Unravelling the potential of social media data analysis to improve the warranty service operation. *Industrial Management & Data Systems*, 123(5), 1281–1309. <https://doi.org/10.1108/imds-07-2022-0427>
- Shi, T., Yu, J., Hu, Z., & Jiang, K. (2025). Improved Method of ResNet50 Image Classification Based on Transfer Learning. *International Journal of Advanced Network, Monitoring and Controls*, 10(2), 1–9. <https://doi.org/10.2478/ijanmc-2025-0011>
- Siewert, J., & Kroszczyński, K. (2023). Evaluation of High-Resolution Land Cover Geographical Data for the WRF Model Simulations. *Remote Sensing*, 15(9), 2389. <https://doi.org/10.3390/rs15092389>
- Savitri, R. & Fransiska, E. (2022). Analisis Kesesuaian Penggunaan Lahan Terhadap Rencana Detail

- Tata Ruang (Rdtr) Dki Jakarta Kelurahan Pulo Gebang , Kecamatan Cakung. *Jurnal Ilmiah Plano Krisna*, 18, 28–45.
- Wang, E., Jiang, Y., Li, Y., Yang, J., Ren, M., & Zhang, Q. (2019). Mfcsnet: multi-scale deep features fusion and cost-sensitive loss function based segmentation network for remote sensing images. *Applied Sciences*, 9(19), 4043. <https://doi.org/10.3390/app9194043>
- Xie, Y., Wang, Y., Kandeepan, S., & Wang, K. (2022). Machine learning applications for short reach optical communication. *Photonics*, 9(1), 30. <https://doi.org/10.3390/photonics9010030>
- Zahidi, I., Yusuf, B., Hamedianfar, A., Shafri, H. Z. M., & Mohamed, T. A. (2015). Object-based classification of QuickBird image and low point density LIDAR for tropical trees and shrubs mapping. *European Journal of Remote Sensing*, 48(1), 423–446. <https://doi.org/10.5721/EuJRS20154824>
- Zhang, C., Sargent, I., Pan, X., Li, H., Gardiner, A., Hare, J., & Atkinson, P. M. (2018). An Object-Based Convolutional Neural Network (OCNN) for Urban Land Use Classification. *Remote Sensing of Environment*, 216, 57–70. <https://doi.org/10.1016/j.rse.2018.06.034>
- Zheng, W., & Wang, M. (2023). Three-Dimensional Land-Use Configuration and Property Prices: A Spatially Filtered Multi-Level Modelling Perspective. *Environment and Planning B: Urban Analytics and City Science*, 51(2). <https://doi.org/10.1177/23998083231180213>