

## Pembuatan Model Prediksi Lahan Terbangun di Kabupaten Kulon Progo dengan Citra Satelit Penginderaan Jauh

*Development A Prediction Model for Built-up Land in Kulon Progo Regency with Remote Sensing Satellite Imagery*

Rifqi Alghifari Wibowo, Harintaka\*

Departemen Teknik Geodesi, FT UGM, Yogyakarta, 55281, Indonesia

\*Korespondensi penulis: harintaka@ugm.ac.id

Diterima: 10072023; Diperbaiki:14082023; Disetujui:06092023; Dipublikasi: 08092023

**Abstrak:** Perubahan tutupan lahan terbangun pada kota atau kabupaten menjadi suatu hal umum yang sering terjadi dan terus berkembang di kawasan yang cepat tumbuh. Perkembangan lahan terbangun tersebut dapat diprediksi dengan melakukan pembuatan model prediksi dengan menggunakan teknologi penginderaan jauh dan sistem informasi geografis. Pada kajian ini, dilakukan pemodelan prediksi tutupan lahan di wilayah Kabupaten Kulon Progo pada tahun 2023 dengan menggunakan metode Cellular Automata (CA). Model prediksi tersebut disusun dengan hasil klasifikasi tutupan lahan pada tahun 2017 dan 2020 dengan menggunakan algoritma Support Vector Machine (SVM) dan variabel spasial berupa jangkauan jalan terhadap lahan terbangun. Model prediksi lahan terbangun yang berhasil dimodelkan memiliki pola persebaran dimana kelas daerah bervegetasi banyak mendominasi di Kapanewon Kokap, Girimulyo, Samigaluh, dan Kalibawang. Untuk Kapanewon lain lebih didominasi oleh tutupan lahan pertanian dan lahan terbangun. Berkaitan dengan itu, luasan tutupan lahan untuk masing-masing kelas meliputi lahan terbangun dengan 7.353,84 ha, badan air dengan 440,59 ha, daerah bervegetasi dengan 29.273,71 Ha, lahan pertanian dengan 17.665,76 ha, dan lahan terbuka dengan 2.920,24 ha. Di samping itu, untuk nilai akurasi tutupan lahan terbangun pada model prediksi memiliki nilai *producer's accuracy* dan *user's accuracy* secara berturut-turut sebesar 89% dan 76%. Adapun secara keseluruhan model prediksi ini mendapatkan nilai *overall accuracy* dan Indeks Kappa berturut-turut sebesar 81% dan 0,75. Berdasarkan nilai tersebut, model prediksi memiliki nilai akurasi yang cukup baik dan dapat digunakan sebagai salah satu alternatif untuk menjadi acuan dalam melihat potensi perubahan yang terjadi di masa yang akan datang.

*Copyright © 2023 Geoid. All rights reserved.*

**Abstract:** Changes of land cover in built-up area have become a common occurrence and have the potential to continue rapidly in developing towns. The development of built-up area can be predicted by utilizing a prediction model using remote sensing technology and geographic information system. In this study, a prediction model for land cover in the Kulon Progo Regency in 2023 was developed using the Cellular Automata method. The prediction model was constructed based on the classification results of land cover in 2017 and 2020 using Support Vector Machine (SVM) algorithm and spatial variables such as road network in built-up area. A prediction model for built-up land shows a distribution pattern where the vegetation class dominates in Kapanewon (Subdistrict) Kokap, Girimulyo, Samigaluh, and Kalibawang. Other Kapanewons are predominantly characterized by agricultural land and built-up land. In terms of land cover area, built-up land covers an area of 7,353.84 hectares, water bodies cover 440.59 hectares, vegetation covers 29,273.71 hectares, agricultural land covers 17,665.76 hectares, and open land covers 2,920.24 hectares. Furthermore, the accuracy of built-up land cover in the prediction model has producer's accuracy and user's accuracy of 88.889% and 76.190% respectively. Overall, the prediction model achieves an overall accuracy and Kappa Index of 81 % and 0.75 respectively. Based on these values, it is known that the prediction model has good accuracy. Therefore, the development of this prediction model is still suitable as a reference for assessing potential changes that will occur in the future.

Kata kunci: Model Prediksi; Lahan Terbangun; Kulon Progo; Citra Satelit Penginderaan Jauh

Cara untuk sitasi: Wibowo, R.A., Harintaka. (2023). Pembuatan Model Prediksi Lahan Terbangun di Kabupaten Kulon Progo dengan Citra Satelit Penginderaan Jauh. *Geoid*, 19(1), 18 – 27.

## Pendahuluan

Perkembangan kota atau kabupaten memiliki sifat yang dinamis atau berubah-ubah setiap waktunya. Fenomena ini memiliki daya tarik tersendiri, karena fenomena ini akan selalu mengubah kenampakan dari suatu wilayah (Fuglsang dkk., 2013). Perubahan yang semakin mencirikan sebuah perkotaan dapat menjadi daya tarik bagi para penduduk untuk mencari pekerjaan dan menetap di wilayah tersebut. Perubahan ini merujuk pada istilah urbanisasi yakni perubahan suatu wilayah menjadi daerah perkotaan (Fitri, 2013). Fenomena urbanisasi ini dapat berakibat pada peristiwa *urban sprawl*. *Urban sprawl* sendiri terjadi akibat dari laju urbanisasi yang tidak terkontrol, karena kurangnya pemantauan pemerintah dalam merencanakan pembangunan di suatu wilayah.

Perubahan penggunaan lahan tersebut dapat dilihat melalui tutupan lahan yang ada pada wilayah kota atau kabupaten. Salah satu tutupan lahan yang marak terjadi pada perkembangan kota atau kabupaten adalah lahan terbangun. Lahan terbangun merupakan lahan yang telah menghadapi tahapan pembangunan atau perkerasan yang terjadi di atas lahan (Yuliasuti dkk., 2012). Perubahan tutupan lahan terbangun ini menjadi suatu hal umum yang sering terjadi di kota kecil cepat tumbuh yang berada di dekat kota besar, seperti Kabupaten Kulon Progo. Kabupaten Kulon Progo mengalami pertumbuhan yang cepat karena adanya faktor eksternal dan faktor internal. Faktor eksternal ini muncul karena adanya tekanan dari kota besar yang terus-menerus melebarkan aktivitasnya (Setyono dkk., 2017). Selain itu menurut Mardiansyah (2011), faktor internal dari pesatnya pertumbuhan ini dikarenakan maraknya kegiatan-kegiatan yang mencirikan suatu perkotaan.

Perubahan lahan terbangun di Kabupaten Kulon Progo dapat dianalisis menggunakan citra penginderaan jauh Sentinel-2 yang telah dilakukan klasifikasi tutupan lahan dengan algoritma *Support Vector Machine* (SVM) pada tahun 2017 dan 2020. Pada penggunaan data multispektral dan resolusi spasial rendah serta menengah, algoritma SVM menunjukkan rata-rata akurasi yang tinggi, sehingga algoritma ini dipilih. Citra Sentinel-2 dipilih dikarenakan memiliki resolusi spasial sebesar 10-meter yang tergolong menengah. Rentang waktu tersebut dipilih agar dapat dilihat perubahan penggunaan lahan yang signifikan. Rentang waktu ini meliputi mulai dibangunnya Kawasan Bandara *New Yogyakarta International Airport* (NYIA) hingga kawasan tersebut beroperasi sepenuhnya yang dapat menjadi salah satu faktor berubahnya penggunaan lahan di Kabupaten Kulon Progo.


Hasil klasifikasi tutupan lahan tersebut dapat dimanfaatkan untuk melakukan prediksi terhadap sebaran dan luasan lahan terbangun pada waktu mendatang dengan algoritma *Cellular Automata* (CA) – *Artificial Neural Network* (ANN). Algoritma CA-ANN melibatkan beberapa komponen yakni sel pada keadaan awal, kondisi ketetangan, dan aturan transisi tertentu dalam menyimulasikan model pada waktu tertentu. Prinsip CA tersebut dimodifikasi dan diterapkan dengan menggunakan aturan transisi dalam bentuk model probabilitas transisi. Model probabilitas transisi tersebut tersusun atas perubahan tutupan lahan pada dua tahun kajian sebelumnya yakni 2017 dan 2020, serta faktor pendukung penyebab perubahan tutupan lahan terjadi. Hal ini berarti CA dapat memprediksi lahan terbangun di masa mendatang dengan menggunakan hasil klasifikasi tutupan lahan pada tahun sebelumnya. Selain itu, dilibatkan pula data pendukung perubahan tutupan lahan terbangun saat pembuatan model prediksi seperti jalan yang menjadi salah satu indikator pembangunan infrastruktur.

Marsoedy (2020) melakukan prediksi perubahan penggunaan lahan di Kabupaten Sleman. Pada penelitiannya, digunakan algoritma *maximum likelihood* untuk klasifikasi tutupan lahan dan digunakan *plugin* MOLUSCE untuk melakukan simulasi model prediksi. Hasil kajian menunjukkan Kappa sebesar 0,6 yang tergolong pada kategori menengah. Fardani dkk. (2020) melakukan kajian perubahan dan prediksi dari tutupan lahan di suatu daerah dan dimanfaatkan untuk mengevaluasi rencana tata ruang di suatu wilayah. Pada penelitian digunakan algoritma *maximum likelihood* untuk klasifikasi tutupan lahan dan prediksi tutupan lahan tahun 2031 yang di-*overlay* dengan pola ruang RTRW Kota Cirebon tahun 2031. Hasil menunjukkan terdapat 21.9% tutupan lahan yang tidak sesuai dengan RTRW yang ada. Hasil ini dapat digunakan sebagai masukan bagi pemerintah Kota Cirebon dalam mengevaluasi RTRW. Ardiyanti (2022) melakukan pemodelan prediksi untuk melihat perkembangan tutupan lahan yang lebih spesifik seperti lahan terbangun di suatu wilayah kajian. Ekstraksi

informasi penutup lahan pada penelitian tersebut dilakukan dengan menggunakan indeks NDBI yang dikombinasikan dengan indeks NDVI dari citra Landsat. Adapun model CA-ANN yang dibuat memiliki ketelitian rata-rata sebesar 0,69.

## Data dan Metode

Lokasi penelitian ini adalah Kabupaten Kulon Progo, Provinsi Daerah Istimewa Yogyakarta, yang secara geografis terletak pada  $7^{\circ}38'42''$  -  $7^{\circ}59'3''$  LS dan  $110^{\circ}1'37''$  -  $110^{\circ}16'26''$  BT. Pertambahan jumlah penduduk yang terus-menerus pada wilayah administratif yang tetap di Kabupaten Kulon Progo, menyebabkan tren kepadatan penduduk semakin meningkat setiap tahunnya. Hal tersebut berarti kebutuhan penduduk untuk melakukan alih fungsi terhadap lahan menjadi lahan terbangun juga semakin meningkat fenomena ini terjadi Kabupaten Kulon Progo, dimana setiap tahunnya tingkat kepadatan penduduk yang ada selalu bertambah. Pada tahun 2017, tercatat bahwa Kabupaten Kulon Progo memiliki kepadatan penduduk sebesar 710 per km<sup>2</sup> (BPS, 2017). Kepadatan penduduk tersebut bertambah pada tahun 2020 menjadi sebesar 744 per km<sup>2</sup> dan meningkat kembali pada tahun 2022 menjadi sebesar 770 per km<sup>2</sup> (BPS, 2023). Pesatnya pertumbuhan kabupaten ini dipengaruhi oleh dua hal, yakni adanya faktor eksternal dari tekanan kota besar di sekitarnya dan faktor internal dari meningkatnya aktivitas yang mencirikan suatu perkotaan. Kondisi ini secara langsung dan tidak langsung mempengaruhi perubahan penggunaan lahan di Kabupaten Kulon Progo dari lahan non-terbangun menjadi lahan terbangun. Lingkup lokasi penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Lokasi Penelitian (Sumber: Citra Satelit Sentinel-2 tahun 2023)

Kajian ini menggunakan citra Sentinel-2 MSI (*MultiSpectral Instrument*) Level-1C untuk perekaman tahun 2017, citra Sentinel-2 MSI (*MultiSpectral Instrument*) Level-2A untuk perekaman tahun 2020 dan 2023, data vektor jaringan jalan tahun 2022, dan data vektor batas administrasi Kabupaten Kulon Progo. Untuk pemrosesan data digunakan beberapa perangkat lunak, yaitu : Microsoft Edge untuk mengakses Google Earth Engine dan Google Colaboratory, Google Earth Engine Code Editor dan Google Colaboratory untuk melakukan pemrosesan citra satelit, QGIS untuk rasterisasi data vektor, pembuatan model prediksi dan visualisasi data, dan GPS Map Camera, digunakan untuk pengambilan foto objek pada titik sampel di lapangan. Adapun tahapan kajian ini terdiri atas:

1. Persiapan Data Raster  
Persiapan data raster mencakup data citra satelit Sentinel-2 MSI dengan tanggal akuisisi 12 Agustus 2017, 21 Agustus 2020, dan 24 Maret 2023, yang tersedia pada katalog Google Earth Engine. Citra satelit ini termasuk resolusi menengah dengan jumlah kanal 13 buah.
2. Koreksi Atmosferik  
Citra Sentinel-2 MSI diakuisisi dengan 2 tingkat yang berbeda. Citra tahun 2017 merupakan produk Sentinel-2 MSI Level-1C, sedangkan citra tahun 2020 dan 2023 merupakan produk dari Sentinel-2 MSI Level-2A. Seluruh produk satelit Sentinel-2 MSI Level-1C merupakan produk *Top-of-Atmosphere Reflectance* (TOA), sehingga perlu dilakukan koreksi atmosfer terlebih dahulu. Ini berbeda dengan produk dari satelit Sentinel-2 MSI Level-2A yang merupakan produk *Surface Reflectance* (SR), yang telah terkoreksi secara atmosferik. Koreksi atmosfer pada produk satelit

- Sentinel-2 MSI Level-1C dilakukan dengan menerapkan algoritma SIAC (*Sensor Invariant Atmospheric Correction*) yang memanfaatkan direktori penyimpanan file proyek SIAC di GitHub. Algoritma ini dipilih dikarenakan proses pengolahan citra menggunakan platform Google Earth Engine, sehingga kustomisasi dapat diterapkan.
3. *Cloud Masking*  
*Cloud masking* diterapkan supaya citra satelit terbebas dari tutupan awan. *Cloud masking* dilakukan dengan memanfaatkan *S2 Cloud Probability (s2cloudless)* dataset. *S2 Cloud Probability dataset* dapat dipanggil untuk menggantikan nilai piksel yang tertutupi oleh awan dengan nilai piksel yang telah bebas awan atau minim awan.
  4. Klasifikasi Tutupan Lahan dengan Algoritma SVM  
 Klasifikasi tutupan lahan dilakukan dengan menggunakan skema klasifikasi yang mengacu pada SNI 7645-1:2014 dan disesuaikan dengan daerah kajian. Kelas yang digunakan meliputi lahan terbangun dan lahan non-terbangun, dimana kelas lahan non-terbangun dibagi menjadi beberapa subkelas yakni badan air, daerah bervegetasi, lahan terbuka, dan lahan pertanian. Proses klasifikasi citra dilakukan dengan menggunakan algoritma *Supervised Learning* dari *machine learning* yakni SVM. Algoritma tersebut menggunakan fungsi *libsvm* yang dimiliki oleh Google Earth Engine. Pada dasarnya SVM merupakan sebuah *classifier* biner linear yang mampu mengenali batas antara dua kelas. SVM linear mengasumsikan bahwa data multidimensional dapat dipisahkan secara linear. SVM mencari *hyperplane* yang optimal, yaitu garis lurus untuk memisahkan dataset menjadi kelas-kelas yang telah ditentukan menggunakan data pelatihan (Sheykhmousa dkk., 2020). Klasifikasi ini dilakukan dengan beberapa konfigurasi parameter agar menemukan hasil yang optimal, yakni meliputi tipe kernel, besaran nilai cost (C) dan nilai gamma ( $\gamma$ ). Pada penelitian yang dilakukan, tipe kernel yang dipilih untuk penelitian ini adalah linear yang umum dipakai untuk studi kasus klasifikasi dataset tutupan lahan. Dalam hal ini, nilai cost (C) yang digunakan sebesar 100 dan nilai gamma ( $\gamma$ ) yang digunakan adalah *default*, yang ditetapkan berdasarkan proses *trial and error*.
  5. Persiapan Data Vektor  
 Persiapan data raster dilakukan dengan menyiapkan data raster berupa jaringan jalan yang diambil dari geoportal Kabupaten Kulon Progo (<http://geoportal.kulonprogokab.go.id/>). Data ini digunakan pada tahap pembuatan *euclidean distance*.
  6. Pembuatan *Euclidean Distance*  
 Pembuatan *euclidean distance* meliputi proses rasterisasi data vektor yang dilakukan untuk mengubah data vektor jalan menjadi data raster jalan. Proses ini menggunakan menu *Rasterize* pada QGIS. Raster yang terbentuk lalu dibuat *euclidean distance*-nya dengan menggunakan menu *Proximity* pada QGIS pula. *Euclidean distance* sendiri merupakan proses yang berkaitan dengan jarak pada data spasial. Jarak yang dimaksud adalah jarak terukur dari setiap sel yang dimiliki terhadap sumber terdekat, dihitung dari pusat sel menuju pusat sel lain. Dengan begitu dapat diketahui jarak jangkauan jalan terhadap lahan terbangun yang ada di wilayah kajian. Jarak jangkauan tersebut digunakan sebagai variabel pendukung dalam pembuatan model prediksi.
  7. Pembuatan Model Prediksi dengan algoritma *Cellular Automata*  
 Dengan menggunakan kondisi ketetanggaan dan peta potensi transisi, maka pola perubahan spasial dapat diatur dengan model *Cellular Automata* (Liu, 2020). Pembuatan model prediksi dengan model *Cellular Automata* terbukti cukup baik (Marsoedy, 2020). *Cellular Automata* tampil sangat baik dalam memprediksi pertumbuhan area urban untuk tahun-tahun mendatang berdasarkan pola pertumbuhan pada tahun sebelumnya (Khoshgoftar & Taleei, 2010). Proses ini menggunakan citra multitemporal yang telah terklasifikasi dan data raster jangkauan jalan di wilayah kajian. Tahapan diawali dengan melakukan pengecekan geometri antar data. Selanjutnya data faktor pendukung dilakukan pengecekan korelasi menggunakan *Pearson's Correlation*. Data masukkan tersebut dilihat perubahan area lahan terbangun yang ada dari tahun ke tahun dan dibuat area transisi dari dua *epoch* tutupan lahan tersebut. Tahapan selanjutnya adalah pembuatan model probabilitas transisi. Model probabilitas transisi dibuat dengan jaringan syaraf tiruan atau *Artificial Neural Network (Multi-layer Perceptron)*. Dengan dibentuknya model probabilitas transisi tersebut, maka model prediksi tutupan lahan tahun 2023 dapat disimulasikan. Simulasi dilakukan dengan mengisikan jumlah iterasi simulasi sebanyak 1 kali. Iterasi 1 kali dipilih karena model prediksi yang dibuat adalah model prediksi tutupan

lahan tahun 2023, dimana menggunakan rentang *gap* yang sama dengan data klasifikasi tutupan lahan tahun sebelumnya yakni 2017 dan 2020, dengan *gap* sebesar 3 tahun. Dapat dikatakan bahwa pemilihan jumlah iterasi tergantung pada tahun model yang ingin diprediksikan serta rentang waktu dari data citra satelit yang dijadikan masukan.


#### 8. Validasi Model Prediksi

Hasil model prediksi tersebut nantinya divalidasi dengan pengecekan langsung di lapangan menggunakan matriks konfusi, seperti halnya yang dilakukan pada uji akurasi hasil klasifikasi. Uji validasi model ini menggunakan sampel uji yang sama dengan yang digunakan pada saat melakukan pengujian pada citra hasil klasifikasi tahun 2023. Perbandingan dari jumlah titik uji dengan titik *training* sendiri berturut-turut sebesar 1:2 dengan persebaran titik uji yang berbeda dengan titik *training*. Hal ini bertujuan agar akurasi dari kedua model tidak menunjukkan bias. Matriks konfusi ini dapat digunakan untuk menghitung *producer's accuracy*, *consumer's accuracy*, dan *overall accuracy* (Lillesand dkk., 2008). Tingkat *overall accuracy* yang diacu pada kasus klasifikasi tutupan lahan di penelitian ini adalah >85% (Anderson dkk., 1976). Selain akurasi di atas, dilakukan pula perhitungan Indeks Kappa untuk mengetahui tingkatan kesesuaian pada tabel matriks konfusi yang dihitung berdasarkan diagonal utama serta total baris dan kolom untuk masing-masing elemen, dimana menurut Congalton dkk. (2004) terdapat beberapa kelas kesesuaian yakni tidak ada kesesuaian (<0), kesesuaian kecil (0,01 – 0,20), kesesuaian cukup (0,21 – 0,40), kesesuaian menengah (0,41 – 0,60), kesesuaian substansial (0,61 – 0,80), dan kesesuaian mendekati sempurna (0,81 – 0,99).

## Hasil dan Pembahasan

*Cellular Automata* dikenal sebagai model sederhana dari proses terdistribusi spasial (Baja, 2012). Pemodelan prediksi yang dibentuk melalui *Cellular Automata* ini menggunakan data spasial raster. *Cellular Automata* didefinisikan sebagai sistem dinamis yang terdiri dari beberapa Net-linear yang memiliki hubungan. Perubahan piksel yang terjadi pada *Cellular Automata* mengikuti waktu, kondisinya sendiri, maupun perlakuan yang diterima oleh piksel tetangga atau piksel yang berdekatan dengannya (Ilachinski, 2001). Pada kajian ini, model prediksi tutupan lahan dibuat menggunakan *Cellular Automata* yang telah dimodifikasi pada *plugin* MOLUSCE QGIS. Data masukkan di awal berupa data raster hasil klasifikasi dengan *classifier* SVM pada tahun 2017 dan tahun 2020, serta menggunakan data pendukung berupa raster jangkauan jalan di Kabupaten Kulon Progo.

### 1. Hasil Klasifikasi Tutupan Lahan Tahun 2017, 2020, dan 2023




Gambar 2. Tampilan Hasil Klasifikasi Tutupan Lahan. (a) Tahun 2017; (b) Tahun 2020; Tahun 2023 (Sumber: Pengolahan Data, 2023)

Proses klasifikasi tutupan lahan diawali dengan pembuatan *training dataset* pada ketiga tahun perekaman citra, yakni 126 untuk tahun 2017, 135 untuk tahun 2020, dan 116 untuk tahun 2023. Dengan *training dataset* tersebut, maka dapat diperoleh hasil klasifikasi seperti pada Gambar 2. Pada Gambar 2 (a) dapat diketahui terdapat 2 kelas tutupan lahan yang banyak ditemukan yakni kelas daerah bervegetasi dan kelas lahan pertanian, sedangkan kelas badan air, lahan terbuka, dan lahan terbangun teridentifikasi sedikit. Pada hasil klasifikasi tutupan lahan tahun 2020 dan 2023 yang ditampilkan melalui Gambar 2(b) dan (c) dapat diketahui bahwa terdapat 3 kelas tutupan lahan yang mendominasi, yaitu kelas daerah bervegetasi, lahan pertanian, dan lahan terbangun, sedangkan untuk kelas tutupan lahan yang sedikit ditemukan adalah kelas badan air dan lahan terbuka.

## 2. Hasil Model Prediksi Tutupan Lahan Tahun 2023

Terdapat persyaratan dalam pembuatan model prediksi, bahwa data masukan yang digunakan harus memiliki geometri yang cocok, oleh karena itu sebelum pembuatan model prediksi dimulai perlu dilakukan pendefinisian geometri data yang sama untuk setiap data masukan. Data hasil klasifikasi tahun 2017 dan 2020 serta data raster jangkauan jalan perlu disamakan sistem referensi koordinat dengan perimeter batas administrasi Kabupaten Kulon Progo. Data pendukung yakni data raster jangkauan jalan juga perlu dicek korelasinya dengan menggunakan Pearson's Correlation. Pearson's Correlation sendiri memiliki rentang nilai dari -1 hingga 1, dimana rentang nilai di bawah 0 menunjukkan nilai korelasi negatif dan untuk rentang nilai di atas 0 menunjukkan terdapat korelasi positif. Dari data pendukung yang digunakan memiliki nilai korelasi sebesar 0,11 dengan hasil klasifikasi tutupan lahan tahun 2017 dan memiliki nilai korelasi sebesar 0,08 dengan hasil klasifikasi tutupan lahan tahun 2020. Berdasar data raster hasil klasifikasi tahun 2017 dan 2020 tersebut perlu dilihat perubahan area lahan terbangun yang ada dari tahun ke tahun dan dibuat area transisi dari tutupan lahan tahun 2017 menuju 2020.



Gambar 3. Tampilan Hasil Model Prediksi Tutupan Lahan Tahun 2023 (Sumber: Pengolahan Data, 2023)

Model prediksi tutupan lahan tahun 2023 dengan model probabilitas transisi yang dibangun dibuat dengan model jaringan syaraf tiruan. Adapun hasil model prediksi tutupan lahan tahun 2023 dapat dilihat pada Gambar 3. Pada gambar tersebut, kelas tutupan lahan yang banyak mendominasi adalah daerah bervegetasi, lahan pertanian, dan lahan terbangun, sedangkan kelas badan air dan lahan terbuka sedikit diketemukan. Jika dilihat pada distribusi persebarannya, tutupan lahan berupa daerah bervegetasi banyak ditemukan di Kapanewon Kokap, Girimulyo, Samigaluh, dan Kalibawang. Adapun untuk Kapanewon lain lebih didominasi oleh tutupan lahan pertanian dan lahan terbangun.

### 3. Perubahan Luas Tutupan Lahan

Perubahan luasan tutupan lahan yang terjadi di Kabupaten Kulon Progo dari tahun 2017, 2020, dan 2023 berdasarkan hasil klasifikasi tahun 2017 dan 2020, serta hasil model prediksi tahun 2023 dapat dilihat pada Tabel 1 dan Gambar 4.

Tabel 1. Luasan Tutupan Lahan Hasil Klasifikasi Tahun 2017, 2020, dan Model Prediksi Tahun 2023.

	Lahan Terbangun (ha)	Badan Air (ha)	Daerah Bervegetasi (ha)	Lahan Pertanian (ha)	Lahan Terbuka (ha)
Hasil Klasifikasi 2017	3.165,48	552,55	30.264,92	21.638,67	2.032,52
Hasil Klasifikasi 2020	5.938,09	796,06	30.172,08	17.567,31	3.180,6
Model Prediksi 2023	7.353,84	440,59	29.273,71	17.665,76	2.920,24

Perubahan yang fluktuatif terjadi pada tutupan lahan pertanian, badan air, dan lahan terbuka. Pada tahun 2020 tutupan lahan pertanian mengalami penurunan sebesar 4.071,36 ha, dan kenaikan pada tahun 2023 sebesar 98,45 ha. Pada tutupan lahan badan air terjadi kenaikan pada tahun 2020 sebesar 243,51 ha dan turun pada tahun 2023 sebesar 355,47 ha. Pada tutupan lahan terbuka, terjadi kenaikan pada tahun 2020 sebesar 1.148,08 ha dan penurunan di tahun 2023 sebesar 260,36 ha. Adapun untuk kelas tutupan lahan lain seperti daerah bervegetasi mengalami tren penurunan di setiap tahunnya, berbanding terbalik dengan tren kenaikan pada lahan terbangun. Pada tahun 2020 daerah bervegetasi mengalami penurunan sebesar 92,48 ha, sedangkan lahan terbangun mengalami kenaikan sebesar 2.772,61 ha. Selanjutnya pada tahun 2023, luas daerah bervegetasi turun sebesar 898,37 ha dan luas lahan terbangun naik sebesar 1.415,75 ha.




Gambar 4. Grafik Perubahan Luas Tutupan Lahan Pada Hasil Klasifikasi Tahun 2017, 2020, dan Model Prediksi Tahun 2023 (Sumber: Pengolahan Data, 2023)

### 4. Perbandingan Luas Hasil Klasifikasi Tahun 2023 dengan Hasil Model Prediksi Tahun 2023


Apabila dilihat melalui luasan tutupan lahan, hasil klasifikasi tahun 2023 dengan hasil model prediksi tahun 2023 memiliki perbedaan. Besarnya perbedaan tersebut disajikan melalui Tabel 2.

Tabel 2. Perbandingan Luas Tutupan Lahan Hasil Klasifikasi Tahun 2023 dengan Model Prediksi Tahun 2023

	Lahan Terbangun (ha)	Badan Air (ha)	Daerah Bervegetasi (ha)	Lahan Pertanian (ha)	Lahan Terbuka (ha)
Hasil Klasifikasi 2023	8.950,14	707,44	33.040,27	14.464,78	460,99
Model Prediksi 2023	7.353,84	440,59	29.273,71	17.665,76	2.920,24



Gambar 5. Perbedaan Tutupan Lahan Terbangun Pada Area Sampel. (a) Hasil Klasifikasi Tahun 2023; (b) Model Prediksi Tahun 2023 (Sumber: Pengolahan Data, 2023)



Gambar 6. Perbedaan Tutupan Lahan Terbangun Berupa Jalan Pada Area Sampel. (a) Hasil Klasifikasi Tahun 2023; (b) Model Prediksi Tahun 2023 (Sumber: Pengolahan Data, 2023)

Berdasarkan Tabel 2 dapat diketahui bahwa perbedaan yang kurang signifikan ada pada tutupan lahan badan air, yang memiliki perbedaan sebesar 266,85 ha, sedangkan pada tutupan lahan yang lain memiliki perbedaan luasan yang signifikan. Tutupan lahan terbuka memiliki perbedaan sebesar 2.459,25 ha, tutupan lahan pertanian memiliki perbedaan sebesar 3.200,98 ha, tutupan lahan daerah bervegetasi memiliki perbedaan sebesar 3.766,56 ha, sedangkan untuk tutupan lahan terbangun memiliki perbedaan sebesar 1.596,3 ha, dimana luasan lahan terbangun pada model prediksi tahun 2023 lebih rendah daripada luasan lahan terbangun pada hasil klasifikasi tahun 2023. Lebih lanjut, perbedaan luasan lahan terbangun pada hasil klasifikasi tahun 2023 dan model prediksi tahun 2023 dapat dilihat pada Gambar 5 dan Gambar 6.

Pada Gambar 5, dapat diketahui bahwa hasil klasifikasi tahun 2023 menunjukkan tutupan lahan terbangun yang begitu rapat. Di samping itu, tutupan lahan terbangun pada model prediksi tahun 2023 memiliki tingkat kerapatan yang lebih rendah daripada hasil klasifikasi tahun 2023 pada kawasan urban tersebut. Namun, pada Gambar 6 dapat diketahui bahwa data pendukung berupa jangkauan jalan pada model prediksi tahun 2023 membuat tutupan lahan terbangun berupa jalan menjadi lebih detail jika dibandingkan dengan hasil klasifikasi 2023. Perbedaan sebaran dan luasan tutupan lahan terbangun maupun tutupan lahan yang lain dapat terjadi disebabkan oleh data pendukung yang digunakan serta data *training* untuk pembuatan model probabilitas transisi saat simulasi *Cellular Automata*.

## 5. Uji Validasi Model

Pada hasil model prediksi tutupan lahan tahun 2023 ini dilakukan uji validasi melalui matriks konfusi dan tingkat kesesuaian dengan perhitungan Indeks Kappa. Pengujian dilakukan dengan menggunakan 53 titik sampel uji lapangan. Nilai *Producer's Accuracy* (PA), *User's Accuracy* (UA), *Omission Error* (OE), *Commission Error* (CE), *Overall Accuracy* (OA), dan Indeks Kappa pada model prediksi tutupan lahan tahun 2023 dapat dilihat pada Tabel 3.

Berdasarkan Tabel 3, dapat dilihat bahwa nilai *Producer's Accuracy* dan *User's Accuracy* terendah dimiliki oleh tutupan lahan terbuka yakni berturut-turut sebesar 40% dan 66.66%. Di sisi lain, kelas tutupan lahan yang memiliki nilai *Producer's Accuracy* tertinggi adalah daerah bervegetasi sebesar 90.90% dan nilai *User's Accuracy* tertinggi ditemukan pada 2 tutupan lahan yakni badan air sebesar 100% dan daerah bervegetasi sebesar 100%. Adapun untuk tutupan lahan terbangun dapat memberikan nilai *Producer's Accuracy* dan

*User's Accuracy* di bawah 2 tutupan lahan sebelumnya, yakni sebesar 88.88% dan 76.19%. Model prediksi ini memiliki nilai *Overall Accuracy* (OA) sebesar 81.13%, yakni sedikit di bawah standar 85%. Sementara itu, Indeks Kappa model prediksi sebesar 0.745, dimana nilai tersebut tergolong sebagai model yang memiliki kesesuaian substansial.

Tabel 3. Matriks Konfusi Model Prediksi Tahun 2023

		Hasil Model Prediksi					Total	PA (%)	OE (%)	
		Lahan Terbangun	Badan Air	Daerah Bervegetasi	Lahan Pertanian	Lahan Terbuka				
Data Uji Lapangan	Lahan Terbangun	16	0	0	2	0	18	88.88	11.11	
	Badan Air	1	4	0	0	0	5	80	20	
	Daerah Bervegetasi	0	0	10	1	0	11	90.90	9.09	
	Lahan Pertanian	2	0	0	11	1	14	78.57	21.42	
	Lahan Terbuka	2	0	0	1	2	5	40	60	
Total		21	4	10	15	3	43			
UA (%)		76.19	100	100	73.33	66.66	OA (%)	81.13		
CE (%)		23.81	0	0	26.66	33.33				
Kappa									0.75	

Nilai akurasi dan Indeks Kappa dari model prediksi tersebut masih layak untuk menjadi acuan dalam melihat potensi perubahan yang terjadi melalui model prediksi di masa yang akan datang. Sedikit perbedaan antara model prediksi dengan klasifikasi tahun 2023 dapat disebabkan oleh berbagai faktor, antara terjadinya perubahan tutupan lahan (Ardiyanti, 2022). Tidak dilibatkannya faktor tersebut disinyalir dapat membuat model prediksi yang dihasilkan belum mampu memprediksi tutupan lahan tahun 2023 dengan sempurna (Wibowo, 2023).

## Kesimpulan

Hasil klasifikasi tutupan lahan pada tahun 207 dan 2020 dapat dimanfaatkan untuk melakukan prediksi terhadap sebaran dan luasan lahan terbangun pada tahun 2023 menggunakan model Cellular Automata. Model prediksi tutupan lahan tahun 2023 memiliki pola persebaran dimana kelas daerah bervegetasi banyak mendominasi di Kapanewon Kokap, Girimulyo, Samigaluh, dan Kalibawang. Adapun untuk Kapanewon lain lebih didominasi oleh tutupan lahan pertanian dan lahan terbangun. Untuk nilai akurasi tutupan lahan terbangun pada model prediksi memiliki nilai *producer's accuracy* dan *user's accuracy* secara berturut-turut sebesar 88.88% dan 76.19%. Selain itu, model prediksi ini mendapatkan nilai *overall accuracy* dan Indeks Kappa berturut-turut sebesar 81.13% dan 0.74. Berdasarkan nilai tersebut, diketahui bahwa model prediksi memiliki nilai akurasi dan Indeks Kappa yang cukup baik. Dengan demikian, pembuatan model prediksi masih layak untuk menjadi acuan dalam melihat potensi perubahan yang terjadi di masa yang akan datang.

## Daftar Pustaka

- Anderson, J. R., Hardy, E. E., Roach, J. T., & Witmer, R. E. (1976). *A Land Use and Land Cover Classification System for Use with Remote Sensor Data*. Virginia: USGS.
- Ardiyanti, F. (2022). Pemodelan Spasial Perkembangan Lahan Terbangun Kawasan Perkotaan Boyolali Menggunakan Model Cellular Automata dan Regresi Logistik Biner. *Skripsi*. Program Sarjana, Fakultas Geografi, Departemen Sains Informasi Geografi, Universitas Gadjah Mada.
- Baja, S. (2012). *Perencanaan Tata Guna Lahan Dalam Pengembangan Wilayah Pendekatan Spasial dan Aplikasinya*. Yogyakarta: Penerbit Andi.
- BPS. (2017). *Kabupaten Kulon Progo dalam Angka 2017*. Kulon Progo: Badan Pusat Statistik.
- BPS. (2023). *Kabupaten Kulon Progo dalam Angka 2023*. Kulon Progo: Badan Pusat Statistik.
- Congalton, R. G., Stehman, S., Jeffrey T. Morisette, John S. Iames, Jr. Andrew N. Pilant, Elijah Ramsey, John Sydenstricker-Neto, & Siamak Khorram. (2004). *Remote Sensing and GIS Accuracy Assessment Ed 1*. Boca Raton: CRC Press.
- Fardani, I., Alain, F., Mohmed, J., & Chofyan, I. (2020). Pemanfaatan Prediksi Tutupan Lahan Berbasis Cellular Automata-Markov dalam Evaluasi Rencana Tata Ruang. Diambil kembali dari *Media Komunikasi Geografi*. No.2 Vol.21. hal. 157–171. <https://ejournal.undiksha.ac.id/index.php/MKG/article/view/28121>
- Fitri, R. H. (2013). Dampak Urbanisasi Bagi Perkembangan Kota di Indonesia. Diambil dari *Jurnal Society*. No.1. Vol.I. hal. 35–45: <https://media.neliti.com/media/publications/130628-ID-dampak-urbanisasi-bagi-perkembangan-kota.pdf>
- Fuglsang, M., Münier, B., & Hansen, H. S. (2013). Modelling land-use effects of future urbanization using cellular automata: An Eastern Danish case. Diambil dari *Environmental Modelling & Software*. Vol.50. hal. 1–11: <https://www.sciencedirect.com/science/article/abs/pii/S1364815213001813>
- Ilachinski, A. (2001). *Cellular Automata: A Discrete Universe* (Edisi Pertama). Singapore: World Scientific Publishing Company.
- Khoshgofar, M., & Taleei. (2010). Simulation of Urban Growth in Tehran Using CA - Markov Model. *Journal of Remote Sensing and GIS*. No. 2. Vol. 2. hal 18-33: [https://www.researchgate.net/publication/262684478\\_SIMULATING\\_URBAN\\_GROWTH\\_IN\\_TEHRAN\\_USING\\_THE\\_CA-MARKOV\\_MODEL](https://www.researchgate.net/publication/262684478_SIMULATING_URBAN_GROWTH_IN_TEHRAN_USING_THE_CA-MARKOV_MODEL)
- Lillesand, T. M., Kiefer, R. W., & Chipman, J. (2008). *Remote Sensing and Image Interpretation Ed 6*. Hoboken: John Wiley and Sons Inc.
- Liu, Y. (2020). *Modelling Urban Development with Geographical Information Systems and Cellular Automata Ed 1*. Boca Raton: CRC Press.
- Mardiansyah, F. H. (2011). *Menarik Pelajaran dari Judul Buku 50 Tahun Perjalanan Perencanaan Wilayah dan Kota di Indonesia Ed 1*. Jakarta: ITB.
- Marsoedy, A. A. F. (2020). Analisa Kekauratan Add-On MOLUSCE pada QGIS untuk Prediksi Perubahan Penggunaan Lahan di Kabupaten Sleman, DI Yogyakarta. *Skripsi*. Program Sarjana, Fakultas Teknik, Departemen Teknik Geodesi, Universitas Gadjah Mada.
- Setyono, J. S., Yunus, H. S., & Giyarsih, S. R. (2017). Pengelolaan Kota-Kota Kecil di Jawa Tengah: Studi Kasus Pada Empat Kota Kecil di Wilayah JOGLOSEMAR. Diambil dari *Tataloka*. No.2. Vol.19. hal. 142-162: <https://ejournal2.undip.ac.id/index.php/tataloka/article/view/1334/pdf>
- Sheykhmousa, M., Mahdianpari, M., Ghanbari, M., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. Diambil dari *Ieee Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. Vol. 13. hal. 6308-6325: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9206124>
- Wibowo, R. A. (2023). Pembuatan Model Prediksi Lahan Terbangun di Kabupaten Kulon Progo dengan Memanfaatkan Hasil Klasifikasi Tutupan Lahan dengan Algoritma Support Vector Machine Pada Citra Satelit Sentinel-2 MSI Tahun 2017, 2020, dan 2023. *Skripsi*. Program Sarjana, Fakultas Teknik, Departemen Teknik Geodesi, Universitas Gadjah Mada.
- Yuliasuti, N., Fatchurochman, A., Sudarto, J. H., & Semarang, T. (2012). Pengaruh Perkembangan Lahan Terbangun Terhadap Kualitas Lingkungan Permukiman (Studi Kasus: Kawasan Pendidikan Kelurahan Tembalang. Diambil dari *Jurnal Presipitasi: Media Komunikasi Dan Pengembangan Teknik Lingkungan*. No.1. Vol.9. hal. 10–16: <https://ejournal.undip.ac.id/index.php/presipitasi/article/view/4806/4356>

