

Proyeksi Debit dan Limpasan Akibat Perubahan Tutupan Lahan dan Iklim di Sungai Citarum Kecamatan Dayeuhkolot pada Tahun 2045

Projection of Discharge and Runoff Due to Land Cover and Climate Changes in the Citarum River, Dayeuhkolot Subdistrict, in 2045

Asep Suheri¹, Yoyo Suhaya¹, Andika Putra Kunigara¹

Diterima: 4 Juli 2024

Disetujui: 22 Oktober 2024

Abstrak: Perubahan iklim dan tutupan lahan mengakibatkan peningkatan aliran permukaan (surface runoff) dan debit Sungai yang berpotensi dalam peningkatan frekuensi dan intensitas banjir. Salah satu daerah yang mengalami masalah ini adalah Kecamatan Dayeuhkolot yang terletak di DAS Citarum Hulu. Oleh karena itu, penelitian ini, dengan tujuan memprediksi perubahan debit dan limpasan Sungai Citarum di Kecamatan Dayeuhkolot pada tahun 2045 dengan mempertimbangkan skenario perubahan tutupan lahan dan iklim disusun agar dapat menjadi masukan dalam strategi rehabilitasi lahan di DAS Citarum Hulu. Dalam penelitian ini, dilakukan simulasi perubahan penggunaan lahan dari tahun 2022 hingga 2045 menggunakan model CA-Markov dengan skenario Business as Usual (BAU). Selain itu, dilakukan Statistical Downscaling Model (SDSM) untuk menganalisis tren perubahan iklim pada tiga skenario berbeda. Setelah itu, kombinasi dari masing-masing skenario perubahan penggunaan lahan dan iklim, akan dimodelkan dalam model hidrologi Soil and Water Assessment Tool (SWAT) untuk mensimulasikan aliran air masa depan dan menganalisis risiko banjir masa depan. Hasil penelitian menunjukkan peningkatan limpasan tahunan tertinggi terjadi pada skenario perubahan iklim RCP 8.5 dan skenario perubahan tutupan lahan Business As Usual, yaitu sebesar 24,42%. Selain itu, peningkatan debit tertinggi terjadi pada skenario perubahan tutupan lahan dengan skenario Business As Usual dan skenario iklim RCP 8.5, yaitu sebesar 91,84%.

Kata kunci: *Banjir, DAS Citarum Hulu, CA-Markov, SDSM, SWAT*

Abstract: Changes in climate and land cover have resulted in an increase in surface runoff and river discharge, potentially increasing the frequency and intensity of flooding. One of the areas experiencing this problem is Dayeuhkolot Sub-district, which is located in the Upper Citarum Watershed. Therefore, this study, with the aim of predicting the changes in discharge and runoff of the Citarum River in Dayeuhkolot Sub-district in 2045 by considering land cover change and climate scenarios, was prepared in order to provide input for land rehabilitation strategies in the Upper Citarum Watershed. In this study, a simulation of land use change from 2022 to 2045 was conducted using CA-Markov model with Business as Usual (BAU) scenario. In addition, a Statistical Downscaling Model (SDSM) was conducted to analyse climate change trends under three different scenarios. Afterwards, the combination of each land use and climate change scenario was modelled in the Soil and Water Assessment Tool (SWAT) hydrological model to simulate future water flows and analyse future flood risks. The results showed that the highest increase in annual runoff occurred in the RCP 8.5 climate change scenario and the Business As Usual land cover change scenario, which was 24.42%. In addition, the highest increase in discharge occurred in the land cover change

¹ Program Studi Rekayasa Kehutanan, Institut Teknologi Bandung, Bandung, Indonesia

Korespondensi: 11520024@mahasiswa.itb.ac.id

scenario with the Business As Usual scenario and the RCP 8.5 climate scenario, which was 91.84%.

Keywords: Flood, Upper Citarum Watershed, CA-Markov, SDSM, SWAT

PENDAHULUAN

Sungai Citarum merupakan salah satu Sungai terpenting di Jawa Barat. Sungai ini memiliki peran vital dalam mendukung kehidupan jutaan penduduk di sekitarnya, salah satunya di Kecamatan Dayeuhkolot. Sungai ini menyediakan sumber air bagi keperluan rumah tangga, irigasi pertanian, dan industri. Namun, dalam beberapa dekade terakhir, Sungai Citarum menghadapi tekanan yang semakin besar akibat perubahan tutupan lahan dan iklim.

Perubahan tutupan lahan, seperti konversi hutan menjadi kawasan non hutan serta perkembangan pesat urbanisasi, telah menyebabkan peningkatan aliran permukaan (*surface runoff*) dan debit Sungai. Selain itu, perubahan iklim global telah mempengaruhi pola curah hujan yang berpotensi meningkatkan frekuensi dan intensitas banjir. Menurut data BPBD Jawa Barat, pada tahun 2022, Kecamatan Dayeuhkolot mengalami 12 kali bencana banjir. Hal ini menjadi contoh nyata bagaimana interaksi antara perubahan tutupan lahan dan perubahan iklim dapat mempengaruhi limpasan dan debit Sungai.


Tantangan utama dalam penelitian ini adalah memproyeksikan kondisi debit dan limpasan Sungai Citarum pada tahun 2045 dengan mempertimbangkan berbagai skenario perubahan lahan dan iklim. Pendekatan ini memerlukan pengumpulan data historis yang akurat serta integrasi antara model iklim dan penggunaan lahan. Selain itu, penelitian ini harus dapat mengatasi keterbatasan data yang sering menjadi kendala dalam studi proyeksi dalam waktu jangka panjang.

Tujuan utama dari penelitian ini adalah untuk memprediksi perubahan debit dan limpasan Sungai Citarum di Kecamatan Dayeuhkolot pada tahun 2045 dengan mempertimbangkan skenario perubahan tutupan lahan dan iklim. Sementara itu, kebaruan dari penelitian ini terletak pada pendekatan integratif yang menggabungkan analisis perubahan tutupan lahan, model iklim, dan model hidrologi untuk memberikan proyeksi yang akurat dan relevan dengan kondisi masa depan. Penelitian ini juga memberikan kontribusi penting dalam pengembangan strategi rehabilitasi baik itu perkeayaan secara vegetasi dan sipil teknis terhadap risiko banjir di masa depan, khususnya di wilayah urban yang berkembang dengan pesat.

METODE

Waktu dan Lokasi

Penelitian ini dilakukan pada tanggal 1 Juli-26 November 2023, kajian ini meliputi Sub-DAS Cisangkuy, Sub-DAS Citarik, Sub-DAS Cikapundung, Sub-DAS Cirasea yang termasuk dalam DAS Citarum Hulu yang terletak pada wilayah Cekungan Bandung. Secara geografis, lokasi penelitian berada pada 6°44'13.65"S-7°14'31.046"S dan 107°22'38.61"E-107°56'42.374"E. Secara administratif area penelitian mencakup Kota Bandung, Kabupaten Bandung, Kabupaten Sumedang, dan Kabupaten Garut yang terdiri dari 78 kecamatan dengan luas area penelitian sebesar 137.440,49 ha.



Gambar 1. Peta Lokasi Penelitian

Bahan dan Peralatan Penelitian

Pada penelitian ini digunakan data primer dan data sekunder berupa:

- Citra DEMNAS resolusi 8,3 x 8,3 m² dari Badan Informasi Geospasial (BIG).
- Batas Administrasi Kecamatan Dayeuhkolot skala 1:25.000 dari Badan Informasi Geospasial (BIG).
- Jaringan Sungai DAS Citarum skala 1:25.000 dari Badan Informasi Geospasial (BIG).
- Citra satelit Sentinel 2A/2B tahun 2016, 2018, 2020, dan 2022.
- Peta tutupan lahan DAS Citarum tahun 2016, 2018, 2020, dan 2022 dari Badan Informasi Geospasial (BIG).
- Peta jalan di DAS Citarum dari *Open Street Map*.
- Peta jenis tanah skala 1:250.000 dari Balai Besar Pengujian Standar Instrumen Sumberdaya Lahan Pertanian (BBSDLDP).
- Debit Sungai harian pada tahun 2018-2022 di DAS Citarum dari Direktorat Jenderal Sumber Daya Air.
- Data iklim tahun 2000-2022 dari BMKG berupa data curah hujan (mm), temperatur maksimum dan minimum (°C), kelembaban udara relatif (%), intensitas penyinaran matahari (MJ/m²/hari) dan data kecepatan angin (m/s).

Selain itu, digunakan alat berupa ArcGIS, QGIS QSWAT, Google *Earth Pro*, Terrset, Google *Earth Engine*, SDSM (*Statistical DownScaling Model*), Microsoft Excel, Microsoft *Access Database Redistributable*, dan Notepad++.

Metode Analisis

Analisis data yang dilakukan dibagi menjadi empat tahapan besar, yaitu prediksi penggunaan lahan dengan CA-Markov *Model*, prediksi cuaca lokal dengan *Statistical Downscaling*, simulasi hidrologi dengan *Soil and Water Assessment Tools* (SWAT), dan prediksi debit dan limpasan dengan SWAT.

Prediksi Penggunaan Lahan dengan CA-Markov Model

Penggunaan lahan dilakukan dengan metode *Supervised Classification* berupa *Support Vector Mechanism* (SVM). SVM dipilih karena efektivitasnya dalam menangani data hiperspektral, bahkan jika *training sample* yang dilakukan terbatas (Rudrapal & Subhedar, 2015). Klasifikasi tutupan lahan yang dilakukan berdasarkan Kamus Data Geospasial Lingkungan Hidup dan Kehutanan, kemudian diadaptasi dengan *database* yang disediakan SWAT agar model bisa dijalankan (Bahdi, 2012).

Tabel 1. Klasifikasi Penggunaan Lahan

<i>Land Use</i>	Tutupan Lahan
RICE	Sawah
FRST	Hutan Lahan Kering Primer
	Hutan Lahan Kering Sekunder
	Hutan Tanaman
URMD	Permukiman
	Bandara/Pelabuhan
AGRL	Pertanian Lahan Kering Bercampur Semak
	Pertanian Lahan Kering
WATR	Badan Air
PAST	Savana/Padang Rumput
	Tegalan

Dari data yang sudah terklasifikasikan dilakukan uji akurasi dengan mencari nilai *overall accuracy*, *producers accuracy*, *users accuracy*, *Kappa Coefficient*. Guna menentukan banyaknya titik sampel pada setiap kelas penggunaan lahan digunakan persamaan penentuan banyaknya titik uji dengan *stratified random sampling* yang dihitung dengan persamaan (Olofsson, 2021).

$$N = \sum_{i=1}^c (W_i - S_i) / S_o)^2 \quad (1)$$

Keterangan:

N = banyak titik sampel

W_i = proporsi wilayah kelas i yang dipetakan

S_i = standar deviasi strata i

S_o = standar deviasi yang diharapkan dari akurasi keseluruhan

Untuk perhitungan *overall accuracy*, *producers accuracy*, *users accuracy*, dan koefisien Kappa dilakukan dengan persamaan 2-6 (Hariati, et al, 2022).

$$\text{Overall Accuracy (\%)} = \left(\frac{\text{Jumlah prediksi benar}}{\text{jumlah total data}} \right) \quad (2)$$

$$\text{Producers Accuracy (\%)} = \left(\frac{TP}{TP + FN} \right) \quad (3)$$

$$\text{Users Accuracy} = \left(\frac{TP}{TP + FP} \right) \quad (4)$$

$$\text{Koefisien Kappa} = \left(\frac{\text{Overall accuracy} - \text{Pr}(e)}{1 - \text{Pr}(e)} \right) \quad (5)$$

$$\text{Pr}(e) = \left(\frac{(TP+FP) \times (TP \times FN) \times (TN+FP) \times (TN+FN)}{(\text{Jumlah total data})^2} \right) \quad (6)$$

Keterangan:

TP = *True Positive*, jumlah data yang benar diprediksi sebagai positif

TN = *True Negative*, jumlah data yang benar diprediksi sebagai negative

FP = *False Positive*, jumlah data yang salah diprediksi sebagai positif

FN = *False Negative*, jumlah data yang salah diprediksi sebagai negative

Pr(e) = Tingkat kesepakatan yang diharapkan secara acak antara dua pengamat (model dan kelas sebenarnya)

Nilai *overall accuracy* merupakan ukuran sejauh mana model terklasifikasi dengan benar dalam memprediksi semua kelas secara keseluruhan. Nilai *producers accuracy* mengukur sejauh mana model dapat benar-benar mengidentifikasi sampel dari suatu kelas tertentu. Nilai *users accuracy* mengukur sejauh mana prediksi positif dari model adalah benar untuk suatu kelas tertentu. Koefisien Kappa mengukur tingkat kesepakatan antara model klasifikasi dan kelas sebenarnya yang disesuaikan dengan tingkat kesepakatan yang diharapkan secara acak. Tabel 2 merupakan klasifikasi akurasi yang dihasilkan berdasarkan nilai kappa yang didapatkan dari model.

Tabel 2. Klasifikasi Nilai Kappa

Koef Kappa	Akurasi/Ketepatan
≤0,2	Rendah
>0,2 – ≤ 0,4	Lumayan
>0,4 – ≤ 0,6	Cukup
>0,6 – ≤ 0,8	Kuat
>0,8 – 1,0	Sangat Kuat

Sumber: Islami et al., 2022

Setelah dilakukan *accuracy assessment*, dalam memprediksi penggunaan lahan, dilakukan *backward stepwise regression* dari *driven factor* yang sudah ditentukan sehingga diperoleh model terbaik dari kombinasi variabel terpilih (Smith, 2018). Langkah selanjutnya, adalah dilakukan pembelajaran terhadap *machine learning* sehingga terbentuk matriks *probability* dari setiap kelas klasifikasi penggunaan lahan. Matriks *probability* (*transition probability matrix*) adalah matriks yang menunjukkan probabilitas perubahan dari satu kelas ke kelas lainnya pada setiap iterasi atau waktu.

Setelah itu, model proyeksi penggunaan lahan akan terbuat. Model yang dihasilkan adalah model dengan menggunakan skenario Business As Usual (BAU)/model alami. Pada model ini, prediksi perubahan penggunaan lahan didasarkan pada tren perubahan

penggunaan lahan yang dijadikan bahan pembelajaran sehingga dapat diartikan pada model ini belum mempertimbangkan kebijakan dan upaya pengaturan penggunaan lahan (Dewi et al., 2024). Tahapan selanjutnya dilakukan validasi proyeksi penggunaan lahan pada tahun 2022. Tahun 2022 dipilih karena terdapat data acuan untuk validasi model prediksi penggunaan lahan. Model akan dilakukan pengujian akurasi dengan dua pendekatan:

1. Membandingkan luas wilayah perkelas penggunaan lahan antara model dan data acuan (Tabel 3).
2. Mencari nilai *accuracy assessment* dengan mencari nilai *overall accuracy*, *producers accuracy*, *users accuracy*, *Kappa Coeficient* (Persamaan 2-6).

Tabel 3. Perhitungan Uji Akurasi Luas Wilayah pada Setiap Kelas

PL	Act (ha)	Prdct (ha)	Diff (ha)	Pct (%)	Accur (%)
X	X _{act}	X _{prdct}	X _{prdct} - X _{akt}	$\left(\frac{Diff}{X_{act}}\right) \times 100$	$100 - \sqrt{pct^2}$

Keterangan:

PL = klasifikasi kelas-kelas penggunaan lahan

Act = luas penggunaan lahan acuan

Prdct = luas prediksi penggunaan lahan

Diff = selisih luas penggunaan lahan

Pct = persentase selisih luas penggunaan lahan

Accur = akurasi dari model

Berdasarkan Tabel 2, jika model yang dihasilkan memiliki koefisien kappa lebih dari 0,6 sampai 1 maka akan dilakukan pemodelan prediksi penggunaan lahan pada tahun 2045.

Simulasi Hidrologi dengan Soil and Water Assessment Tools

Data-data yang sudah dilakukan pra-pemrosesan akan diolah dengan menggunakan plugin QSWAT melalui tahapan-tahapan sebagai berikut:

1. Delineasi DAS
Data *Digital Elevation Model* (DEM) dari DAS Citarum dan data vektor berupa *Shapefile* (SHP) *outlet point* (data titik stasiun pengamatan debit air) akan diolah oleh SWAT sehingga menghasilkan batas daerah/subbasin dan jaringan-jaringan Sungai.
2. Pembentukan dan Pendefinisian HRU (*Hydrological Response Unit*)
Data peta jenis tanah, penggunaan lahan, *slope* yang telah terklasifikasikan sesuai klasifikasi yang terdapat pada SWAT akan menghasilkan diskritisasi karakteristik yang seragam berdasarkan kombinasi dari ketiga parameter tersebut.
3. Pembentukan data iklim
Data iklim berupa data intensitas curah hujan, data temperatur maksimum dan minimum, kelembaban udara relatif, intensitas penyinaran matahari dan data kecepatan angin diolah agar bisa dilakukan pemodelan oleh SWAT.
4. Simulasi SWAT
Proses ini akan me-*running* model pada tahun yang akan dimodelkan sehingga menghasilkan data berupa debit rata-rata dan limpasan rata-rata.
5. Kalibrasi dan Validasi
Kalibrasi dilakukan dengan mengubah *Curve Number* (CN). Nilai CN adalah fungsi dari penggunaan lahan, jenis tanah, dan kondisi kelembapan (Gassman et al., 2007). Selain itu, dilakukan validasi pada model dengan mencari nilai *Correlation coefficient* (R), *Root Mean Squared Error* (RMSE), *Coefficient of Determination* (R²), *Percent bias* (PBIAS), *Nash-Sutcliffe Efficiency* (NSE) dengan Persamaan (7-11).

$$R = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (8)$$

$$PBIAS = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)}{\sum_{i=1}^n Y_i} \quad (9)$$

$$R^2 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (10)$$

$$NSE = \frac{\sum_{i=1}^n (X_i - Y_i)^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (11)$$

Keterangan:

- Y_i = nilai observasi pada pengamatan ke-i
 $\hat{Y}_i$ = nilai yang diprediksi oleh model pada pengamatan ke-i
 $\bar{Y}$ = rata-rata dari nilai observasi
 $\bar{X}$ = rata-rata dari nilai simulasi
 n = jumlah pengamatan

Nilai R dapat mengukur kekuatan dan arah hubungan linear antara dua variabel. Nilai RMSE menggambarkan seberapa baik model memprediksi data. Nilai R^2 menggambarkan seberapa baik variabel independen dalam model menjelaskan variabilitas dalam variabel dependen. Nilai PBIAS memberikan informasi sejauh mana model cenderung memprediksi *output* yang lebih tinggi atau lebih rendah dari observasi. Nilai NSE menggambarkan Seberapa besar ketelitian yang dihasilkan dari korelasi hubungan yang terbentuk antara data observasi serta data perkiraan. Tabel 4-6 menunjukkan kriteria dari setiap klasifikasi nilai yang didapatkan dari setiap nilai *Correlation coefficient* (R), *Root Mean Squared Error* (RMSE), *Coefficient of Determination* (R^2), *Percent bias* (PBIAS), *Nash-Sutcliffe Efficiency* (NSE).

Tabel 4. Klasifikasi Nilai *Correlation Coefficient*

Nilai R	Kriteria
0 – 0.19	Sangat Rendah
0.20 – 0.39	Rendah
0.40 – 0.59	Sedang
0.60 – 0.79	Kuat
0.81 - 1	Sangat Kuat

Sumber: Mukaka, 2020

Tabel 5. Klasifikasi *Nash-Sutcliffe Efficiency*

Nilai NSE	Kriteria
$NSE > 0,75$	Baik
$0,36 < NSE \leq 0,75$	Memenuhi
$NSE < 0,36$	Tidak Memenuhi

Sumber: Eryani et al., 2022

Tabel 6. Klasifikasi Nilai R²

Nilai R ²	Kriteria
$0,7 \leq R^2 < 1,0$	Tinggi
$0,4 \leq R^2 < 0,7$	Sedang
$0,2 \leq R^2 < 0,4$	Rendah
$R^2 < 0,2$	Diabaikan

Sumber: Amali et al., 2022

Prediksi Iklim Menggunakan Statistical Downscaling Modelling

Metode *statistical downscaling* dilakukan dalam memprediksi cuaca lokal karena memungkinkan untuk memperoleh informasi pada skala lokal dari skala yang lebih besar, seperti hasil dari model iklim global. Hal ini dilakukan dengan menarik kesimpulan dari hubungan-hubungan antara variabel iklim global (misalnya hasil dari *General Circulation Model/GCM*) dengan variabel iklim lokal.

Pada tahapan ini diperlukan data dari variabel prediktan berupa data cuaca lokal periode 2000-2022. Data prediktan diambil dari Pos Curah Hujan Dago Pakar-Bengkok, Dayeuhkolot, Cibeureum, dan Rancaekek. Sementara itu, data iklim diambil dari Stasiun Iklim Ciparay. Selain itu, dibutuhkan data prediktor berupa data *Global Climate Model* (GCM), yaitu CMIP 5 (*Coupled Model Intercomparison Project Phase 5*) dengan beberapa skenario RCP, yaitu RCP (*Representative Concentration Pathways*) 2.6 (CanESM2_rcp26_2006_2100), RCP 4.5 (CanESM2_rcp45_2006_2100), RCP 8.5 dan (CanESM2_rcp85_2006_2100) dari area studi. Pada model CMIP 5 terdapat 26 variabel prediktor pada setiap skenario yang disediakan. Penjelasan dari masing-masing skenario terdapat pada Tabel 7.

Tabel 7. Skenario-skenario pada Model CMIP 5

Skenario	Penjelasan
RCP 2.6	Tindakan mitigasi besar besaran dimana <i>radiative forcing</i> mencapai 3 W/m ² pada tahun 2100
RCP 4.5	Upaya mitigasi moderat dimana nilai <i>radiative forcing</i> mencapai 4.5 W/m ² pada tahun 2100
RCP 8.5	Tindakan mitigasi yang signifikan dimana nilai <i>radiative forcing</i> mencapai 8.5 W/m ² pada tahun 2100

Tahapan selanjutnya adalah dengan mengatur beberapa konfigurasi pada *software Statistical Downscaling Model* (SDSM) sehingga pemrosesan model yang dapat berjalan dengan baik. Pertama, dilakukan pengaturan pada pemrosesan *optimization alghorithm* dengan memilih proses *ordinary least square*. Proses ini dipilih karena dapat digunakan untuk mengoptimalkan parameter dalam model *downscaling* sehingga hasilnya sesuai dengan data observasi sebaik mungkin. Mengenai curah hujan dipilih *event threshold* sebesar 0,3 yang menyatakan ambang batas suatu hari dikatakan sebagai hari kering jika nilainya dibawah 0,3 mm/hari. Mengenai *process* dipilih *unconditional process* atau *conditional process*. Unconditional process dipilih saat pengembangan model statistik yang dilakukan tidak bergantung pada kondisi atau kejadian tertentu, seperti pada suhu udara, kelembapan, dan variabel-variabel lainnya. Sementara itu, *conditional process* dipilih Ketika pengembangan model statistik mempertimbangkan variabilitas lokal atau faktor-faktor kondisional tertentu atau model *downscaling* memperhitungkan informasi atau variabel tambahan yang dapat mempengaruhi variabel iklim pada skala yang lebih kecil, seperti topografi, penggunaan lahan, atau variabel iklim lokal lainnya. Konfigrasi ini dipilih saat menjalankan model curah hujan.

Pemilihan prediktor dilakukan dari variabel prediktor yang memiliki hubungan yang kuat dengan kondisi cuaca lokal. Kuatnya hubungan prediktor dan prediktan dilihat dari nilai korelasi parsial dan nilai *P-value*. Dalam hal ini, pemilihan variabel prediktor dipilih dengan melihat nilai korelasi parsial yang terbesar. Apabila nilai korelasi parsial semakin besar maka hubungan antara variabel prediktor semakin kuat ketika memperhitungkan efek dari variabel lain. Selain itu, variabel prediktor yang dipilih memiliki nilai *P-value* kecil dipilih karena menunjukkan bahwa variabel yang diuji (prediktor) memiliki dampak yang signifikan terhadap variabel target yang ingin diprediksi. Hal ini dilakukan dengan memilih 2-3 prediktor. Setelah itu, dilakukan kalibrasi dari variabel prediktor terpilih agar bias yang terjadi antara model dan observasi semakin berkurang sehingga model lebih akurat. Model yang telah dikalibrasi akan divalidasi dengan menentukan nilai *Correlation coefficient* (R), *Root Mean Squared Error* (RMSE), *Coefficient of Determination* (R^2), *Percent bias* (PBIAS), dan Nash-Sutcliffe *Efficiency* (NSE).

Sebagai tambahan, terkhusus untuk pemodelan curah hujan, karena data berasal dari 4 stasiun acuan yang berbeda maka data yang dijadikan data observasi akan diwakili oleh curah hujan wilayah yang merupakan rata-rata dari hasil pengukuran beberapa stasiun dengan metode pengukuran *polygon* Thiessen. Metode ini dipandang cukup baik karena memberikan koreksi terhadap kedalaman hujan sebagai fungsi luas daerah yang dianggap mewakili. Hal ini dilakukan dengan menggunakan Persamaan 12 (Amrulloh et al., 2021).

$$R = \frac{\sum_{i=1}^n A_i R_i + A_2 R_2 + \dots + A_n R_n}{\sum_{i=1}^n A_1 + A_2 + \dots + A_n} \quad (12)$$

Keterangan:

A_n = luas area pengaruh pada stasiun hujan ke-n

R_n = curah hujan di stasiun hujan ke-n

R = Curah hujan rata-rata di area penelitian

Setelah itu, model yang dibuat akan divalidasi dengan mencari nilai *Correlation coefficient*, *Root Mean Squared Error*, *Coefficient of Determination*, *Percent bias*, Nash-Sutcliffe *Efficiency*. Jika hasilnya baik maka akan dilakukan untuk memodelkan prediksi cuaca pada tahun 2045 di area kajian.


Prediksi Penggunaan Lahan dengan CA-Markov Model

Tahapan dalam prediksi debit dan limpasan dengan SWAT sama seperti tahapan sebelumnya. Namun, data prediksi penggunaan lahan dan prediksi cuaca akan dijadikan input pada simulasi hidrologi dengan SWAT sehingga didapatkan respons hidrologi dari perubahan penggunaan lahan yang terjadi.

HASIL DAN PEMBAHASAN


Analisis Perubahan Penggunaan Lahan di Sub DAS Cisangkuy, Citarik, Cirasea, dan Cikapundung pada tahun 2016 dan 2022

Berdasarkan analisis klasifikasi penggunaan lahan dengan metode supervised classification dengan SVM, diperoleh hasil visualisasi berupa peta perubahan penggunaan lahan pada tahun 2016 (Gambar 2) dan pada tahun 2022 (Gambar 3).



Gambar 2. Peta Penggunaan Lahan pada Tahun 2016 dan 2022

Berdasarkan Gambar 2, diperoleh data penambahan dan pengurangan luas pada masing-masing penggunaan lahan pada tahun 2016 dan 2022 seperti yang terlihat pada Gambar 3.



Gambar 3. Perubahan Penggunaan Lahan pada Tahun 2016 dan 2022

Berdasarkan Gambar 3, terdapat indikasi bahwa telah terjadi konversi penggunaan lahan yang cukup besar pada perkebunan, semak/belukar, savana/padang rumput, dan tanah terbuka menjadi permukiman dan sawah. Hal ini mengindikasikan terdapat

kebutuhan papan dan pangan yang meningkat. Hal ini sesuai dengan pernyataan bahwa pertumbuhan penduduk yang pesat bukan hanya menciptakan tekanan pada lahan untuk pemukiman, tetapi juga memicu perubahan dalam pola konsumsi dan kebutuhan pangan (Sugiharto & Agustin, 2023). Selain itu, perubahan penggunaan lahan dari kawasan hutan menuju kawasan nonhutan akan berdampak pada berubahnya respon DAS (Daerah Aliran Sungai) terhadap hujan sehingga meningkatkan intensitas dan frekuensi terjadinya banjir (Hariati et al., 2022).

Analisis Prediksi Perubahan Penggunaan Lahan di Sub DAS Cisangkuy, Citarik, Cirasea, dan Cikapundung pada tahun 2045

Prediksi perubahan penggunaan lahan, dilakukan dengan menginput data spasial penggunaan lahan tahun 2016 dan 2020. Selanjutnya dilakukan pengetesan kemampuan dari variabel-variabel spasial (lihat Tabel 8).

Tabel 8. Variabel-Variabel Prediktor yang Digunakan Pada Simulasi

Input Files	
Independent variable 1	Vegetated_dist
Independent variable 2	All_to_urban_tren_3rd
Independent variable 3	Slope_AOI
Independent variable 4	Permukiman_dist
Independent variable 5	River_dist
Independent variable 6	Road_dist
Independent variable 7	DEM_AOI
Training site file	Future_Train

Variabel-variabel (*driven factors*) di atas dipilih karena dianggap akan mempengaruhi perubahan penggunaan lahan. Jarak dari area bervegetasi akan mempengaruhi nilai dari *land surface temperature* karena tanaman dapat menyerap panas dan mengurangi radiasi matahari yang mencapai permukaan tanah. Hal ini akan mempengaruhi indeks kenyamanan tempat tinggal. *Slope* dapat mempengaruhi tingkat erosi dan kestabilan lereng sehingga hal ini mempengaruhi kecocokan dalam menyediakan lahan untuk pertanian dan keamanan. Selain itu, *slope* mempengaruhi keterbatasan akses terhadap infrastruktur sehingga membatasi dalam pemanfaatan lahan untuk tujuan tertentu. Elevasi akan mempengaruhi dalam pemilihan jenis tanaman untuk dibudidayakan sebagai tanaman pertanian dan mempengaruhi keterbatasan akses terhadap infrastruktur/fasilitas. Selain itu, elevasi juga mempunyai pengaruh terhadap iklim mikro di sekitar wilayah sehingga mempengaruhi indeks kenyamanan untuk tinggal. Jarak dari sungai akan mempengaruhi ketersediaan irigasi untuk pertanian, beresiko terhadap bencana banjir, dan kemudahan dalam pemanfaatan sumber daya air. Jarak dari permukiman cenderung mengalami tekanan untuk dikembangkan sebagai daerah perkotaan (ekspansi permukiman) karena ketersediaan terhadap infrastruktur/fasilitas dan aktivitas ekonomi. Kemudian, *driven factors* yang telah ditentukan dilakukan *backward stepwise constant forcing* untuk melihat akurasi dari setiap kombinasi variabel-variabel terpilih seperti pada Tabel 9.

Tabel 9. Hasil *Backward Stepwise Regression*


<i>Model</i>	<i>Variables included</i>	<i>Accuracy (%)</i>	<i>Skill measure</i>
<i>With all variables</i>	All variables	68.09	0.5883
<i>Step 1: var.[6] constant</i>	[1,2,3,4,5,7]	65.42	0.5652
<i>Step 2: var.[6,1] constant</i>	[2,3,4,5,7]	65.63	0.5670
<i>Step 3: var.[6,1,4] constant</i>	[2,3,5,7]	63.73	0.5506
<i>Step 4: var.[6,1,4,2] constant</i>	[3,5,7]	63.73	0.5506
<i>Step 5: var.[6,1,4,2,3] constant</i>	[5,7]	59.23	0.5117
<i>Step 6: var.[6,1,4,2,3,5] constant</i>	[7]	37.06	0.3201

Berdasarkan Tabel 9, dari kombinasi yang dilakukan model terbaik dari variabel prediktor berdasarkan tingkat akurasi dan ukuran keterampilan dengan secara berurutan menghilangkan variabel prediktor terlemah satu per satu (Rahmadya, 2021). Hasil pada Tabel 9 membuktikan bahwa kombinasi 7 variabel prediktor menghasilkan kombinasi model terbaik dengan tingkat akurasi sebesar 68.09% dan ukuran keterampilan sebesar 0,5883. Selain itu, menurut analisis yang dilakukan variabel yang paling berpengaruh adalah variabel ke-7. Sementara itu, variabel paling tidak berpengaruh adalah variabel ke-6. Selanjutnya, diperoleh potensi matriks transisi (*matrix probability*) perubahan penggunaan lahan pada setiap tipe kelas penggunaan lahan. Matriks transisi adalah matriks yang menunjukkan pergantian penggunaan lahan ke penggunaan lahan lainnya. Matriks ini akan dijadikan acuan dalam melakukan prediksi penggunaan lahan bersama dengan variabel dan model yang akan digunakan (Rahmadya, 2021).

Tabel 10. Tabel Matriks Transisi Perubahan Penggunaan Lahan

<i>Land Use</i>	RICE	FRST	URMD	AGRL	WTR	PAST
RICE	0.681	0.065	0.023	0.089	0.006	0.114
FRST	0.132	0.665	0.010	0.098	0.005	0.086
URMD	0.130	0.001	0.337	0.021	0.028	0.040
AGRL	0.033	0.1526	0.037	0.627	0.001	0.158
WATR	0.479	0.0275	0.054	0.013	0.380	0.013
PAST	0.193	0.032	0.039	0.181	0.002	0.340

Berdasarkan nilai *matrix probability*, *machine learning* akan mempelajari pola yang ada sehingga akan menghasilkan peta prediksi penggunaan lahan seperti Gambar 4.



Gambar 4. Peta Prediksi Penggunaan Lahan Pada Tahun 2022

Selanjutnya akan dilakukan uji akurasi dengan membandingkan hasil luas kelas penggunaan lahan model dengan acuan seperti yang terlihat pada Tabel 11.

Tabel 11. Nilai Akurasi Tiap Kelas dengan Membandingkan Luas Model dan Acuan

Land Use	Act (ha)	Pct (ha)	Diff (ha)	Pct (%)	Accur (%)
RICE	40174	34946	-5228	-13.01	86.98
FRST	23329	22432	-897	-3.84	96.15
URMD	31348	45966	14618	46.63	53.36
AGRL	20028	15951	-4077	-20.35	79.64
WATR	1976	2014	38	1.92	98.07
PAST	19032	16124	-2908	-15.27	84.72

Keterangan pada Tabel 11 sama dengan keterangan pada Tabel 3

Validasi yang dilakukan selanjutnya adalah dengan melakukan *accuracy assessment* pada model yang terbentuk seperti yang terlihat pada Tabel 12-15.

Tabel 12. *Producers Accuracy* Prediksi Penggunaan Lahan Pada Tahun 2022

<i>Land Use</i>	TP	TP+FN	<i>Producers Accuracy (%)</i>
RICE	15	19	0.789
FRST	11	12	0.916
URMD	14	16	0.875
AGRL	6	8	0.750
WATR	1	1	1
PAST	7	9	0.778

Keterangan pada Tabel 12 sama seperti Persamaan (3)

Tabel 13. *Users Accuracy* Prediksi Penggunaan Lahan Pada Tahun 2022

<i>Land Use</i>	TP	TP+FP	<i>Users Accuracy (%)</i>
RICE	15	19	0.789
FRST	11	12	0.916
URMD	14	16	0.875
AGRL	6	7	0.857
WATR	1	2	0.500
PAST	7	9	0.778

Keterangan pada Tabel 13 sama seperti Persamaan (4)

Tabel 14. *Overall Accuracy* Prediksi Penggunaan Lahan Pada Tahun 2022

Jumlah Prediksi Benar	Jumlah Total Data	<i>Overall Accuracy</i>
54	65	0.830

Keterangan pada Tabel 14 sama seperti Persamaan 2

Tabel 15. *Kappa Coefficient* Prediksi Penggunaan Lahan Pada Tahun 2022


Jumlah Total Data	Jumlah Prediksi Benar	Pr(e)	Koefisien Kappa
65	54	0.213	0.785

Keterangan pada Tabel 15 sama seperti Persamaan (2,4, dan 6)

Hasil prediksi penggunaan lahan (model) pada *area of interest* menghasilkan *producers accuracy* seperti yang terlihat pada Tabel 12. *Producers Accuracy* menggambarkan keadaan sebenarnya dari data referensi/acuan/observasi. Sementara itu, hasil *Users Accuracy* model dapat dilihat pada Tabel 13. Perlu diingat bahwa *Users Accuracy* mengukur keandalan dalam pemasukan data dalam kategori/kelas tertentu.


Disamping itu, berdasarkan pengujian yang dilakukan, didapatkan nilai *Overall Accuracy* sebesar 0,830 dan nilai kappa sebesar 0,785. Hasil uji kappa lebih terpakai dibandingkan dengan *overall accuracy* karena koefisien kappa memperhitungkan tingkat kesepakatan antara hasil klasifikasi yang diamati dan hasil klasifikasi yang diharapkan secara acak, sementara *overall accuracy* hanya memperhitungkan jumlah klasifikasi yang benar dibagi dengan jumlah total sampel. Dengan demikian, koefisien kappa memberikan gambaran yang lebih komprehensif tentang seberapa baik model klasifikasi dalam memprediksi kelas sebenarnya dibandingkan dengan *overall accuracy* yang dapat dipengaruhi oleh distribusi kelas yang tidak seimbang. Oleh karena itu, koefisien kappa

sering dianggap sebagai pendekatan yang lebih dapat diandalkan dalam mengevaluasi kinerja model klasifikasi Berdasarkan hasil uji akurasi yang dilakukan, model yang ada dianggap baik untuk dilakukan pemroyeksian perubahan penggunaan lahan di *area of interest* pada tahun 2045 seperti yang terlihat pada Gambar 5.



Gambar 5. Peta Prediksi Penggunaan Lahan Pada Tahun 2045

Dari Gambar 4 dan Gambar 5, dapat terlihat bahwa telah terjadi pengurangan penggunaan lahan di *area of interest* dari tahun 2022 dan 2045. Hal ini divisualisasikan oleh Gambar 6.




Gambar 6. Penambahan dan Pengurangan Penggunaan Lahan Pada Tahun 2022 dan 2045

Penggunaan lahan permukiman cenderung semakin bertambah, sedangkan penggunaan lahan lain semakin berkurang terjadi karena dalam memprediksi penggunaan lahan menggunakan skenario *Business as Usual* (BAU). Dalam skenario BAU, peningkatan jumlah bangunan (*built up*) semakin tinggi terutama di lahan-lahan bervegetasi, sedangkan penggunaan lahan lainnya mengalami pengurangan.

Analisis Proyeksi Perubahan Cuaca di Sub DAS Cisangkuy, Citarik, Cirasea, dan Cikapundung

Dilakukan pemodelan perubahan cuaca lokal dengan *software* SDSM. Dalam menghitung curah hujan rata-rata digunakan perhitungan dengan pendekatan *Polygon Thiessen*.



Gambar 7. Peta Polligon Thiessen

Tabel 16. Luas Area Berdasarkan *Polygon Thiessen*


Stasiun	Luas (ha)	Luas (%)
Dago Pakar - Bengkok	24542.07	17.856
Dayeuh Kolot	22851.75	16.626
Cibeureum	40350.28	29.358
Rancaekek	49696.39	36.158

Selanjutnya, dilakukan pemodelan prediksi cuaca lokal dengan masing-masing skenario RCP pada setiap parameter cuaca lokal, seperti curah hujan, temperatur maksimum, temperatur minimum, radiasi sinar matahari, kecepatan angin, dan kelembapan relatif. Parameter-parameter ini dipilih karena akan mempengaruhi neraca air, Dimana jumlah presipitasi sama dengan jumlah evapotranspirasi, perubahan *ground water storage*, dan total *runoff*. Parameter-parameter cuaca akan mempengaruhi jumlah presipitasi dan jumlah evapotranspirasi yang terjadi.

Tabel 17. Hasil Performa Setiap Skenario pada Curah Hujan

Model	R	RMSE	R ²	PBIAS	NSE
RCP 2.6	0.861	2.233	0.742	-0.301	0.399
RCP 4.5	0.849	3.629	0.721	-0.479	0.394
RCP 8.5	0.818	2.728	0.818	-0.359	0.379

Model curah hujan yang diperoleh berasal dari prediktor yang berbeda-beda pada setiap skenario. Pada RCP 2.6 dipilih prediktor 1000 hPa *Zonal wind component* dan *Air temperature at 2 m*. Pada RCP 4.5 dipilih prediktor *Air temperature at 2 m* dan 1000 hPa *Specific humidity*. Sementara itu, pada RCP 8.5 dipilih prediktor *Air temperature at 2 m* dan 1000 hPa *Specific humidity*. Selain itu, model menghasilkan nilai R yang sangat kuat, R² yang tinggi, serta nilai NSE dengan kriteria memenuhi.




Gambar 8. Jumlah Curah Hujan di Setiap Skenario pada Tahun 2045

Pada RCP 2.6 selama setahun diperkirakan akan terjadi curah hujan sebesar 2.628,76 mm/tahun di tahun 2045. Pada RCP 4.5 di tahun 2045 diperkirakan akan terjadi curah hujan sebesar 2.694,58 mm/tahun. Sementara itu, pada RCP 8.5 di tahun 2045 diperkirakan akan terjadi 2.793,94 mm/tahun. Berdasarkan hasil prediksi ini diketahui bahwa semakin meningkat *radiative forcing* akan meningkatkan intensitas curah hujan. Hal ini dikarenakan semakin hangat atmosfer akan menyebabkan peningkatan pada kemampuan untuk menahan kelembapan sehingga akan memicu hujan yang lebih tinggi intensitasnya.

Tabel 18. Hasil Performa Setiap Skenario pada Temperatur Maksimum

Model	R	RMSE	R ²	PBIAS	NSE
RCP 2.6	0.72	0.02	0.52	0.02	0.42
RCP 4.5	0.73	0.005	0.54	-0.005	0.53
RCP 8.5	0.79	0.01	0.63	0.01	0.59

Model temperatur maksimum yang diperoleh berasal dari prediktor yang berbeda-beda pada setiap skenario. Pada RCP 2.6 dipilih prediktor 1000 hPa *Meridional wind component* dan *Air temperature at 2 m*. Pada RCP 4.5 dipilih prediktor 1000 hPa *Meridional wind component* dan 850 hPa *Specific humidity*. Sementara itu, pada RCP 8.5 dipilih prediktor 1000 hPa *Meridional wind component* dan *Air temperature at 2 m*. Selain itu, model menghasilkan nilai R yang kuat, R² yang sedang, serta nilai NSE dengan kriteria memenuhi.


**Gambar 9. Rata-Rata Temperatur Maksimum di Setiap Skenario pada Tahun 2045**

Pada RCP 2.6 selama setahun diperkirakan suhu maksimum rata-rata di *area of interest* akan berada di angka 30,59 °C. Dalam setahun, dengan RCP 4.5, diperkirakan menghasilkan suhu rata-rata maksimum sebesar 30,61 °C, Sementara itu, pada RCP 8.5, dalam setahun diprediksi suhu rata-rata maksimum mencapai 30,64 °C. Berdasarkan hasil prediksi, peningkatan *radiative forcing* akan meningkatkan temperatur maksimum. Hal ini dikarenakan meningkatnya *radiative forcing* akan disebabkan oleh meningkatnya gas rumah kaca karena gas-gas ini akan menjebak panas di atmosfer.

Tabel 19. Hasil Performa Setiap Skenario pada Temperatur Minimum

Model	R	RMSE	R ²	PBIAS	NSE
RCP 2.6	0.722	0.012	0.521	-0.017	0.509
RCP 4.5	0.74	0.031	0.556	-0.047	0.486
RCP 8.5	0.915	0.0057	0.838	0.0086	0.815

Model temperatur minimum yang diperoleh berasal dari prediktor yang berbeda-beda pada setiap skenario. Pada RCP 2.6 dipilih prediktor 1000 hPa *Specific humidity* dan *Air temperature at 2 m*. Pada RCP 4.5 dipilih prediktor 850 hPa *Zonal wind component*, 1000 hPa *Specific humidity*, dan *Air temperature at 2 m*. Sementara itu, pada RCP 8.5 dipilih prediktor 850 hPa *Meridional wind component* dan 1000 hPa *Specific humidity*. Selain itu, model menghasilkan nilai R yang kuat-sangat kuat, R² yang sedang-tinggi, serta nilai NSE dengan kriteria memenuhi-baik.




Gambar 10. Rata-rata Temperatur Minimum di Setiap Skenario pada Tahun 2045

Pada RCP 2.6 selama setahun diperkirakan suhu minimum rata-rata di *area of interest* akan berada di angka 19,47 °C. Dalam setahun, dengan RCP 4.5, diperkirakan menghasilkan suhu rata-rata minimum sebesar 19,29 °C, Sementara itu, pada RCP 8.5, dalam setahun diprediksi suhu rata-rata minimum mencapai 19,41 °C. Berdasarkan hasil prediksi, peningkatan *radiative forcing* akan meningkatkan temperatur maksimum. Hal ini dikarenakan meningkatnya *radiative forcing* akan disebabkan oleh meningkatnya gas rumah kaca karena gas-gas ini akan menjebak panas di atmosfer. Namun, hubungan antara *radiative forcing* dan suhu bersifat kompleks dan dapat dipengaruhi oleh berbagai macam faktor.

Tabel 20. Hasil Performa Setiap Skenario pada Kecepatan Angin

Model	R	RMSE	R ²	PBIAS	NSE
RCP 2.6	0.860	0.006	0.740	-0.112	0.734
RCP 4.5	0.713	0.005	0.509	-0.111	0.494
RCP 8.5	0.709	0.002	0.502	0.056	0.485

Model kecepatan angin yang diperoleh berasal dari prediktor yang berbeda-beda pada setiap skenario. Pada RCP 2.6 dipilih prediktor 1000 hPa *Wind direction*, 850 hPa *Wind speed*, 850 hPa *Zonal wind component*. Pada RCP 4.5 dipilih prediktor 1000 hPa *Zonal wind component* dan 850 hPa *Wind speed*. Sementara itu, pada RCP 8.5 dipilih prediktor 1000 hPa *Wind speed* dan 1000 hPa *Zonal wind component*. Selain itu, model menghasilkan nilai R yang kuat-sangat kuat, R² yang sedang-tinggi, serta nilai NSE dengan kriteria memenuhi.




Gambar 11. Rata-Rata Kecepatan Angin di Setiap Skenario pada Tahun 2045

Berdasarkan Gambar 11, skenario RCP 2.6, diprediksi pada tahun 2045 kecepatan angin rata-rata dalam setahun mencapai 1,50 m/s². Pada RCP 4.5 diprediksi pada tahun 2045 diperoleh kecepatan angin rata-rata sebesar 1,47 m/s². Sementara itu, pada RCP 8.5, diprediksi pada tahun 2045 kecepatan angin rata-rata dalam setahun mencapai 1,49 m/s². Pengaruh dari *radiative forcing* terhadap kecepatan angin sangatlah kompleks dan melibatkan beberapa aspek dalam prosesnya. Perubahan keseimbangan energi dan suhu bumi akan menyebabkan perubahan pada pola sirkulasi yang mempengaruhi kecepatan angin.

Tabel 21. Hasil Performa Setiap Skenario pada Kelembapan Relatif

Model	R	RMSE	R ²	PBIAS	NSE
RCP 2.6	0.730	0.150	0.534	-0.049	0.475
RCP 4.5	0.889	0.014	0.791	0.004	0.620
RCP 8.5	0.748	0.006	0.560	0.002	0.485

Model kelembapan relatif yang diperoleh berasal dari prediktor yang berbeda-beda pada setiap skenario. Pada RCP 2.6 dipilih prediktor 500 hPa *Geopotential* dan 850 hPa *Zonal wind component*. Pada RCP 4.5 dan 8.5 dipilih prediktor 500 hPa *Geopotential* dan 1000 hPa *Specific humidity*. Selain itu, model menghasilkan nilai R yang sangat kuat-sangat kuat, R² yang sedang-tinggi, serta nilai NSE dengan kriteria memenuhi.




Gambar 12. Rata-Rata Kelembapan Relatif di Setiap Skenario pada Tahun 2045

Berdasarkan Gambar 12, selama tahun 2045, pada RCP 2.6, diprediksi diperoleh kelembapan relatif rata-rata sebesar 88,57%. Dalam setahun pada 2045, RCP 4.5 diprediksi memiliki kelembapan relatif rata-rata sebesar 88,76%. Sementara itu, pada RCP 8.5 diprediksi diperoleh kelembapan relatif rata-rata sebesar 88,72%. Hal ini dikarenakan pengaruh suhu, Dimana udara yang lebih hangat mampu memiliki kemampuan memegang kelembapan yang lebih tinggi dibandingka udara yang dingin. Udara yang lebih hangat lebih menyimpan banyak energi sehingga menciptakan banyak ruang untuk uap air tersimpan.

Tabel 22. Hasil Performa Setiap Skenario pada Radiasi Sinar Matahari

Model	R	RMSE	R ²	PBIAS	NSE
RCP 2.6	0.872	0.064	0.761	-0.104	0.380
RCP 4.5	0.917	0.063	0.842	0.104	0.428
RCP 8.5	0.849	0.034	0.722	0.056	0.379

Model radiasi sinar matahari yang diperoleh berasal dari prediktor yang berbeda-beda pada setiap skenario. Pada RCP 2.6 dipilih prediktor 1000 hPa *Wind speed* dan 500 hPa *Relative vorticity of true wind*. Pada RCP 4.5 dan 8.5 dipilih prediktor 1000 hPa *Wind speed* dan 1000 hPa *Meridional wind component*. Selain itu, model menghasilkan nilai R yang sangat kuat, R² yang tinggi, serta nilai NSE dengan kriteria memenuhi.




Gambar 13. Rata-Rata Radiasi Sinar Matahari di Setiap Skenario pada Tahun 2045

Berdasarkan Gambar 13, pada tahun 2045 dengan RCP 2.6 diprediksi terjadi rata-rata radiasi sinar matahari sebesar 17,74 MJ/m²/hari. Pada RCP 4.5 diprediksi terjadi radiasi sinar matahari rata-rata dalam setahun sebesar 17,63 MJ/m²/hari. Sementara itu, pada RCP 8.5 pada tahun 2045 diprediksi akan terjadi radiasi sinar matahari rata-rata sebesar 17,72 MJ/m²/hari. Peningkatan *radiative forcing* akan meningkatkan radiasi sinar matahari karena *radiative forcing* adalah perbedaan antara radiasi sinar matahari yang masuk dan radiasi sinar matahari yang keluar.

Analisis Kondisi Biofisik di di Sub DAS Cisangkuy, Citarik, Cirasea, dan Cikapundung


Setelah melakukan delineasi dengan QSWAT, terdapat perbedaan luasan batas wilayah (cekungan) yang terbentuk di Sub-DAS Cisangkuy, Citarik, Cirasea, dan Cikapundung antara model dan data acuan dari Balai Pengelolaan Daerah Aliran Sungai (BPDAS). Dari model yang terbentuk didapatkan luas cekungan sebesar 137.440,48 ha, sedangkan menurut data batas sub-DAS dari BPDAS diperoleh luasan sebesar 148.949,71

ha (lihat Gambar 14). Dalam proses delineasi kawasan, keterbatasan dalam delineasi mungkin terjadi karena ketersediaan data spasial untuk spasial mempunyai resolusi spasial yang kurang baik.




Gambar 14. Peta Hasil Delineasi

Setelah melakukan delineasi, dilakukan pembentukan *Hydrological Response Unit* (HRU). Hal ini dilakukan dengan meng-*overlay* data penggunaan lahan, jenis tanah, dan kelerengan kawasan. HRU yang terbentuk akan memberikan informasi mengenai karakteristik Sub-DAS.




Gambar 15. Peta Jenis Tanah

Berdasarkan analisis spasial yang dilakukan Sub-DAS Cisangkuy, Citarik, Cirasesa, dan Cikapundung didominasi oleh jenis tanah Latosol. Tanah ini menyelimuti kawasan seluas 52.678,75 ha. Latosol adalah jenis tanah yang terbentuk dari pelapukan batuan beku dan sedimen. Selain itu, tanah ini memiliki porositas dan permeabilitas yang rendah karena tekstur tanahnya cenderung berlempung. Tanah andosol meliputi kawasan seluas 44.240,68 ha. Umumnya, dalam keadaan alami, andosol memiliki porositas yang cukup dan struktur tanah yang stabil akibat terbentuk dari material vulkanik sehingga dapat memungkinkan hujan terinfiltrasi dengan baik. Tanah Alluvial melapisi kawasan seluas 27.659,89 ha. Alluvial memiliki kapasitas penyimpanan air yang besar, porositas yang baik, dan permeabilitas yang baik karena berasal dari endapan yang dibawa oleh aliran air (Driessen, 2001). Tanah podsol merah-kuning meng-cover 12.786,23 ha dari luas kawasan. Podsol merah-kuning porositas yang rendah dan permeabilitas yang tinggi. Tanah ini berasal dari proses pencucian bahan organik dan mineral dari lapisan atas tanah. Sementara itu, tanah regosol terdapat pada 75,87 ha kawasan. Regosol merupakan jenis tanah muda yang terbentuk dari material vulkanik, batuan sedimen, atau endapan aluvial yang belum mengalami proses pembentukan tanah yang intensif sehingga kemampuan menyerap dan melewatkan air tergantung struktur dan teksturnya.




Gambar 16. Peta Kelerengan

Berdasarkan analisis spasial dengan mengolah data DEMNAS didapatkan data *slope* (kemiringan lahan) di *area of interest*. Umumnya di bagian Kota Bandung kemiringan lahan berkisar antara 0-8%. Sementara itu, di sekitar pegunungan yang mengelilingi Kota Bandung didapatkan kelerengan curam-sangat curam. Hubungan antara *slope* dengan limpasan, yaitu meningkatnya kemiringan lereng berkorelasi positif dengan meningkatnya limpasan yang terjadi (Jourgholami et al., 2020). Langkah selanjutnya dalam simulasi hidrologi adalah meng-*input* data cuaca lokal seperti yang terlihat pada Gambar 17-21.



Gambar 17. Rata-Rata Temperatur Maksimum dan Minimum di Pos Staslon Iklim Ciparay Tahun 2022


Temperatur mempengaruhi jumlah *runoff* dan *streamflow* secara signifikan. Temperatur mempengaruhi kecepatan proses evapotranspirasi ataupun evaporasi yang terjadi di tumbuhan atau permukaan tanah. Oleh karena itu, temperatur dianggap akan secara langsung mempengaruhi neraca air yang berpengaruh juga terhadap jumlah *runoff* dan *streamflow* di suatu cekungan. Menurut Gambar 16, pada tahun 2022 diperoleh temperatur rata-rata tahunan sebesar 30,25 °C. Temperatur maksimum tertinggi terjadi di bulan April yaitu sebesar 30,83 °C, sedangkan temperatur maksimum terendah terjadi di bulan Desember sebesar 29 °C. Selain itu, pada tahun 2022 diperoleh temperatur tahunan rata-rata sebesar 19,41 °C. Temperatur minimum tertinggi terjadi di bulan Juni sebesar 20,43 °C, sedangkan temperatur minimum terendah terjadi di bulan Agustus dengan suhu pada angka 18,42 °C.



Gambar 18. Jumlah Curah Hujan Bulanan di Pos Staslon Pengamatan Curah Hujan Dayeuhkolot Dago Pakar, Cibereum, dan Rancaekek pada Tahun 2022


Berdasarkan Gambar 18, hujan terjadi dengan intensitas tinggi di bulan Januari-Mei dan Oktober-Desember. Pada Pos Curah Hujan Dayeuhkolot didapatkan jumlah curah hujan dalam setahun sebesar 2039,89 mm. Pos Curah Hujan Rancaekek menangkap jumlah curah hujan sebesar 2.215,27 mm. Pos Curah Hujan Dago Pakar-Bengkong menangkap jumlah curah hujan dalam setahun sebesar 1.782,23 mm. Sementara itu, Pos Curah Hujan Cibereum menangkap jumlah curah hujan dalam setahun sebesar 2.159,91 mm.

mm. Curah hujan memiliki pengaruh yang signifikan terhadap besarnya limpasan dan debit. Tingkat curah hujan yang tinggi akan menyebabkan limpasan dan debit sungai yang semakin tinggi. Sementara itu, curah hujan yang rendah akan menyebabkan limpasan dan debit yang cenderung kecil.



Gambar 19. Rata-Rata Kecepatan Angin Bulanan di Pos Staslun Iklim Ciparay pada Tahun 2022


Kecepatan angin mempengaruhi proses evapotranspirasi karena mempengaruhi penyebaran panas dan kelembapan di permukaan tanah atau tumbuhan. Jika kecepatan angin tinggi, maka panas dan kelembapan akan lebih cepat diserap oleh udara sehingga proses evaporasi dan evapotranspirasi akan tinggi. Sebaliknya, jika kecepatan angin rendah maka panas dan kelembapan akan lebih lama disebarkan dan diserap oleh tanah sehingga laju evapotranspirasi akan lebih rendah. Oleh karena itu, kecepatan angin akan mempengaruhi neraca air yang menentukan besarnya *runoff* dan *stream flow* yang terjadi. Berdasarkan Gambar 19, kecepatan angin, maksimum terjadi di bulan Desember (1,58 m/s) dan minimum terjadi di bulan April (1,09 m/s). Selain itu, selama setahun kecepatan angin rata-rata di *area of interest* didapatkan sebesar 1,49 m/s.



Gambar 20. Rata-Rata Kelembapan Relatif Bulanan di Pos Staslun Iklim Ciparay pada Tahun 2022

Kelembapan relatif mempengaruhi evapotranspirasi karena akan mempengaruhi kemampuan udara untuk menampung uap air. Jika kelembapan relatif tinggi maka udara akan cepat jenuh dengan uap air sehingga laju evapotranspirasi akan lebih rendah. Sebaliknya, jika kelembapan relatif rendah maka udara masih dapat menampung uap air lebih banyak sehingga laju evapotranspirasi akan lebih tinggi. Oleh karena itu, akan mempengaruhi neraca air yang berakibat pada besarnya jumlah *runoff* dan *streamflow*.

yang terjadi di suatu cekungan. Berdasarkan Gambar 20, kelembapan relatif terbesar terjadi di bulan Februari (91,52%) dan terendah di bulan September (86,69%). Selain itu, pada tahun 2022 kelembapan relatif rata-rata selama setahun didapatkan sebesar 89,67%.




Gambar 21. Rata-Rata Radiasi Sinar Matahari Bulanan di Pos Stasiun Iklim Ciparay pada Tahun 2022


Radiasi sinar matahari mempunyai peran yang signifikan dalam mempengaruhi besaran *runoff* dan *streamflow* pada suatu cekungan. Sinar matahari akan mempengaruhi suhu yang akan digunakan untuk mengevaporasi dan evapotranspirasi air dari permukaan tanah dan tumbuhan. Oleh karena itu, radiasi sinar matahari akan berpengaruh terhadap keseimbangan neraca air yang berpengaruh terhadap *runoff* dan *streamflow*. Berdasarkan Gambar 21, radiasi sinar matahari maksimum terjadi di bulan September (20,97 MJ/m²/hari) dan terendah di bulan Februari (14,31 MJ/m²/hari). Selain itu, pada tahun 2022 didapatkan radiasi sinar matahari rata-rata tahunan sebesar 17,35 MJ/m²/hari.

Analisis Simulasi Hidrologi debit dan limpasan di Dayeuhkolot pada Tahun 2022

Tahapan selanjutnya, dilakukan simulasi hidrologi untuk mendapatkan debit dan limpasan di *area of interest* (lihat Gambar 22 dan Gambar 23).



Gambar 22. Perbandingan Data Debit Bulanan Rata-Rata Hasil Observasi dan Model Tahun 2022




Gambar 23. Perbandingan Data Debit Harian Rata-Rata Hasil Observasi dan Model Tahun 2022

Dapat dilihat pada tahun 2022 dari bulan Januari-April debit bulanan mengalami kenaikan dan mencapai puncaknya pada bulan April sebesar 99,52 m³/s dengan nilai debit maksimum harian sebesar 282,5 m³/s, setelah itu terus mengalami penurunan sampai bulan Oktober dan mulai beranjak naik dari bulan November-Desember. Selain itu, didapatkan debit bulanan rata-rata dalam setahun sebesar 36,77 m³/s.

Tabel 23. Hasil Statistik untuk Analisis Sensitivitas Model

R	RMSE	R ²	PBIAS	NSE
0.933	0.103	0.735	0.067	0.788

Hasil model tersebut divalidasi dengan data debit harian acuan sehingga didapatkan nilai *Correlation coefficient* (R), *Root Mean Squared Error* (RMSE), *Coefficient of Determination* (R²), *Percent bias* (PBIAS), Nash-Sutcliffe *Efficiency* (NSE) lihat Tabel 23. Nilai R tersebut berfungsi untuk mengukur kekuatan dan arah hubungan linear antara dua variabel. Dalam hal ini, hasil pemodelan menunjukkan nilai 0,993 yang mengindikasikan adanya hubungan linear positif yang sangat kuat. Nilai RMSE sebesar 0,103 menggambarkan model yang lebih akurat karena mendekati nol. Nilai R² sebesar 0,735 berarti bahwa model menjelaskan 73,5% variabilitas pada data. Nilai NSE sebesar 0,788 menggambarkan bahwa model baik dalam memprediksi data yang diakurasi.




Gambar 24. Limpasan Rata-Rata Bulanan Pada Tahun 2022


Selain itu, didapatkan limpasan rata-rata bulanan pada tahun 2022 pada *area of interest* seperti yang terlihat pada Gambar 24. Pada tahun 2022, Limpasan yang terjadi sampai pada puncaknya di bulan Januari (132,54 mm) dan titik limpasan terendah terjadi di bulan Juli (0 mm). Selain itu, didapatkan limpasan rata-rata tahunan sebesar 47,93 mm.

Analisis Prediksi Debit dan Limpasan di Dayeuhkolot pada Tahun 2045

Berikut adalah hasil dari model proyeksi debit bulanan dan debit harian (lihat Gambar 25 dan Gambar 26).




Gambar 25. Perbandingan Rata-Rata Debit Bulanan Hasil Observasi dan Model Tahun 2045




Gambar 26. Perbandingan Rata-Rata Debit Harian Hasil Observasi dan Model Tahun 2045

Terlihat bahwa puncak debit bulanan terjadi di bulan April pada ketiga skenario, RCP 2,6 (110,1 m³/s); RCP 4.5 (114.5 m³/s); RCP 8.5 (110.4 m³/s). Debit bulanan terendah di setiap model terjadi pada bulan Juli, yaitu sebesar 41,88 m³/s pada RCP 2.6; 39,69 m³/s pada RCP 4.5; dan 40,98 m³/s pada RCP 8.5. Selain itu, didapatkan debit maksimum harian pada RCP 2.6 sebesar 278,5 m³/s; RCP 4.5 sebesar 276,3 m³/s; RCP 8.5 sebesar 276 m³/s.




Gambar 27. Perbandingan Debit Rata-Rata Tahunan

Berdasarkan Gambar 27, diprediksi akan terjadi kenaikan debit rata-rata tahunan pada setiap skenario iklim yang terjadi, dimana terjadi kenaikan sebesar 80,59%; 84,44% pada RCP 4.5; dan 91,84% pada RCP 8.5 antara tahun 2022 dan 2045.



Gambar 28. Perbandingan Limpasan Bulanan Rata-Rata Hasil Observasi dan Model Tahun 2045



Gambar 29. Perbandingan Jumlah Limpasan Rata-Rata Tahunan

Dari ketiga skenario limpasan bulanan terbesar terjadi pada bulan Januari dengan besar limpasan 114, 561 mm untuk RCP 2.6; 108,987 mm untuk RCP 4.5; dan 112,594 mm untuk RCP 8.5. Sementara itu, limpasan terendah terjadi di bulan Juni pada RCP 2.6 (15,64 mm) dan 8.5 (19,42 mm), sedangkan RCP 4.5 terjadi di bulan Juli (19,577 mm). Berdasarkan data limpasan tahunan, diprediksi terjadi peningkatan limpasan tahunan sebesar 19, 06% pada RCP 2.6, peningkatan 20,11% pada RCP 4.5, peningkatan sebesar 24, 42% pada RCP 8.5.

KESIMPULAN

Penelitian ini berhasil memproyeksikan perubahan debit dan limpasan Sungai Citarum di Kecamatan Dayeuhkolot pada tahun 2045 dengan mempertimbangkan skenario perubahan tutupan lahan dan iklim. Berdasarkan hasil pemodelan akibat perubahan tutupan lahan dengan skenario *Business As Usual* dan perubahan iklim pada masing-masing RCP, menyebabkan peningkatan aliran permukaan dan debit yang lebih tinggi pada tahun 2045.

Secara spesifik, peningkatan limpasan tahunan terbesar terjadi pada skenario perubahan iklim RCP 8.5 dan skenario perubahan tutupan lahan *Business As Usual*, yaitu sebesar 24,42%. Selain itu, peningkatan debit tertinggi terjadi pada skenario perubahan tutupan lahan dengan skenario *Business As Usual* dan skenario iklim RCP 8.5, yaitu sebesar 91,84%.

UCAPAN TERIMA KASIH

Terima kasih kami ucapkan kepada jajaran Balai Pengelolaan Daerah Aliran Sungai (BPDAS) Citarum-Ciliwung; Badan Meteorologi, Klimatologi dan Geofisika (BMKG) Bogor, Balai Besar Wilayah Sungai Citarum; dan Balai Besar Penelitian dan Pengembangan Sumberdaya Lahan Pertanian (BBSDLP), Balai Besar Wilayah Sungai (BBWS) Citarum, yang telah membantu dalam proses penyediaan data untuk kelancaran penelitian sehingga saya dapat menyelesaikan publikasi ini.

DAFTAR PUSTAKA

- Amali, L. N., Katili, M. R., Suhada, S., Hadjaratie, L., & Mardlatillah, H. (2022). Technology acceptance model in government context: A systematic review on the implementation of IT governance in a government institution. *Jurnal Online Informatika*, 7(1), 80-88. DOI: <https://doi.org/10.15575/join.v7i1.853>.
- Amrulloh, M., Widiarti, W. Y., & Halik, G. (2021). Evaluasi Kinerja Sistem Drainase Jalan Kaliurang Kecamatan Sumbersari Kabupaten Jember. *Jurnal Teknik Pengairan*, 12(2), 81-91. DOI: <https://doi.org/10.21776/ub.pengairan.2021.012.02.01>.
- Bahdi, A. H. (2012, October 29). Soil & Water Assessment Tool. SWAT. Retrieved July 3, 2024 from <https://swat.tamu.edu/docs/>.
- Badan Penanggulangan Bencana Daerah (BPBD) Provinsi Jawa barat. (2023, December). Retrieved August 17, 2024 from <https://bpbd.jabarprov.go.id/>.
- Dewi, A. S., Sitorus, S. R., & Makalew, A. D. (2024). Analisis Perubahan Penggunaan Lahan dan Ruang Terbuka Hijau serta Arahannya di Kota Bandung Provinsi Jawa Barat. *Tataloka*, 26(2), 77-88. DOI: <https://doi.org/10.14710/tataloka.26.2.77-88>.
- Gassman, P. W., Reyes, M. R., Green, C. H., & Arnold, J. G. (2007). The soil and water assessment tool: historical development, applications, and future research directions. *Transactions of the ASABE*, 50(4), 1211-1250. DOI: <https://doi.org/10.13031/2013.23637>.
- Driessen, P. M. (2001). Lecture Notes on the Major Soils of the World. Food & Agriculture Organization of the UN (FAO).
- Eryani, I. G. A. P., Jayantari, M. W., & Wijaya, I. K. M. (2022). Sensitivity Analysis in Parameter Calibration of the WEAP Model for Integrated Water Resources Management in Unda Watershed. *Civil Engineering and Architecture*, 10(2), 455-469. DOI: <https://doi.org/10.13189/cea.2022.100206>.
- Hariati, F., Saputra, D., Alimuddin, A., & Yanuarsyah, I. (2022). Dampak Peningkatan Intensitas Hujan dan Tutupan Lahan Terhadap Debit Banjir Puncak Sungai Ciseel. *Jurnal Komposit*, 4(1), 13-22. DOI: <https://doi.org/10.32832/komposit.v4i1.3748>.
- InaRISK (BNPB). (2020, December 31). Retrieved July 9, 2023, from <https://inarisk.bnpb.go.id/>.
- Islami, F. A., Tarigan, S. D., Wahjunie, E. D., & Dasanto, B. D. (2022). Accuracy assessment of land use change analysis using Google Earth in Sadar Watershed Mojokerto Regency. *IOP Conference Series: Earth and Environmental Science*, 950(1), 012091. DOI: <https://doi.org/10.1088/1755-1315/950/1/012091>.
- Jourgholami, M., Karami, S., Tavankar, F., Lo Monaco, A., & Picchio, R. (2020). Effects of Slope Gradient on Runoff and Sediment Yield on Machine-Induced Compacted Soil in Temperate Forests. *Forests*, 12(1), 49-69. DOI: <https://doi.org/10.3390/f12010049>.
- Mukaka, M. M. (2020, January 15). A guide to appropriate use of Correlation coefficient in medical. PubMed Central. Retrieved July 3, 2024 from <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3576830/>.
- Olofsson, P. (2021). Updates to good practices for estimating area and assessing accuracy of land cover and land cover change products. *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*. DOI: <https://doi.org/10.1109/igarss47720.2021.9554475>.
- Rahmadya, T. (2021, June 10). Land Change Modeler. Clark Labs, Terrset. Retrieved July 3, 2024. from <https://clarklabs.org/terrset/land-change-modeler/>.
- Rudrapal, D., & Subhedar, M. (2015). Land Cover Classification using Support Vector Machine. *International Journal of Engineering Research and Technology*, 4(9), 584-588. DOI: <https://doi.org/10.17577/ijertv4is090611>.
- Smith, G. (2018). Step away from stepwise. *Journal of Big Data*, 5(1), 22-88. DOI: <https://doi.org/10.1186/s40537-018-0143-6>.
- Sugiharto, F., & Agustin, N. (2023). Pengaruh perubahan lahan pertanian menjadi non pertanian terhadap aspek sosial ekonomi masyarakat. *Jurnal Perencanaan dan Pengembangan Kebijakan*, 3(2), 129-143. DOI: <https://doi.org/10.35472/jppk.v3i2.950>.