

BAB II TINJAUAN PUSTAKA

2.1 Hasil Penelitian Terdahulu

Dalam upaya mitigasi bencana hidrometeorologi di wilayah tropis seperti Indonesia, kebutuhan akan data curah hujan resolusi tinggi menjadi sangat krusial. Berdasarkan penelusuran terhadap literatur-literatur terkini (2021–2025), perkembangan teknologi *downscaling* telah berevolusi dari metode statistik konvensional menuju pendekatan *deep learning* generatif.

Tabel 2.1 *The State of The Art*

No	Penulis	Objek Downscaling		Dataset		Algoritma/Arsitektur	
		Curah Hujan	Lainnya	Low Resolution	High Resolution	SRGAN	Lainnya
				CMIP6	Data Satelit/Grid		
1	Lei Fan dkk. (2025)	√	X	X	√	X	√ (CNN)
2	Yichen Wu dkk. (2022)	√	X	X	X	X	√ (GBR, RF, SVM)
3	Neelesh Rampal dkk. (2022)	√	X	X	√	X	√ (CNN)
4	Bipin Kumar dkk. (2023)	√	X	X	√	√	X
5	Norihiko Oyama dkk. (2023)	√	√	X	√	√	X
6	Sanaa Hobeichi dkk. (2023)	X	√	X	√	X	√ (MLP, MLR RF)
7	Midhun Murukesh dkk. (2023)	√	X	X	√	√	X
8	Abbas Yeganeh Bakhtiary dkk. (2022)	X	√	X	√	X	√ (M5 DT)
9	Majid Niazkari dkk. (2022)	X	√	√	X	X	√ (MGGP)
10	Alfonso Hernanz dkk. (2023)	X	√	X	√	X	√ (UNET)
11	Nurul Ainina Filza Sulaiman dkk. (2022)	√	X	X	X	X	√ (SVC RVM)
12	Ahmed M.S. Kheir dkk. (2023)	X	√	X	√	X	√ (CNN)
13	Teerachai Amnuaylojaroen (2023)	X	√	√	√	X	√ (DT, RF, GBM)
14	Marceau Michel dkk. (2022)	X	√	X	X	X	√ (HCNN)
15	Jose González Abad dkk. (2023)	X	√	X	√	X	√ (CNN)
16	Vahid Nourani dkk. (2023)	√	√	√	X	X	√ (LSTM LUBE)

No	Penulis	Objek Downscaling		Dataset		Algoritma/Arsitektur	
		Curah Hujan	Lainnya	Low Resolution	High Resolution	SRGAN	Lainnya
				CMIP6	Data Satelit/Grid		
17	Fang Wang dkk. (2021)	√	√	X	√	X	√ (SRDRN)
18	Yida Liu dkk. (2025)	√	X	X	√	√	X
19	David W. Pierce dkk. (2023)	√	√	√	√	X	√ (LOCA)
20	Guangdi Chen dkk. (2025)	X	√	X	√	√	X
21	Penelitian ini (2026)	√	X	√	√	√	X

Tinjauan terhadap penelitian penelitian terdahulu, yang dirangkum dalam Tabel 1, menunjukkan bahwa pemanfaatan kecerdasan buatan untuk *downscaling* didominasi oleh algoritma *Machine Learning* (ML) klasik. Yichen Wu dkk. mendemonstrasikan bahwa *Random Forest* (RF), *Support Vector Machine* (SVM) dan *Gradient Boosting Regression* (GBR) mampu mereduksi bias statistik pada data curah hujan harian secara lebih efektif dibandingkan Model Regresi Linier (MLR) [14]. Begitu pula Nurul Ainina Filza Sulaiman dkk. pada penelitiannya yang menggunakan pendekatan *hybrid machine learning* dua fase, mengombinasikan *Support Vector Classification* (SVC) untuk klasifikasi kejadian hujan dan *Relevance Vector Machine* (RVM) untuk estimasi jumlah curah hujan [22]. Namun, validitas kedua penelitian ini dalam konteks perubahan iklim masih perlu dikaji lebih lanjut [14], [22]. Hal ini dikarenakan evaluasi model masih terbatas pada data historis dan reanalisis, serta belum diterapkan pada skenario proyeksi iklim masa depan seperti data GCM untuk melihat respons model terhadap kondisi pemanasan global yang berbeda [14], [22]. Abbas Yeganeh Bakhtiary dkk. menerapkan M5' Decision Tree untuk memproyeksikan kecepatan angin masa depan, namun secara eksplisit mengakui bahwa model M5' menghasilkan error yang tinggi di dekat daratan karena tidak mampu menangani perubahan arah angin yang cepat [23]. Teerachai Amnuaylojaroen memang berhasil meningkatkan resolusi data *Coupled Model Intercomparison Project Phase 6* (CMIP6) di Asia Tenggara menggunakan pendekatan ML, namun studi tersebut mengakui bahwa metode klasik yang digunakan belum memanfaatkan kapabilitas *deep learning* yang lebih canggih

untuk menangkap pola spasial yang rumit [24]. Selain itu, Majid Niazkar dkk. yang menggunakan *Multi Gene Genetic Programming* (MGGP) menunjukkan peningkatan akurasi pada prediksi suhu harian. Namun, karena penelitian ini berbasis pada satu titik stasiun pengamatan, analisis distribusi spasial maupun korelasi antar grid tidak tercakup dalam studi tersebut [25]. Di sisi lain, pendekatan statistik *Localized Constructed Analogs* (LOCA) versi 2 yang digunakan David W. Pierce dkk. memiliki keterbatasan fundamental pada asumsi stasioneritas. Algoritma ini sangat bergantung pada analogi pola cuaca masa lalu (1950–2018), sehingga berisiko gagal merepresentasikan variabilitas ekstrem jika perubahan iklim di masa depan menciptakan fenomena atmosfer baru yang belum pernah terekam dalam sejarah (1950–2018) [26].

Keterbatasan metode statistik dan *machine learning* klasik dalam menangkap pola spasial mendorong adopsi pendekatan *deep learning*. Dalam konteks ini, Vahid Nourani dkk. menunjukkan bahwa pendekatan *deep learning* berbasis *Long Short Term Memory* (LSTM) yang dikombinasikan dengan metode *Lower Upper Bound Estimation* (LUBE) mampu meningkatkan akurasi dan mengestimasi ketidakpastian *downscaling* pada data CMIP6, namun pendekatan tersebut masih bersifat *point based* sehingga belum dapat merepresentasikan pola spasial dan korelasi antar grid secara eksplisit [27].

Dalam perkembangan selanjutnya, *Convolutional Neural Networks* (CNN) mulai banyak digunakan untuk *downscaling* iklim karena kemampuannya mengekstraksi fitur spasial. Ahmed M.S. Kheir dkk. membuktikan bahwa model berbasis CNN mampu secara efektif men-*downscale* proyeksi temperatur maksimum dan minimum dari model CMIP6 [28]. Keunggulan CNN di wilayah dengan topografi kompleks juga dikonfirmasi oleh Neelesh Rampal dkk. yang menunjukkan bahwa CNN mampu menangkap pola curah hujan ekstrem di Selandia Baru lebih baik daripada MLR [15]. Meskipun demikian, model ini dilaporkan masih memiliki kecenderungan *dry bias* atau mengestimasi nilai yang lebih rendah dari kenyataan (*underestimate*) pada kejadian curah hujan yang sangat ekstrem [15]. Alfonso Hernanz dkk. mengungkapkan keterbatasan arsitektur UNET (salah satu jenis CNN), di mana meskipun performanya sangat presisi pada *Earth System Model* (ESM) yang sama dengan data latihnya, kemampuannya menurun

drastis saat diterapkan pada ESM yang berbeda hingga setara dengan metode regresi linier biasa [29]. Begitu pula yang terjadi pada Jose González Abad dkk. menemukan bahwa arsitektur CNN yang menggunakan lapisan *dense* mengalami kegagalan pada proyeksi iklim masa depan meskipun performanya terlihat baik pada data historis [30].

Penelitian lain juga menyatakan pendekatan CNN memiliki kelemahan *underestimate* dan *over smoothing*. Seperti penelitian Marceau Michel dkk. untuk data kelautan yang menggunakan model HCNN untuk *downscaling* ketinggian gelombang laut mengalami *underestimate* pada nilai gelombang ekstrem [17]. Penelitian terbaru oleh Lei Fan dkk. juga mencatat bahwa model CNN dengan mekanisme *attention* sekalipun masih mengalami *underestimate* [18]. Meskipun metode yang diusulkan, seperti *Attention Based Laplacian Pyramid Network* (AttLap), berhasil meningkatkan kinerja CNN standar, tetapi evaluasi terhadap indeks iklim ekstrem menunjukkan selisih nilai yang negatif [18].

Untuk mengatasi *underestimate* dan *over smoothing* pada CNN, penelitian beralih ke *Generative Adversarial Networks* (GAN). Bipin Kumar dkk. dan Midhun Murukesh dkk. memberikan bukti bahwa *Super Resolution GAN* (SRGAN) mampu menyelesaikan masalah *underestimate* tersebut [19], [20]. Melalui mekanisme *Adversarial Training* dan penggunaan *Perceptual Loss*, SRGAN mampu memulihkan tekstur hujan yang realistis yang sering hilang pada model CNN biasa [19], [20]. Temuan ini diperkuat oleh Guangdi Chen dkk. yang menerapkan SRGAN untuk suhu permukaan dan berhasil mendapatkan detail spasial yang lebih baik [31]. Meskipun demikian, mayoritas studi SRGAN ini masih dilakukan pada data observasi historis atau reanalisis, dan belum dieksplorasi secara mendalam untuk data proyeksi masa depan CMIP6 secara spesifik [19], [20], [31].


Seiring dengan kemajuan teknologi, varian varian algoritma baru yang lebih canggih dan kompleks terus dikembangkan untuk menyempurnakan hasil *downscaling*. Yida Liu dkk. mengembangkan *Multi Scale SRGAN* (MSRGAN) untuk menangkap fitur presipitasi yang bervariasi ukurannya [21]. Di sisi lain, Norihiro Oyama dkk. mengusulkan *Physics Informed SRGAN* yang memasukkan hukum fisika atmosfer dan data elevasi ke dalam jaringan [32].

Berdasarkan tabel tersebut, penelitian ini mengisi kesenjangan pengetahuan (*research gap*) yang signifikan. Berbeda dengan Midhun Murukesh dkk., Bipin Kumar dkk dan model SRDRN yang dikembangkan Fang Wang dkk. menggunakan inputan data sintetis dari data high resolution, sehingga masih memerlukan pengujian serta penyesuaian lebih lanjut untuk menangani dataset nyata *low resolution*, seperti GCM [19], [20], [33]. Sanaa Hobeichi dkk. mencoba pendekatan hibrida untuk efisiensi komputasi dari *dynamical downscaling*, namun terbatas karena hanya menggunakan data reanalisis yang memiliki bias lebih rendah, sehingga tantangan penskalaan pada GCM sebenarnya mungkin jauh lebih sulit [34]. Penelitian ini mengimplementasikan arsitektur SRGAN secara spesifik pada data GCM terbaru CMIP6 di wilayah tropis Jawa Barat. Dengan menggabungkan keunggulan SRGAN dalam merekonstruksi tekstur dan penggunaan data satelit *Climate Hazards Group InfraRed Precipitation with Station data version 2* (CHIRPS2) sebagai referensi resolusi tinggi, penelitian ini menawarkan solusi untuk menghasilkan proyeksi iklim regional yang tidak hanya akurat secara statistik, tetapi juga realistis secara perseptual guna mendukung mitigasi bencana hidrometeorologi yang lebih akurat.

2.2 Dasar Teori

2.2.1 Deep Learning

Deep Learning (DL) merupakan subbidang dari *machine learning* dan *Artificial Intelligence* yang menggunakan jaringan saraf tiruan berlapis banyak (*deep neural networks*) untuk memodelkan hubungan nonlinier yang kompleks pada data berskala besar. Arsitektur berlapis ini memungkinkan pembelajaran representasi secara hierarkis, di mana setiap lapisan mengekstraksi tingkat abstraksi yang semakin tinggi dari data masukan, sehingga *deep learning* mampu menangani permasalahan dengan kompleksitas tinggi yang sulit diselesaikan oleh metode *shallow learning* (metode *machine learning* selain *deep learning*) [35].



Gambar 2.1 (a) *Shallow Network* (b) *Deep Neural Network* [35]

Gambar 2.1 menunjukkan perbedaan utama antara *shallow learning* dan *deep learning* berdasarkan jumlah lapisan tersembunyinya. *Shallow learning* pada Gambar (a) hanya menggunakan satu lapisan tersembunyi, yang membatasi kemampuannya dalam mempelajari fitur data yang kompleks. Sebaliknya, *deep learning* pada Gambar (b) memiliki banyak lapisan tersembunyi yang memungkinkan terjadinya ekstraksi fitur secara hierarkis dan pembentukan representasi data yang lebih canggih.

Deep learning dibangun di atas berbagai komponen utama, meliputi lapisan jaringan (*layers*), fungsi aktivasi nonlinier (*Activation Functions*), fungsi kerugian (*loss functions*), dan algoritma optimisasi (*Optimization Algorithms*). Kombinasi komponen tersebut memungkinkan proses pelatihan dilakukan secara *end to end* melalui algoritma *backpropagation*, sehingga parameter jaringan dapat disesuaikan secara iteratif untuk meminimalkan kesalahan prediksi [21].

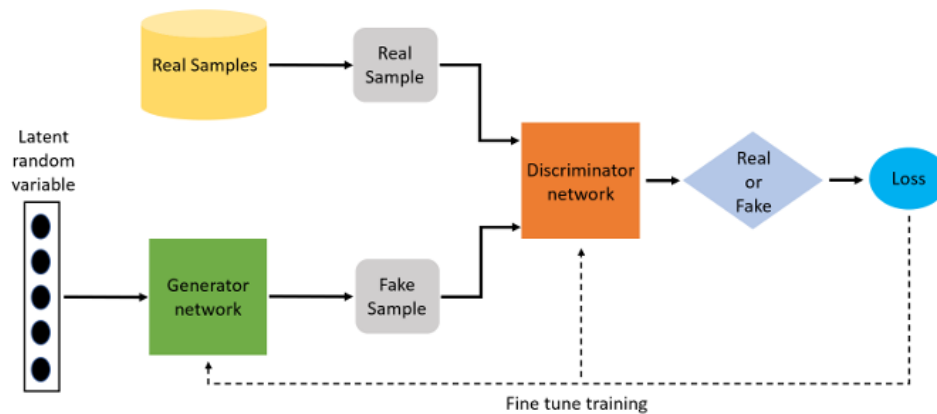
Berbagai pendekatan pembelajaran diterapkan dalam *deep learning*, termasuk pembelajaran terawasi (*supervised learning*), tidak terawasi (*unsupervised learning*), *reinforcement learning*, serta pendekatan hibrida. Pendekatan pendekatan ini memungkinkan *deep learning* digunakan secara fleksibel pada beragam jenis data dan permasalahan, baik yang memiliki label maupun yang tidak [36].

Dalam implementasinya, *deep learning* memanfaatkan beragam arsitektur jaringan yang disesuaikan dengan karakteristik data, seperti *Convolutional Neural Networks* (CNN) untuk data spasial dan *Recurrent Neural Networks* (RNN) untuk data berurutan atau temporal. Selain arsitektur tersebut, *Generative Adversarial Networks* (GAN) merupakan salah satu arsitektur *deep learning* generatif yang dikembangkan untuk mempelajari distribusi data melalui mekanisme *adversarial* antara dua jaringan saraf [35].

Berdasarkan kemampuan *deep learning* dalam mempelajari fitur data yang kompleks dari data berskala besar, pendekatan ini dinilai lebih sesuai untuk memodelkan dinamika curah hujan yang bersifat nonlinier. Oleh karena itu, penelitian ini menggunakan pendekatan *deep learning* berbasis GAN sebagai kerangka pemodelan utama.

2.2.2 Generative Adversarial Network (GAN)

GAN merupakan salah satu arsitektur *deep learning* yang termasuk dalam kelompok *generative models*, yang bertujuan untuk mempelajari distribusi probabilitas data pelatihan dan menghasilkan data sintetis yang menyerupai data asli. GAN dikembangkan untuk menghasilkan sampel baru yang realistis dengan cara mempelajari karakteristik statistik dari data masukan [35], [36], [37].



Gambar 2.2 Arsitektur GAN [37]

Arsitektur umum *Generative Adversarial Network* (GAN) terdiri dari dua komponen utama, yaitu *Generator* dan *Discriminator*, sebagaimana ditunjukkan pada Gambar 2.2 *Generator* (G) menerima masukan berupa vektor *noise* acak Z , kemudian menghasilkan sebuah citra berdasarkan vektor *noise* tersebut yang dinotasikan sebagai $G(z)$. Citra hasil *Generator* ini selanjutnya diberikan kepada *Discriminator*, dan berdasarkan keluaran yang dihasilkan oleh *Discriminator*, parameter parameter pada *Generator* diperbarui selama proses pelatihan [37].

Discriminator (D) merupakan pengklasifikasi biner yang mengevaluasi sampel asli (*real*) dan palsu (*fake*) secara bersamaan, serta berupaya membedakan citra yang berasal dari data asli dan citra yang dihasilkan oleh *Generator*. Untuk setiap sampel citra X , *Discriminator* memodelkan probabilitas bahwa citra tersebut merupakan citra asli atau citra palsu. Nilai probabilitas yang dihasilkan oleh *Discriminator* kemudian dikembalikan kepada *Generator* sebagai umpan balik (*feedback*) untuk meningkatkan kualitas citra hasil generasi [37].

Seiring waktu, *Generator* dan *Discriminator* saling berkompetisi untuk mengungguli satu sama lain. Proses persaingan ini melatarbelakangi istilah

“*adversarial*” pada GAN, di mana proses optimasi diformulasikan sebagai suatu permasalahan *minimax game* yang pertama kali diperkenalkan oleh Goodfellow dkk. pada saat memperkenalkan GAN. Selama proses pelatihan, parameter parameter pada kedua jaringan diperbarui menggunakan metode *backpropagation*, dengan tujuan akhir agar *Generator* mampu menghasilkan citra yang semakin realistis, sementara *Discriminator* menjadi semakin akurat dalam membedakan citra hasil generasi dari citra asli [35], [37].

Secara matematis, proses pelatihan GAN menggunakan *minimax loss function*, di mana *Generator* berupaya meminimalkan kemampuan *Discriminator* dalam mendeteksi data palsu, sementara *Discriminator* berusaha memaksimalkan akurasi klasifikasinya. Fungsi tersebut dinyatakan sebagai berikut:

$$\text{Min}_G \text{Max}_D f(D, G) = E_x[\log(D(x))] + E_z[\log(1 - D(G(z)))] \quad \dots(1)$$

Dimana:

- a. E_x adalah nilai harapan terhadap seluruh sampel data asli
- b. $D(x)$ adalah estimasi probabilitas sampel x
- c. $G(z)$ adalah keluaran *Generator* untuk vektor noise acak z
- d. $D(G(z))$ adalah estimasi probabilitas hasil generasi merupakan citra asli
- e. E_z adalah nilai harapan terhadap seluruh vektor noise acak yang diberikan.

Pendekatan *adversarial* ini memungkinkan GAN menghasilkan data dengan tingkat kemiripan yang tinggi terhadap data nyata tanpa memerlukan asumsi eksplisit mengenai bentuk distribusi data. Dibandingkan model generatif tradisional, GAN memiliki keunggulan dalam menghasilkan keluaran yang lebih tajam dan realistis [37].

Dalam perkembangan selanjutnya, berbagai varian GAN dikembangkan untuk meningkatkan stabilitas pelatihan dan kualitas hasil generatif, serta memperluas penerapannya pada berbagai jenis data. GAN telah digunakan secara luas dalam berbagai domain, termasuk pengolahan citra, penginderaan jauh, data deret waktu, dan pemodelan data ilmiah [37].

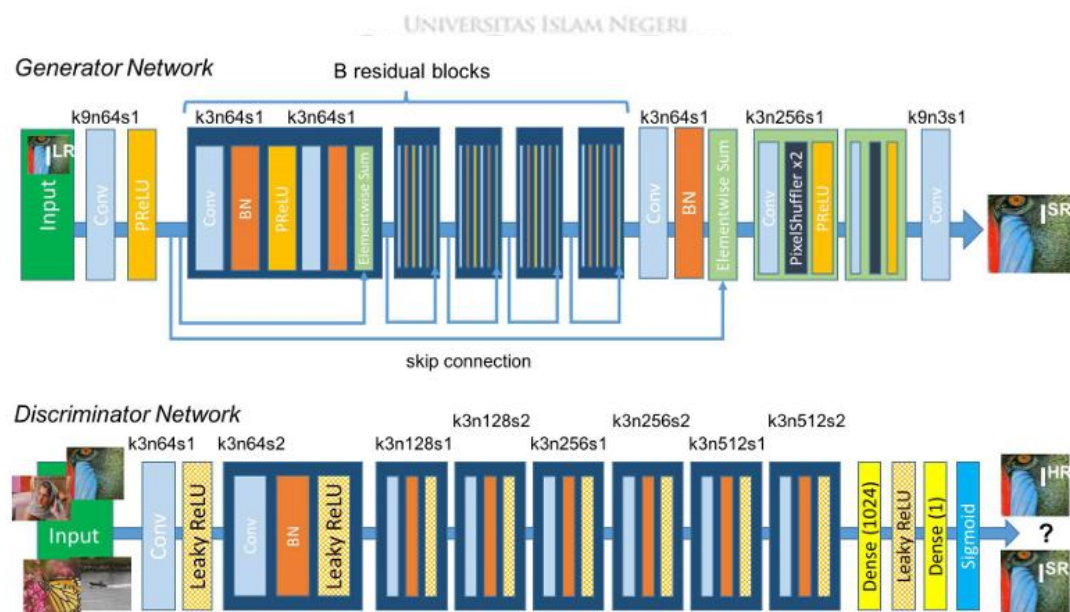
Dalam konteks penelitian ini, pendekatan GAN digunakan sebagai kerangka pemodelan dalam proses *statistical downscaling* data curah hujan. Pemilihan metode ini didasarkan pada kemampuan GAN dalam mempelajari

hubungan yang kompleks serta mempertahankan detail spasial pada proses rekonstruksi data resolusi tinggi. Melalui mekanisme *adversarial training* antara *Generator* dan *Discriminator*, model diharapkan mampu mentransformasikan data curah hujan resolusi rendah dari model iklim global menjadi data resolusi tinggi yang lebih representatif terhadap kondisi observasi.

2.2.3 Super Resolution GAN (SRGAN)

SRGAN merupakan metode *deep learning* untuk *super resolution* citra yang diperkenalkan oleh Christian Ledig dkk. dalam makalah berjudul “*Photo Realistic Single Image Super Resolution Using a Generative Adversarial Network*” yang dipublikasikan pada CVPR 2017 [38].

SRGAN dikembangkan untuk mengatasi keterbatasan metode super resolution konvensional yang umumnya mengandalkan *pixel wise loss* seperti *Mean Squared Error (MSE)*. Meskipun pendekatan tersebut mampu menghasilkan nilai *Peak Signal to Noise Ratio (PSNR)* yang tinggi, hasil citra yang diperoleh cenderung terlalu halus (*over smoothing*) dan kurang mampu merepresentasikan detail tekstur berfrekuensi tinggi secara realistis. Untuk mengatasi permasalahan tersebut, Ledig dkk. mengusulkan penggunaan arsitektur *Generative Adversarial Network (GAN)* yang terdiri dari dua komponen utama, yaitu *Generator* dan *Discriminator* [38].



Gambar 2.3 Arsitektur SRGAN [38]

Gambar 2.3 Arsitektur jaringan *Generator* dan *Discriminator* beserta ukuran kernel (k), jumlah *feature map* (n), dan *stride* (s) yang ditunjukkan untuk setiap lapisan konvolusi. *Generator* pada SRGAN dirancang menggunakan jaringan *deep residual network* (ResNet) yang bertugas merekonstruksi citra beresolusi tinggi dari citra beresolusi rendah. Sementara itu, *Discriminator* dilatih untuk membedakan antara citra hasil *super resolution* dan citra resolusi tinggi asli. Proses pelatihan *adversarial* ini mendorong *Generator* menghasilkan citra yang tidak hanya akurat secara numerik, tetapi juga lebih realistis secara visual [38].

Selain itu, SRGAN memperkenalkan konsep *perceptual loss*, yaitu *loss function* yang mengombinasikan *content loss* berbasis fitur tingkat tinggi dari jaringan VGG dan *adversarial loss*. Pendekatan ini memungkinkan SRGAN menghasilkan detail tekstur yang lebih tajam dan mendekati citra asli dibandingkan metode *super resolution* berbasis MSE semata [38].

Dalam konteks penelitian ini, arsitektur SRGAN dimanfaatkan untuk melakukan proses *statistical downscaling* pada data curah hujan. Melalui kemampuan rekonstruksi detail spasial dari data resolusi rendah menjadi resolusi tinggi, model diharapkan mampu meningkatkan representasi variabilitas curah hujan pada skala lokal sehingga menghasilkan data yang lebih mendekati karakteristik observasi.

2.2.4 *Downscaling* Iklim

Downscaling iklim merupakan teknik yang digunakan untuk mengubah data iklim berskala global menjadi informasi berskala lokal yang lebih detail [14], [18], [33]. Pendekatan ini diperlukan karena keluaran model iklim global (*General Circulation Models* /GCM) umumnya memiliki resolusi spasial yang masih kasar, dengan ukuran grid sekitar 1° atau lebih, setara dengan area lebih dari 100×100 km², sehingga tidak dapat digunakan secara langsung untuk analisis pada skala lokal seperti wilayah perkotaan, daerah aliran sungai (DAS), atau lokasi penelitian tertentu [32], [39]

Ada dua pendekatan utama untuk *downscaling* keluaran model iklim yakni *statistical* dan *dynamical downscaling* [18], [33].

- a. *Dynamical Downscaling*: Pendekatan yang menggunakan *Regional Climate Models* (RCMs) beresolusi lebih tinggi untuk merepresentasikan

iklim regional atau lokal. Dalam metode ini, RCM dijalankan dengan menggunakan keluaran GCM sebagai kondisi batas lateral dan mensimulasikan proses fisik atmosfer secara eksplisit. Meskipun mampu menggambarkan detail iklim regional dengan lebih baik, *dynamical downscaling* memiliki keterbatasan karena memerlukan sumber daya komputasi yang sangat besar dan waktu komputasi yang tinggi, sehingga penggunaannya sering kali terbatas pada wilayah dan periode tertentu.

- b. *Statistical Downscaling*: Metode yang membangun hubungan statistik antara variabel iklim berskala besar yang dihasilkan oleh model iklim global atau data reanalisis dengan data iklim lokal yang teramati pada periode historis yang sama. Hubungan statistik tersebut kemudian diaplikasikan pada keluaran model iklim untuk menghasilkan proyeksi iklim masa depan pada resolusi yang lebih tinggi. Pendekatan ini relatif lebih efisien secara komputasi dibandingkan *dynamical downscaling* dan banyak digunakan dalam studi iklim regional.

Dalam konteks penelitian ini, pendekatan yang digunakan adalah *statistical downscaling*, di mana model pembelajaran mesin digunakan untuk mempelajari hubungan antara data iklim berskala global dengan data observasi pada skala lokal. Pendekatan ini memungkinkan peningkatan resolusi spasial data curah hujan dari model iklim global sehingga dapat memberikan informasi yang lebih representatif untuk analisis iklim regional.

2.2.5 *General Circulation Models (GCM)*

GCM merupakan model numerik yang digunakan untuk merepresentasikan dan mensimulasikan sistem iklim bumi secara global. Model model ini dibangun berdasarkan prinsip fisika fundamental, termasuk hukum konservasi massa, momentum, dan energi, untuk merepresentasikan interaksi antara komponen utama sistem iklim seperti atmosfer, lautan, daratan, kriosfer, serta proses biogeokimia. GCM digunakan untuk memahami dinamika iklim masa lalu, mensimulasikan kondisi iklim saat ini, serta memproyeksikan perubahan iklim di masa depan di bawah berbagai skenario emisi gas rumah kaca yang terstandarisasi dalam kerangka penilaian *Intergovernmental Panel on Climate Change (IPCC)* [40].

Secara spasial, GCM membagi permukaan bumi dan atmosfer ke dalam grid tiga dimensi dengan resolusi horizontal yang relatif kasar. Resolusi spasial GCM umumnya berada pada ukuran grid lebih dari 100 km, sehingga GCM mampu menangkap pola iklim berskala besar seperti sirkulasi atmosfer global, sistem monsun, dan variabilitas iklim antar benua. Namun, resolusi tersebut belum memadai untuk merepresentasikan variasi iklim pada skala regional [40].

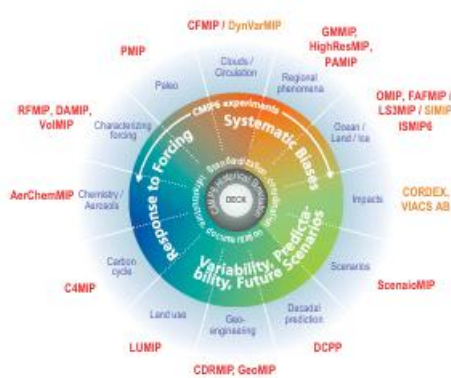
Keterbatasan resolusi spasial GCM menyebabkan informasi iklim yang dihasilkan tidak dapat digunakan secara langsung untuk analisis dampak iklim pada skala lokal. Fenomena iklim berskala lokal, seperti hujan ekstrem lokal, variabilitas suhu mikro, serta pengaruh topografi terhadap distribusi curah hujan, sering kali tidak tertangkap dengan baik oleh GCM. Oleh karena itu, diperlukan metode tambahan untuk menjembatani kesenjangan skala antara keluaran GCM dan kebutuhan analisis lokal [40].

Dalam konteks penelitian perubahan iklim, GCM umumnya digunakan sebagai sumber utama proyeksi iklim masa depan melalui skenario yang dikembangkan dalam kerangka *Coupled Model Intercomparison Project (CMIP)*. CMIP menyediakan keluaran dari berbagai GCM yang dikembangkan oleh pusat-pusat riset iklim di seluruh dunia dan digunakan secara luas sebagai referensi dalam studi iklim global dan regional yang dinilai oleh IPCC. Namun, untuk aplikasi pada skala lokal dan regional, keluaran GCM tersebut perlu diproses lebih lanjut melalui teknik *downscaling* agar menghasilkan informasi iklim dengan resolusi spasial yang lebih tinggi dan relevan dengan lokasi penelitian [40].

2.2.6 Data Proyeksi CMIP6

Coupled Model Intercomparison Project (CMIP) merupakan kerangka kerja internasional yang dirancang untuk membandingkan kinerja berbagai *General Circulation Models (GCM)* dan *Earth System Models (ESM)* melalui pelaksanaan eksperimen yang seragam. Sejak dikembangkan pada pertengahan 1990an, CMIP telah berkembang melalui beberapa fase dan melibatkan pusat-pusat pemodelan iklim utama di dunia. Hasil dari proyek ini telah berperan penting dalam penyusunan laporan-laporan IPCC, termasuk evaluasi hasil dari CMIP5 dan fase terbarunya, yaitu CMIP6 [40].

Pada fase CMIP6, desain eksperimen mengalami penyempurnaan dengan diperkenalkannya seperangkat simulasi inti yang dikenal sebagai DECK (*Diagnostic, Evaluation and Characterization of Klima*) serta simulasi historis yang wajib dijalankan oleh seluruh model peserta. Simulasi DECK mencakup eksperimen kontrol pra industri (*piControl*), eksperimen idealisasi peningkatan konsentrasi CO₂, serta simulasi transien seperti AMIP, yang menjadi dasar dalam evaluasi sensitivitas dan respons iklim. Selain itu, CMIP6 juga mencakup berbagai *Model Intercomparison Projects* (MIPs) yang disahkan untuk mengkaji aspek aspek iklim tertentu secara lebih spesifik [40].



Gambar 2.4 Struktur CMIP6 [40]

Gambar 2.4 menunjukkan struktur CMIP6, fase keenam dari *Coupled Model Intercomparison Project*. Bagian tengah menggambarkan eksperimen bersama yang disebut DECK (*Diagnostic, Evaluation and Characterization of Klima*) serta simulasi historis yang wajib dijalankan oleh seluruh model yang berpartisipasi. Lingkaran terluar menunjukkan topik topik yang dicakup oleh Model Intercomparison Projects (MIPs) yang disahkan (ditandai warna merah) dan MIPs lainnya (warna oranye) [40].

Hasil simulasi CMIP6, khususnya variabel curah hujan, banyak dimanfaatkan sebagai data masukan dalam studi dampak dan proyeksi iklim regional. Namun, karena resolusi spasialnya masih sangat rendah, data CMIP6 umumnya memerlukan proses *downscaling* statistik dan penyesuaian bias agar lebih representatif terhadap kondisi lokal. Oleh karena itu, dalam penelitian ini CMIP6 digunakan sebagai data beresolusi rendah (*low resolution*) atau input (X) dalam pelatihan model [40].

2.2.7 Data Observasi CHIRPS2

Climate Hazards Group InfraRed Precipitation with Station data version 2 (CHIRPS2) merupakan produk curah hujan berbasis grid yang dikembangkan oleh *Climate Hazards Group* bekerja sama dengan *University of California, Santa Barbara* (UCSB) dan *U.S. Geological Survey* (USGS). Dataset ini menyediakan data curah hujan harian dengan cakupan hampir global pada rentang waktu sejak tahun 1981 hingga mendekati waktu saat ini, dengan resolusi spasial utama sebesar $0,05^\circ$ (~ 5 km) dan $0,25^\circ$ [41].

CHIRPS2 dibangun melalui penggabungan data satelit inframerah, estimasi curah hujan berbasis *cold cloud duration*, serta data pengamatan stasiun hujan, sehingga mampu menghasilkan representasi curah hujan yang lebih konsisten secara spasial dan temporal dibandingkan produk berbasis satelit murni. Berbagai studi menunjukkan bahwa CHIRPS2 memiliki kinerja yang baik dalam merepresentasikan variasi curah hujan bulanan dan musiman, serta cukup andal untuk analisis kekeringan dan studi hidroklimatologi, meskipun performanya dapat bervariasi bergantung pada kondisi geografis dan kerapatan stasiun hujan [41].

Karena resolusi spasialnya yang relatif tinggi serta telah melalui validasi di berbagai wilayah dan kondisi iklim, CHIRPS2 dalam penelitian ini digunakan sebagai data observasi atau *ground truth*.

2.2.8 Digital Elevation Model Nasional (DEMNAS)

DEMNAS adalah sebuah peta digital tiga dimensi yang secara khusus menggambarkan bentuk permukaan daratan Indonesia dengan tingkat detail yang tinggi. Berbeda dengan model elevasi global yang tersedia secara umum, DEMNAS dirancang khusus oleh Badan Informasi Geospasial (BIG) untuk menyediakan data ketinggian yang lebih akurat dan berkesinambungan di seluruh wilayah nusantara. Data ini memiliki resolusi sebesar 0,27 detik busur atau 8 meter. Artinya, setiap piksel dalam data ini mewakili area seluas 8x8 meter di lapangan [42].

DEMNAS dibangun melalui integrasi berbagai sumber data penginderaan jauh yang heterogen, mulai dari teknologi radar IFSAR, satelit TerraSAR X, hingga ALOS PALSAR. Penggabungan berbagai sumber data ini dilakukan menggunakan metode asimilasi berbasis *GMT surface* dengan *tension* 0,32 untuk memastikan

transisi data yang halus dan akurat, meskipun kepadatan datanya bervariasi di setiap wilayah[42].

Dalam penelitian ini, DEMNAS berperan sebagai variabel prediktor topografis yang membantu model memahami efek orografis, yaitu fenomena di mana massa udara yang dipaksa naik oleh ketinggian gunung memicu kondensasi dan meningkatkan curah hujan pada sisi lereng tertentu.

2.2.9 *Cross Industry Standard Process for Data Mining (CRISP-DM)*

CRISP-DM adalah kerangka metodologis standar yang dikembangkan untuk memandu proses data mining dan pengembangan model berbasis data [43], [44]. Metodologi ini diperkenalkan pada tahun 1999 oleh konsorsium industri Eropa dan hingga saat ini menjadi pendekatan yang paling banyak digunakan karena sifatnya yang fleksibel, terstruktur, dan dapat diterapkan pada berbagai domain [45].



Gambar 2.5 Diagram Alur CRISP-DM [45]

CRISP-DM terdiri atas enam tahap utama yang bersifat iteratif seperti pada Gambar 2.5 [45]. Artinya, proses dapat kembali ke tahap sebelumnya apabila hasil yang diperoleh belum memenuhi tujuan, sehingga cocok digunakan dalam berbagai proyek data mining maupun machine learning. Ke enam tahap tersebut adalah sebagai berikut:

1. *Business Understanding* (Pemahaman Permasalahan): Tahap ini berfokus pada pemahaman tujuan proyek secara konseptual, identifikasi kebutuhan, serta penentuan ruang lingkup penelitian.

2. *Data Understanding* (Pemahaman Data): Tahap ini mencakup pengumpulan data awal, pemeriksaan struktur dan kualitas data, eksplorasi data, dan identifikasi pola awal.
3. *Data Preparation* (Persiapan Data): Pada tahap ini, data dipersiapkan melalui pembersihan data, normalisasi, ekstraksi fitur, hingga pembuatan dataset akhir.
4. *Modeling* (Pembangunan Model): Tahap ini melibatkan pemilihan teknik pemodelan yang sesuai, perancangan parameter, pelatihan model, serta pengujian awal.
5. *Evaluation* (Evaluasi): Model yang telah dibangun kemudian dievaluasi untuk menilai kualitas dan konsistensinya. Jika hasil belum memadai, dilakukan kembali iterasi ke tahap sebelumnya.
6. *Deployment* (Implementasi/Pemanfaatan Model): Model yang telah dievaluasi diterapkan dalam konteks operasional atau penelitian. Implementasi dapat berupa integrasi model ke sistem, atau penerapan model terhadap data baru.

2.2.10 Tools yang digunakan

2.2.10.1 Python

Python merupakan bahasa pemrograman tingkat tinggi yang bersifat interpretatif dan bersifat *cross platform*, sehingga dapat dijalankan pada berbagai sistem operasi. Python banyak digunakan dalam bidang *scientific computing*, *data science*, dan *machine learning* karena sintaksnya yang sederhana, mudah dibaca, serta didukung oleh ekosistem pustaka yang sangat lengkap. Beberapa studi menyebutkan bahwa Python menjadi bahasa pemrograman utama dalam pengembangan model *machine learning* dan karena kemampuannya dalam menangani pengolahan data, komputasi numerik, dan pemodelan berbasis jaringan saraf secara efisien [46].

Dalam penelitian ini, Python digunakan sebagai bahasa pemrograman utama untuk membangun dan mengimplementasikan model *statistical downscaling* berbasis SRGAN. Python memfasilitasi seluruh tahapan penelitian, mulai dari pra-proses data CMIP6 sebagai data beresolusi rendah, pemanfaatan data observasi CHIRPS2 sebagai referensi resolusi tinggi, pelatihan model SRGAN, hingga

evaluasi performa model secara statistik dan visual. Penggunaan Python memungkinkan proses penelitian dilakukan secara sistematis, efisien, dan mudah direproduksi.

2.2.10.2 Google Colab

Google Colab merupakan platform berbasis *cloud* yang dikembangkan oleh Google dengan model lingkungan *notebook* Jupyter yang memungkinkan eksekusi kode Python secara daring. Platform ini dirancang untuk memfasilitasi kegiatan *machine learning* dan *data science* tanpa memerlukan konfigurasi lingkungan lokal, sehingga pengguna dapat langsung menjalankan kode melalui peramban web. Salah satu keunggulan utama dari Google Colab adalah penyediaan akses terhadap sumber daya komputasi tingkat tinggi, seperti *Graphics Processing Units* (GPU) dan *Tensor Processing Units* (TPU), yang sangat krusial untuk mempercepat proses pelatihan model *deep learning* yang kompleks [47].

Dalam implementasi riset, penggunaan platform ini memberikan efisiensi tinggi dalam mengintegrasikan ekosistem Python dengan berbagai pustaka ilmiah untuk pemrosesan data berukuran besar dan visualisasi hasil pemodelan. Selain menawarkan performa komputasi yang kuat, Google Colab mendukung prinsip reproduktibilitas penelitian karena setiap eksperimen disimpan dalam lingkungan berbasis *cloud* yang konsisten. Hal ini memungkinkan kode dan hasil analisis dapat diakses, dibagikan, serta dijalankan kembali oleh peneliti lain tanpa adanya hambatan perbedaan spesifikasi perangkat keras maupun dependensi perangkat lunak lokal [47].

Dalam konteks penelitian ini, Google Colab digunakan sebagai platform utama untuk mengembangkan, melatih, dan mengevaluasi model SRGAN dalam proses *downscaling* curah hujan berbasis data CMIP6. Lingkungan berbasis *cloud* yang disediakan oleh Google Colab Pro memudahkan integrasi Python dengan pustaka *deep learning*, pengolahan data iklim berukuran besar, serta visualisasi hasil *downscaling*. Selain itu, sifatnya yang berbasis *cloud* mendukung reproduktibilitas penelitian, karena kode dan eksperimen dapat dijalankan kembali tanpa ketergantungan pada spesifikasi perangkat keras lokal.

2.2.11 Metrik Evaluasi

2.2.11.1 Root Mean Square Error (RMSE)

RMSE merupakan salah satu metrik evaluasi yang digunakan untuk menunjukkan besarnya perbedaan antara hasil prediksi model dan data observasi. Dengan demikian, RMSE menggambarkan tingkat kesalahan model dalam memprediksi nilai aktual [48], RMSE didefinisikan sebagai:

$$RMSE = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n}} \quad \dots(2)$$

Dimana:

- a. y_i adalah nilai observasi sebenarnya
- b. \hat{y}_i adalah nilai hasil prediksi model
- c. n adalah jumlah total data observasi

Dalam studi *downscaling* curah hujan dari data global ke skala lokal, RMSE mempunyai keunggulan sebagai salah satu indikator utama untuk mengevaluasi tingkat kesesuaian antara data hasil *downscaling* dan data observasi. Pada penelitian Tu dan Duan (2024), RMSE digunakan untuk mengukur besarnya perbedaan antara data curah hujan hasil *downscaling* GPM IMERG dan data stasiun hujan. Pada Penelitian ini penurunan nilai RMSE setelah proses *downscaling* menunjukkan peningkatan akurasi data curah hujan berskala lokal dibandingkan dengan data global sebelum *downscaling* [49].

2.2.11.2 Mean Absolute Error (MAE)

MAE adalah salah satu metrik evaluasi yang umum digunakan untuk mengukur tingkat kesalahan atau akurasi dari suatu model regresi atau prediksi. Metrik ini menghitung rata-rata aritmatika dari selisih absolut antara nilai yang diprediksi oleh model dengan nilai observasi yang sebenarnya. Secara matematis, MAE memberikan gambaran tentang seberapa besar rata-rata kesalahan yang dihasilkan oleh model tanpa memperhatikan arah (positif atau negatif) dari kesalahan tersebut [50]. Perhitungan MAE dinyatakan dalam rumus berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad \dots(3)$$

Dimana:

- a. y_i adalah nilai observasi sebenarnya
- b. \hat{y}_i adalah nilai hasil prediksi model
- c. n adalah jumlah total data observasi

Dalam konteks pemodelan statistik dan *machine learning*, MAE sangat berguna karena memberikan interpretasi yang linier terhadap besaran kesalahan. Hal ini berarti semua kesalahan individual memiliki bobot yang sama dalam perhitungan rata-rata. Nilai MAE yang lebih kecil menunjukkan bahwa model memiliki performa yang lebih baik karena prediksi yang dihasilkan semakin mendekati nilai observasi asli. Penggunaan MAE sering kali dibandingkan dengan metrik lain RMSE untuk memberikan analisis yang lebih komprehensif mengenai stabilitas dan akurasi model dalam memproses data [50].

Dalam konteks penelitian ini metrik ini memberikan gambaran langsung mengenai seberapa besar deviasi prediksi dalam satuan yang sama dengan variabel yang diukur (misalnya mm untuk curah hujan).

2.2.11.3 *Pearson Correlation Coefficient (PCC)*

Pearson Correlation Coefficient (PCC) merupakan metrik statistik yang digunakan untuk mengukur kekuatan dan arah hubungan linier antara dua variabel yang berkesinambungan. Dalam analisis data, PCC memberikan nilai numerik yang berkisar antara -1 hingga 1, di mana nilai 1 menunjukkan korelasi positif sempurna, -1 menunjukkan korelasi negatif sempurna, dan 0 menunjukkan tidak adanya hubungan linier antara kedua variabel tersebut. Metrik ini sangat penting dalam evaluasi model prediktif untuk menentukan sejauh mana pola tren yang dihasilkan oleh model selaras dengan pola data observasi yang sebenarnya [51].

Dalam konteks pemodelan berbasis jaringan saraf, PCC sering digunakan sebagai salah satu indikator akurasi untuk memvalidasi performa model. Koefisien ini dihitung dengan membagi kovarians dari dua variabel dengan hasil kali simpangan bakunya. Nilai PCC yang tinggi mendekati 1 menandakan bahwa model mampu menangkap variabilitas spasial atau temporal dari data target dengan sangat baik, sehingga menjadikannya metrik pelengkap yang efektif selain metrik kesalahan absolut seperti MAE atau RMSE [51]. Secara matematis, rumus PCC dinyatakan sebagai:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad \dots(4)$$

Dimana:

- a. x_i adalah nilai curah hujan observasi (data aktual lapangan atau referensi) pada urutan data atau titik waktu ke .
- b. y_i adalah nilai curah hujan hasil prediksi model *downscaling* pada urutan data atau titik waktu ke .
- c. \bar{x} adalah rata-rata nilai curah hujan dari keseluruhan data observasi.
- d. \bar{y} adalah rata-rata nilai curah hujan dari keseluruhan data hasil prediksi model *downscaling*.
- e. n adalah jumlah total pasangan data curah hujan (jumlah deret waktu atau jumlah titik grid) yang dianalisis.

Dalam konteks penelitian ini, PCC berfungsi untuk memvalidasi sejauh mana pola spasial maupun temporal yang dihasilkan model selaras dengan variabilitas data lapangan yang sebenarnya.

