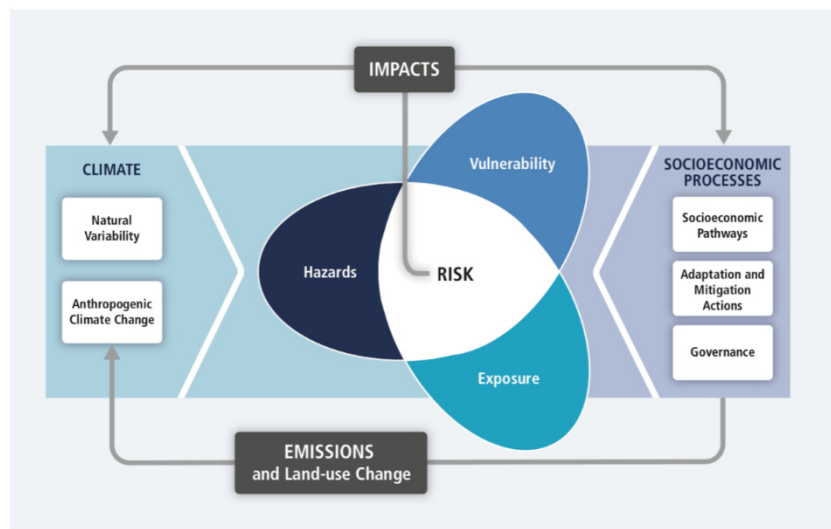


## Bab II Tinjauan Pustaka

### II.1 Analisis Iklim *Baseline*

Perubahan iklim menimbulkan risiko bagi manusia dan sistem alam. Risiko perubahan iklim menurut IPCC (2014) merupakan potensi dampak negatif perubahan iklim yang dihasilkan dari interaksi antara kerentanan (*vulnerability*), keterpaparan (*exposure*) dan ancaman (*hazard*). Analisis risiko perubahan iklim melibatkan interaksi iklim, lingkungan dan faktor manusia yang mengarah pada dampak serta peranan faktor non-iklim yang menentukan dampak (Gambar II.1). Evaluasi variabilitas iklim alami dan perubahan iklim antropogenik pada kejadian cuaca dan iklim ekstrem merupakan bagian dari analisis ancaman (kiri). Sedangkan proses adaptasi dan mitigasi, sosial dan ekonomi, kebijakan pemerintah (kanan) terkait dengan analisis keterpaparan dan kerentanan.



Gambar II.1 Konsep risiko dampak perubahan iklim hasil interaksi ancaman/hazard, keterpaparan/exposure dan kerentanan/vulnerability (sumber: IPCC, 2014)

Analisis perubahan iklim menurut IPCC-TGICA (2007) secara umum dilakukan dengan dua pendekatan yakni *top-down* berdasarkan skenario proyeksi hasil-hasil simulasi GCM dan *bottom-up* berdasarkan analisis data observasi iklim *baseline*. Data klimatologi observasi dengan kualitas yang baik dibutuhkan untuk periode *baseline*. Data iklim *baseline* ditentukan berdasarkan tipe data, durasi periode

*baseline*, sumber data dan bagaimana aplikasi penggunaannya dalam penilaian dampak. Presipitasi merupakan salah satu parameter penting untuk analisis perubahan iklim. Kriteria pemilihan periode *baseline* menurut IPCC, (Carter dkk., 1994) antara lain:

- menggambarkan kondisi saat ini atau rata-rata iklim saat ini di suatu wilayah studi
- durasi yang cukup untuk mencakup variasi iklim termasuk jumlah signifikan anomali cuaca
- mencakup ketersediaan periode data semua parameter iklim dan terdistribusi serta berkualitas baik
- konsisten dan dapat dibandingkan dengan *baseline* yang digunakan oleh penilaian dampak lainnya

Periode *baseline* iklim yang umum digunakan adalah periode “normal” 30 tahun yang ditentukan oleh *World Meteorology Organization* (WMO). Sejak 1956, WMO (2007) telah merekomendasikan negara anggotanya untuk menghitung normal iklim 30 tahun setiap sepuluh tahun. Standar normal klimatologi WMO merupakan data iklim rata-rata yang dihitung setiap periode 30 tahun diakhiri dengan tahun yang berakhiran nol (0) misalkan standar normal saat ini adalah adalah 1 Januari 1981 hingga 31 Desember 2010. Periode referen standar normal untuk analisis perubahan iklim saat ini adalah periode 1961 hingga 1990, sehingga untuk melakukan analisis perubahan iklim diperlukan periode minimal 60 tahun atau dua periode normal misalkan periode 1961-1990 dibandingkan dengan normal lainnya seperti 1981-2010. Beberapa sumber untuk memperoleh data iklim *baseline* (IPCC-TGICA, 2007) antara lain: badan meteorologi nasional dan arsip, *dataset* supranasional dan global, serta output dari model iklim dan generator cuaca.

## **II.2    *Dataset* Presipitasi**

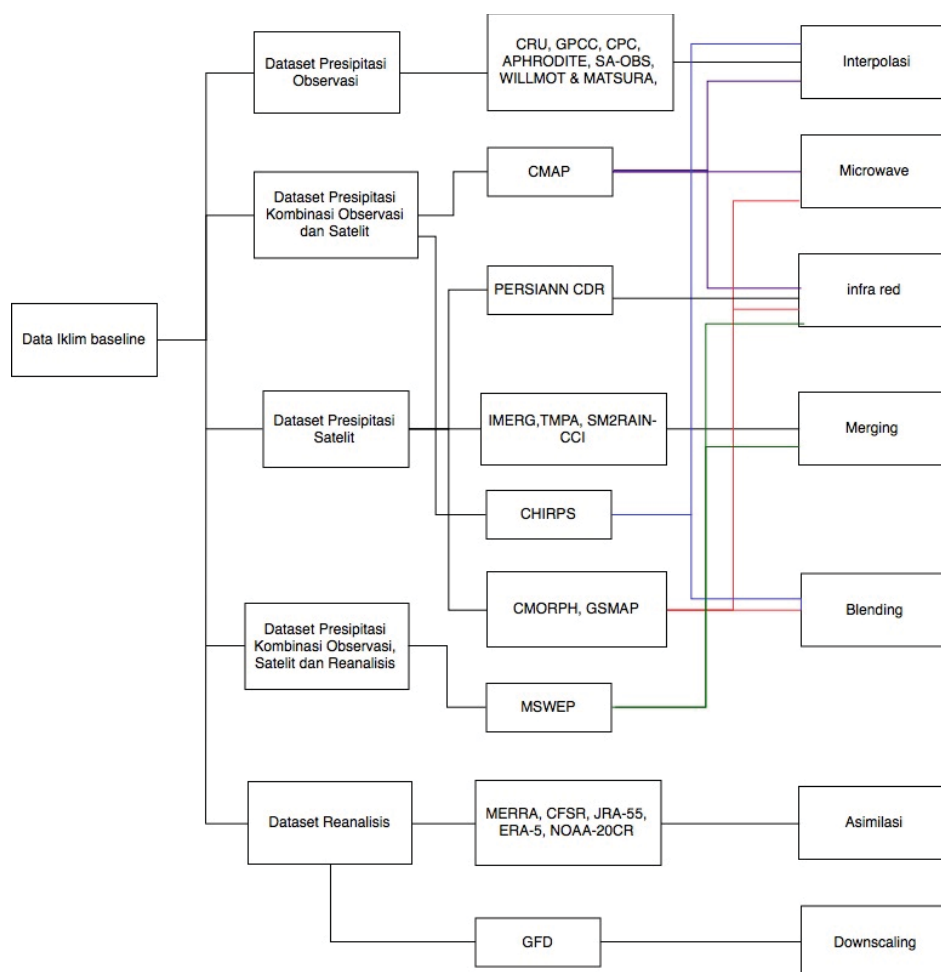
Presipitasi merupakan komponen utama dalam siklus hidrologi, presipitasi adalah berbagai produk hasil kondensasi uap air di atmosfer yang jatuh ke Bumi (Tjasyono, 2004) akibat pengaruh gravitasi. Presipitasi berupa hujan, gerimis, salju, batu es (*hail*), *sleet*, *graupel*, virga, kabut, dan embun. Pengukuran presipitasi permukaan

dilakukan oleh penakar hujan, disdrometer, dan *ground* radar. Sedangkan estimasi presipitasi menggunakan satelit dengan teknik *microwave* (aktif dan pasif) dan *merging* infra merah serta kombinasi dari teknik tersebut (Tapiador dkk., 2012).

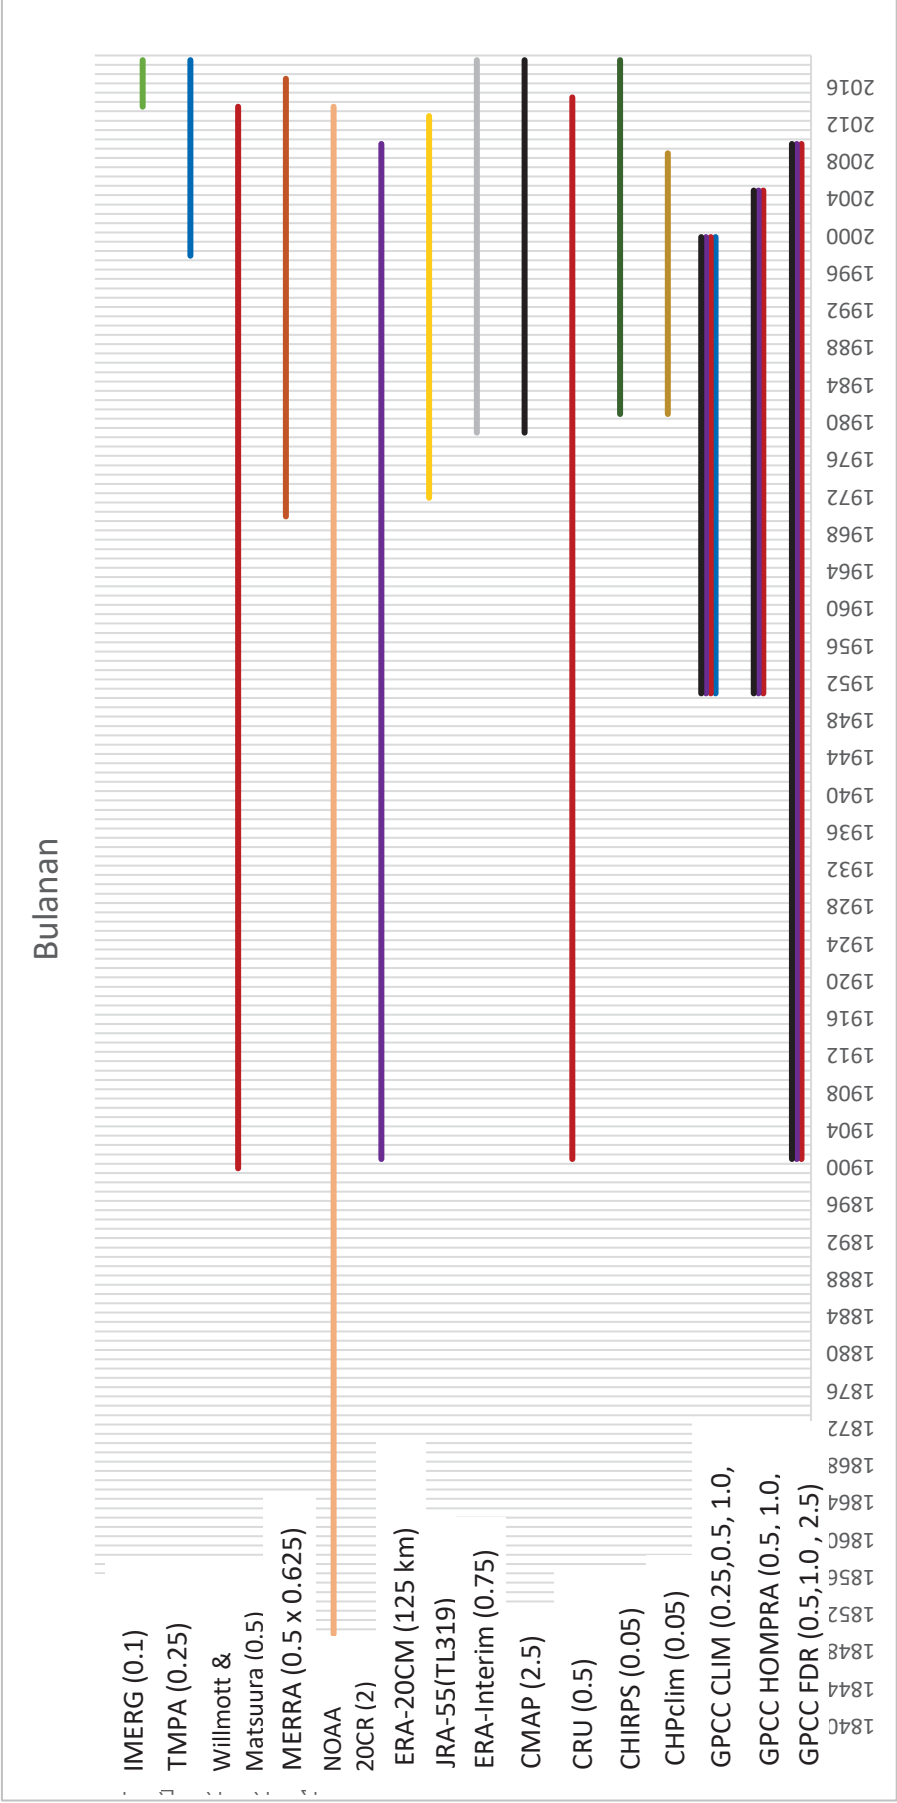
*Dataset* presipitasi yaitu kumpulan data presipitasi global dengan resolusi grid tertentu dapat dimanfaatkan dalam melakukan analisis iklim *baseline*. Saat ini sudah banyak dikembangkan *dataset* presipitasi berbasis grid, menurut Beck dkk. (2017), *dataset* berbeda-beda dalam hal: desain objektif (homogenitas temporal, akurasi atau keduanya), sumber data (radar, penakar hujan satelit, analisis atau reanalisis atau kombinasi), resolusi spasial (dari 0,05 hingga 2,5 derajat), cakupan wilayah (dari benua hingga global), resolusi temporal yang dipublikasi (dari 30 menit hingga bulanan), rentang waktu (dari satu hingga 115 tahun), dan latensi/lamanya perpindahan data (dari tiga jam hingga beberapa tahun).

Jenis *dataset* presipitasi beserta metode pembuatannya disajikan dalam Gambar II.2. Resolusi spasial maupun temporal *dataset* presipitasi cukup beragam, Gambar II.3 menunjukkan panjang *dataset* presipitasi berbagai resolusi spasial dengan resolusi temporal bulanan dan Gambar II.4 merupakan resolusi temporal harian (termasuk di dalamnya subharian: tiga jam-an dan enam jam-an). Ketersediaan *dataset* presipitasi bulanan yang memiliki periode terpanjang berdasarkan Gambar II.3 adalah *dataset National Oceanic & Atmospheric Administration 20 Century* (NOAA 20 CR) diikuti oleh *Climatic Research Unit* (CRU), Willmot & Matsuura, *Global Precipitation Climatology Centre Full Data Reanalysis* (GPCC FDR), dan ERA-20CM. *Dataset* presipitasi harian terpanjang berdasarkan Gambar II.4 adalah NOAA-20CR, ERA-20CM, dan *Global Meteorological Forcing Dataset* (GFD). *Dataset* berdasarkan data penakar hujan dan reanalisis umumnya menyediakan periode jangka waktu yang cukup panjang, sedangkan *dataset* berdasarkan data satelit memiliki keterbatasan panjang periode namun dapat memberikan informasi penting mengenai dinamika cuaca, kekeringan, dan monitoring hidrologi (Sun dkk, 2017).


Terdapat tiga kategori *dataset* presipitasi (Arakawa dan Kitoh, 2011) antara lain: pertama, *dataset* berdasarkan penakar hujan. Kedua, *dataset* berdasarkan data satelit baik menggunakan perangkat infra merah (*infrared*) maupun gelombang mikro (*microwave*). Ketiga, *dataset* berdasarkan kombinasi penakar hujan dan satelit. Selain itu, ada juga *dataset* presipitasi reanalisis yang dibuat dengan skema asimilasi dan model melibatkan semua data observasi yang ada pada setiap jam tertentu (misal sembilan hingga 12 jam) dalam proses analisisnya. Data observasi yang digunakan antara lain: data radiosonde, satelit, *buoy*, penerbangan, dan kapal laut. Data reanalisis meliputi data observasi masa lalu dengan model berdasarkan sistem asimilasi data yang juga digunakan dalam prakiraan cuaca, selain itu terdapat juga *dataset* kombinasi observasi, satelit, dan reanalisis. Kelebihan dan kekurangan *dataset* presipitasi berdasarkan sumber datanya disajikan dalam Tabel II.1.



Gambar II.2 Ketersediaan *dataset* presipitasi untuk mendukung data iklim *baseline*.



Gambar II.3 Ketersediaan periode *dataset* presipitasi bulanan.



Gambar II.4 Ketersediaan periode *dataset* presipitasi harian.

Tabel II.1 Kelebihan dan kekurangan dataset presipitasi berdasarkan sumber data (Li dkk., 2018; Sun dkk., 2018).

No	Dataset Presipitasi	Kelebihan	Kekurangan
1	Berdasarkan penakar hujan (contoh: <i>Asian Precipitation – Highly Resolved Observational Data Integration Towards Evaluation of Water Resources</i> /APHRODITE dan <i>Southeast Asia Observation/SA-OBS</i> )	- Merupakan aplikasi pengukuran original dari permukaan dengan periode data yang panjang (Li dkk., 2018)	-Kualitas <i>dataset</i> tergantung dari kerapatan penakar hujan, semakin rapat realitas presipitasi semakin baik (Li dkk., 2018) dan topografi mempengaruhi <i>error</i> -Metode interpolasi kurang mampu mengatasi kelemahan dari pengukuran penakar hujan (Li dkk., 2018) -Jumlah penakar hujan yang semakin menurun akibat masalah biaya operasional, kebijakan organisasi meteorologi setempat, perpindahan, dan penelantaran lokasi, masalah ekonomi-politik (Strangways, 2006; Sun dkk., 2018)
2	Berdasarkan satelit (contoh: <i>Climate Prediction Center MORPHing technique</i> /CMORPH, <i>Global Precipitation Measurement-Integrated Multi-satellite Retrievals for GPM</i> /GPM-IMERG, dan <i>Global Satellite Mapping of Precipitation</i> /GSMaP)	- Data observasi secara spasial, kualitas data tidak terpengaruh oleh angin dan parameter cuaca lain (Li dkk., 2018) - Data selalu ada pembaharuan mendekati <i>real time</i> - Memiliki resolusi temporal yang lebih tinggi hingga 30 menit sehingga dapat menggambarkan kejadian hujan ekstrem	- Ketergantungan pada bias <i>platform</i> dan sensor yang disebabkan oleh salju dan es (Li dkk., 2018) - Periode data umumnya lebih pendek dibandingkan <i>dataset</i> berdasarkan penakar hujan dan reanalisis (Sun dkk., 2018) - Masing-masing sensor satelit, algoritma pengolahan dan <i>granularity</i> mempengaruhi keakuratan estimasi presipitasi (Huffman dkk., 2010)

3	Berdasarkan reanalisis (contoh: ERA-20C, ERA5, dan JRA-25)	<ul style="list-style-type: none"> <li>- Kombinasi dari data model dengan berbagai tipe data observasi (Li dkk., 2018)</li> <li>- Ketersediaan Periode <i>dataset</i> yang panjang</li> </ul>	<ul style="list-style-type: none"> <li>- Adanya perubahan <i>error</i> sistem observasi model (Li dkk., 2018)</li> <li>- Resolusi spasial yang rendah</li> </ul>
4	Berdasarkan kombinasi (contoh: <i>Climate Hazards group Infrared Precipitation with Stations/CHIRPS</i> , MSWEP, GFD, <i>Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks- Climate Data Record /PERSIANN-CDR</i> dan <i>TRMM Multisatellite Precipitation Analysis/TMPA 3B42</i> )	Memperoleh keunggulan yang lengkap dari sumber data penakar hujan, satelit, dan reanalisis (Li dkk., 2018)	-tetap ada koreksi untuk mengurangi kesalahan

### II.3 Evaluasi *Dataset* Presipitasi

Studi evaluasi terhadap *dataset* presipitasi telah banyak dilakukan pada penelitian sebelumnya untuk memahami kelebihan dan kekurangan dari produk *dataset* presipitasi tersebut (Beck dkk., 2017). Ada yang menggunakan data stasiun sebagai data referen (Hirpa dkk., 2010; Buarque dkk., 2011; Bumke dkk., 2016; Alijanian dkk., 2017) atau radar yang telah dikoreksi dengan penakar hujan (AghaKouchak dkk., 2011; Islam dkk., 2012), perbandingan pola spasio-temporal (Kidd dkk., 2013), dan perbandingan hasil modeling hidrologi yang berkaitan dengan simulasi debit sungai (Collischonn dkk., 2008; Behrangi dkk., 2011; Beck dkk., 2017; Mazzoleni dkk., 2019).

Metode studi perbandingan *dataset* presipitasi sebelumnya menggunakan metrik performa statistik antara lain: koefisien korelasi (Beck dkk., 2017), bias (RMSE, *Mean Absolute Error*/MAE, persentil 90,99, *dryspell*, dan lain-lain) (Prasetya dkk.,



2011; Vernimmen dkk., 2012; Beck dkk., 2017), performa kategori seperti tabel kontingensi (Van den Besselaar dkk., 2017), *Kling-Gupta efficiency*/KGE (Beck dkk., 2019), *Probability of Detection* (POD), dan *False Alarm Ratio* (FAR) (Maggioni dkk., 2016). Metrik performa lainnya yang digunakan seperti *Nash–Sutcliffe model efficiency coefficient* (NSE) untuk simulasi modeling hidrologi (Beck dkk., 2017; Mazzoleni dkk., 2019), indeks musim: Entropi Relatif/RE dan indeks musim nondimensi/DSI (Pascale dkk., 2015; Ceglar dkk., 2017), analisis distribusi, *skill score* fraksi kejadian hujan lebat atau nilai ekstrem (Ceglar dkk., 2017). Ahmadelipour dkk. (2017) serta Chinn dan Yoden (2018) melakukan analisis performa multi data model iklim dengan *dataset* presipitasi sebagai referen menggunakan multi metrik antara lain: rata-rata, varians, koefisien korelasi, tren dan perubahan relatif untuk teknik univariat, sedangkan teknik multivariat menggunakan PCA, SVD, *Canonical Correlation Analysis* (CCA), dan analisis kluster.

Sun dkk. (2018) melakukan investigasi perbandingan dan perbedaan secara global terhadap 30 *dataset* presipitasi skala waktu tahunan, bulanan, dan harian berdasarkan kategorinya. Hasil menunjukkan terdapat ketidakpastian yang tinggi pada besaran nilai dan variabilitas presipitasi pada berbagai skala waktu. Variasi tahunan hingga mencapai 300 mm dan perbedaan tertinggi umumnya terdapat pada *dataset* reanalisis dibandingkan *dataset* basis lainnya. Secara musiman, perbedaan jumlah presipitasi periode JJA (Juni-Juli-Agustus) dan MAM (Maret-April-Mei) berkontribusi terhadap perbedaan tahunan dibandingkan periode lain. Pada skala harian kejadian hujan ringan lebih sering terjadi dan memiliki perbedaan yang tinggi. Perbedaan kejadian presipitasi ekstrem lebih tinggi di lintang rendah dibandingkan lintang yang lebih tinggi. Jumlah ketersediaan penakar hujan semakin menurun dan terbatas pada sampling bulanan, sehingga sulit untuk melihat perubahan kejadian ekstrem jangka pendek. *Dataset* berdasarkan satelit sulit digunakan untuk studi berbasis klimatologi karena ketersediaan paling panjang hanya 40 tahun.

Studi sebelumnya mengenai perbandingan berbagai *dataset* presipitasi untuk wilayah Indonesia yaitu performa *dataset* SA-OBS di wilayah Asia Tenggara dibandingkan dengan APHRODITE, CMORPH dan *Tropical Rainfall Measuring Mission* (TRMM) menunjukkan SA-OBS lebih mewakili observasi stasiun dalam hal frekuensi kering/basah, waktu kejadian presipitasi dan reproduksi presipitasi ekstrem (Van den Besselaar dkk., 2017). Validasi TRMM terhadap 20 penakar hujan data observasi di Indonesia berdasarkan tipe hujan tahun 2004-2008 menunjukkan data TRMM *underestimate* pada tipe monsun dan semi-monsun sedangkan pada tipe anti-monsun *overestimate* (Prasetia dkk., 2011). *Dataset* TMPA 3B42RT memiliki akurasi tertinggi dibandingkan PERSIANN dan CMORPH di wilayah Indonesia untuk musim kemarau dan tahunan dengan tujuan monitoring kekeringan (Vernimmen dkk., 2012).

## II.4 Rekonstruksi Data

Pendekatan untuk mengatasi keterbatasan data dapat dilakukan dengan rekonstruksi data presipitasi atau curah hujan masa lalu. Beberapa metode rekonstruksi *dataset* presipitasi dalam mendukung ketersediaan data iklim *baseline* antara lain metode interpolasi, *merging*, *blending*, *microwave* (aktif maupun pasif), *infrared*, asimilasi dan *downscaling* serta beberapa kombinasi dari metode tersebut seperti pada Gamabr II.2. Penelitian mengenai rekonstruksi curah hujan sebelumnya disajikan pada Tabel II.2.

Rekonstruksi curah hujan di wilayah Indonesia pernah dilakukan oleh Van den Besselaar dkk. (2017) yaitu *dataset* SA-OBS dengan panjang data dari tahun 1981 hingga 2017, dan untuk wilayah Pulau Jawa oleh Yanto dkk. (2017) periode 1985-2014 dengan metode interpolasi. Rekonstruksi data oleh Kautz dkk. (2019), Caillouet dkk. (2016), dan Caillouet dkk. (2019) dengan melakukan pengembangan model presipitasi secara stokastik atau *downscaling dataset* reanalisis global.

Metode *downscaling* dilakukan untuk mendapatkan informasi cuaca dan iklim skala lokal terutama dekat permukaan, dari variabel atmosfer skala regional dari GCM. Metode *downscaling* dapat dibagi dalam dua jenis yaitu dinamik dan

statistik. Dalam metode *downscaling* dinamik luaran dari GCM digunakan untuk menjalankan model numerik regional dengan resolusi spasial yang lebih tinggi sehingga kondisi lokal disimulasi lebih detil. Dalam DS, hubungan statistik antara variabel observasi dan GCM yang dibangun untuk mendapatkan variabel lokal dari luaran GCM.

Tabel II.2 Penelitian sebelumnya mengenai rekonstruksi data.

No	Tema Penelitian	Sumber Pustaka
1	SA-OBS <i>dataset</i> suhu udara permukaan dan presipitasi harian di wilayah Asia Tenggara	Van den Besselaar dkk. (2017)
2	Pengembangan <i>dataset</i> grid cuaca di wilayah Pulau Jawa Indonesia 1985–2014	Yanto dkk. (2017)
3	Simulasi <i>Weather Research and Forecasting</i> (WRF) untuk analisis presipitasi klimatologis dan ekstrem	Cardoso dkk. (2013)
4	Pengembangan <i>dataset</i> presipitasi di Eropa secara stokastik	Kautz dkk. (2019)
5	Rekonstruksi <i>dataset</i> cuaca <i>ensemble</i> harian 142 tahun dengan resolusi tinggi di wilayah Prancis	Caillouet dkk. (2019)

Rekonstruksi dengan metode *downscaling* dinamik dilakukan oleh Cardoso dkk. (2013) dan Kautz dkk. (2019) terhadap data reanalisis global yaitu data ERA-Interim dan ERA-20C dengan tujuan aplikasi hidrologi untuk menganalisis representasi sistem cuaca *transient* (tidak tetap) dan mereproduksi variabilitas spasial data observasi serta cuaca ekstrem secara statistik (Cardoso dkk., 2013). Luaran data hasil proses berupa *Regional Climate Model* (RCM) dengan integrasi data curah hujan harian. Informasi yang didapatkan dari hasil RCM lebih akurat dibandingkan dengan data global yang resolusinya lebih kasar, namun proses *downscaling* dinamik membutuhkan kapasitas komputasi tinggi untuk menghasilkan hasil simulasi RCM dengan resolusi tinggi. Keterbatasan kapasitas komputasi dapat diatasi dengan melakukan *downscaling* metode lainnya yaitu

secara statistik. Metode DS dapat dilakukan untuk menurunkan dari variabel atmosfer skala global seperti data reanalisis menjadi variabel meteorologi dekat permukaan skala lokal. Metode DS membutuhkan lebih sedikit sumber daya dan lebih kecil waktu perhitungan dibandingkan dengan *downscaling* dinamik (Hidalgo dkk., 2008).

Cillouet dkk. (2016) melakukan DS *Stepwise Analogue Downscaling method for Hydrology* (SANDHY) untuk memperoleh rekonstruksi probabilitas presipitasi dan suhu di Prancis dari tahun 1871-2012 dari data reanalisis global NOAA 20CR. SANDHY menyediakan 125 analog *ensemble* harian periode 1871-2012 untuk 608 zona homogen di Prancis. Metode DS memiliki tiga macam teknik (Wilby dkk., 2004) antara lain: *weather classification*, *regression models*, dan *weather generators*. Pendekatan analog merupakan salah satu contoh teknik *weather classification* dimana prediktor dipilih berdasarkan kecocokan analog pola cuaca sebelumnya dengan saat ini. Dalam penelitian ini dilakukan pengembangan metode DS CA untuk merekonstruksi presipitasi masa lalu dengan langkah ke belakang (*backward*).

### II.2.1 *Constructed Analogue*

Metoda DS dengan pendekatan analog telah dikembangkan oleh Lorenz (1969), Van den Dool (1994), dan Zorita dkk. (1995) untuk prediksi cuaca. Zorita dan von Storch (1999) serta Hidalgo dkk. (2008) menggunakannya untuk memperoleh statistik iklim lokal yang konsisten dengan kondisi atmosfer skala luas. Penerapan metode analog membutuhkan basis data yang panjang agar dapat mencakup pola cuaca atau kondisi atmosfer yang mungkin muncul di masa mendatang. Kelebihan dari metode CA adalah adanya analogi pola iklim skala lokal dengan suatu kondisi/pola iklim skala luas sehingga struktur spasial dari iklim lokal terwakilkan dengan baik pada hasil simulasi. Metode CA meminimalisir bias dan menggunakan nilai absolut dari prediktan dalam estimasi. Perbandingan metode DS CA dibandingkan metode DS lainnya disajikan pada Tabel II.3.

Tabel II.3 Perbandingan metode CA dengan metode DS lainnya

No	Metode CA	Metode DS lainnya
1	Variabel prediktor bisa sama atau berbeda dengan prediktan, hubungan fisis masih dipertahankan dengan adanya pemilihan analog pola iklim/cuaca. Distribusi yang digunakan bisa dengan non normal (Hidalgo dkk., 2008).	Metode SD kategori linier seperti regresi linier, analisis CCA, SVD, dan metode Delta, dapat menggunakan banyak prediktor namun memiliki asumsi distribusi normal sehingga tidak cocok untuk kejadian eskترم (Hidalgo dkk., 2008)
2	Mempertahankan pola cuaca harian dari data GCM/reanalisis, yaitu dengan melakukan kombinasi linier data prediktor yang digunakan untuk membentuk analog (minimal 30) dan hasil <i>downscaling</i> diperoleh dengan mengaplikasikan kombinasi linier tersebut terhadap data prediktan pada tanggal yang sama (Wilby dkk., 2004).	Metode DS bias koreksi hanya menggunakan rata-rata bulanan dari GCM/reanalisis dan merekonstruksi pola data harian dengan mengambil sampel ulang secara acak pada data bulanan historis dan menskalakan nilai variabel harian mengikuti nilai proyeksi bulanan (Wilby dkk., 2004).
3	Interval waktu hasil DS CA mengikuti prediktor, tidak mampu memprediksi di luar kondisi yang direkam (Hidalgo dkk., 2008). Metode DS kategori <i>weather classification</i> seperti metode analog dan kluster tidak mampu mereproduksi <i>wet</i> dan <i>dry spell</i> (wilby dkk., 2004)	Metode DS kategori <i>weather generator</i> , dapat <i>men-generate</i> informasi sub-harian dari prediktor harian, menghasilkan banyak <i>time-series</i> dan <i>post-processing</i> dan dapat mensimulasi <i>wet</i> dan <i>dry spell</i> (Hidalgo dkk., 2008).

Kemampuan metode DS CA bergantung pada kemiripan antar pola yang didefinisikan dalam pencarian analog (Zorita dan von Storch, 1998). Timbal dan McAvaney (2001) serta Anuchaivong dkk. (2017) menggunakan metrik *Euclidean distance* paling minimum sebagai perhitungan derajat kemiripan pola cuaca dari prediktor. Metrik lainnya yaitu *Cosine Similarity* seperti yang digunakan oleh Syahputra (2012) dan Surmaini dkk. (2015).

Pemilihan prediktor dalam metode DS CA penelitian ini menggunakan pendekatan “*indirect analogue downscaling method*” dengan variabel prediktor dan prediktan yang berbeda. Variabel sirkulasi atmosfer yang dipilih sebagai prediktor adalah variabel yang merepresentasikan medan angin horizontal karena merupakan variabel yang menentukan fase-fase evolusi monsun. Tiga variabel medan angin antara lain: medan angin zonal (U850), medan fungsi arus  $\psi$ , dan medan potensial kecepatan  $\chi$ , ketiganya di lapisan 850 mb (Saha dkk., 2014; Surmaini dkk., 2015). U850 sebagai prediktor karena banyak digunakan untuk merepresentasikan indeks-indeks monsun. Sementara  $\psi$  dan  $\chi$  adalah kuantitas sirkulasi atmosfer yang diturunkan dari variabel angin zonal dan angin meridional.  $\psi$  dan  $\chi$  masing-masing merepresentasikan komponen rotasional dan divergen dari medan angin horizontal.  $\psi$  and  $\chi$  lebih sesuai dalam menggambarkan pola aliran di lintang rendah dimana keseimbangan geostropis menurun karena adanya pengaruh Coriolis yang rendah (Palmer, 1952; Li dkk., 2006).

Prosedur menggunakan CA untuk prediksi dibagi menjadi dua bagian: diagnosis dan prognosis. Tahap diagnosis yaitu pemilihan subset pola cuaca historis dari GCM dan menentukan kombinasi multilinier yang paling sesuai dengan pola target dengan 30 *subsets* menghasilkan *constructed analogue* (Hidalgo dkk., 2008; Syahputra, 2012). *Empirical Orthogonal Function* (EOF) digunakan untuk mengurangi derajat bebas bidang sirkulasi atmosfer prediktor (Surmaini dkk., 2015; Zorita dan von Storch, 1999). Menurut Lorenz (1969), derajat bebas sirkulasi atmosfer tinggi dan rentang waktu data observasi yang tersedia pendek sehingga kemungkinan ditemukannya suatu analog pola iklim skala hemisfer dengan kualitas

baik sangat kecil. Van den Dool (1994) mengestimasi  $10^{30}$  tahun waktu yang dibutuhkan untuk menemukan dua pola atmosfer yang identik.

Tahap prognosis dilakukan dengan mengaplikasikan persamaan multilinier 30 *subset* analog prediktor yang didapatkan dalam tahap diagnosis terhadap data prediktan untuk memprediksi atau mengestimasi di waktu target. Persamaan yang digunakan dapat menggunakan metode regresi linier berganda (Surmaini dkk., 2015), metode perata-rataan berbobot (Fernández dan Sáenz, 2003) atau metode regresi lainnya. Menurut Pierce dkk. (2014), terdapat beberapa kelemahan metode CA yaitu: pertama, adanya peningkatan koherensi spasial bidang hasil *downscaling*. Kedua, proses *averaging* (rata-rata) yang cenderung menurunkan variasi temporal hasil akhir. Ketiga, proses rata-rata menghasilkan terlalu banyak *drizzle* (hujan ringan) untuk kasus *downscaling* presipitasi. Untuk perbedaan hari hujan di suatu wilayah dengan wilayah lain, oleh metode CA dilakukan penjumlahan terbobot pada hari analog yang menyebabkan presipitasi rendah di kedua wilayah tersebut. Beberapa metode telah dipelajari untuk mengatasi kelemahan CA seperti *Localized Constructed Analogue/LOCA* (Pierce dkk., 2014), *Multivariate Adaptive Constructed Analogue/MACA* (Abatzoglou dan Brown, 2012), dan BCCA (Maurer dkk., 2010). Kesalahan metode LOCA lebih kecil dibandingkan dengan BCCA untuk *downscaling* suhu dan presipitasi di lokasi Amerika Serikat (Pierce dkk., 2014). Pada metode LOCA dilakukan pemilihan analog hari tunggal yang terbaik/paling sesuai dengan observasi di wilayah lokal di sekitar titik yang *downscaling*, dan dapat mereproduksi suhu dan presipitasi ekstrem.


### **II.2.2 Pengaruh Angin Monsun terhadap Curah Hujan di Indonesia**

Angin monsun terjadi karena adanya perbedaan fisis antara lautan dan daratan (benua), dimana kapasitas panas yang dimiliki lautan lebih tinggi dibandingkan benua. Laut lebih dingin selama musim panas dan lebih hangat selama musim dingin dibandingkan dengan benua sehingga mempengaruhi perbedaan tekanan udara dengan arah gradien gaya tekanan dari benua ke lautan pada musim dingin dan dari lautan ke benua pada musim panas (Tjasyono dkk., 2008).



Penelitian ini melakukan pendekatan multi-jendela dalam pemilihan subset pola cuaca historis prediktor GCM di lokasi tujuh jendela/*window* wilayah monsun (Gambar II.5). Pendekatan ini bertujuan untuk mendapatkan hasil CA secara probabilistik atau *ensemble* seperti yang dilakukan oleh Syahputra (2012) dan Surmaini dkk. (2015). *Window-window* berupa wilayah-wilayah yang didefinisikan sebagai wilayah monsun oleh kajian-kajian indeks monsun ditambah wilayah benua maritim Indonesia. Sirkulasi atmosfer pada ketujuh *window* tersebut diasumsikan mempengaruhi pola curah hujan di wilayah Indonesia. Wilayah-wilayah yang dipilih sebagai *window* domain adalah:

- Benua maritim Indonesia: 80° – 150° BT dan 15° LS – 15° LU (Robertson dkk., 2011)
- Wilayah indeks monsun Australia (AUSMI): 110° – 130° BT dan 15° – 5° LS (Kajikawa dkk., 2010)
- Wilayah indeks monsun definisi Webster dan Yang (WYMI): 40° – 110° BT dan EQ – 20° LU (Webster dan Yang, 1992)
- Wilayah monsun India (ISM): 40° – 80° BT dan 5° – 15° LU serta 70° – 90° BT dan 20° – 30° LU (Wang dkk., 2001)
- Wilayah monsun Pasifik Barat Daya (WNPMI) : 100° – 130° BT dan 5° – 15° LU serta 110° – 140° BT dan 20° – 30° LU (Wang dkk., 2001).



Gambar II.5 *Window* domain yang digunakan dalam tahap diagnosis: (1) benua maritim, (2) wilayah monsun Australia, (3) wilayah indeks monsun definisi Webster dan Yang, (4 dan 5) wilayah monsun India, serta (6 dan 7) wilayah monsun Pasifik Barat Daya (Sumber: Syahputra, 2012).



Monsun benua maritim memiliki variabilitas spasial dan temporal pada semua skala waktu dan berkaitan dengan siklus diurnal, tipe cuaca *subseasonal*, dan variabilitas *interannual* ENSO di wilayah Indonesia. Interaksi medan angin dan modulasi siklus diurnal mempengaruhi wilayah sub regional dengan topografi kepulauan yang kompleks (Robertson dkk., 2011). Monsun benua maritim umumnya memiliki curah hujan tinggi pada musim dingin di Benua Asia (*boreal winter*). Wilayah AUSMI mencerminkan variabilitas curah hujan di benua maritim dan Australia Utara secara musiman, *intraseasonal*, *interannual*, dan antar dekade (*interdecadal*). Awal monsun musim panas Australia umumnya sejalan dengan transisi angin zona troposfer bawah dari timur ke barat (Kajikawa dkk., 2010).

Wilayah WYMI definisi Webster dan Yang (1992) sebagai wilayah indeks sirkulasi monsun menggunakan selisih kecepatan angin antara 850 hPa dan 200 hPa (angin geser) untuk merepresentasikan skala besar baroklinik Benua Asia dan Samudra Hindia yang berkaitan dengan intensitas monsun Asia musim panas. Menurut Ailikon and Yasunari (1998) intensitas WYMI memiliki hubungan yang kuat dengan aktivitas konveksi di Samudera Pasifik Barat pada daerah yang hangat.

Kekuatan monsun musim panas Asia menurut Wang dkk. (2001) berkaitan dengan intensitas dua sumber panas konvektif utama yang berpusat di Teluk Benggala (wilayah ISM) dan Laut Filipina (wilayah WNPMI). Wilayah ISM berkaitan dengan peningkatan hujan di India dan Teluk Benggala dan pergerakan pusaran arus di Samudra Hindia di wilayah tropis. Kajian hubungan ISM dengan variabilitas curah hujan di wilayah Indonesia dilakukan oleh Kripalani dan Kurkalni (1997) menggunakan indeks hujan monsun India (IMR) bulan Juni-September 1871-1995 (Parthasarathy dkk., 1994). Hubungan positif yang signifikan antara IMR dan curah hujan di wilayah utara ekuator antara Pulau Sulawesi dan Papua, sedangkan di Pulau Jawa dan Sumatera negatif dan lebih lemah. Menurut D'Arrigo dan Smerdon (2008), penguatan monsun India berkaitan dengan kekeringan di wilayah Pulau Jawa.

Wilayah WNPMI (Wang dkk., 2001) berkaitan dengan curah hujan di Laut China Selatan dan Samudera Pasifik Barat Daya serta zona konvektif dari Kalimantan hingga India Selatan. Menurut Mulsandi dkk., 2021, hubungan indeks monsun WNPMI dengan hujan *Global Precipitation Climatology Project* (GPCP) wilayah Indonesia berkebalikan, dimana aktivitas monsun di Pasifik Barat menguat maka aktivitas monsun di selatan Indonesia akan melemah begitu juga sebaliknya. WNPM yang kuat dapat meningkatkan divergensi level atas di Laut Filipina dan arus lintas-ekuator timur dan selatan di atas benua maritim yang terhubung ke dataran tinggi Australia (Wang dkk., 2001).

### II.2.3 Kalibrasi Luaran Hasil *Downscaling*

Model DS menurut Wilby dkk (2004) sering dikalibrasi untuk mengatasi permasalahan kejadian ekstrem karena umumnya metode DS sukses dalam mereproduksi nilai rata-rata iklim. Modifikasi metode CA dalam penelitian ini untuk mendapatkan representasi data ekstrem adalah dengan melakukan kalibrasi menggunakan metode BMA. Metode BMA yang telah banyak digunakan untuk mengkalibrasi prediksi *ensemble* jangka pendek hingga menengah dari luaran model prediksi global (Slougher dkk., 2007; Raftery dkk., 2005, Muharsyah, 2020). BMA diusulkan oleh Raftery dkk. (2005) sebagai metode statistik *postprocessing ensemble* yang mengkombinasi distribusi prediktif dari *ensemble* anggota. *Probability density function* (PDF) prediktif BMA dari sejumlah *ensemble* merupakan rata-rata terboboti PDF yang berpusat pada prediksi masing-masing anggota dengan bobot yang terkoreksi bias. Bobot tersebut sama dengan probabilitas *posterior* model yang menggambarkan kontribusi relatif model terhadap *skill* prediktif selama periode *training*.

Raftery dkk. (1997) merekomendasikan penggunaan algoritma *Expectation-Maximization* (EM) untuk training model BMA, Vrugt (2016) menyajikan metode alternatif untuk training model BMA menggunakan simulasi *Markov chain Monte Carlo* (MCMC) dengan *Differential Evolution Adaptive Metropolis* (DREAM). BMA merupakan cara yang mungkin dapat dilakukan dalam menangani

ketidakpastian model (Vrugt, 2016). Metode BMA sangat berguna ketika berhadapan dengan output dari model simulasi dinamis.

