

**OPTIMASI PRAKIRAAN CURAH HUJAN BERDASARKAN
SKENARIO RENCANA TAHUNAN OPERASIONAL
WADUK DI BENDUNGAN SUTAMI-LAHOR
MENGUNAKAN PENDEKATAN
MULTI-MODEL ENSEMBEL**

THESIS

**Oleh:
RIKHA RIZKI MAHMUDIAH
NIM. 220605220013**



**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

**OPTIMASI PRAKIRAAN CURAH HUJAN BERDASARKAN
SKENARIO RENCANA TAHUNAN OPERASIONAL
WADUK DI BENDUNGAN SUTAMI-LAHOR
MENGUNAKAN PENDEKATAN
MULTI-MODEL ENSEMBEL**

THESIS

**Diajukan Kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk Memenuhi Salah Satu Persyaratan Dalam
Memperoleh Gelar Magister Komputer (M.Kom)**

**Oleh:
RIKHA RIZKI MAHMUDIAH
NIM. 220605220013**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

**OPTIMASI PRAKIRAAN CURAH HUJAN BERDASARKAN
SKENARIO RENCANA TAHUNAN OPERASIONAL
WADUK DI BENDUNGAN SUTAMI-LAHOR
MENGUNAKAN PENDEKATAN
MULTI-MODEL ENSEMBEL**

THESIS

**Diajukan Kepada:
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk Memenuhi Salah Satu Persyaratan Dalam
Memperoleh Gelar Magister Komputer (M.Kom)**

**Oleh:
RIKHA RIZKI MAHMUDIAH
NIM. 220605220013**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**


**OPTIMASI PRAKIRAAN CURAH HUJAN BERDASARKAN SKENARIO
RENCANA TAHUNAN OPERASIONAL WADUK DI BENDUNGAN
SUTAMI-LAHOR MENGGUNAKAN PENDEKATAN
MULTI-MODEL ENSEMBEL**

THESIS


Oleh:
RIKHA RIZKI MAHMUDIAH
NIM. 220605220013

Telah diperiksa dan disetujui untuk diuji:
Tanggal: 25 November 2024

Pembimbing I,



Dr. Cahyo Crysdian
NIP. 19740424 200901 1 008

Pembimbing II,


Dr. M. Amin Hariyadi, M.T
NIP. 19670018 200501 1 001

Mengetahui,
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Cahyo Crysdian
NIP. 19740424 200901 1 008

**OPTIMASI PRAKIRAAN CURAH HUJAN BERDASARKAN SKENARIO
RENCANA TAHUNAN OPERASIONAL WADUK DI BENDUNGAN
SUTAMI-LAHOR MENGGUNAKAN PENDEKATAN
MULTI-MODEL ENSEMBEL**

THESIS

**Oleh:
RIKHA RIZKI MAHMUDIAH
NIM. 220605220013**

Telah Dipertahankan di Depan Dewan Penguji Thesis
Dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Magister Komputer (M.Kom)
Tanggal: 25 November 2024

Susunan Dewan Penguji

Penguji I	:	<u>Dr. M. Ainul Yaqin, M.Kom</u> NIP. 19761013 200604 1 004
Penguji II	:	<u>Prof. Dr. Hj. Sri Harini, M.Si</u> NIP. 19731014 200112 2 002
Pembimbing I	:	<u>Dr. Cahyo Crysdiان</u> NIP. 19740424 200901 1 008
Pembimbing II	:	<u>Dr. M. Amin Hariyadi, M.T</u> NIP. 19670018 200501 1 001

Tanda Tangan

()
()
()
()

Mengetahui dan Mengesahkan,
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Cahyo Crysdiان
NIP. 19740424 200901 1 008

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Rikha Rizki Mahmudiah

NIM : 220605220013

Program Studi : Magister Informatik

Fakultas : Sains dan Teknologi

Menyatakan dengan sebenarnya bahwa Thesis yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambilalihan data, tulisan atau pikiran orang lain yang saya akui sebagai tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila di kemudian hari terbukti atau dapat dibuktikan Thesis ini hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, Desember 2024

Yang menyatakan,

A handwritten signature in black ink is written over a yellow and red 1000 Rupiah stamp. The stamp features the Garuda Pancasila emblem and the text 'SERUPAH RIBU RUPIAH', '1000', 'KEMENTERIAN TEMPER', and the serial number '9BC54AJX100993248'.

Rikha Rizki Mahmudiah
NIM. 220605220013

MOTTO

*“Belajar adalah perjalanan tanpa akhir,
sementara setiap pencapaian adalah langkah menuju pemahaman
yang lebih dalam”*

PERSEMBAHAN

Dengan segenap rasa syukur kepada Allah SWT, tesis ini saya persembahkan kepada:

1. Seluruh keluarga saya (ibu, almarhum bapak, suami, anak, dan kakak-kakak) yang selalu memberikan doa, dukungan, dan semangat tanpa henti.
2. Dosen pembimbing dan seluruh pengajar, yang telah sabar membimbing, memberi ilmu, dan berbagi pengalaman yang begitu berharga, sehingga saya bisa belajar lebih banyak dalam bidang ilmu ini.
3. Rekan-rekan angkatan 7 Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang yang telah mendukung, berbagi pengetahuan, ide, dan dukungan moral selama ini.
4. Institusi BMKG, khususnya Stasiun Klimatologi Jawa Timur, yang telah memberikan kesempatan untuk melanjutkan pendidikan serta mendukung penelitian ini.
5. Bapak, Ibu, rekan-rekan dan semua pihak yang tidak dapat saya sebutkan satu per satu yang telah membantu saya selama masa studi ini.

Semoga karya ini dapat bermanfaat dan menjadi langkah awal bentuk kontribusi nyata bagi lingkungan dan ilmu pengetahuan.

KATA PENGANTAR

Assalamu'alaikum warahmatullah wabarakatuh

Puji syukur, alhamdulillah, kehadiran Allah SWT atas limpahan rahmat dan kasih sayang-Nya, sehingga penulis dapat menyelesaikan studi di Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang sekaligus menyelesaikan Thesis ini dengan baik. Penulis mengucapkan terima kasih sebesar-besarnya kepada semua pihak yang telah membantu terselesaikannya Thesis ini. Ucapan terima kasih ini penulis sampaikan kepada:

1. Bapak Dr. Cahyo Crysdiand dan Bapak Dr. M. Amin Hariyadi, M.T selaku dosen pembimbing Thesis atas arahan dan motivasi yang telah diberikan,
2. Segenap civitas akademika Program Studi Magister Informatika atas ilmu dan bimbingannya,
3. Keluarga tercinta atas dukungan dan doa yang selalu dilangitkan, dan
4. Semua rekan-rekan Magister Informatika, baik angkatan 7 maupun senior-junior yang berkenan berbagi pengalaman dan memberi masukan.

Penulis menyadari bahwa penyusunan Thesis ini masih mengandung kekurangan. Meski demikian, penulis berharap semoga Thesis ini dapat memberi manfaat kepada para pembaca, khususnya pihak-pihak yang menjadi tujuan penyelenggaraan penelitian ini, dan penulis secara pribadi.

Wassalamu'alaikum warahmatullah wabarakatuh.

Malang, Desember 2024
Penulis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGANTAR	ii
HALAMAN PERSETUJUAN	iv
HALAMAN PENGESAHAN	v
HALAMAN PERNYATAAN	vi
MOTTO	vii
HALAMAN PERSEMBAHAN	viii
KATA PENGANTAR.....	ix
DAFTAR ISI.....	x
DAFTAR TABEL	xii
DAFTAR GAMBAR.....	xiv
ABSTRAK	xvi
ABSTRACT	xvii
الخلاصة	xviii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Pernyataan Masalah	4
1.3 Tujuan Penelitian	5
1.4 Batasan Masalah.....	5
1.5 Manfaat Penelitian	5
BAB II STUDI PUSTAKA	7
2.1 Model Prakiraan Curah Hujan	7
2.1.1 ARIMA (<i>Autoregressive Integrated Moving Average</i>).....	7
2.1.2 ECMWF (<i>European Centre for Medium-Range Weather Forecasts</i>).....	8
2.1.3 Regresi Linier	10
2.2 Ensembel Prakiraan Curah Hujan	13
2.3 Kerangka Teoritis.....	18
BAB III MODEL KONSEPTUAL	25
3.1 Kerangka Konseptual	25
3.2 Desain Penelitian.....	26
3.2.1 Pengumpulan Data.....	26
3.2.2 Desain Sistem dan Implementasi.....	29
3.2.3 Eksperimen	46
3.3 Instrumen Penelitian.....	50
3.4 Kerangka Operasional.....	50

3.4.1 Kebutuhan Informasi Rencana Tahunan Operasional Waduk	50
3.4.2 Informasi Iklim	51
BAB IV MODEL SKENARIO DASAR RTOW	54
4.1 Prakiraan Curah Hujan Luaran Model Skenario Dasar RTOW	54
4.2 Verifikasi Luaran Prakiraan Curah Hujan dengan Skenario Dasar RTOW	56
BAB V MODEL ARIMA.....	60
5.1 Prakiraan Curah Hujan Luaran Model ARIMA.....	60
5.2 Verifikasi Luaran Prakiraan Curah Hujan dengan Model ARIMA ...	61
BAB VI MODEL ECMWF	64
6.1 Prakiraan Curah Hujan Luaran Model ECMWF	64
6.2 Verifikasi Luaran Prakiraan Curah Hujan dengan Model ECMWF..	66
BAB VII MODEL REGRESI	67
7.1 Prakiraan Curah Hujan Luaran Model Regresi ONI	67
7.2 Verifikasi Luaran Prakiraan Curah Hujan dengan Model Regresi ONI.....	68
7.3 Prakiraan Curah Hujan Luaran Model Regresi DMI	72
7.4 Verifikasi Luaran Prakiraan Curah Hujan dengan Model Regresi DMI	74
7.5 Prakiraan Curah Hujan Luaran Model Regresi Komponen Utama ERSST	78
7.6 Verifikasi Luaran Prakiraan Curah Hujan dengan Model Regresi Komponen Utama ERSST	81
BAB VIII MODEL ENSEMBEL.....	82
8.1 Prakiraan Curah Hujan Luaran Model Ensemble	82
8.2 Verifikasi Prakiraan Curah Hujan Luaran Model Ensemble	85
BAB IX EVALUASI MODEL	91
9.1 Rekomendasi Model Terbaik Tiap Zona Musim (ZOM).....	91
9.2 Studi Kasus.....	94
BAB X PENUTUP.....	103
10.1 Kesimpulan	103
10.2 Saran.....	104
DAFTAR PUSTAKA	105
LAMPIRAN.....	108

DAFTAR TABEL

Tabel 2.1	Daftar penelitian terdahulu yang digunakan sebagai rujukan	20
Tabel 3.1	Pembagian periode data latih dan uji	31
Tabel 3.2	Kelas curah hujan	34
Tabel 3.3	Hasil ujicoba prakiraan dengan skenario RTOW, ECMWF dan ARIMA di ZOM 41	47
Tabel 3.4	Hasil ujicoba prakiraan dengan skenario regresi ONI, DMI dan SST di ZOM 41	48
Tabel 3.5	Hasil ujicoba prakiraan dengan skenario ensemble di ZOM 41 ...	49
Tabel 3.6	Rekomendasi model terbaik di ZOM 41	50
Tabel 3.7	Urutan dasarian setiap tahun	52
Tabel 4.1	Hasil verifikasi luaran model skenario dasar untuk ZOM 20	56
Tabel 4.2	Hasil verifikasi luaran model skenario dasar RTOW	58
Tabel 5.1	Hasil verifikasi luaran model ARIMA untuk ZOM 32 dan 38	62
Tabel 5.2	Hasil verifikasi luaran model ARIMA	63
Tabel 6.1	Hasil verifikasi luaran model ECMWF	66
Tabel 7.1	Hasil verifikasi luaran model regresi ONI berdasarkan kesesuaian rata-rata	69
Tabel 7.2	Hasil verifikasi luaran model regresi ONI berdasarkan kesesuaian Minimum	70
Tabel 7.3	Hasil verifikasi luaran model regresi ONI berdasarkan MAE rata-rata	71
Tabel 7.4	Hasil verifikasi luaran model regresi ONI berdasarkan MAE Maksimum	72
Tabel 7.5	Hasil verifikasi luaran model regresi DMI berdasarkan kesesuaian rata-rata	74

Tabel 7.6	Hasil verifikasi luaran model regresi DMI berdasarkan kesesuaian Minimum.....	75
Tabel 7.7	Hasil verifikasi luaran model regresi DMI berdasarkan MAE rata-rata.....	76
Tabel 7.8	Hasil verifikasi luaran model regresi DMI berdasarkan MAE Maksimum.....	77
Tabel 7.9	Hasil verifikasi luaran model regresi komponen utama ERSST ZOM 20	81
Tabel 8.1	Bobot model ke-1 hingga ke-150 untuk memprakirakan curah hujan periode 2015/2016 di ZOM 141 menggunakan ensemble kesesuaian-based n=150.....	83
Tabel 8.2	Bobot model ke-1 hingga ke-150 untuk memprakirakan curah hujan dasarian 1 Desember 2014/2015 di ZOM 141 menggunakan ensemble kesesuaian-based n=10.....	84
Tabel 9.1	Rekomendasi model terbaik tiap ZOM	92
Tabel 9.2	Rangkuman Verifikasi Prakiraan di Tiap ZOM.....	95

DAFTAR GAMBAR

Gambar 2.1	Kerangka teoritis.....	19
Gambar 3.1	Kerangka konsep penelitian yang akan dilakukan.....	25
Gambar 3.2	Desain penelitian.....	26
Gambar 3.3	Wilayah penelitian (Sumber: Stasiun Klimatologi Jawa Timur)	29
Gambar 3.4	Desain sistem	30
Gambar 3.5	Diagram alir proses prakiraan menggunakan skenario RTOW ..	32
Gambar 3.6	Diagram alir proses prakiraan menggunakan ARIMA	35
Gambar 3.7	Diagram alir proses prakiraan menggunakan ECMWF.....	38
Gambar 3.8	Diagram alir proses prakiraan menggunakan regresi ONI-DMI	40
Gambar 3.9	Diagram alir proses prakiraan menggunakan regresi komponen utama ERSST.....	41
Gambar 3.10	Diagram alur proses prakiraan dengan membentuk ensemble ...	42
Gambar 4.1	Grafik <i>time series</i> hasil prakiraan (garis merah) curah hujan dasarian ZOM 20 menggunakan skenario basah (atas), normal (tengah), dan kering (bawah).....	54
Gambar 5.1	Grafik <i>time series</i> hasil prakiraan (garis merah) curah hujan dasarian menggunakan model ARIMA di ZOM 32 (atas) dan 38 (bawah)	60
Gambar 6.1	Grafik <i>time series</i> hasil prakiraan (garis merah) curah hujan dasarian menggunakan model ECMWF <i>raw</i> (atas) dan terkoreksi (bawah) di ZOM 30	64
Gambar 6.2	Grafik <i>time series</i> hasil prakiraan (garis merah) curah hujan dasarian menggunakan model ECMWF <i>raw</i> (atas) dan terkoreksi (bawah) di ZOM 38	65
Gambar 7.1	Grafik <i>time series</i> hasil prakiraan curah hujan dasarian (garis merah) menggunakan model regresi ONI di ZOM 35.....	67
Gambar 7.2	Grafik <i>time series</i> hasil prakiraan curah hujan dasarian (garis merah) menggunakan model regresi DMI di ZOM 35.....	73

Gambar 7.3	Grafik <i>time series</i> hasil prakiraan curah hujan dasarian (garis merah) menggunakan model regresi komponen utama ERSST di ZOM 40	79
Gambar 8.1	Prakiraan curah hujan 2015/2016 di ZOM 141 menggunakan beberapa model	85
Gambar 8.2	Grafik visualisasi luaran model dan hasil verifikasi.....	85
Gambar 8.3	Grafik perbandingan hasil verifikasi prakiraan ensemble MAE-based (garis hijau) dan ensemble Kesesuaian-based (garis hitam) terhadap model tunggal (urut dari kiri ke kanan: skenario dasar RTOW, ARIMA, ECMWF, regresi ONI-DMI, dan regresi ERSST)	86
Gambar 8.4	Grafik perbandingan hasil verifikasi prakiraan ensemble MAE-based (garis hijau) dan ensemble Kesesuaian-based (garis hitam) terhadap model tunggal (urut dari kiri ke kanan: skenario dasar RTOW, ARIMA, ECMWF, regresi ONI-DMI, dan regresi ERSST) di ZOM 20	88
Gambar 8.5	Hasil verifikasi berbasis kesesuaian (atas) dan MAE (bawah) hasil prakiraan ensemble di ZOM=41	89
Gambar 9.1	Penentuan rekomendasi model	91
Gambar 9.2	Perbandingan prakiraan (garis orange) dan observasi (garis biru) curah hujan di Bendungan Sutami-Lahor	97
Gambar 9.3	Hubungan antara curah hujan dasarian dengan debit masuk (<i>inflow</i>) pada periode musim hujan (atas) dan kemarau (bawah) di Bendungan Sutami-Lahor.....	98
Gambar 9.4	Perbandingan debit masuk/ <i>inflow</i> (atas) dan selisih prakiraan absolut (bawah) berdasarkan hasil prakiraan multimodel dan skenario dasar RTOW	99

ABSTRAK

Mahmudiah, Rikha Rizki. 2024. **Optimasi Prakiraan Curah Hujan Berdasarkan Skenario Rencana Tahunan Operasional Waduk di Bendungan Sutami-Lahor Menggunakan Pendekatan Multi-model Ensemble**. Thesis. Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Cahyo Crysdian, (II) Dr. M. Amin Hariyadi, M.T.

Kata kunci: rencana operasional waduk, prakiraan curah hujan, simulasi operasional, ensemble

Terdapat kesenjangan antara informasi iklim yang ada dengan kebutuhan perencanaan tahunan operasional waduk. Penelitian ini ingin membuktikan bahwa pendekatan persentil yang digunakan saat ini tidak optimum. Tujuan dari studi ini adalah mendesain otomatisasi prakiraan dan evaluasinya berbasis curah hujan 36 dasarian ke depan menggunakan pendekatan multi-model yang terdiri dari model persentil, ARIMA, ECMWF+ARIMA, regresi ONI DMI, regresi komponen utama ERSST, dan ensemble. Otomatisasi ini memungkinkan perbandingan pendekatan persentil terhadap multi-model dapat dilangsungkan secara cepat. Selain itu, studi ini juga bertujuan untuk mendemonstrasikan bagaimana alternatif prakiraan curah hujan berbasis multi-model yang telah diverifikasi ini lebih mampu memberikan kepastian pada kasus perencanaan tahunan operasional waduk Lahor-Sutami yang disimulasikan secara operasional pada November 2022 untuk perencanaan 2022/2023. Data yang digunakan adalah curah hujan historis dasarian tahun 1991 sampai 2023, luaran model ECMWF mentah dan terkoreksi, indeks Nino-Dipole, serta suhu muka laut global. Metode verifikasi yang digunakan adalah 4 kriteria berdasar MAE dan kesesuaian. Pendekatan simulasi operasional digunakan untuk pembagian periode pelatihan-pengujian. Jendela 10 tahunan digunakan untuk mewakili prinsip kemungkinan perubahan hubungan karena perubahan iklim. Regresi linier tunggal digunakan untuk menghindari *overfitting*. Pembangunan sistem otomatisasi dilakukan dengan menggunakan R-Statistics. Hasil menunjukkan bahwa pendekatan yang digunakan saat ini hanya optimal dilakukan untuk 58% lokasi. Metode yang terbukti unggul adalah metode ECMWFcor, regresi ERSST, dan ensemble. Adanya ensemble berdampak pada peningkatan indeks kesesuaian minimum dan penurunan MAE maksimum. Penelitian ini juga menyajikan studi kasus tahun 2022/2023 yang menunjukkan penggunaan hasil luaran lebih baik dari skenario saat ini setidaknya pada 78% periode yang ada.

ABSTRACT

Mahmudiah, Rikha Rizki. 2024. **Optimizing Rainfall Forecast Based on Single-Year Operational Plan Scenarios at Sutami-Lahor Dam Using Multi-model Ensemble Approach**. Theses. Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Promotor: (I) Dr. Cahyo Crysdiyan.(II) Dr. M. Amin Hariyadi.

Key words: Dam operational plan; rainfall prediction; operational simulation

There is gap between existing climate information and the need for annual planning of dam operations. This study aims to demonstrate that the currently employed percentile approach is not optimal. The objective of this research is to design an automated forecasting and evaluation system based on rainfall for 36 10-days forward using multi-model approach consisting of percentile, ARIMA, ECMWF+ARIMA, ONI DMI regression, ERSST principal component regression, and ensemble models. The automation facilitates rapid comparisons between the percentile and multi-model approach. In addition, this study also aims to demonstrate how the verified multi-model rainfall forecasting alternative can provide greater certainty in the case of annual operational planning for Lahor-Sutami dams which was operationally simulated in November 2022 for the 2022/2023 planning period. The data used are the historical 10-days rainfall from 1991 to 2023, raw and corrected ECMWF's output, Nino-Dipole indices, and global sea surface temperature. The verification methods employed involve four criteria based on Mean Absolute Error (MAE) and fit index. The operational simulation approach is used for the training-testing period segmentation. The 10-year window applied to account for principle of potential changes in relationships due to climate change. Single linear regression is used to prevent overfitting. The development of the automation system is carried out using R-Statistics. The results show that the current approach is optimal for only 58% of locations. The proven superior methods include ECMWFcor, ERSST regression, and ensemble. The ensemble method enhances the minimum fit index and reduces the maximum MAE. Additionally, a 2022/2023 case study demonstrates that the proposed outputs outperform the current scenario in at least 78% of the periods analyzed.

الخلاصة

محمودية، ركا رزقي. ٢٠٢٤. تحسين توقعات الأمطار وفقا للخطة التشغيلية السنوية للحاووز في سدّ سوتامي - لاهور باستخدام منهج تعدد النماذج انساميل. رسالة ماجستير. شعبة المعلوماتية الدراسة العليا كلية العلوم والتكنولوجيا جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانغ. المشرف : (١) د. جهيو كريسديان، (٢) د. محمد أمين هاريادي، م، ت.

الكلمات الرئيسية : الخطة التشغيلية للحاووز، توقعات الأمطار، محاكاة التشغيل، انساميل

قد وجدت الفجوة بين معلومات الطقس الحالية والخطة السنوية لتشغيل الحاووز. ويريد هذا البحث الإثبات بأن منهج النسبة المئوية المستخدم حاليا غير أمثل. والهدف من هذا البحث هو تصميم آلية التوقعات والتقييمات الذي يعتمد على هطول الأمطار لمدة ٣٦ -١٠ أيام في المستقبل باستعمال منهج تعدد النماذج الذي يتكون من نموذج النسبة المئوية، ونموذج التحليل بالتراجع والتوسط المتحرك (ARIMA)، والمركز الأوروبي للتنبؤات الجوية المتوسطة المدى + نموذج التحليل بالتراجع والتوسط المتحرك (ECMWF+ARIMA)، وانحدار ثنائية قطب المحيط الهندي (IOD) اضطراب ثنائي القطب (DMI)، وانحدار المكون الرئيسي لدرجة حرارة سطح البحر الممتدة المعاد بناؤها (ERSST)، وانساميل. وتستطيع هذه الآلية أن تقارن بين منهج النسبة المئوية ومنهج تعدد النماذج مقارنة سريعة. وعلاوة على ذلك، يهدف هذا البحث إلى عرض الكيفية الرديفة لتوقعات الأمطار المؤسسة ب منهج تعدد النماذج المتحققة أكثر قدرة من الأخرى على التثبيت في خطة التشغيل السنوية للحاووز في سدّ سوتامي – لاهور التي تم محاكاتها التشغيلي في نوفمبر ٢٠٢٢ لخطة عام ٢٠٢٣\٢٠٢٢. والبيانات المستخدمة في هذا البحث هي هطول الأطار التاريخي عشرة الأيام من عام ١٩٩١ حتى عام ٢٠٢٣، وظاهر خارجي المركز الأوروبي للتنبؤات الجوية المتوسطة المدى سوا أكان الفجي أو ال مصحح، وقائمة النيونيو – ثنائي القطب، ودرجة حرارة سطح البحري العالمية. وطريق التحقق المستخدمة هي ٤ معايير التي تستند على استخراج بمساعدة الميكروويف (MAE) والملائمة. وقد استخدم أسلوب محاكاة التشغيلي لتقسيم فترة التدريب والاختبار. وقد استخدمت نافذة ١٠ سنوات تمثيلا لقاعدة تغيير العلاقة بسبب تغيير المناخ. وقد استخدم الانحدار الخطي الفردي للتجنب عن الإفراط في التجهيز. وإن بناء نظام التشغيل الآلي مستعمل باستخدام إحصائية – آر (R-Statistics). وتظهر النتيجة بأن المنهج المستخدم حاليا أمثل ل ٥٨٪ موقعا فقط. وإن المنهج الأمثل المتفوق هو منهج المركز الأوروبي للتنبؤات الجوية المتوسطة المدى (ECMWFcor)، وانحدار المكون الرئيسي لدرجة حرارة سطح البحر الممتدة المعاد بناؤها (ERSST)، وانساميل. وإن لوجود انساميل تأثير لزيادة الحد الأدنى للقائمة وتخفيض الحد الأقصى لا استخراج بمساعدة الميكروويف (MAE). وقد قدم هذا البحث أيضا دراسة للفترة ٢٠٢٣\٢٠٢٢ التي توضح نتيجة الظاهر الخارجي بأنها أفضل من الخطة المستخدمة حاليا على الأقل ٧٨٪ من الفترة الحالية.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), berdasarkan Peraturan Presiden Nomor 12 Tahun 2024, memiliki peran sentral dalam menyediakan informasi dan layanan dalam bidang meteorologi, klimatologi, dan geofisika di Indonesia. Di bidang klimatologi, BMKG berperan memberikan pemahaman yang lebih baik tentang dinamika iklim Indonesia serta membantu pemerintah dan pengguna lain dalam mengambil langkah-langkah adaptasi dan mitigasi terhadap isu iklim terkini. Salah satu produk informasi klimatologi yang dihasilkan BMKG adalah prakiraan musim yang memuat prakiraan curah hujan dan sifat musim. Informasi ini merupakan komponen penting dalam perencanaan operasional waduk. Pengetahuan tentang musim hujan dan musim kemarau memungkinkan pengelola waduk untuk mengantisipasi fluktuasi pasokan air (Hurkmans et al, 2023).

Merujuk pada Rencana Alokasi Air Tahunan Wilayah Sungai (RAAT WS) Brantas Tahun 2023/2024 (Bestari, 2023), terdapat beberapa kesenjangan antara informasi prakiraan yang disediakan BMKG dengan kebutuhan praktis dalam perencanaan operasional dan berpotensi menimbulkan ketidaktepatan informasi. Dalam analisis awal mengacu pada RAAT 2022/2023, informasi debit pada RTOW dan prakiraan curah hujan memiliki korelasi 0,9, lebih tinggi daripada korelasi debit dengan prakiraan sifat seperti yang digunakan saat ini. Prakiraan musim pada informasi BMKG memiliki periode yang bervariasi tiap tahunnya,

sedangkan musim dalam Rencana Tahunan Operasional Waduk (RTOW) memiliki periode yang tetap setiap tahun. Durasi prakiraan musim di Jawa Timur dari BMKG mencakup periode tujuh bulan ke depan, sedangkan perencanaan operasional waduk memerlukan informasi untuk satu tahun. Penentuan sifat musim BMKG menggunakan batasan 115% dan 85% dari nilai normal, sedangkan RTOW menggunakan nilai persentil ke 35 dan ke-65. Prakiraan musim BMKG biasanya dirilis pada bulan September sedangkan rapat perencanaan operasional waduk dilaksanakan November. Kesenjangan tersebut menunjukkan urgensi untuk melakukan studi yang menyelidiki kualitas informasi dalam konteks skenario yang dibutuhkan, dimana ini belum pernah dilakukan.

Beberapa model prakiraan yang saat ini sering digunakan di BMKG adalah ARIMA, ECMWF, dan regresi. Variasi luaran model-model tersebut menunjukkan masih ada kesalahan (error) yang berpotensi untuk diminimalisir sehingga menghasilkan prakiraan yang lebih optimal. Misalnya, ARIMA memiliki rata-rata akurasi tertinggi diantara model dalam HyBMG dengan rata-rata 60% (Kurniawan, et al, 2020). Salah satu upaya optimasi yang bisa dilakukan adalah pemanfaatan teknik ensemble yang memungkinkan penggabungan beberapa model tunggal dengan performa yang berbeda-beda. Pada beberapa penelitian sebelumnya, penggunaan ensemble dinilai efektif meningkatkan kualitas prakiraan (Gu, et al, 2022). Optimasi ditujukan untuk meningkatkan kesesuaian dan/atau pengurangan beda nilai prakiraan. Penelitian ini akan memberikan wawasan untuk membentuk standar dan kriteria informasi musim yang lebih baik dan dapat diandalkan bagi kebutuhan praktis, seperti perencanaan dan pengelolaan operasional waduk.

Allah SWT dalam Al-Qur'an surah Al-An'am ayat 165 berfirman:

وَهُوَ الَّذِي جَعَلَكُمْ خَلَائِفَ الْأَرْضِ وَرَفَعَ بَعْضَكُمْ فَوْقَ بَعْضٍ دَرَجَاتٍ لِّيَبْلُوكُمْ فِي مَا
 أَتَيْتُمْ أَنْ رَبَّكَ سَرِيعُ الْعِقَابِ وَإِنَّهُ لَغَفُورٌ رَحِيمٌ ﴿١٦٥﴾

Artinya: *Dialah yang menjadikan kamu sebagai khalifah-khalifah di bumi dan Dia meninggikan sebagian kamu beberapa derajat atas sebagian (yang lain) untuk menguji kamu atas apa yang diberikan-Nya kepadamu. Sesungguhnya Tuhanmu sangat cepat hukuman-Nya. Sesungguhnya Dia Maha Pengampun lagi Maha Penyayang (Al An'am: 165).*

Menurut tafsir Jalalain, (Dan Dialah yang menjadikan kamu penguasa-penguasa di bumi) jamak dari kata khalifah; yakni sebagian di antara kamu mengganti sebagian lainnya di dalam masalah kekhalifahan ini (dan Dia meninggikan sebagian kamu atas sebagian yang lain beberapa derajat) dengan harta benda, kedudukan dan lain sebagainya (untuk mengujimu) untuk mencobamu (tentang apa yang diberikan kepadamu) artinya Dia memberi kamu agar jelas siapakah di antara kamu yang taat dan siapakah yang maksiat. (Sesungguhnya Tuhanmu itu adalah amat cepat siksaan-Nya) terhadap orang-orang yang berbuat maksiat kepada-Nya (dan sesungguhnya Dia Maha Pengampun) terhadap orang-orang mukmin (lagi Maha Penyayang.") terhadap mereka. Peran BMKG sebagai penyedia informasi dan layanan di bidang meteorologi, klimatologi, dan geofisika membawa konsekuensi dimana tindakan dan keputusan yang diambil harus didasarkan pada tanggungjawab. Harapannya, keputusan yang diambil memiliki nilai manfaat untuk lebih banyak pihak.

Pembuatan prakiraan musim di Jawa Timur melibatkan data historis dalam jumlah besar yang memerlukan pendekatan tertentu yang dapat meningkatkan efisiensi pekerjaan. Otomatisasi dapat menjadi pendekatan baru, dimana ini

mencakup penggunaan algoritma dan teknik pemrosesan data besar untuk ekstraksi pola dalam dataset kompleks, memungkinkan pembaruan prakiraan secara berkala dengan cepat dan memberi respon adaptif terhadap perubahan kondisi cuaca dan lingkungan. Dalam norma terbaru, penggunaan perangkat lunak sumber terbuka dalam proses pembuatan prakiraan musim di BMKG lebih disarankan, demi keberlanjutan dan aksesibilitas yang lebih luas. Dalam konteks ini, R-Statistics yang memiliki fitur RClim muncul sebagai pilihan.

Berdasarkan latar belakang di atas, penelitian ini fokus pada upaya optimasi prakiraan curah hujan sesuai skenario dalam kerangka kerja Rencana Tahunan Operasional Waduk (RTOW), menggunakan pendekatan multi-model ensemble. Optimasi yang ingin dicapai adalah peningkatan kesesuaian dan/atau pengurangan beda nilai prakiraan. Dengan demikian, diharapkan penelitian ini dapat memberikan kontribusi nyata dalam meningkatkan kualitas prakiraan musim yang lebih sesuai dengan kebutuhan operasional waduk sehingga berguna dalam pengelolaan sumber daya air yang lebih efektif.

1.2 Pernyataan Masalah

Pernyataan masalah yang akan dibahas pada penelitian ini adalah:

- a. Bagaimana performa model prakiraan yang digunakan dalam Rencana Tahunan Operasional Waduk (RTOW) saat ini dibandingkan dengan pendekatan multi-model ensemble?
- b. Bagaimana dampak ensemble terhadap kualitas informasi prakiraan curah hujan musim berdasarkan kerangka kerja rencana tahunan operasional waduk (RTOW)?

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah:

- a. Mengukur performa model prakiraan yang digunakan dalam Rencana Tahunan Operasional Waduk (RTOW) saat ini dibandingkan dengan pendekatan multi-model ensemble.
- b. Menganalisis dampak ensemble terhadap kualitas informasi prakiraan curah hujan musim berdasarkan kerangka kerja rencana tahunan operasional waduk (RTOW).

1.4 Batasan Masalah

Batasan masalah dalam penelitian ini adalah sebagai berikut:

- a. Wilayah penelitian meliputi 12 ZOM terbaru, disusun berdasarkan curah hujan periode 1991-2020 dan mulai digunakan sejak akhir tahun 2022, yang merupakan DAS hulu Bendungan Sutami-Lahor di Malang, Jawa Timur.
- b. Data curah hujan menggunakan luaran model ECMWF System 4 dan curah hujan *blending* berbasis pewilayahan ZOM dari tahun 1991-2023.
- c. Debit diasumsikan mengikuti curah hujan.
- d. Curah hujan wilayah yang mempengaruhi debit diasumsikan dapat diwakili oleh informasi berbasis ZOM.

1.5 Manfaat Penelitian

Hasil dari penelitian ini dapat dimanfaatkan oleh:

- a. Bagi BMKG: sebagai landasan pembuatan Norma, Standar, Prosedur, dan Kriteria (NSPK) tentang informasi iklim terkait RTOW.

- b. Bagi Tim Koordinasi Pengelolaan Sumber Daya Air (TKPSDA) yang merupakan forum gabungan antara Kementerian PUPR, Direktorat Jendral Sumber Daya Air, Balai Besar Wilayah Sungai, Badan Usaha Milik Negara, Jasa Tirta, BMKG, Dinas Pengairan Kabupaten/Kota: dapat menjadi masukan yang lebih tepat guna dalam penyusunan RTOW (salah satu bagian dari RAAT).

BAB II

STUDI PUSTAKA

2.1 Model Prakiraan Curah Hujan

2.1.1 ARIMA (*Autoregressive Integrated Moving Average*)

Pusat Penelitian dan Pengembangan BMKG telah menciptakan Hybrid BMG (HyBMG), sebuah model prakiraan statistik berbasis prakiraan iklim sebagai langkah pencegahan untuk mengurangi dampak bencana hidrometeorologi seperti kekeringan dan curah hujan tinggi. HyBMG merupakan hasil pemodelan iklim yang diharapkan efektif untuk wilayah-wilayah dengan pola curah hujan monsun, termasuk Jawa Timur. Prakiraan curah hujan pada HyBMG menggunakan metode ARIMA, ANFIS (*Adaptive Neuro Fuzzy Inference System*), wavelet-ARIMA, dan wavelet-ANFIS.

Kurniawan et al. (2022) mengevaluasi sejauh mana model prakiraan HyBMG dapat memberikan prakiraan curah hujan bulanan yang akurat untuk wilayah Jawa Timur, dengan fokus pada verifikasi berdasarkan persentase akurasi dalam pengkategorian curah hujan sesuai dengan standar SNI 8196:2015. HyBMG (Hybrid BMG) adalah sebuah model prakiraan statistik berbasis prakiraan iklim yang dikembangkan oleh Pusat Penelitian dan Pengembangan (Puslitbang) BMKG dan diharapkan efektif untuk wilayah-wilayah dengan pola curah hujan monsun, termasuk Jawa Timur. Penelitian ini menggunakan data simulasi prakiraan curah hujan bulanan dari model HyBMG yang dijalankan ulang dengan metode ARIMA, ANFIS, wavelet-ARIMA, dan wavelet-ANFIS dengan jeda 0 hingga 11 bulan pada 197 pos hujan di Jawa Timur dari Agustus

2010 hingga April 2020. Luaran model dianalisis dalam konteks kondisi Netral, El Niño, dan La Niña dengan menggunakan indeks Nino 3.4 (*Oceanic Nino Index/ONI*) untuk menentukan kondisi ENSO. Hasil analisis menunjukkan bahwa metode ARIMA memiliki tingkat verifikasi tertinggi diantara model lainnya, yaitu rata-rata 60%. Secara umum, luaran model HyBMG memiliki verifikasi di bawah 60% saat fase La Niña, sedangkan pada fase El Niño hanya ARIMA yang mencapai tingkat verifikasi antara 60% hingga 70%.

Noviasari et al. (2023) menyoroti pentingnya metode prakiraan curah hujan yang baik untuk mendukung produksi garam di Madura yang menggunakan metode solar evaporator. Penelitian ini memanfaatkan metode ARIMA Boox-Jenkins untuk memprakirakan curah hujan dan menganalisis dampaknya terhadap garam yang diproduksi. Data curah hujan bulanan selama 30 tahun digunakan sebagai masukan dan model ARIMA yang digunakan adalah AR1. Pada penelitian ini, AR1 mampu menghasilkan prakiraan dengan pola yang mirip terhadap data observasi. Tingkat korelasi yang dihasilkan menunjukkan kecocokan yang baik untuk digunakan sebagai metode prakiraan curah hujan di Madura dengan koefisien korelasi Pearson sebesar 0,94%.

2.1.2 ECMWF (*European Centre for Medium-Range Weather Forecasts*)

Menurut Molteni et al (2017), sistem prakiraanensemble model ECS4 (ECMWF *System-4*) merupakan penyempurnaan dari model sebelumnya, yaitu *System-3*. Perbedaannya terletak pada penggunaan model laut dari *Nucleus for European Modelling of the Ocean* dan sistem data asimilasi NEMO/NEMOVAR. Selain itu, model ini memanfaatkan re-analisis ERA-Interim sebagai kondisi awal untuk atmosfer dan menggunakan siklus *integrated forecasting system* terbaru.

Gabungan semua ini meningkatkan kemampuan ECS4 dari versi sebelumnya dalam beberapa aspek, termasuk resolusi horizontal, vertikal, jumlah anggota ensemble, dan jangkauan prakiraan.

Hasil dari penelitian A. Weisheimer dan Palmer (2014) menunjukkan bahwa kemampuan prakiraan probabilistik curah hujan musim dari luaran mentah model ECS4 yang telah disesuaikan dengan data CPC-P (*Climate Prediction Center – Precipitation*) bervariasi tergantung pada wilayah dan periode musim yang dipertimbangkan. Mereka menyimpulkan bahwa prakiraan tersebut memiliki tingkat keandalan yang *dangerous* di wilayah Belahan Bumi Utara (BBU) dan *still very useful* di wilayah tropis selama periode musim Dingin (DJF) dan Panas (JJA).

Ruslana et al. (2021) melakukan penelitian untuk menguji keandalan prakiraan curah hujan dasarian operasional pada kondisi ekstrem, khususnya pada peristiwa banjir yang terjadi di Kabupaten Kebumen pada tanggal 26 Oktober 2020. Dalam penelitian ini, sensitivitas model univariat HyBMG dan ECMWF diuji melalui metode visual kesesuaian spasial, korelasi sederhana, dan RMSE untuk membandingkan performa keduanya. Salah satu hasil yang diperoleh menunjukkan bahwa luaran mentah ECMWF memberikan hasil terbaik dibanding model lainnya. ECMWF merupakan model dinamis yang memiliki peran besar dalam menghasilkan ringkasan dan penjelasan untuk ramalan operasional secara dasarian dan bulanan. Hal ini disebabkan karena model ini memperhitungkan faktor-faktor dinamis dari sirkulasi atmosfer dan suhu permukaan laut, termasuk variabilitas iklim seperti La Nina dan El Nino. Analisis dilakukan berbasis wilayah ZOM dengan melibatkan sampel 1 pos hujan di tiap ZOM. Hasil prakiraan

dievaluasi dengan RMSE dan koefisien korelasi yang menunjukkan bahwa ECMWF menjadi yang terbaik dilihat dari RMSE yang kecil diantara model lainnya. Namun, dilihat dari sisi korelasi, ANFIS masih lebih baik dibanding ECMWF maupun model HyBMG lainnya.

Weyn et al. (2021) mengembangkan sebuah model prakiraan ensemble menggunakan model Deep Learning Weather Prediction (DLWP) yang secara iteratif memproyeksikan enam variabel atmosfer utama dengan resolusi waktu enam jam. Model ini menggunakan jaringan saraf konvolusional (CNN) untuk menghasilkan prakiraan global. Secara rata-rata, baik secara global maupun selama dua tahun pengujian, RMSE rerata ensemble tetap menunjukkan kemampuan yang lebih baik dibandingkan dengan klimatologinya setelah dua minggu, dengan koefisien korelasi anomali yang tetap di atas 0.6 hingga enam hari. Aplikasi utama penelitian ini adalah memprakiraan pada jangka waktu sub musiman hingga musiman (S2S) dengan lead time dua hingga enam minggu. Skor probabilitas terurut terus menerus (CRPS) dan skor keterampilan probabilitas terurut (RPSS) menunjukkan bahwa ECMWF, meski hanya sedikit, menunjukkan performa yang lebih baik dibandingkan dengan DLWP terutama pada lead time yang lebih pendek dari 4 minggu.

2.1.3 Regresi Linier

Maulita dan Nurdin (2023) mencoba mengembangkan prakiraan cuaca yang memanfaatkan teknologi terkini, khususnya dengan menggunakan teknik data mining regresi linear berganda. Tujuan dari penelitian ini adalah menganalisis perubahan pola hujan dan memungkinkan masyarakat untuk melakukan persiapan yang sesuai dengan musim hujan yang akan datang. Metode yang digunakan

adalah regresi linear berganda dari empat variabel, yaitu suhu, kelembapan, lama penerangan matahari, dan kecepatan angin. Data yang digunakan diperoleh dari Stasiun Meteorologi Malikussaleh melalui website BMKG untuk Kabupaten Aceh Utara selama periode Januari 2020 hingga Januari 2023. Hasil analisis menunjukkan bahwa secara bersama-sama, variabel suhu, kelembapan, lama penerangan matahari, dan kecepatan angin berpengaruh positif dan signifikan terhadap curah hujan. Selain itu, nilai Root Mean Square Error (RMSE) sebesar 0.009.

Ardhitama dan Sholihah (2013) berupaya meningkatkan kualitas hasil prakiraan cuaca di Pekanbaru dengan melibatkan simulasi prakiraan jumlah curah hujan di Kota Pekanbaru untuk tahun 2011 dan 2012 menggunakan input prediktor seperti SOI, SST, Nino 3.4, dan IOD. Metode yang digunakan adalah regresi linear berganda. Evaluasi hasil prakiraan curah hujan dilakukan menggunakan Root Mean Square Error (RMSE) dan Standar Deviasi (SD). Tujuan utama kajian ini adalah untuk mengidentifikasi faktor prediktor yang paling signifikan dalam mempengaruhi kondisi curah hujan di Pekanbaru. Hasil penelitian menunjukkan bahwa kondisi cuaca, terutama curah hujan di Pekanbaru, dipengaruhi oleh faktor global, regional, dan lokal. Ditemukan bahwa prediktor SOI memiliki hubungan dengan curah hujan yang memiliki tingkat korelasi yang tinggi. Hal ini menunjukkan bahwa metode regresi linier berganda dapat menjadi opsi dalam mengetahui pengaruh beberapa variabel terhadap curah hujan di Pekanbaru.

Mahera et al. (2023) meneliti tentang hubungan antara SML dan karakteristik curah hujan musim di wilayah Utara-Timur Aceh untuk. Metode

yang digunakan adalah analisis korelasi. Hasil analisis menunjukkan bahwa pola curah hujan di wilayah Utara-Timur Aceh cenderung bersifat monsun dengan sedikit pengaruh dari iklim ekuatorial. Korelasi antara curah hujan musim dan anomali SML bervariasi di setiap wilayah. Awal masuk musim hujan tertinggi terjadi di Banda Aceh, dengan korelasi sebesar 0,1495 pada dasarian ke-25, sementara awal masuk musim hujan terendah terjadi di Aceh Timur, dengan korelasi sebesar 0,0278 pada dasarian ke-24. Durasi musim hujan juga berbeda-beda, dengan Banda Aceh memiliki musim hujan selama 12 dasarian dan Aceh Timur selama 13 dasarian.

Abdullah (2021) meneliti sejauh mana tingkat hubungan antara Indeks Nino 3.4 dan curah hujan di Jawa Tengah. Metode yang digunakan dalam penelitian ini mencakup penggunaan data ONI bulanan tahun 1981-2015 sebagai sumber data, serta pemanfaatan koefisien korelasi untuk mengukur hubungan antara Indeks Nino 3.4 dan curah hujan di Jawa Tengah. Hasil penelitian menunjukkan bahwa terdapat hubungan positif dengan tingkat korelasi kuat namun tidak signifikan antara curah hujan dan Indeks Nino 3.4 pada kategori El Nino kuat di wilayah Kawunganten, Purwonegoro, Penusupan, dan Kandangserang. Sementara itu, terdapat hubungan negatif cukup signifikan dengan tingkat korelasi kuat antara curah hujan dan Indeks Nino 3.4 pada kategori La Nina moderate di wilayah Trangkil, Cabean, dan Jakenan. Hasil tersebut menunjukkan adanya hubungan kuat antara kejadian ENSO dengan curah hujan di Jawa Tengah. Stockdale et al. (2010) dalam penelitiannya mengungkapkan hal serupa dimana prakiraan musiman bergantung pada perubahan probabilitas cuaca, terutama terkait dengan perubahan lambat seperti anomali suhu permukaan laut dari El Niño-Southern

Oscillation (ENSO). Namun, cuaca musiman juga dipengaruhi oleh banyak faktor lain dan variasi internal atmosfer, sehingga diperlukan model komprehensif untuk mengidentifikasi apa yang dapat diprakiraan.

2.2 Ensemble Prakiraan Curah Hujan

Kullahci dan Altunkaynak (2023) melakukan penelitian untuk memanfaatkan metode ensemble *stacking* dalam meningkatkan akurasi model prakiraan curah hujan harian. Model dasar yang digunakan adalah regresi linier logistik, KNN, dan DT. Adapun ensemble disusun menggunakan *hybrid wavelet stacking*. Model ensemble *hybrid wavelet* telah menunjukkan potensi kinerja yang lebih baik dari model dasar maupun model ensemble yang berdiri sendiri dengan memanfaatkan kombinasi struktur model yang beragam. Model *hybrid wavelet-stacking* menunjukkan kemampuan yang kuat untuk memprakiraan curah hujan harian.

Guet al. (2022) membangun sebuah model prakiraan curah hujan bulanan dengan teknik ensemble untuk menggabungkan beberapa model dasar yang memiliki kelebihan masing-masing. Penelitian ini dilakukan di DAS Taihu, China. Model dasar yang digunakan adalah *k-nearest neighbors* (KNN), *extreme gradient boosting* (XGB), *support vector regression* (SVR), dan *artificial neural networks* (ANN). Ensemble dibangun menggunakan pembobotan dari tiap model dasar. Prakiraan curah hujan bulanan ensemble menghasilkan MAE terendah yaitu 41.65 menunjukkan bahwa adanya ensemble meningkatkan performa prakiraan dibanding luaran model dasarnya. Lebih spesifik, prakiraan curah hujan

menggunakan *ensemblstacking* lebih baik pada musim semi dan dingin dibanding musim panas dan gugur.

Jose et al. (2022) melakukan sebuah penelitian yang dilatarbelakangi banyaknya model prakiraan iklim yang berkembang dengan performa yang berbeda-beda, termasuk teknik pembelajaran mesin yang terbukti memiliki performa yang dapat diperhitungkan. Penelitian ini melibatkan metode rata-rata aritmatika, regresi linier berganda (MLR), *support vector machine* (SVM), *extra tree regressor* (ETR), *random forest* (RF) dan *long short-term memory* (LSTM). Hasilnya menunjukkan bahwa pembentukan ensemble multi-model menggunakan pendekatan pembelajaran mesin memberikan hasil yang lebih baik dibandingkan pendekatan rata-rata dengan RMSE terkecil dihasilkan oleh LSTM yaitu 14.56 mm dan koefisien determinasi 0.9.

Wei et al. (2022) melakukan sebuah penelitian untuk mengetahui efek penambahan model dengan performa rendah terhadap akurasi prakiraan dengan model ensemble. Penelitian ini mencoba mengetahui dampak dari perbedaan teknik pembobotan terhadap kualitas prakiraan yang diukur menggunakan RMSE. Ensemble dibentuk menggunakan regresi linier dengan bobot antar model sama (ENEW) dan bervariasi (ENVW) yang diasumsikan berbanding terbalik terhadap varians error (MAE). Hasil dari penelitian ini menunjukkan bahwa prakiraan ensemble dengan bobot bervariasi lebih baik dibanding bobot sama. Prakiraan suhu dengan berbagai variasi jeda waktu juga menunjukkan hal serupa dimana penggunaan bobot bervariasi lebih baik. Metode bobot bervariasi dapat mengatasi permasalahan penurunan akurasi akibat penambahan model dengan performa rendah.

Model *Deep Learning Weather Prediction* (DLWP) dikembangkan oleh Weyn et al. (2021) untuk membuat prakiraan cuaca dengan menggunakan jaringan saraf konvolusional (CNN) untuk memproyeksikan enam variabel atmosfer utama dengan resolusi waktu enam jam secara iteratif. Secara keseluruhan, hasil rerata *Mean Square Error* (RMSE) ensemble DLWP menunjukkan kinerja yang lebih baik daripada klimatologi setelah dua minggu, dengan koefisien korelasi anomali yang tetap tinggi di atas 0.6 hingga enam hari. Fokus aplikasi utama dari penelitian ini adalah pada prakiraan jangka waktu sub-musiman hingga musiman (S2S) dengan lead time dua hingga enam minggu. *Continuous Ranked Probability Score* (CRPS) dan *Relative Probability Skill Score* (RPSS) menunjukkan bahwa ensemble DLWP memiliki kinerja yang hampir sebanding dengan ensemble S2S dari ECMWF pada lead time 4 dan 5-6 minggu di daratan. Namun, pada lead time yang lebih pendek, ensemble ECMWF menunjukkan kinerja yang lebih baik dibandingkan dengan DLWP.

Chowdary et al. (2020) mengungkapkan bahwa curah hujan adalah proses penting yang mempengaruhi siklus air sehingga perlu adanya prakiraan pola curah hujan untuk mengantisipasi banjir. Penelitian ini dilakukan dengan menggunakan teknik *ensemblestacking* yang melibatkan model dasar *Naive Bayes*, *Decision Tree*, KNN, dan SVM. Sementara itu, ensemble dibangun dengan menggunakan metode *Deep Neural Network*. Hasil dari penelitian ini menunjukkan tingkat akurasi dan spesifisitas yang lebih baik pada hasil ensemble, yaitu 80% dan 97%.

Raju dan Kumar (2020) melakukan sebuah studi pustaka mengenai beberapa metode penyusunan ensemble model prakiraan curah hujan. Seleksi *Global Climate Model* (GCM) yang sesuai perlu dilakukan pada studi dampak.

Pengukuran performa dan teknik pengambilan keputusan yang tepat berperan penting pada ensemble yang akan dibangun. Ketidakpastian pada GCM mempengaruhi akurasi proyeksi. Pendekatan ensemble multi model memberikan hasil yang menjanjikan dan dapat ditiru dalam mengurangi ketidakpastian dalam proyeksi.

Fathi et al. (2019) menggabungkan 9 model prakiraan curah hujan harian di Iran untuk membangun sebuah model ensemble berdasarkan rata-rata (ENSM) dan rata-rata berbobot (ENSWM). Bobot tiap anggota ensemble ditentukan dari performa terdahulu pada periode pelatihan. Performa model dasar dan ensemble dibandingkan menggunakan RMSE dan ACC. Penelitian ini menunjukkan bahwa proses ensemble efektif meningkatkan kualitas prakiraan dimana hasil terbaik ditunjukkan oleh ensemble rata-rata berbobot (ENSWM) dengan RMSE 2.8-3.3.

Anggraeniet al. (2018) membentuk sebuah model ensemble prakiraan curah hujan di Jember menggunakan model dasar luaran GSTAR dan ARIMA. Penelitian ini tidak hanya memperhitungkan data historis stasiun-stasiun cuaca, tetapi juga faktor spasial lainnya. Tujuannya adalah untuk menerapkan model GSTAR, yang menggabungkan faktor waktu, lokasi (stasiun), dan interaksi spasial antar stasiun, untuk mengevaluasi korelasi di antara mereka. GSTAR kemudian dibandingkan dengan model ARIMA, yang hanya mempertimbangkan faktor waktu tanpa memperhitungkan faktor spasial. Hasil prakiraan dari kedua model digabungkan menggunakan teknik ensemble rata-rata dan *stacking* untuk menghasilkan model dengan nilai RMSE yang lebih rendah. Analisis spasial membedakan wilayah penelitian menjadi 4 kluster berdasarkan topografinya.

Ensemble*stacking* dari GSTAR dan ARMA memiliki performa terbaik di semua kluster, dibanding model dasar GSTAR, ARMA dan ensemble rata-rata.


Bermula dari kompleksitas interaksi antar komponen atmosfer yang mempengaruhi curah hujan di Asia Barat Daya, Pakdaman et al. (2022) melakukan penelitian yang bertujuan untuk menawarkan pendekatan baru berbasis jaringan saraf tiruan (ANN) dan *Random Forest (RF)* dalam melakukan *post-processing* terhadap luaran model prakiraan. Algoritma ensemble multi-model dibangun dengan melibatkan model GEM-NEMO, NASA-GEOSS2S, CanCM4i, dan COLA-RSMAS-CCSM4, yang merupakan bagian dari proyek ensemble multi-model Amerika Utara (NMME). Karena setiap model memiliki sembilan *lead time* yang berbeda, total 108 model ANN dan RF yang berbeda dilatih untuk setiap bulan dalam setahun. Dataset reanalisis ERA5 digunakan untuk melatih model ANN dan RF yang diusulkan. Untuk membandingkan kinerja algoritma yang diusulkan, empat kriteria evaluasi kinerja dihitung untuk setiap model, meliputi koefisien korelasi, RMSE, efisiensi Kling-Gupta (KGE), dan efisiensi Nash-Sutcliffe (NSE). Hasil penelitian menunjukkan bahwa kinerja pengolahan pasca prakiraan dengan ANN dan RF lebih baik daripada model NMME individual. Selain itu, RF lebih unggul dibandingkan ANN untuk semua *lead time* dan bulan dalam setahun ($r = 0.7-0.8$, $NSE = 0.5-0.6$, $RMSE = 20-27$).

Specq et al. (2020) melakukan prakiraan ulang curah hujan *multi-model ensemble* (MME) pada skala waktu sub musiman di wilayah tropis barat daya Pasifik menggunakan enam model (BoM, CMA, ECCC, ECMWF, Météo-France, dan UKMO) dari basis data *Subseasonal-to-Seasonal* (S2S) dengan pengumpulan anggota. Prakiraan ulang ini diverifikasi pada setiap titik grid 110°BT hingga

200°BT; Domain 30°S hingga 0° untuk periode Desember-Januari-Februari (DJF) 1996–2013. Evaluasi dilakukan dengan menggunakan korelasi dan skor keterampilan ROC dari curah hujan kuartil atas untuk target mingguan dan perkiraan Minggu ke-3–4. Seperti yang telah dikonfirmasi sebelumnya pada skala waktu musiman, MME menunjukkan keterampilan tertinggi dan meningkatkan keandalan perkiraan probabilitas. Namun, perbandingan ukuran ensemble yang setara antara MME dan model individual menunjukkan bahwa kinerja MME yang lebih baik dibandingkan dengan model individu terbaik secara signifikan berhubungan dengan ukuran ensemble MME yang lebih besar. Keterampilan prakiraan kemudian dijelaskan berdasarkan sumber potensi prediktabilitas dengan mengevaluasi kinerja model bergantung pada keadaan ENSO dan MJO awal. Meskipun peran ENSO dalam prediktabilitas cukup konsisten dengan anomali curah hujan yang terkait, peran MJO lebih ambigu dan sangat bergantung pada lokasi: inisialisasi dalam kondisi MJO aktif tidak selalu berarti prakiraan yang lebih baik. Pengaruh ENSO dan MJO terhadap prediktabilitas tetap tidak berubah ketika beralih dari model individual ke MME.

2.3 Kerangka Teoritis

Dalam sub bagian ini, disusun kerangka teori dari studi pustaka dengan langkah-langkah mengelompokkan parameter atau variabel sebagai input dalam kerangka teori dan menjelaskan metode yang digunakan serta hasil yang dihasilkan dari kerangka teori tersebut. Kerangka teori ini dapat ditemukan dalam Gambar 2.1.



Gambar 2.1 Kerangka teoritis

Berdasarkan Gambar 2.1 dapat diketahui bahwa terdapat beberapa opsi data masukan untuk membuat prakiraan curah hujan, meliputi curah hujan observasi (hasil pengamatan), curah hujan luaran model, suhu muka laut (SST), indeks ENSO (SOI), indeks Nino 3.4 (ONI), suhu udara, kelembaban relatif, durasi penyinaran matahari, dan kecepatan angin. Seluruh data disediakan dalam format numerik sehingga dapat diproses secara matematis.

Tahapan selanjutnya adalah menentukan metode terbaik yang akan digunakan dalam penelitian ini berdasarkan hasil studi pustaka. Beberapa penelitian yang dijadikan acuan untuk penelitian ini dituangkan pada Tabel 2.1 sebagai berikut.

Tabel 2.1 Daftar penelitian terdahulu yang digunakan sebagai rujukan

No.	Identitas Tulisan	Masalah yang Diselesaikan	Metode	Hasil
1	Weisheimer dan Palmer. 2014. <i>On the Reliability of Seasonal Climate Forecast.</i>	Kebutuhan informasi mengenai performa model prakiraan terkini (ECMWF)	Analisis diagram keandalan (<i>reliability diagram</i>)	ECMWF kategori <i>still very useful</i> untuk wilayah tropis
2	Ruslana et al. 2021. Reliabilitas Prakiraan Curah Hujan Dasarian Pada Kejadian Curah Hujan Ekstrem Pemicu Banjir 26 Oktober 2020 di Kebumen: Model Statistik (HyBMG) versus Model Dinamik (ECMWF).	Uji keandalan prakiraan curah hujan dasarian operasional HyBMG dan ECMWF	- Kesesuaian spasial - Korelasi - RMSE	- ECMWF RMSE 405.93, korelasi negatif - ANFIS korelasi kuat, RMSE 556.5 mm - ANFIS lebih handal untuk kejadian hujan ekstrem

No.	Identitas Tulisan	Masalah yang Diselesaikan	Metode	Hasil
3	Weyn et al. 2021. <i>Sub-Seasonal Forecasting With a Large Ensemble of Deep-Learning Weather Prediction Models.</i>	Pengembangan model prakiraan ensemble <i>Deep Learning Weather Prediction</i> dan dibandingkan dengan ECMWF	- CNN - CRPS - RPSS	ECMWF lebih baik daripada DLWP
4	Kullahci dan Altunkaynak. 2023. <i>Integrating Wavelet Decomposition and Stacking Ensemble learning for Accurate Daily Rainfall Forecasting.</i>	Akurasi model prakiraan curah hujan harian perlu ditingkatkan	- Regresi linier - logistik - KNN - <i>Decission tree</i> - <i>Hybrid wavelet stacking ensemble</i>	MSE=2.27 <i>wavelet-stacking</i> paling kecil
5	Gu et al. 2022. <i>A Stacking Ensemble Learning Model for Monthly Rainfall Prediction in the Taihu Basin, China.</i>	Banyaknya model prakiraan curah hujan bulanan yang memiliki kelebihan masing-masing	- KNN - XGB - SVR - ANN - Ensemble pembobotan	MAE ensemble = 41.56 (terkecil)
6	Jose et al. 2022. <i>Improving Multiple Model Ensemble Predictions of Daily Precipitation and Temperature through Machine Learning Techniques.</i>	Banyaknya model prakiraan iklim yang berkembang dengan performa berbeda	- Regresi linier berganda - SVM - <i>Extra tree regressor</i> - <i>Random forest</i> - <i>Long short-term memory (LSTM)</i>	RMSE LSTM=14.56 (terkecil) dan $R^2=0.9$
7	Wei et al. 2022. <i>A Comparative Study of Multi-Model Ensemble Forecasting Accuracy between Equal and Variant Weight Techniques.</i>	Identifikasi dampak penambahan model dengan performa rendah terhadap akurasi prakiraan model ensemble	- Ensemble regresi linier (bobot sama dan bervariasi)	- MAE = 0.1-0.2 - Bobot bervariasi lebih baik performanya

No.	Identitas Tulisan	Masalah yang Diselesaikan	Metode	Hasil
8	Chowdary et al. 2020. <i>Enhanced Rainfall Predictions using Stacking Technique.</i>	Peningkatan akurasi prakiraan curah hujan karena hujan mempengaruhi siklus air	- <i>Naïve bayes</i> - <i>Decision tree</i> - KNN - SVM - Ensembel <i>Deep Neural Network</i>	Akurasi 80% dan sensitivitas 97% hasil ensembel
9	Pakdaman et al. 2022. <i>Improved Monthly and Seasonal Multi-Model Ensemble Precipitation Forecasts in Southwest Asia Using Machine Learning Algorithms.</i>	Pendekatan baru dalam <i>post-processing</i> luaran model prakiraan	- ANN - RF - Ensembel	<i>Post processing</i> dengan RF lebih unggul (RMSE = 20-27, $r=0.7-0.8$, NSE=0.5-0.6)
10	Specq et al. 2020. <i>Multimodel Forecasting of Precipitation at Subseasonal Timescales Over the Southwest Tropical Pacific.</i>	Prakiraan ulang skala waktu sub musiman di wilayah tropis barat daya Pasifik menggunakan 6 model <i>existing</i>	Ensembel pembobotan (rata-rata aritmatika)	r dan ROCSS ensembel multimodel paling baik
11	Fathi et al. 2019. <i>Improving Precipitation Forecasts over Iran using A Weighted Average Ensemble Technique.</i>	Peningkatan kualitas curah hujan di Iran pada periode musim gugur dan dingin	- Ensembel bobot rata-rata (ENSWM) - Ensembel bobot berdasarkan koefisien korelasi (ENSM)	- RMSE pada ENSWM berkurang 2-5% - Koefisien korelasi ENSWM meningkat 15% dibanding ENSM
12	Anggraeni et al. 2018. <i>Ensemble averaging and stacking of ARIMA and GSTAR model for rainfall forecasting.</i>	Perlunya alat dengan akurasi tinggi untuk memprakirakan curah hujan di masa depan	- GSTAR model - ARIMA - Ensembel rata-rata dan <i>stacking</i>	RMSE ensembel <i>stacking</i> = 87-131 (terendah di tiap klaster)

No.	Identitas Tulisan	Masalah yang Diselesaikan	Metode	Hasil
13	Kurniawan et al. 2022. Verifikasi Luaran HyBMG saat Kejadian El Niño dan La Niña di Jawa Timur.	Verifikasi performa luaran model HyBMH di wilayah Jawa Timur, khususnya saat ENSO.	- ARIMA - ANFIS - <i>Wavelet</i> -ARIMA - Wavelet-ANFIS - Verifikasi kesesuaian	ARIMA memiliki tingkat verifikasi paling tinggi diantara model lainnya, rata-rata 60% dan mencapai 70% saat El Nino.
14	Noviasari et al. 2023. Peramalan Curah Hujan terhadap Produktivitas Garam di Gresik Putih Sumenep.	Kebutuhan metode prakiraan curah hujan yang baik untuk mendukung produksi garam di Madura	ARIMA	Metode AR1 menghasilkan prakiraan dengan $r = 0.94$.
15	Ardhitama dan Sholihah. 2013. Model Simulasi Prakiraan Curah Hujan Bulanan pada Wilayah Riau dengan Menggunakan Input Data SOI, SST, NINO 3.4, dan IOD.	Peningkatan kualitas hasil prakiraan cuaca di Pekanbaru	Regresi linier berganda (variabel: SOI, SST, Nino 3.4, IOD)	ENSO memiliki korelasi cukup tinggi dengan curah hujan di Pekanbaru
16	Abdullah. 2021. Analisis Hubungan Indeks Nino 3.4 dengan Curah Hujan di Jawa Tengah	Identifikasi hubungan indeks Nino 3.4 dengan curah hujan di Jawa Tengah	Regresi linier	$r = -0.6$
17	Maulita dan Nurdin. 2023. Pendekatan Data Mining untuk Analisis Curah Hujan Menggunakan Metode Regresi Linear Berganda (Studi Kasus: Kabupaten Aceh Utara).	Pengembangan prakiraan cuaca dengan memanfaatkan teknologi terkini	Regresi linier berganda (variabel: suhu, kelembapan, lama penyinaran matahari, dan kecepatan angin)	- RMSE = 0.009 - Uji F sig+ untuk semua variabel

No.	Identitas Tulisan	Masalah yang Diselesaikan	Metode	Hasil
18	Mahera et al. 2023. Pengaruh Suhu Muka Laut terhadap Awal Masuk Musim hujan di Wilayah Utara-Timur Aceh.	Identifikasi hubungan suhu muka laut (SST) dengan curah hujan musim	Analisis korelasi	$r = 0.1495$ untuk musim hujan dan $r=0.0278$ untuk musim kemarau


Pada tahap studi pustaka, hasil kinerja yang diperoleh dari setiap penelitian umumnya dievaluasi berdasarkan parameter verifikasi yang dipakai dan dibandingkan untuk memperoleh metode terbaik diantara yang sudah terdaftar dalam Tabel 2.1. Dengan melakukan penelitian menggunakan metode tersebut diharapkan dapat memberikan hasil terbaik sebagai upaya mengoptimasi kualitas informasi prakiraan musim di Jawa Timur sesuai dengan kebutuhannya. Hasilnya menunjukkan bahwa penelitian yang terangkum pada proses studi pustaka menggunakan ukuran verifikasi yang berbeda-beda sehingga terdapat kesulitan dalam menentukan metode terbaik. Oleh karena itu, keputusan akhir dibuat dengan mempertimbangkan pendapat dari lebih dari satu ahli (Tuysuzoglu, et al.,2023) dan ditentukan bahwa metode ensemble yang akan digunakan adalah pembobotan.

BAB III

MODEL KONSEPTUAL

3.1 Kerangka Konseptual

Setelah melakukan kajian terhadap penelitian terdahulu dalam studi pustaka, konsep penelitian yang akan dilakukan dituangkan dalam bentuk kerangka konsep seperti pada Gambar 3.1. Pada penelitian ini, data masukan yang akan dipakai adalah curah hujan dasarian terdahulu, indeks Nino 3.4 (ONI), indeks *Dipole Mode* (DMI), suhu muka laut (SST), dan curah hujan luaran model ECMWF. Tahap awal adalah pembentukan prakiraan curah hujan dasarian menggunakan model ARIMA, ECMWF, dan regresi. Hasil prakiraan model dasar ini diverifikasi dan dilakukan pembobotan sesuai hasil verifikasi. Berikutnya, ensemble dibentuk menggunakan bobot yang diperoleh untuk tiap model dasar. Tahap terakhir adalah komparasi hasil prakiraan ensemble dengan model dasar dengan menganalisis besarnya *error* dan kesesuaiannya.




Gambar 3.1 Kerangka konsep penelitian yang akan dilakukan

Prakiraan pada penelitian ini disimulasikan mengikuti keadaan riil operasional dimana rapat perencanaan operasional waduk biasanya dilaksanakan bulan November. Sehingga, periode prakiraan dimulai pada bulan Desember menggunakan data terakhir yang tersedia di bulan Oktober. Prakiraan juga mengadopsi skenario penentuan sifat musim RTOW berdasarkan persentil ke-35 dan 65 dengan periode musim yang tetap. Selain itu, penelitian ini juga mengeksplorasi pemanfaatan teknik ensemble untuk mengoptimalkan kualitas prakiraan yang akan diukur dari tingkat kesesuaian dan beda nilai prakiraan yang dihasilkan.

3.2 Desain Penelitian

Penelitian ini didesain berdasarkan hasil studi pustaka dan pendeskripsiannya dituangkan dalam kerangka teori. Tahapan yang akan dilalui meliputi pengumpulan data, desain sistem dan implementasi, eksperimen, pembahasan, dan evaluasi kinerja metode. Tahapan tersebut diperlihatkan dalam Gambar 3.2 sebagai berikut.



Gambar 3.2 Desain penelitian

3.2.1 Pengumpulan Data

Penelitian ini beberapa jenis data meliputi: curah hujan *blending*, curah hujan luaran model ECS4, suhu muka laut (SST), indeks Nino 3.4 (ONI), dan indeks *Dipole Mode* (DMI) selama periode 1991-2023. Seluruh data merupakan jenis data sekunder dalam bentuk numerik. Data curah hujan, baik *blending*

maupun luaran model, bersumber dari jejaring internal BMKG (intranet yang dikembangkan sejak penyusunan normal baru periode 1991-2020 pada tahun 2021).

A. Curah hujan *blending*

Curah hujan *blending* adalah hasil pengamatan di setiap pos hujan yang tersebar di seluruh Provinsi Jawa Timurdikombinasikan dengan data satelit untuk titik yang tidak ada penakaran curah hujan di lokasi tersebut. Penelitian ini menggunakan data curah hujan dasarian (akumulasi per 10 harian) dengan satuan milimeter (mm) dan berbasis wilayah ZOM. Data curah hujan *blending* ini digunakan sebagai data latih untuk membangun model prakiraan dan data uji untuk mengevaluasi prakiraan yang dihasilkan. Pembagian periode uji-latih menggunakan simulasi operasional yang disesuaikan dengan bagaimana operasional berjalan.

B. Curah hujan luaran model ECMWF (ECS4)

Seperti halnya data observasi, curah hujan luaran model ECS4 yang digunakan pada penelitian ini adalah akumulasi dasarian yang tersedia untuk 7 bulan ke depan (November – Mei) berbasis wilayah ZOM sepanjang 33 tahun di 74 ZOM di Jawa Timur. Luaran mentah model ini dievaluasi terhadap data observasi. Lebih lanjut, data ini juga digunakan sebagai salah satu anggota ensemble.

C. Anomali suhu muka laut (SST)

Data anomali suhu muka laut global yang digunakan memiliki resolusi spasial $2^{\circ} \times 2^{\circ}$. Data SST yang dipakai meliputi periode 2004-2014 sebanyak 180

grid x 89 = 16020 data. Format data SST tersedia dalam skala waktu bulanan yang bersumber dari tautan berikut:

<https://iridl.ldeo.columbia.edu/SOURCES/.NOAA/.NCDC/.ERSST/.version5/.anom/T/%28Nov%201990%29%28Sep%202022%29RANGEEDGES/datafiles.html>

D. Indeks Nino 3.4 (ONI)

Data ONI yang digunakan dalam penelitian ini adalah nilai anomali 3 bulanan yang dirata-ratakan. Jumlah data ONI yang digunakan sebanyak 396 data. ONI merupakan indeks yang menjelaskan aktivitas El Nino dan La Nina dengan kriteria $ONI < -0.5$ menunjukkan kondisi La Nina, $0.5 < ONI < +0.5$ kondisi netral, dan $ONI > +0.5$ kondisi El Nino. El Nino/La Nina dikatakan aktif jika indeks berkategori sama berlangsung minimal 5 bulan berturut-turut. Aktifnya El Nino berpotensi menyebabkan pengurangan curah hujan di wilayah Indonesia. Sebaliknya, La Nina dapat mengakibatkan penambahan curah hujan di wilayah Indonesia. Efek ini tidak merata di seluruh wilayah sehingga perlu dianalisis lebih lanjut. Data ini diperoleh melalui tautan berikut:

https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php


E. Indeks Dipole (DMI)

Data DMI menunjukkan anomali suhu muka laut di wilayah Samudera Hindia barat Sumatera dan menunjukkan aktivitas dinamika atmosfer di wilayah tersebut yang disebut *Dipole Mode*. Jumlah data yang digunakan sebanyak 396 data meliputi 12 bulan sepanjang 33 tahun. Sama halnya El Nino/La

Nina, adanya *Dipole Mode* berpotensi mempengaruhi curah hujan di wilayah Indonesia dengan dampak yang bervariasi di setiap wilayah. DMI diperoleh dari tautan berikut:

https://psl.noaa.gov/gcos_wgsp/Timeseries/Data/dmi.had.long.data.

Wilayah penelitian ini meliputi Provinsi Jawa Timur yang terdiri dari 74 Zona Musim (ZOM). ZOM menunjukkan daerah dengan karakteristik pola hujan yang sama, disusun menggunakan data normal curah hujan dan selalu diperbarui setiap 30 tahun sekali. ZOM terbaru disusun berdasarkan data normal curah hujan periode 1991-2020 dan mulai digunakan pada tahun 2022.




Gambar 3.3 Wilayah penelitian (Sumber: Stasiun Klimatologi Jawa Timur)

3.2.2 Desain Sistem dan Implementasi

Pada tahapan desain sistem, proses yang akan dilakukan oleh sistem didesain secara utuh. Secara umum, terdapat empat tahapan yang dirancang akan dilakukan oleh sistem pada penelitian ini, meliputi proses prakiraan dengan model

dasar, penentuan bobot, pembentukan ensemble prakiraan curah hujan, dan verifikasi. Proses ini digambarkan sebagaimana pada Gambar 3.4.



Gambar 3.4 Desain sistem

Pendefinisian periode data latih dan uji sesuai Tabel 3.1. Pada penelitian ini, periode data latih dan uji terus diperbarui tiap satu tahun (36 dasarian) menyesuaikan skenario penyusunan RTOW setiap tahun. Bentuk penyesuaian lainnya adalah penentuan akhir periode data latih pada bulan Oktober dan awal periode data uji pada bulan Desember karena rapat penyusunan RTOW biasanya diselenggarakan pada bulan November.

Prakiraan dilakukan untuk menghasilkan prakiraan curah hujan dasarian sehingga perlu dipahami urutan dasarian. Setiap tahun, urutan dasarian selalu sama dimulai dari dasarian 1 pada periode tanggal 1 sampai 10 Januari hingga dasarian 36 pada periode tanggal 21-31 Desember. Penelitian ini melakukan prakiraan curah hujan untuk 36 dasarian ke depan yang dimulai pada dasarian ke-34, yaitu periode tanggal 1-10 Desember, hingga dasarian 33, periode tanggal 21-30 November tahun berikutnya.

Tabel 3.1 Pembagian periode data latih dan uji


Urutan	Data Latih	Data Uji
1	Jan 1991-Okt 2014	Des 2014-Nov 2015
2	Jan 1992-Okt 2015	Des 2015-Nov 2016
3	Jan 1993-Okt 2016	Des 2016-Nov 2017
4	Jan 1994-Okt 2017	Des 2017-Nov 2018
5	Jan 1995-Okt 2018	Des 2018-Nov 2019
6	Jan 1996-Okt 2019	Des 2019-Nov 2020
7	Jan 1997-Okt 2020	Des 2020-Nov 2021
8	Jan 1998-Okt 2021	Des 2021-Nov 2022
9	Jan 1999-Okt 2022	Des 2022-Nov 2023

3.2.2.1 Prakiraan dengan Model Dasar

Model dasar yang digunakan pada penelitian ini adalah ARIMA, ECMWF, dan regresi linier. ARIMA menggunakan data historis curah hujan, ECMWF telah tersedia dalam bentuk curah hujan prakiraan, dan regresi linier melibatkan variabel SST, ONI, dan DMI. Secara umum, prakiraan yang akan dilakukan merupakan simulasi kondisi operasional. Tahapan prakiraan dari masing-masing model dasar diuraikan sebagai berikut.

A. Skenario Dasar RTOW

Prakiraan dengan skenario dasar menggunakan data masukan curah hujan historis yang akan dicari nilai persentil ke-35, 50, dan 65 sebagai ambang batas sifat musim kering, normal, dan basah secara berturut-turut. Tahapan yang dilakukan adalah seperti pada Gambar 3.5.



Gambar 3.5 Diagram alir proses prakiraan menggunakan skenario RTOW

1. Dataset masukan curah hujan historis dipotong periodenya sesuai skenario simulasi yang pertama yaitu dasarian I Desember (36) 1991 – dasarian III November 2014 untuk ZOM 1.
2. Dataset diurutkan dari nilai terkecil ke terbesar lalu dicari nilai persentil ke-35, 50, dan 65 menggunakan persamaan 3.1.

$$P_i = x_k + d(x_{k+1} - x_k) \quad (3.1)$$

Keterangan:

P_i : nilai data persentil ke- i

x_k : nilai urutan ke- k

x_{k+1} : nilai urutan ke- $(k+1)$

Nilai yang diperoleh menjadi prakiraan curah hujan dasarian I Desember 2014 dimana nilai P35 menjadi prakiraan curah hujan ketika musim bersifat kering, P50 ketika musim bersifat normal, dan P65 ketika musim bersifat basah.

3. Data masukan ditambah 1 dasarian untuk menghasilkan prakiraan dasarian II Desember 2014. Hal ini dilakukan terus menerus hingga dihasilkan prakiraan curah hujan dasarian III November 2015.
4. Hasil prakiraan diverifikasi menggunakan parameter MAE dan kesesuaian.
5. Parameter verifikasi *Mean Absolute Error* (MAE) dipilih karena interpretasinya yang tidak rumit (Willmott dan Matsuura, 2005) dan dihitung menggunakan persamaan 3.2.

$$\text{Mean Absolute Error (MAE)} = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (3.2)$$

dimana:

MAE : rata-rata beda *error* mutlak

y_i : nilai prakiraan curah hujan musim

x_i : nilai curah hujan musim hasil pengamatan

n : banyaknya data

6. Parameter verifikasi kesesuaian digunakan dalam operasional BMKG (Kurniawan et al, 2022). Kesesuaian diukur berdasarkan kesamaan kelas curah hujan hasil prakiraan dengan observasinya. Adapun kelas curah hujan berdasarkan Standar Nasional Indonesia (SNI) sesuai yang tertera pada Tabel 3.2.

Tabel 3.2 Kelas curah hujan


Curah Hujan	Kategori
<20 mm	1
20 – 50 mm	2
50 – 100 mm	3
100 – 150 mm	4
150 – 200 mm	5
200 – 300 mm	6
300 – 400 mm	7
400 – 500 mm	8
>500 mm	9

Untuk dapat mengetahui frekuensi prakiraan yang “sesuai”, tabel kontingensi digunakan dalam penelitian ini. Proporsi “sesuai” pada metode kesesuaian ini adalah curah hujan prakiraan dan observasi berada pada kelas yang sama, dengan batas toleransi satu kelas di atas atau di bawahnya. Verifikasi ini didasarkan pada prinsip perbedaan informasi prakiraan dan observasi yang dianggap masih cukup layak (Kurniawan et al., 2022).

7. Prakiraan dilanjutkan untuk periode prakiraan ke-2 yaitu Desember 2015 – November 2016 dengan melakukan langkah 1-3.
8. Langkah 4 diulangi hingga seluruh periode prakiraan terpenuhi (9 periode prakiraan).
9. Nilai MAE dan kesesuaian yang terkumpul direkap.
10. Seluruh langkah prakiraan diulangi untuk seluruh ZOM wilayah penelitian.

B. ARIMA (*Autoregressive Integrated Moving Average*)

Prakiraan curah hujan dengan model ARIMA membutuhkan masukan berupa data curah hujan periode sebelumnya. Pada tahap ini, data masukan yang digunakan adalah curah hujan hasil observasi dalam format dasarian untuk menghasilkan prakiraan dalam format dasarian pula. Proses yang akan dilakukan pada tahap ini sebagaimana terdapat pada Gambar 3.6 berikut.



Gambar 3.6 Diagram alir proses prakiraan menggunakan ARIMA

Tahapan pembuatan prakiraan curah hujan dasarian menggunakan ARIMA adalah sebagai berikut:

1. Prakiraan pertama menggunakan data uji periode Januari 1991 sampai Oktober 2014 sebagai masukan untuk memprakirakan curah hujan Desember 2014 sampai November 2015 untuk ZOM 1.
2. Pengurangan komponen musiman sebagai proses stasionerisasi data. Stasioner menunjukkan bahwa data tidak tergantung pada waktu. Data yang tidak stasioner berpotensi memunculkan korelasi palsu atau tidak menunjukkan kausalitas. Data curah hujan di Jawa Timur umumnya memiliki pola musiman sehingga perlu distasionerkan dengan mengurangi komponen musimannya.
3. Pembuatan prakiraan curah hujan dengan model ARIMA. Penelitian ini memanfaatkan fungsi `auto.arima` yang menerapkan algoritma Hyndman-Khandakar (Hyndman dan Khandakar, 2008). Fungsi `auto.arima` akan secara otomatis menentukan model ARIMA terbaik untuk data yang dimasukkan. Proses yang termuat dalam fungsi ini adalah diferensiasi hingga data stasioner, plot ACF (*Auto Correlation Function*)/PACF (*Partial Auto Correlation Function*) untuk menentukan bentuk model yang mungkin, dan percobaan dengan model yang mungkin lalu diverifikasi dengan AIC (*Akaike Information Criterion*). Data masukan yang belum stasioner akan mengalami diferensiasi sebanyak d hingga stasioneritas itu tercapai, dimana rata-rata, varian, dan autokorelasi dari data deret waktu konstan terhadap waktu. Jika data sudah stasioner maka model yang akan dibangun tidak memiliki ordo q sehingga model yang terbentuk berjenis ARMA. Diferensiasi dengan ordo (d) dilakukan dengan persamaan 3.3 sebagai berikut.

$$z_d = y_d - y_{d-1} \quad (3.3)$$

dimana :

z_d : data deret waktu (curah hujan dasarian) yang sudah didiferensiasi

y_t : curah hujan dasarian historis ke- t

y_{t-1} : curah hujan dasarian historis ke- $(t-1)$

Tahapan berikutnya adalah identifikasi model ARIMA yang dapat dilakukan dengan melihat plot grafik ACF/PACF dari data yang sudah stasioner. Penentuan ordo p memperhatikan grafik ACF dan q grafik PACF. Jika paramater p , d , dan q sudah ditentukan maka proses prakiraan bisa dilakukan. ARIMA (p, d, q) akan membentuk prakiraan menggunakan Persamaan 3.4. Percobaan dengan model yang mungkin lalu diverifikasi dengan AIC dimana model ARIMA paling cocok untuk lokasi terseut diidentifikasi dari nilai AIC terkecil.

$$\Delta Y_t = \phi_1 \Delta Y_{t-1} + \dots + \phi_p \Delta Y_{t-p} + a_t - \theta_1 \Delta Y_{t-1} - \dots - \theta_p \Delta Y_{t-p} \quad (3.4)$$


Proses di atas diulang sampai seluruh periode pengujian dilakukan (urutan percobaan ke-9) sesuai Tabel 3.2.

4. Hasil prakiraan curah hujan diverifikasi menggunakan MAE dan kesesuaian seperti pada bagian 3.1.2.1.A.
5. Hasil prakiraan curah hujan dan verifikasinya disimpan.
6. Langkah 1 hingga 5 dilakukan untuk seluruh ZOM hingga Zom 74.

C. ECMWF

Model dasar ketiga adalah ECMWF dengan luaran curah hujan prakiraan dalam format dasarian. Menyesuaikan skenario RTOW yang disusun pada bulan

November, luaran ECMWF yang tersedia pada waktu tersebut mencakup prakiraan hingga bulan Mei. Untuk melengkapi prakiraan satu tahun, curah hujan periode Juni – November diperkirakan menggunakan ARIMA dengan langkah-langkah seperti pada bagian sebelumnya. Masukan dalam proses tersebut adalah curah hujan dasarian observasi yang digabung dengan prakiraan ECMWF (7 bulan). Proses prakiraan dengan model ECMWF yang tertera pada Gambar 3.7.



Gambar 3.7 Diagram alir proses prakiraan menggunakan ECMWF

D. Regresi Linier

Prakiraan curah hujan metode regresi linier menggunakan data suhu muka laut (SST), indeks Nino 3.4 (ONI), dan indeks *Dipole Mode* (DMI) sebagai

masukan (variabel independen). Berikut adalah tahapan membuat prakiraan curah hujan dengan metode regresi linier yang diterapkan pada penelitian ini.

1. Pembentukan *series* curah hujan musim hujan dan kemarau sebagai variabel dependen (Y).
2. Penentuan korelasi variabel independen terhadap curah hujan musim hujan. Proses ini diawali dengan menentukan indeks prakiraan untuk menentukan data masukan periode mana yang dipakai. Pada percobaan pertama, untuk memprakirakan curah hujan bulan Desember 2014 akan menggunakan masukan ONI periode JAS 2014 (Juli-Agustus-September), anomali SST dan DMI bulan September 2014. Demikian seterusnya hingga seluruh kebutuhan prakiraan terpenuhi. Indeks ini disusun untuk periode pelatihan dan pengujian.
3. Pembentukan regresi untuk prakiraan curah hujan dilakukan masing-masing terhadap data ONI, DMI, dan SST untuk menghindari *overfitting*. menggunakan variabel independen dengan korelasi tertinggi. Bentuk persamaan umum dari regresi linier berganda yang digunakan seperti yang tertera pada Persamaan 3.5.

$$Y = a + b_i X_i \quad (3.5)$$

dimana:

Y : curah hujan musim

a : bilangan konstanta (intersep)


b_i : koefisien regresi untuk setiap variabel independen i

X_i : variabel independen (SST, ONI, dan DMI)


4. Hasil prakiraan diverifikasi menggunakan parameter MAE (persamaan 3.2) dan kesesuaian.

5. Prakiraan dilanjutkan untuk periode prakiraan ke-2 yaitu Desember 2015 – November 2016 dengan melakukan langkah 1-4.
6. Langkah 5 diulangi hingga seluruh periode prakiraan terpenuhi (9 periode prakiraan).
7. Nilai MAE dan kesesuaian yang terkumpul direkap.
8. Seluruh langkah prakiraan diulangi untuk seluruh ZOM wilayah penelitian.

Tahapan dalam membuat prakiraan dengan metode regresi linier berdasarkan ONI dan DMI seperti pada Gambar.3.8, sedangkan untuk SST seperti pada Gambar 3.9.



Gambar 3.8 Diagram alir proses prakiraan menggunakan regresi ONI-DMI



Gambar 3.9 Diagram alir proses prakiraan menggunakan regresi komponen utama ERSST

3.2.2.2 Pembentukan Ensemble Prakiraan Curah Hujan Musim

Ensemble dibentuk menggunakan prakiraan curah hujan dasarian luaran model dasar ARIMA, ECMWF, dan Regresi ONI-DMI-ERSST. Rekapitulasi kualitas hasil prakiraan tiap model menentukan besarnya bobot dalam ensemble yang dibentuk. Curah hujan dasarian luaran model ensemble diverifikasi kembali untuk mengetahui dampak proses ensemble terhadap kualitas prakiraan. Tahapan yang akan dilalui dalam proses pembentukan ensemble ini seperti yang tertera pada Gambar 3.10.

$n=1$ hingga $n=150$. Adapun persamaan matematis untuk pembentukan ensemble disajikan pada Persamaan 3.7.

$$Y_{p,i} = \frac{\sum_{m=1}^M \omega_m f_{m,i}}{\sum_{m=1}^M \omega_m} \quad (3.7)$$

dimana:

$y_{p,i}$: prakiraan curah hujan bulanan luaran ensemble

$f_{m,i}$: prakiraan curah hujan bulanan model m pada pengamatan ke- i

m, M, i : urutan model ke- m hingga ke- M

3.2.2.3 Implementasi

Setelah desain sistem, tahapan berikutnya adalah implementasi sistem yang akan dilakukan dengan merancang *pseudocode* setiap tahapan sebagai berikut.

A. Prakiraan dengan model ARIMA

1	input=ch_training
2	output=ver_ARIMA
3	buat rekap_ver_ARIMA
4	tahun=2014
5	while tahun≤2022
6	buat set_ch_training
7	buat set_ch_testing
8	lakukan prakiraan ARIMA ke set_ch_training #39 langkah
9	lakukan transformasi informasi set_sm_ARIMA

10	lakukan transformasi informasi set_sm_testing
11	lakukan verifikasi
12	lakukan penambahan ke rekap_ver_ARIMA
13	tahun=tahun+1
14	end while

B. Prakiraan dengan model ECMWF

1	input=ch_training, ECMWF
2	output=ver_ECMWF
3	buat rekap_ver_ECMWF
4	tahun=2014
5	while tahun $\leq$ 2022
6	buat set_ch_training
7	lakukan penyambungan ch_training & ECMWF
8	buat set_ch_testing
9	lakukan prakiraan ARIMA ke set_ch_training #18 langkah
10	lakukan transformasi informasi set_sm_ARIMA
11	lakukan transformasi informasi set_sm_testing
12	lakukan verifikasi
13	lakukan penambahan ke rekap_ver_ARIMA
14	tahun=tahun+1
15	end while

C. Prakiraan dengan model regresi

1	input=ch_training, SST, IOD, DMI
2	output=ver_regresi
3	buat rekap_ver_regresi
4	tahun=2014
5	while tahun $\leq$ 2022
6	buat set_ch_training
7	buat set_ch_testing
8	buat indeks_training
9	buat indeks_testing
10	lakukan corr(set_ch_training dengan indeks_training)
11	lakukan pengurutan
12	lakukan pilih corr tertinggi
13	buat indeks_training_pakai
14	lakukan regresi set_ch_training dengan indeks_training_pakai
15	lakukan memasukkan indeks testing ke regresi
16	lakukan prakiraan regresi ke set_ch_training
17	lakukan transformasi informasi set_sm_regresi
18	lakukan transformasi informasi set_sm_testing
19	lakukan verifikasi
20	lakukan penambahan ke rekap_ver_ARIMA
21	tahun=tahun+1
22	end while

D. Prakiraan dengan ensemble

1	input=output_ARIMA, output_ECMWF, output_regresi, ver_ARIMA, ver_ECMWF, ver_regresi
2	output=ver_ensemble
3	tahun=2015
4	while tahun $\leq$ 2022
5	lakukan pembobotan dari verifikasi
6	lakukan prakiraan ensemble dari bobot*prakiraan/total bobot
7	lakukan transformasi informasi set_sm_ans
8	lakukan transformasi informasi set_sm_testing
9	lakukan verifikasi
10	lakukan penambahan ke rekap_ver_ans
11	tahun=tahun+1
12	end while

3.2.3 Eksperimen

Tahapan eksperimen pada penelitian ini bertujuan untuk memastikan bahwa sistem yang sudah dirancang dapat berjalan. Adapun eksperimen dilakukan terhadap data ZOM 41. Hasil dari eksperimen ini sebagaimana tertera pada Tabel 3.3 sampai Tabel 3.5.

Tabel 3.3 Hasil ujicoba prakiraan dengan skenario RTOW, ECMWF dan ARIMA di ZOM 41

Verifikasi Prakiraan	Skenario Basah	Skenario Normal	Skenario Kering	Skenario EcARIMA	Skenario ErARIMA	Skenario ARIMA
KS20142015	78	89	86	78	64	75
KS20152016	75	69	69	75	67	75
KS20162017	78	86	86	78	44	75
KS20172018	75	92	86	78	53	81
KS20182019	64	78	83	69	58	61
KS20192020	69	75	78	75	67	75
KS20202021	67	67	61	69	67	72
KS20212022	58	53	44	64	56	61
KS20222023	75	81	81	81	69	72
KSAVG	70	75	74	74	60	72
KSMIN	58	53	44	64	44	61
STDEV ($\pm$)	6.93	12.30	14.43	5.58	8.42	6.70
MAE20142015	21.3	20.3	22.6	23.2	27.4	22.9
MAE20152016	28.9	30.1	34.5	29.4	33.1	26.2
MAE20162017	24	19.5	22.5	19.9	32.2	23.1
MAE20172018	19.9	14.4	13.8	18.3	29.3	18.2
MAE20182019	24.7	18.1	15.9	19.5	26.9	23.5
MAE20192020	28.7	25.5	23.1	22.1	30.7	25.1
MAE20202021	31.8	33.9	37.4	34.3	34.6	32.5
MAE20212022	42.8	49.1	55.4	45.2	52.1	43.9
MAE20222023	24.3	18.9	17.4	21.6	27.6	24.3
MAEAVG	28.1	26.2	27.5	26.3	33.3	27.1
MAEMAX	42.8	49.1	55.4	45.2	52.1	43.9
STDEV ($\pm$)	6.91	10.8	13.3	8.88	7.78	7.48

Tabel 3.4 Hasil ujicoba prakiraan dengan skenario regresi ONI, DMI dan SST di ZOM 41

Verifikasi	ONI_	ONI_	DMI_	DMI_	PC_1_	PC_10_
Prakiraan	ASO	JAS	OCTtd	SEP	OKT	SEP
KS20142015	75	72	81	78	72	72
KS20152016	81	56	81	81	69	67
KS20162017	69	72	69	67	72	64
KS20172018	75	69	81	67	64	67
KS20182019	61	56	61	44	64	61
KS20192020	69	69	44	47	69	72
KS20202021	67	61	58	64	69	61
KS20212022	58	50	64	64	64	64
KS20222023	72	78	75	75	75	72
KSAVG	69	64	67	64	68	66
KSMIN	58	50	44	44	64	61
STDEV ($\pm$)	7.16	9.36	12.74	12.75	4.0	4.53
MAE20142015	24.5	26.2	22.4	23.2	24.2	24.8
MAE20152016	27.2	47.3	26.2	26	35.3	36.1
MAE20162017	38.5	25.1	31.8	31.5	38.5	30.7
MAE20172018	24	23.3	21.9	23.6	27.6	23.8
MAE20182019	29.8	30.1	28.3	43.4	28.6	33.5
MAE20192020	28.1	28.2	42.3	41.3	27	27.7
MAE20202021	33.7	35.3	44.6	34.7	33.4	38.9
MAE20212022	45.5	50.3	45.1	45.7	45.1	43.7
MAE20222023	23.6	23	21.9	23.5	23.8	26.2
MAEAVG	31.3	32.8	32.8	33.7	32.4	32.6
MAEMAX	45.5	50.3	45.1	45.7	45.1	43.7
STDEV ($\pm$)	7.43	10.22	9.87	9.12	7.15	6.85

Tabel 3.5 Hasil ujicoba prakiraan dengan skenario ensemble di ZOM 41

Verifikasi Prakiraan	Ens_KES_ n=1	Ens_KES_ n=150	Ens_MAE_ n=1	Ens_MAE_ n=150
KS20142015	72	72	72	72
KS20152016	81	81	81	81
KS20162017	53	69	81	69
KS20172018	61	67	92	67
KS20182019	58	61	78	61
KS20192020	67	69	75	72
KS20202021	67	67	67	67
KS20212022	58	64	53	64
KS20222023	75	72	81	72
KSAVG	65	69	76	69
KSMIN	53	61	53	61
STDEV ($\pm$)	9.12	5.67	10.96	5.77
MAE20142015	24.6	24.6	24.6	24.6
MAE20152016	26.5	26.6	27	26.7
MAE20162017	38.4	26.2	29.5	26.1
MAE20172018	27.5	23.9	14.4	23.7
MAE20182019	28.4	29.3	18.1	29.1
MAE20192020	28.1	27.7	25.5	27.6
MAE20202021	33.6	33.8	33.9	33.8
MAE20212022	45.6	45.7	49.1	45.7
MAE20222023	28.9	23.3	18.9	23.3
MAEAVG	32.1	29.6	27	29.5
MAEMAX	45.6	45.7	49.1	45.7
STDEV ($\pm$)	6.78	7.03	10.33	7.05

Berdasarkan hasil verifikasi tersebut, direkomendasikan beberapa model yang memiliki performa cukup baik di ZOM 41 sebagai berikut.

Tabel 3.6 Rekomendasi model terbaik di ZOM 41

Model Rekomendasi	KSAVG	KSMIN	MAEAVG	MAEMAX
Ens_MAE_n=2	77	47	27.1	52.3
PC_10_DES	72	67	28.8	41.6
PC_9_OKT	67	56	30.4	37.2
Skenario_Normal	75	53	26.2	49.1

3.3 Instrumen Penelitian

Penelitian ini melibatkan beberapa variabel meliputi independen, antara, dan dependen. Variabel independen pada penelitian ini adalah curah hujan observasi, curah hujan luaran ECMWF, suhu muka laut, indeks Nino 3.4, dan indeks Dipole Mode. Terdapat variabel antara (*intervening*) pada penelitian ini, yaitu prakiraan curah hujan luaran model dasar yang akan digunakan sebagai masukan dalam model ensemble. Variabel dependen merupakan luaran terakhir pada sistem yang dibangun yaitu adalah prakiraan curah hujan.

3.4 Kerangka Operasional

3.4.1 Kebutuhan Informasi Rencana Tahunan Operasional Waduk (RTOW)

RTOW menyediakan panduan strategis bagi otoritas pengelola waduk dalam merencanakan dan mengelola sumber daya air secara efisien dan berkelanjutan sepanjang tahun. Informasi yang tercakup dalam RTOW meliputi prakiraan sifat hujan musim, tinggi muka air, kapasitas penyimpanan waduk, dan kebutuhan air untuk berbagai sektor seperti irigasi, pembangkit listrik, dan pengendalian banjir.

Dengan memperhatikan faktor-faktor tersebut, RTOW memungkinkan terjadinya pengambilan keputusan yang tepat waktu dan efektif dalam menjaga keseimbangan antara kebutuhan manusia dengan kelestarian lingkungan, serta mengurangi risiko bencana terkait air. Oleh karena itu, keberadaan informasi RTOW menjadi kunci dalam mencapai tujuan pengelolaan sumber daya air yang berkelanjutan dan adaptif terhadap perubahan lingkungan dan iklim.

Berdasarkan laporan Rencana Alokasi Air Tahunan Wilayah Sungai (RAAT WS) Brantas Tahun 2023/2024 (Bestari, 2023), penyusunan RTOW dilaksanakan secara rutin setiap bulan November dan membutuhkan informasi prakiraan curah hujan untuk 2 musim ke depan (36 dasarian). Periode ini meliputi musim hujan (Desember-Mei) dan musim kemarau (Juni-November) dengan periode musim diasumsikan tetap. Skenario sifat musim menggunakan nilai persentil (P_i) yang dikategorikan menjadi 3 kelas yaitu basah (curah hujan $> P_{65}$), normal ($P_{35} \geq$ curah hujan $\geq P_{65}$), dan kering (curah hujan $< P_{35}$). Selain RTOW, RAAT juga memuat RTTG (Rencana Tata Tanam Global).

3.4.2 Informasi Iklim

BMKG, melalui Kedeputan Bidang Klimatologi, secara berkala mengeluarkan buletin prakiraan bulanan dan musim. Menurut Peraturan BMKG Nomor 7 Tahun 2019 tentang Penyediaan dan Penyebaran Prakiraan Musim, prakiraan musim didefinisikan sebagai hasil analisis data berupa informasi awal musim, sifat musim, perbandingan awal musim terhadap normalnya, dan puncak musim. Buletin ini diterbitkan 2 (dua) kali dalam setahun, yaitu prakiraan musim hujan dan prakiraan musim kemarau. Proses pembuatan buletin musim melibatkan prakiraan hujan di wilayah Jawa Timur untuk 7 (tujuh) bulan ke depan. Sementara

itu, buletin bulanan mencakup analisis hujan bulan sebelumnya dan prakiraan hujan 3 (tiga) bulan ke depan. Informasi ini mencakup evaluasi dan prakiraan kondisi curah hujan, karakteristik hujan, tingkat kandungan air tanah, serta potensi kekeringan meteorologis. Melalui buletin prakiraan musim dan bulanan, masyarakat dapat memperoleh prakiraan pola iklim yang dapat dijadikan sebagai dasar pengambilan kebijakan dalam kegiatan operasional.

Tabel 3.7 Urutan dasarian setiap tahun

Tanggal	Dasarian ke-	Tanggal	Dasarian ke-
1-10 Januari	1	1-10 Juli	19
11-20 Januari	2	11-20 Juli	20
21-31 Januari	3	21-31 Juli	21
1-10 Februari	4	1-10 Agustus	22
11-20 Februari	5	11-20 Agustus	23
21-28/29 Februari	6	21-31 Agustus	24
1-10 Maret	7	1-10 September	25
11-20 Maret	8	11-20 September	26
21-31 Maret	9	21-30 September	27
1-10 April	10	1-10 Oktober	28
11-20 April	11	11-20 Oktober	29
21-30 April	12	21-31 Oktober	30
1-10 Mei	13	1-10 November	31
11-20 Mei	14	11-20 November	32
21-31 Mei	15	21-30 November	33
1-10 Juni	16	1-10 Desember	34

Tanggal	Dasarian ke-	Tanggal	Dasarian ke-
11-20 Juni	17	11-20 Desember	35
21-30 Juni	18	21-31 Desember	36


Pada prakiraan yang ada, variasi periode musim disebabkan oleh penggunaan kriteria awal musim sesuai definisi BMKG yang menerapkan batasan curah hujan 50 mm selama 3 (tiga) dasarian berturut-turut. Dasarian adalah kerangka kerja waktu per 10 harian atau sesuai jumlah hari pada akhir bulan sehingga tiap bulan mengandung 3 dasarian, yaitu I (tanggal 1-10), II (tanggal 11-20), dan III (tanggal 21-terakhir di bulan tersebut). Dalam setahun terdapat 36 dasarian urut dari Januari I sebagai dasarian 1 hingga Desember III sebagai dasarian 36. Dengan demikian, awal musim hujan (AMH) pada tahun ini bisa jadi berbeda dengan AMH tahun sebelumnya. Urutan dasarian dalam setahun disajikan pada Tabel 3.7. Demikian pula untuk awal musim kemarau (AMK). Hal ini berbeda dengan pendefinisian musim pada operasional waduk yang mengasumsikan periode musim hujan dan kemarau setiap tahun. Berikut adalah urutan dasarian setiap tahunnya.

BAB IV

MODEL SKENARIO DASAR RTOW

4.1 Prakiraan Curah Hujan Luaran Model Skenario Dasar RTOW

Pembentukan prakiraan dengan skenario dasar dimaksudkan untuk mengakomodir penggunaan sifat musim dalam operasional waduk. Skenario dasar terdiri dari 3 (tiga) kondisi musim, yaitu basah, normal, dan kering. Prakiraan untuk kondisi basah, normal, dan kering secara berurutan menggunakan nilai persentil ke-35, 50, dan 65 sebagai nilai prakiraan. Contoh prakiraan pada daerah pengisi Bendungan Sutami-Lahor ditampilkan pada Gambar 4.1 menggunakan sampel ZOM 20.



Gambar 4.1 Grafik *time series* hasil prakiraan (garis merah) curah hujan dasarian ZOM 20 menggunakan skenario basah (atas), normal (tengah), dan kering (bawah)

Grafik 4.1 menampilkan perbandingan data curah hujan untuk tiga skenario prakiraan yang berbeda. Pada skenario basah, terlihat bahwa model prakiraan dapat mengikuti pola umum curah hujan, namun sering kali tidak mencapai puncak curah hujan ekstrem yang tercatat pada data pengamatan. Skenario ini menunjukkan curah hujan yang prakiraan cenderung lebih tinggi dibanding observasinya. Pola musim tetap terlihat, namun ada periode tertentu di mana curah hujan meningkat secara signifikan.

Pada skenario normal, model prakiraan juga menunjukkan tren yang mengikuti pola data pengamatan, namun dengan intensitas yang lebih moderat dibandingkan skenario basah. Grafik ini menunjukkan bahwa curah hujan cenderung stabil dengan puncak yang lebih rendah dibandingkan skenario basah, meskipun pola musim tetap terjaga. Periode ekstrem, seperti yang terjadi pada tahun 2022, juga terlihat namun dengan intensitas yang lebih rendah. Skenario ini merepresentasikan curah hujan dalam kondisi rata-rata tanpa anomali yang signifikan.

Dalam skenario kering, curah hujan yang diamati memiliki puncak yang lebih rendah dibandingkan dengan kedua skenario sebelumnya, menunjukkan bahwa periode curah hujan rendah mendominasi pada skenario ini. Garis prakiraan tetap mengikuti pola tren musiman namun dengan intensitas curah hujan yang lebih kecil. Beberapa puncak kecil masih terlihat di tahun-tahun tertentu, namun model prakiraan pada umumnya menggambarkan curah hujan yang lebih rendah.

Secara keseluruhan, model prakiraan skenario dasar RTOW dapat mengikuti pola tren data pengamatan. Namun, kondisi signifikan pada situasi hujan ekstrem belum mampu ditangkap oleh model. Kondisi ini terjadi pada hasil prakiraan

skenario dasar RTOW pada tiga kondisi musim (kering, normal, dan basah).

4.2 Verifikasi Luaran Prakiraan Curah Hujan dengan Skenario Dasar RTOW

Prakiraan curah hujan dari model skenario dasar diverifikasi menggunakan 4 (empat) parameter, yaitu: (i) kesesuaian rata-rata, (ii) kesesuaian minimum, (iii) MAE rata-rata, dan (iv) MAE maksimum. Contoh hasil verifikasi luaran model skenario dasar ditampilkan pada Tabel 4.1.

Tabel 4.1 Hasil verifikasi luaran model skenario dasar untuk ZOM 20

Periode Prakiraan	Kesesuaian (%)			MAE (mm)		
	Basah	Normal	Kering	Basah	Normal	Kering
2014-2015	69	86	81	27.6	24.0	23.8
2015-2016	53	36	28	49.6	54.9	61.4
2016-2017	56	61	61	36.1	35.5	37.3
2017-2018	75	78	83	25.4	21.9	21.7
2018-2019	67	75	78	30.2	24.6	21.0
2019-2020	75	67	58	34.5	34.1	37.6
2020-2021	58	61	61	40.8	41.4	44.4
2021-2022	64	50	44	48.3	56.2	62.6
2022-2023	67	72	78	29.9	26.2	25.1
Rata-rata	64	62	61	36.9	36.9	38.9

Hasil prakiraan di ZOM 20 menunjukkan kesesuaian yang bervariasi dan tidak terdapat salah satu skenario yang konsisten lebih baik dibanding yang lain. Untuk skenario basah, kesesuaian tertinggi terjadi pada periode 2017-2018 dan 2019-2020, masing-masing sebesar 75%. Sementara untuk skenario normal,

kesesuaian tertinggi sebesar 86% terjadi pada periode 2014-2015, dan untuk skenario kering, kesesuaian tertinggi sebesar 83% pada periode 2017-2018. Pada kasus prakiraan tahun 2015-2016, ketiga skenario sepakat menunjukkan kesesuaian yang rendah. Rata-rata kesesuaian prakiraan dalam tiga skenario menunjukkan model memiliki tingkat kecocokan yang moderat dengan skenario basah memiliki kesesuaian rata-rata yang lebih tinggi dan fluktuasi yang lebih stabil antara 53-75%.

Hasil prakiraan di ZOM 20 menunjukkan kesesuaian yang bervariasi dan tidak terdapat salah satu skenario yang konsisten lebih baik dibanding yang lain. Untuk skenario basah, kesesuaian tertinggi terjadi pada periode 2017-2018 dan 2019-2020, masing-masing sebesar 75%. Sementara untuk skenario normal, kesesuaian tertinggi sebesar 86% terjadi pada periode 2014-2015, dan untuk skenario kering, kesesuaian tertinggi sebesar 83% pada periode 2017-2018. Pada kasus prakiraan tahun 2015-2016, ketiga skenario sepakat menunjukkan kesesuaian yang rendah. Rata-rata kesesuaian prakiraan dalam tiga skenario menunjukkan model memiliki tingkat kecocokan yang moderat dengan skenario basah memiliki kesesuaian rata-rata yang lebih tinggi dan fluktuasi yang lebih stabil antara 53-75%.

MAE menunjukkan seberapa besar kesalahan prakiraan dalam milimeter curah hujan. MAE pada skenario basah dan normal memiliki rata-rata yang senilai yaitu 36,9 mm. Di sisi lain, skenario kering menunjukkan nilai MAE rata-rata yang lebih tinggi yaitu 38,9 mm. Sama halnya dengan hasil kesesuaian, MAE pada skenario basah menunjukkan stabilitas model yang lebih tinggi dengan MAE maksimumnya tidak lebih tinggi dari MAE maksimum pada

skenario normal dan kering. Hasil verifikasi prakiraan skenario dasar untuk seluruh ZOM di daerah pengisi Bendungan Sutami-Lahor ditampilkan pada Tabel 4.2.

Tabel 4.2 Hasil verifikasi siluan model skenario dasar RTOW

ZOM	Skenario Basah				Skenario Normal				Skenario Kering			
	KS ave	KS min	MAE Ave	MAE max	KS ave	KS min	MAE ave	MAE Max	KS ave	KS Min	MAE ave	MAE max
20	64	53	36.9	49.6	62	36	36.9	56.2	61	28	38.9	62.6
30	74	67	31.3	41.7	67	47	32.9	49.2	65	44	34.2	51.9
31	69	61	35.0	44.8	74	44	26.0	39.4	63	42	38.8	51.7
33	70	58	26.0	31.4	72	53	24.5	34.6	73	56	25.3	35.6
34	70	64	31.8	44.1	72	61	24.9	32.0	70	56	31.9	45.0
35	70	53	29.7	40.6	77	67	23.4	31.1	62	42	31.2	46.6
36	66	47	39.7	54.2	75	50	21.8	31.4	59	36	46.0	72.5
37	68	58	33.4	42.4	73	61	23.4	29.5	63	36	36.0	55.6
38	53	36	45.1	65.0	75	61	26.2	42.4	50	22	47.8	77.1
39	51	39	52.9	74.0	77	61	24.9	37.6	47	28	57.9	92.9
40	63	50	43.3	51.7	72	56	30.8	46.6	48	31	51.0	73.3
41	64	50	34.1	46.5	65	53	35.3	46.1	61	39	34.5	59.9

Prakiraan menggunakan skenario dasar (basah-normal-kering) menunjukkan kondisi ketika curah hujan diprakirakan berdasarkan rencana saat ini (*existing plan*) yang biasa digunakan dalam RTOW, yaitu pengelompokan sifat musim. Berdasarkan kesesuaian rata-rata, skenario ini menghasilkan prakiraan dengan tingkat kesesuaian antara 47-77%. Kesesuaian minimum terendah sebesar 22% menunjukkan kemampuan prakiraan yang cenderung


lemah, utamanya pada skenario kering. Penggunaan skenario dasar ini menghasilkan rata-rata MAE antara 21.8-57.9 mm dengan MAE maksimum mencapai 92.9 mm pada kondisi kering. Hasil ini menunjukkan bahwa prakiraan menggunakan skenario dasar kurang dapat diandalkan karena kesesuaian yang dihasilkan masih cukup rendah dan MAE masih cukup tinggi.

BAB V

MODEL ARIMA

5.1 Prakiraan Curah Hujan Luaran Model ARIMA

Prakiraan dengan model ARIMA memanfaatkan historis curah hujan sebelumnya sebagai bahan prakiraan, dengan mengenali pola yang ada di dalamnya. Hasil prakiraan model ARIMA ditampilkan pada Gambar 4.2 menggunakan sampel ZOM 32 dan 38.



Gambar 5.1 Grafik *time series* hasil prakiraan (garis merah) curah hujan dasarian menggunakan model ARIMA di ZOM 32 (atas) dan 38 (bawah)

Prakiraan model ARIMA di ZOM 32 menunjukkan pola yang relatif lebih halus dan terdapat beberapa puncak yang mengikuti tren dari data observasi. Pola curah hujan yang meningkat dapat diikuti cukup baik oleh model, meskipun tidak selalu mencapai tingkat yang sama. Model terlihat tidak mampu mengikuti pola

ketika curah hujan melebihi 150 mm. Hal ini menunjukkan keterbatasan model dalam menangkap puncak ekstrem curah hujan, terutama dalam kondisi hujan yang sangat lebat. Model ARIMA cenderung lebih mampu memperkirakan pola umum atau tren jangka pendek. Pada periode tertentu di mana curah hujan observasi mendekati 0, model ARIMA juga memprakirakan nilai yang rendah. Sementara itu, hasil prakiraan ARIMA di ZOM 38 menunjukkan perbedaan yang cukup signifikan dengan data observasi, baik dari segi pola maupun curah hujannya. Luaran ARIMA cenderung memiliki pola berulang dengan puncak relatif sama, sementara curah hujan observasi di ZOM 38 memiliki pola yang lebih acak dibanding ZOM 30. Sama halnya yang terjadi di ZOM 32, luaran ARIMA cenderung tidak mampu memprakirakan curah hujan ekstrem basah lebih dari 150 mm, padahal kejadian curah hujan ekstrem basah di ZOM 38 cenderung lebih sering.

5.2 Verifikasi Luaran Prakiraan Curah Hujan dengan Model ARIMA

Verifikasi hasil prakiraan curah hujan ZOM 32 dan 38 ditampilkan pada Tabel 4.3 sebagai berikut. Model ARIMA menghasilkan prakiraan curah hujan di ZOM 32 dengan tingkat kesesuaian rata-rata 72% dan variasi berkisar antara 64-78%. Selisih antara curah hujan observasi dan prakiraan ARIMA berada pada kisaran 18.1-31.8 mm dengan rata-rata sebesar 26.0 mm. Kesesuaian rendah dan MAE lebih tinggi terjadi saat model memprakirakan curah hujan periode 2019-2020. Sementara itu, verifikasi prakiraan curah hujan di ZOM 38 memiliki tingkat kesesuaian rata-rata 53% dengan variasi antara 39-61%. MAE rata-rata di ZOM 38 sebesar 51.8 mm dengan variasi antara 39.5-68.5 mm. Hal ini menunjukkan

kondisi tidak lebih baik dibanding hasil prakiraan di ZOM 32. Seperti halnya hasil skenario dasar, model ARIMA juga cenderung kurang baik dalam memprakirakan curah hujan tahun 2015-2016. Meskipun begitu, prakiraan dengan ARIMA pada periode tersebut menunjukkan performa yang lebih baik dibanding model skenario dasar.

Tabel 5.1 Hasil verifikasi luaran model ARIMA untuk ZOM 32 dan 38

Periode Prakiraan	ZOM 32		ZOM 38	
	Kesesuaian (%)	MAE (mm)	Kesesuaian (%)	MAE (mm)
2014-2015	72	22.4	47	47.4
2015-2016	67	27.8	39	68.5
2016-2017	72	31.8	56	42.2
2017-2018	75	21.7	42	47.9
2018-2019	69	24.0	56	39.5
2019-2020	64	30.6	58	42.5
2020-2021	72	26.0	61	50.6
2021-2022	78	28.1	61	66.2
2022-2023	75	18.1	50	56.6
Rata-rata	72	26	53	51.8

Hasil verifikasi prakiraan model ARIMA untuk seluruh ZOM di daerah pengisi Bendungan Sutami-Lahor ditampilkan pada Tabel 5.2. Dengan memanfaatkan data kondisi di masa lalu, model ARIMA mampu menghasilkan prakiraan curah hujan dasarian dengan tingkat kesesuaian rata-rata antara 62-77% di ZOM yang termasuk daerah pengisi bendungan. Kesesuaian minimum terendah sebesar 25% sedikit lebih baik dibanding hasil prakiraan skenario dasar. Ditinjau

dari MAE, prakiraan ARIMA memiliki selisih dengan observasinya rata-rata pada kisaran 21.6-36.7 mm dengan MAE maksimum mencapai 54.0 mm. Secara umum, kondisi ini lebih baik dibanding model sebelumnya yaitu prakiraan dengan skenario dasar.

Tabel 5.2 Hasil verifikasi luaran model ARIMA


ZOM	KS ave (%)	KS min (%)	MAE ave (mm)	MAE max (mm)
20	64	47	36.3	49.0
30	62	36	34.7	43.5
31	65	36	27.2	34.3
33	69	39	25.8	29.3
34	74	67	24.9	29.6
35	71	64	25.1	29.0
36	74	64	21.6	27.7
37	77	69	23.3	28.3
38	73	61	26.4	38.3
39	65	25	31.3	54.0
40	68	39	32.1	41.9
41	63	31	36.7	43.6

BAB VI

MODEL ECMWF

6.1 Prakiraan Curah Hujan Luaran Model ECMWF


Model ECMWF yang digunakan pada penelitian ini meliputi ECMWF mentah (Er) dan ECMWF terkoreksi (Ec). Kekurangan data pada periode akhir bahan prakiraan dilengkapi menggunakan metode ARIMA. Analisis dilakukan terhadap masing-masing hasil prakiraan berdasarkan Er dan Ec. Gambar 6.1 berikut menunjukkan hasil prakiraan curah hujan dasarian di ZOM 30 menggunakan model Er dan Ec.



Gambar 6.1 Grafik *time series* hasil prakiraan (garis merah) curah hujan dasarian menggunakan model ECMWF *raw* (atas) dan terkoreksi (bawah) di ZOM 30

Gambar 6.1 menunjukkan hasil prakiraan ECMWF memiliki pola yang mirip dengan kondisi riil curah hujan di ZOM 30. Jarak antara curah hujan prakiraan dengan observasi cenderung sempit. Sama seperti beberapa model

sebelumnya, ECMWF juga belum mampu menangkap kondisi curah hujan ekstrem basah, namun cukup baik dalam memprakirakan curah hujan rendah. Antara ECMWF mentah dan terkoreksi, Ec menghasilkan curah hujan yang lebih mendekati hasil observasi.



Gambar 6.2 Grafik *time series* hasil prakiraan (garis merah) curah hujan dasarian menggunakan model ECMWF *raw* (atas) dan terkoreksi (bawah) di ZOM 38

Gambar 6.2 adalah kondisi prakiraan dengan ECMWF yang kurang berhasil. Curah hujan observasi di ZOM 38 cenderung memiliki pola yang lebih acak dibanding ZOM 30, sementara luaran ECMWF memiliki pola yang cenderung lebih stabil dan berulang. Pada kondisi curah hujan ekstrem, baik Ec maupun Er tidak mampu menangkap nilai yang signifikan jauh lebih tinggi. Dengan demikian, model ECMWF dapat dikatakan kurang baik dalam membaca pola pergerakan curah hujan di ZOM 38.

6.2 Verifikasi Luaran Prakiraan Curah Hujan dengan Model ECMWF

Verifikasi hasil prakiraan curah hujan ECMWF ditampilkan pada Tabel 6.1. Kesesuaian rata-rata berkisar antara 51-69% untuk ErARIMA dan 54-75% untuk EcARIMA. ErARIMA menghasilkan kesesuaian minimum antara 39-58%, sedangkan EcARIMA antara 39-64%. Ditinjau dari nilai MAE rata-rata, ErARIMA memiliki kisaran antara 30.5-53.5 mm dan EcARIMA antara 25.7-51.4 mm. Nilai MAE maksimum yang dihasilkan ErARIMA antara 40.4-71.5 mm sedangkan EcARIMA antara 31.4-69.0 mm. Dengan demikian, model EcARIMA memiliki performa yang lebih baik dibanding ErARIMA dengan hasil prakiraan terbaik terjadi di ZOM 30 dan paling buruk di ZOM 39, baik Ec maupun Er.

Tabel 6.1 Hasil verifikasi luaran model ECMWF


ZOM	ECMWF mentah (ErARIMA)				ECMWF terkoreksi (EcARIMA)			
	KS ave	KS min	MAE ave	MAE max	KS ave	KS min	MAE ave	MAE max
20	60	53	40.0	49.8	63	47	36.3	49.6
30	69	58	33.0	41.8	75	64	29.9	40.6
31	63	42	39.9	57.9	69	64	34.5	42.6
33	62	42	33.2	40.4	73	64	25.7	31.4
34	66	58	33.1	45.7	72	58	30.1	42.3
35	67	50	30.5	41.9	72	56	28.1	38.5
36	57	44	44.6	62.3	65	53	40.2	57.1
37	65	50	33.9	42.8	69	58	31.7	42.4
38	52	42	46.1	62.1	54	42	43.8	61.8
39	51	39	53.5	71.5	54	39	51.4	69.0
40	58	39	44.1	56.7	60	42	43.0	51.5
41	65	56	33.6	51.2	67	58	31.4	48.1

BAB VII

MODEL REGRESI

7.1 Prakiraan Curah Hujan Luaran Model Regresi ONI

Model regresi ONI dibangun dengan menggunakan data indeks dalam 12 bulan terakhir mengingat fenomena ONI dan DMI seringkali membutuhkan waktu jeda hingga dampaknya terlihat di Jawa Timur. Model prakiraan regresi ONI yang dihasilkan dalam sekali waktu prediksi di satu ZOM adalah sebanyak 12 model dengan formulanya masing-masing.



Gambar 7.1 Grafik *time series* hasil prakiraan curah hujan dasarian (garis merah) menggunakan model regresi ONI di ZOM 35

Grafik 7.1 menunjukkan *time series* perbandingan antara prakiraan curah hujan (garis merah) dan data observasi (garis hitam) yang dikembangkan berdasarkan regresi indeks Nino 3.4 menggunakan data ONI 12 bulan terakhir ke belakang untuk memprakirakan curah hujan di satu waktu. Berdasarkan gambar dapat diamati adanya keseragaman pola antara hasil prakiraan dan observasi yang artinya model cukup baik dalam menangkap pola curah hujan di ZOM 35. Dibanding beberapa model sebelumnya, regresi ONI dapat dikatakan lebih baik dalam memprakirakan curah hujan ekstrem. Keterbatasan model regresi ONI muncul ketika prakiraan umumnya mengalami keterlambatan dibanding observasinya. Hasil ini dapat digunakan untuk memahami kapan model bekerja dengan baik dan kapan model perlu disesuaikan atau ditingkatkan, terutama dalam hal prediksi curah hujan ekstrem yang mungkin sangat dipengaruhi oleh faktor-faktor lain selain indeks Nino 3.4.

7.2 Verifikasi Luaran Prakiraan Curah Hujan dengan Model Regresi ONI

Verifikasi hasil prakiraan curah hujan regresi ONI ditampilkan pada Tabel 7.1 hingga Tabel 7.4. Verifikasi hasil prakiraan curah hujan dasarian regresi ONI berdasarkan parameter kesesuaian rata-rata ditampilkan pada 7.1. Terdapat 12 regresi yang terbentuk untuk setiap ZOM. Secara umum, regresi ONI menghasilkan prakiraan curah hujan dasarian dengan kesesuaian rata-rata antara 45-70%. Di antara 12 bentuk regresi yang ada, regresi ASO, SON, NDJ, dan JFM memiliki tingkat kesesuaian rata-rata paling tinggi sedangkan ONI MAM paling rendah.

Tabel 7.1 Hasil verifikasi luaran model regresi ONI berdasarkan kesesuaian rata-rata

Regresi ONI	ZOM												Rata- Rata
	20	30	31	33	34	35	36	37	38	39	40	41	
ONI_ASO	60	66	63	69	66	62	65	50	48	58	65	69	61.8
ONI_SON	59	64	63	67	65	62	65	50	47	59	63	70	61.2
ONI_OND	58	64	63	67	65	61	64	51	47	58	63	70	60.9
ONI_NDJ	60	65	64	67	65	61	64	51	48	58	63	70	61.3
ONI_DJF	57	67	64	66	64	61	64	52	46	58	63	69	60.9
ONI_JFM	59	67	63	66	65	61	64	54	47	58	63	68	61.3
ONI_FMA	57	65	61	66	62	60	64	52	47	58	62	68	60.2
ONI_MAM	56	64	60	65	59	60	65	51	45	57	63	65	59.2
ONI_AMJ	51	62	58	64	61	54	63	50	48	56	59	61	57.3
ONI_MJJ	54	67	61	64	64	56	64	46	47	55	57	62	58.1
ONI_JJA	56	66	64	64	65	58	64	47	47	57	59	64	59.3
ONI_JAS	57	67	64	68	64	59	64	46	46	55	60	64	59.5

Berdasarkan kesesuaian minimumnya, model regresi ONI menghasilkan prakiraan dengan kesesuaian minimum antara 28-61% sesuai pada Tabel 7.2. Di antara 12 bentuk regresi yang terbentuk, regresi ONI JFM memiliki performa terbaik dimana kesesuaian minimumnya antara 36-61%, paling tinggi diantara seluruhnya. Sementara itu, regresi ONI AMJ dan MJJ menghasilkan kesesuaian minimum paling rendah.

Tabel 7.2 Hasil verifikasi luaran model regresi ONI berdasarkan kesesuaian minimum

Regresi ONI	ZOM												Rata-Rata
	20	30	31	33	34	35	36	37	38	39	40	41	
ONI_ASO	44	58	53	56	47	50	56	36	31	47	53	58	49.1
ONI_SON	44	58	50	56	47	50	56	36	31	50	53	58	49.1
ONI_OND	42	58	53	58	47	50	58	36	31	47	53	58	49.3
ONI_NDJ	44	58	53	58	47	50	56	36	33	47	53	58	49.4
ONI_DJF	44	58	56	56	47	53	56	39	31	44	56	58	49.8
ONI_JFM	44	61	47	56	50	53	56	39	36	44	56	58	50.0
ONI_FMA	42	58	47	56	47	47	56	33	31	47	53	56	47.8
ONI_MAM	36	53	47	53	33	44	56	33	33	42	50	50	44.2
ONI_AMJ	33	36	39	50	42	39	53	33	33	47	42	50	41.4
ONI_MJJ	42	53	47	47	47	36	47	28	33	44	42	47	42.8
ONI_JJA	36	56	44	50	47	42	44	31	33	47	42	50	43.5
ONI_JAS	42	53	50	53	50	42	47	31	33	47	47	50	45.4

Berdasarkan tabel 7.3, model regresi ONI menghasilkan MAEabsolut rata-rata antara 30.9 – 62.5 mm. Regresi ONI DJF dan JFM memiliki performa paling baik karena MAE rata-ratanya paling kecil, antara 30.9 – 57.7 mm. Sedangkan MAE rata-rata terbesar dihasilkan oleh model regresi ONI AMJ dengan rentang 36.0 – 62.5 mm.

Tabel 7.3 Hasil verifikasi luaran model regresi ONI berdasarkan MAE rata-rata

Regresi ONI	ZOM												Rata- Rata
	20	30	31	33	34	35	36	37	38	39	40	41	
ONI_ASO	40.3	33.8	38.2	33.9	32.3	45.5	36.5	49	58.6	46.2	35.3	31.3	40.1
ONI_SON	40.3	34.2	38.6	34.2	32.7	45.8	36.9	49.4	59	46.6	35.5	31.3	40.4
ONI_OND	40	34.2	38.6	34.3	32.8	45.8	36.8	49.4	58.7	46.7	35.4	31.2	40.3
ONI_NDJ	39.6	34	38.3	34	32.7	45.5	36.5	49.1	58.2	46.4	35.2	31.1	40.1
ONI_DJF	39.6	33.8	38.2	34.1	33	45.6	36.3	49.2	57.7	46.2	35.3	30.9	40.0
ONI_JFM	39.7	34	38.8	34.5	33.6	45.9	36.5	49.3	57.7	46.2	35.4	31.3	40.2
ONI_FMA	40.4	34.7	40.5	35.8	35	46.7	37.1	49.6	58.5	46.4	35.9	32	41.1
ONI_MAM	42.7	36.4	42.5	37.5	36.8	47.8	38.6	51.3	60.6	47.7	36.9	33.6	42.7
ONI_AMJ	45.5	37.9	43.3	38	37	50.3	40.9	53.3	62.5	48.7	39.7	36	44.4
ONI_MJJ	43.9	35.5	41.7	36.9	35	50	39.9	52.7	61	47.7	40	35.7	43.3
ONI_JJA	42	33.8	40.4	35.4	33.1	47.8	38	51.1	58.9	46.7	38.8	33.9	41.7
ONI_JAS	41.3	33.2	39.5	34.6	32.1	47.3	37.2	50.3	57.6	46.4	37.9	32.8	40.9

Tabel 7.4 adalah MAE maksimum yang dihasilkan tiap model regresi ONI di masing-masing ZOM. Secara umum, model regresi ONI menghasilkan MAE maksimum pada rentang 43.3 – 89.9 mm. Di antara 12 model regresi yang terbentuk, model ONI ASO dan DJF memiliki MAE maksimum yang paling kecil. Sedangkan performa terendah adalah model ONI MJJ dimana MAE maksimumnya paling besar. Berdasarkan keempat parameter verifikasi dapat diketahui bahwa model regresi ONI AMJ dan MJJ memiliki performa paling rendah, sedangkan regresi ONI DJF dan JFM memiliki performa paling baik. Hal


yang seragam1 ditunjukkan oleh 12 model regresi terbentuk adalah ZOM 38 menunjukkan kondisi paling sulit untuk diperkirakan yang dapat dilihat dari rendahnya tingkat kesesuaian dan tingginya MAE.

Tabel 7.4 Hasil verifikasi luaran model regresi ONI berdasarkan MAE maksimum

Regresi ONI	ZOM												Rata- Rata
	20	30	31	33	34	35	36	37	38	39	40	41	
ONI_ASO	56.7	43.5	55.3	44.9	43.3	58.3	45.5	64.4	76.5	58.1	51.3	45.5	53.6
ONI_SON	56.9	45.0	54.5	44.2	43.4	58.4	44.2	67.5	76.9	60.6	53.1	46.3	54.3
ONI_OND	57.5	45.5	53.3	43.8	44.1	58.5	44.6	68.0	77.6	61.2	53.3	46.4	54.5
ONI_NDJ	56.8	45.9	52.0	43.5	44.9	58.5	45.0	67.3	77.3	60.7	52.8	46.9	54.3
ONI_DJF	55.5	45.7	52.4	43.5	44.2	58.5	44.3	67.2	76.4	59.7	51.8	46.5	53.8
ONI_JFM	56.0	46.9	54.4	45.5	46.7	58.3	45.3	69.0	78.8	60.4	52.2	47.0	55.0
ONI_FMA	58.4	48.9	58.0	49.3	49.4	58.0	47.7	71.2	81.7	62.8	53.6	47.6	57.2
ONI_MAM	62.0	54.5	57.4	51.3	56.2	59.3	53.2	74.5	85.8	66.3	56.0	49.0	60.5
ONI_AMJ	65.9	61.6	63.3	57.2	64.3	72.1	61.6	77.1	88.6	66.1	57.9	49.6	65.4
ONI_MJJ	64.7	55.4	64.9	61.8	65.5	81.6	66.6	80.1	89.9	63.1	69.5	58.2	68.4
ONI_JJA	61.1	49.8	63.2	56.2	59.3	75.7	62.1	77.7	85.7	59.1	66.3	52.8	64.1
ONI_JAS	57.6	46.3	58.3	52.6	52.6	70.6	57.6	71.2	78.6	58.2	59.2	50.3	59.4

7.3 Prakiraan Curah Hujan Luaran Model Regresi DMI

Seperti halnya ONI, regresi DMI menghasilkan 12 bentuk model prakiraan yang dapat digunakan untuk memprakirakan curah hujan suatu waktu. Hasil prakiraan curah hujan dasarian menggunakan model regresi DMI ditunjukkan dalam bentuk *time series* pada Gambar 7.2 berikut ini.



Gambar 7.2 Grafik *time series* hasil prakiraan curah hujan dasarian (garis merah) menggunakan model regresi DMI di ZOM 35

Gambar 7.2 menunjukkan *time series* perbandingan antara prakiraan curah hujan (garis merah) dan data observasi (garis hitam) yang dikembangkan berdasarkan regresi indeks *Dipole Mode*, seperti halnya ONI menggunakan data DMI 12 bulan terakhir. Secara umum, hasil prakiraan regresi DMI dapat menghasilkan curah hujan dengan pola serupa dengan observasinya. Kemampuan memprakirakan curah hujan ekstrem juga semakin baik. Hal ini dapat dilihat pada kondisi tahun 2020-2022 yang prakiraannya mampu mendekati nilai observasinya yang tergolong ekstrem atau sangat berbeda dari biasanya. Dibanding beberapa

model sebelumnya, regresi DMI menunjukkan kemampuan prakiraan yang makin baik ketika ditinjau dari pola curah hujan yang dihasilkan, termasuk lebih baik daripada regresi ONI. Secara keseluruhan, grafik ini menyiratkan adanya hubungan yang cukup baik antara curah hujan dengan fenomena Dipole Mode.

7.4 Verifikasi Luaran Prakiraan Curah Hujan dengan Model Regresi DMI

Verifikasi hasil prakiraan curah hujan regresi DMI ditampilkan pada Tabel 7.5 hingga Tabel 7.8.

Tabel 7.5 Hasil verifikasi luaran model regresi DMI berdasarkan kesesuaian rata-rata

RegresiDMI	ZOM												Rata-Rata
	20	30	31	33	34	35	36	37	38	39	40	41	
DMI_OKTtl	59	65	70	68	65	65	64	52	48	55	67	67	62.1
DMI_NOVtl	58	63	70	68	64	60	62	50	45	55	64	67	60.5
DMI_DEStl	59	66	70	66	66	62	62	52	43	54	65	70	61.3
DMI_JAN	54	62	69	66	67	59	60	49	44	54	62	66	59.3
DMI_FEB	58	62	68	66	66	58	62	48	43	50	62	68	59.3
DMI_MAR	59	65	69	66	67	62	66	48	44	56	63	68	61.1
DMI_APR	60	64	69	68	68	60	66	48	45	55	65	68	61.3
DMI_MEI	55	62	67	64	63	61	62	49	49	55	64	66	59.8
DMI_JUN	56	61	66	63	63	62	62	50	49	58	61	67	59.8
DMI_JUL	58	64	68	67	65	66	67	49	46	56	64	66	61.3
DMI_AGU	55	64	68	67	64	67	68	47	44	55	62	66	60.6
DMI_SEP	54	65	66	65	64	63	62	47	44	54	61	64	59.1

Tabel 7.5 adalah hasil verifikasi model regresi DMI berdasarkan kesesuaian rata-ratanya. Secara umum, regresi DMI menghasilkan prakiraan dengan tingkat kesesuaian rata-rata pada rentang 43-70%. Performa terbaik dengan kesesuaian rata-rata tertinggi 62.1% dan rentang 48-70% dihasilkan oleh model regresi DMI OKTtl. Sedangkan model regresi DMI terburuk adalah DMI SEP dengan kesesuaian rata-rata terendah, yaitu sebesar 59.1% pada rentang 44-66%.

Tabel 7.6 Hasil verifikasi luaran model regresi DMI berdasarkan kesesuaian minimum

RegresiDMI	ZOM												Rata-Rata
	20	30	31	33	34	35	36	37	38	39	40	41	
DMI_OKTtl	42	53	47	50	50	47	56	33	36	47	56	44	46.8
DMI_NOVtl	42	56	58	56	53	42	50	25	31	47	42	56	46.5
DMI_DEStl	50	61	64	58	53	53	53	31	25	47	53	58	50.5
DMI_JAN	31	53	58	47	53	44	47	14	31	39	42	50	42.4
DMI_FEB	50	56	58	58	47	44	50	42	28	36	47	56	47.7
DMI_MAR	42	58	56	56	50	50	56	28	28	44	56	56	48.3
DMI_APR	47	58	58	58	56	42	50	31	28	42	53	58	48.4
DMI_MEI	33	58	56	44	50	39	44	25	25	39	44	50	42.3
DMI_JUN	28	53	58	47	53	36	44	25	31	44	36	53	42.3
DMI_JUL	47	53	58	53	53	50	53	28	31	42	53	53	47.8
DMI_AGU	47	56	58	56	50	50	61	31	33	44	50	47	48.6
DMI_SEP	42	58	53	50	53	47	44	22	31	33	47	44	43.7

Seperti yang ditampilkan pada tabel 7.6, model regresi DMI menghasilkan prakiraan dengan tingkat kesesuaian minimumnya pada rentang 14-64%. Model regresi DMI terbaik adalah DMI DESTl dengan kesesuaian minimumnya pada rentang 25-64%. Sedangkan model regresi DMI yang terburuk dihasilkan oleh DMI JAN dengan kesesuaian minimum pada rentang 14-58%.

Tabel 7.7 Hasil verifikasi luaran model regresi DMI berdasarkan MAE rata-rata

RegresiDMI	ZOM												Rata- Rata
	20	30	31	33	34	35	36	37	38	39	40	41	
DMI_OKTl	39.8	40.9	34.3	36.6	33.1	43.2	35.9	48.9	56.0	46.1	34.6	32.8	40.2
DMI_NOVl	41.4	40.4	34.3	35.8	32.4	44.2	36.3	50.2	57.7	47.5	35.2	32.5	40.7
DMI_DESTl	40.0	39.0	33.1	34.7	32.1	44.9	36.3	48.5	57.9	47.3	35.0	30.9	40.0
DMI_JAN	41.5	39.0	35.2	34.9	32.2	46.1	37.2	48.9	57.8	46.8	35.6	32.4	40.6
DMI_FEB	41.4	37.9	34.2	34.5	32.1	45.8	37.3	50.1	59.5	48.5	36.4	30.9	40.7
DMI_MAR	40.6	38.2	33.3	33.9	31.5	44.3	35.9	49.5	58.0	46.3	35.1	30.4	39.8
DMI_APR	40.5	39.2	32.6	34.3	32.2	45.3	36.1	49.9	57.8	46.6	35.2	31.3	40.1
DMI_MEI	43.0	39.6	34.7	35.0	32.2	45.1	37.3	51.9	60.2	46.4	35.7	31.3	41.0
DMI_JUN	43.5	40.9	35.3	35.6	33.1	44.6	37.1	51.4	60.4	46.0	36.2	32.5	41.4
DMI_JUL	39.9	40.3	33.5	34.6	31.5	43.5	35.7	50.0	58.9	45.8	35.2	32.0	40.1
DMI_AGU	40.3	39.0	32.9	34.4	31.4	43.2	34.9	49.3	58.2	46.3	35.1	32.0	39.8
DMI_SEP	42.0	40.7	34.7	36.4	34.1	45.5	37.7	52.3	62.4	48.0	37.2	33.7	42.1

Tabel 7.7 menunjukkan hasil prakiraan model regresi DMI yang diverifikasi menggunakan MAE rata-rata. Secara umum, model regresi DMI menghasilkan prakiraan dengan rata-rata MAE antara 30.4 – 62.4 mm. Model

regresi DMI terbaik yang menghasilkan prakiraan dengan MAE terkecil adalah DMI APR pada rentang 31.3 – 57.8 mm. Sedangkan model terburuk adalah regresi DMI SEP dengan MAE rata-rata pada rentang 33.7 – 62.4 mm.

Tabel 7.8 Hasil verifikasi luaran model regresi DMI berdasarkan MAE maksimum

Regresi DMI	ZOM												Rata- Rata
	20	30	31	33	34	35	36	37	38	39	40	41	
DMI_OKTtl	48.9	57.3	51.4	49.8	46.5	60.9	45.5	64.2	69.4	61.6	51.2	45.1	54.3
DMI_NOVtl	55.5	50.0	50.0	42.4	42.9	66.8	50.7	68.6	69.2	62.9	52.6	44.9	54.7
DMI_DEStl	49.9	45.9	43.2	40.7	39.6	61.6	41.1	62.5	70.9	51.6	47.6	44.7	49.9
DMI_JAN	51.2	49.6	42.9	38.5	40.2	60.8	43.6	65.2	76.9	51.4	47.3	45.1	51.1
DMI_FEB	55.7	47.1	44.5	41.6	42.7	59.1	46.3	67.0	82.3	60.2	50.4	50.9	54.0
DMI_MAR	54.7	46.9	43.6	40.8	41.7	57.6	45.2	65.4	79.0	55.3	51.2	48.6	52.5
DMI_APR	49.1	48.6	41.6	42.9	42.0	58.8	46.0	60.7	74.6	56.1	49.2	48.0	51.5
DMI_MEI	58.9	47.0	45.4	45.9	41.6	57.8	50.4	69.1	90.6	62.3	47.3	44.9	55.1
DMI_JUN	55.4	49.2	43.6	43.3	40.1	56.4	48.2	60.8	81.3	55.0	47.5	45.1	52.2
DMI_JUL	50.5	65.2	39.4	55.5	43.7	56.1	44.6	61.3	76.0	61.8	48.3	47.5	54.2
DMI_AGU	53.7	54.5	40.3	45.1	40.8	63.5	42.2	64.4	74.3	53.6	49.1	48.9	52.5
DMI_SEP	50.6	51.0	41.5	44.5	39.7	60.3	48.5	70.2	71.9	52.3	48.1	45.7	52.0


Tabel 7.8 merupakan hasil verifikasi menggunakan parameter MAE maksimum yang dihasilkan oleh masing-masing model regresi DMI di tiap ZOM. Secara umum, regresi DMI menghasilkan prakiraan dengan MAE maksimum pada rentang 38.5 – 90.6 mm. Model terbaik yang menghasilkan MAE maksimum

paling rendah adalah DMI DESTl pada rentang 39.6 – 70.9 mm. Sedangkan model terburuk adalah DMI MEI dengan MAE maksimum antara 41.6 – 90.6 mm.

Seperti halnya regresi ONI, model regresi DMI menunjukkan kemampuan kurang baik dalam memprakirakan curah hujan dasarian di ZOM 38, ditinjau dari keempat parameter verifikasi yang digunakan. Secara umum, model regresi DMI menghasilkan prakiraan cukup baik menggunakan DMI pada bulan Desember tahun lalu. Hal lain yang diketahui adalah penggunaan indeks yang terlalu dekat dengan periode yang diprakirakan justru menghasilkan prakiraan yang kurang bagus performanya.

7.5 Prakiraan Curah Hujan Luaran Model Regresi Komponen Utama ERSST

Regresi suhu muka laut (SST) dibentuk menggunakan analisis komponen utama karena jumlah grid SST yang sangat dan perlu disederhanakan untuk mengetahui pola-pola umum yang ada. Pada penelitian ini, jumlah komponen utama yang digunakan adalah 10, meski prosentase keterwakilan polanya hanya mencapai >50%. Hal ini diputuskan karena penambahan prosentase keterwakilan pola saat komponen utama yang digunakana ditambah tidak signifikan. Model regresi ERSST yang terbentuk sebanyak 120 model untuk setiap ZOM. Berikut adalah sampel hasil prakiraan curah hujan dasarian di ZOM 40 menggunakan regresi ERSST.



Gambar 7.3 Grafik *time series* hasil prakiraan curah hujan dasarian (garis merah) menggunakan model regresi komponen utama ERSST di ZOM 40

Gambar 7.3 adalah hasil prakiraan curah hujan dasarian model regresi komponen utama ERSST bulan Oktober menggunakan 10 komponen utama. Secara umum, jika prakiraan lebih mendekati kurva hitam, berarti model dengan komponen utama tersebut lebih baik dalam merepresentasikan variasi curah hujan. Pada grafik KU 1 hingga KU 3, hasil prakiraan belum menangkap pola variabilitas curah hujan dengan baik. Kurva prakiraan tampak lebih sederhana dan sering kali gagal mengikuti fluktuasi intensitas curah hujan pada observasi. Mulai dari KU 4, hasil prakiraan terlihat semakin mendekati pola observasi. Terutama pada KU 5, KU 6, dan KU 7, prakiraan dapat mengikuti fluktuasi tinggi-rendah yang lebih mendetail. Ini menunjukkan bahwa dengan memasukkan lebih banyak

komponen utama, model dapat lebih akurat dalam mencerminkan variasi yang lebih kompleks pada data observasi. Pada grafik dengan KU 8 hingga KU 10, prakiraan masih mengikuti pola observasi dengan baik, tetapi tampaknya tidak ada peningkatan yang signifikan dibandingkan dengan model menggunakan KU 5 hingga KU 7. Bahkan pada KU 10, terlihat adanya sedikit *overfitting*, di mana prakiraan mulai menangkap noise daripada pola yang sebenarnya.

Berdasarkan analisis visual grafik-grafik, model dengan 5 hingga 7 KU memberikan prakiraan yang paling baik. Model pada rentang ini dapat mengikuti fluktuasi curah hujan observasi secara akurat tanpa terlalu banyak *overfitting* yang terlihat pada model dengan lebih dari 8 komponen utama. Menggunakan lebih dari 7 komponen utama tidak memberikan keuntungan signifikan dan justru berpotensi menyebabkan *overfitting*, di mana model terlalu sensitif terhadap variasi minor yang mungkin tidak relevan untuk pola prediksi jangka panjang.

7.6 Verifikasi Luaran Prakiraan Curah Hujan dengan Model Regresi Komponen Utama ERSST

Verifikasi hasil prakiraan curah hujan regresi komponen utama ERSST di ZOM 20 ditampilkan pada Tabel 7.9. Secara umum, penambahan KU efektif meningkatkan kesesuaian hingga KU 6, setelah itu cenderung semakin tidak sesuai. Sementara itu, verifikasi berdasarkan *error* mutlak efektif hingga penambahan KU 4. Pada rentang penambah KU 4-6, model dapat mengikuti fluktuasi curah hujan di ZOM 20. Mengingat banyaknya model yang terbentuk dari regresi ini, gambaran secara umum hasil prakiraan dengan model regresi ERSST termuat pada bagian berikutnya.

Verifikasi hasil prakiraan curah hujan regresi komponen utama ERSST ditampilkan pada Tabel 7.9 sebagai berikut.

Tabel 7.9 Hasil verifikasi luaran model regresi komponen utama ERSST ZOM 20

MODEL	KS ave (%)	KS min (%)	MAE ave (mm)	MAE max (mm)	MODEL	KS ave (%)	KS min (%)	MAE ave (mm)	MAE max (mm)	MODEL	KS ave (%)	KS min (%)	MAE ave (mm)	MAE max (mm)	MODEL	KS ave (%)	KS min (%)	MAE ave (mm)	MAE max (mm)	MODEL	KS ave (%)	KS min (%)	MAE ave (mm)	MAE max (mm)
PC_1_OKT	56	39	27.5	58	PC_2_OKT	61	50	28.1	51.2	PC_3_OKT	56	42	30.5	57.8	PC_4_OKT	56	39	27.9	52.1	PC_5_OKT	59	50	27.7	48.6
PC_1_NOV	57	39	32.3	58	PC_2_NOV	59	47	26.4	52.5	PC_3_NOV	56	47	39	51.6	PC_4_NOV	60	44	28.1	52.8	PC_5_NOV	60	50	28.2	49.8
PC_1_DES	56	39	29.5	57	PC_2_DES	58	44	26.2	54.3	PC_3_DES	54	39	38	49.3	PC_4_DES	60	47	28.4	52.9	PC_5_DES	59	50	29.5	49.1
PC_1_JAN	56	42	30.2	57.9	PC_2_JAN	58	44	25.6	54.8	PC_3_JAN	54	33	36.3	48.3	PC_4_JAN	60	42	27.5	54.6	PC_5_JAN	60	50	30.2	48.2
PC_1_FEB	54	36	29.8	58.5	PC_2_FEB	60	47	24.8	53.4	PC_3_FEB	54	33	32.6	48.9	PC_4_FEB	60	47	26	55.5	PC_5_FEB	59	50	28.2	48.5
PC_1_MAR	55	36	29.1	63.8	PC_2_MAR	56	44	23.2	49.5	PC_3_MAR	51	22	32.8	49.2	PC_4_MAR	60	47	24.7	54.1	PC_5_MAR	59	47	28.1	48.8
PC_1_APR	56	33	28.6	74.4	PC_2_APR	60	44	23.2	52.1	PC_3_APR	52	28	33.4	49.2	PC_4_APR	59	50	22.5	50.3	PC_5_APR	61	53	36.5	48.5
PC_1_MEI	55	28	28.2	71.7	PC_2_MEI	58	50	25	49.2	PC_3_MEI	58	47	33.4	49.9	PC_4_MEI	60	47	22.4	48.7	PC_5_MEI	58	47	49.8	48.9
PC_1_JUN	54	39	26.6	65	PC_2_JUN	55	42	29.7	51.3	PC_3_JUN	60	47	34.8	50.1	PC_4_JUN	58	50	23.9	47.9	PC_5_JUN	56	44	59.3	48.6
PC_1_JUL	54	36	27.6	71.8	PC_2_JUL	58	39	32.3	48.6	PC_3_JUL	62	39	30.3	51.6	PC_4_JUL	57	50	23.1	48.3	PC_5_JUL	56	44	48.6	47.3
PC_1_AGU	54	39	27.8	66.3	PC_2_AGU	58	44	32.1	49.5	PC_3_AGU	62	42	30.6	53.2	PC_4_AGU	58	50	24.3	48.3	PC_5_AGU	56	42	46.7	47.1
PC_1_SEP	54	42	27.7	62.5	PC_2_SEP	60	44	34.6	48.5	PC_3_SEP	61	42	28	55.1	PC_4_SEP	60	50	23.4	49.4	PC_5_SEP	58	44	41.7	46.9
MODEL	KS ave (%)	KS min (%)	MAE ave (mm)	MAE max (mm)	MODEL	KS ave (%)	KS min (%)	MAE ave (mm)	MAE max (mm)	MODEL	KS ave (%)	KS min (%)	MAE ave (mm)	MAE max (mm)	MODEL	KS ave (%)	KS min (%)	MAE ave (mm)	MAE max (mm)	MODEL	KS ave (%)	KS min (%)	MAE ave (mm)	MAE max (mm)
PC_6_OKT	61	47	28.7	53.1	PC_7_OKT	53	39	31.6	49.9	PC_8_OKT	57	47	27.6	53.1	PC_9_OKT	55	44	28.2	57.9	PC_10_OKT	62	47	36.5	49.4
PC_6_NOV	59	42	28.8	51.4	PC_7_NOV	57	44	27.9	49.3	PC_8_NOV	56	44	27.8	48	PC_9_NOV	56	50	30.4	51.9	PC_10_NOV	58	47	28.7	49.2
PC_6_DES	56	47	29.2	52.3	PC_7_DES	59	44	28.6	48.6	PC_8_DES	58	50	26.8	48.9	PC_9_DES	59	53	29.1	53.2	PC_10_DES	58	44	25.8	49.8
PC_6_JAN	56	39	30.4	58.7	PC_7_JAN	60	47	30.5	48.2	PC_8_JAN	54	50	28.5	49	PC_9_JAN	56	47	28	49.2	PC_10_JAN	56	44	26.4	48.2
PC_6_FEB	54	42	29.2	56	PC_7_FEB	62	44	31.8	49	PC_8_FEB	53	42	33.8	49	PC_9_FEB	56	44	27.4	48.2	PC_10_FEB	53	36	27.6	48.6
PC_6_MAR	53	36	29.2	55.2	PC_7_MAR	62	50	30	49.1	PC_8_MAR	53	36	38	49.4	PC_9_MAR	56	44	28.3	48.3	PC_10_MAR	54	33	27.1	48.2
PC_6_APR	51	33	27	53.4	PC_7_APR	60	44	30.4	48.6	PC_8_APR	50	36	34.7	50.2	PC_9_APR	56	31	27.6	49.4	PC_10_APR	55	22	28.1	48.9
PC_6_MEI	50	39	26.4	51	PC_7_MEI	57	33	29	48.4	PC_8_MEI	53	36	31.6	49.7	PC_9_MEI	54	39	27.8	54.1	PC_10_MEI	56	17	28.1	49.8
PC_6_JUN	51	39	26.6	52.8	PC_7_JUN	57	28	27.7	49	PC_8_JUN	58	39	32.3	48.6	PC_9_JUN	60	50	29.4	53.6	PC_10_JUN	55	39	27.5	54.2
PC_6_JUL	51	42	28.2	50	PC_7_JUL	56	36	27.7	50.7	PC_8_JUL	58	42	29.1	48.1	PC_9_JUL	55	39	27.7	57.2	PC_10_JUL	58	44	27.3	56.7
PC_6_AGU	54	44	28.8	55.8	PC_7_AGU	57	31	26.5	48.5	PC_8_AGU	57	44	26.2	49.2	PC_9_AGU	56	39	27.7	60.3	PC_10_AGU	60	44	28.1	53.5
PC_6_SEP	56	42	29	55.6	PC_7_SEP	57	39	29.8	48.1	PC_8_SEP	57	44	25.8	51.5	PC_9_SEP	54	42	30.7	57	PC_10_SEP	58	44	27.4	52.5

BAB VIII

MODEL ENSEMBLE

8.1 Prakiraan Curah Hujan Luaran Model Ensemble

Pendekatan ensemble digunakan pada penelitian ini untuk memberikan opsi model prakiraan yang lebih akurat dan stabil dibandingkan dengan penggunaan model tunggal. Masing-masing model diberi bobot berbeda yang mencerminkan kontribusi atau tingkat kepercayaannya dalam menghasilkan prakiraan yang andal. Bobot yang lebih tinggi menunjukkan model tersebut memiliki keakuratan atau performa yang lebih baik pada periode atau wilayah tertentu. Dengan memahami struktur dan nilai bobot dari model-model ini, kita dapat mengidentifikasi pola, mengevaluasi efektivitas ensemble, dan memberikan rekomendasi untuk pengembangan ensemble di masa depan. Bobot, pada penelitian ini, dihitung berdasarkan MAE dan kesesuaian tiap model.

Dalam penelitian ini, bobot terus mengalami pembaruan ketika periode dan lokasi yang prakiraan berganti. Periode prakiraan berganti setiap 36 dasarian, dimulai dari dasarian I Desember dan diakhir dasarian III November. Maka, bobot tiap model untuk memprakirakan curah hujan 36 dasarian ke depan adalah tidak mengalami perubahan selama 1 periode. Tabel 8.1 adalah besarnya bobot tiap model untuk membentuk prakiraan curah hujan dasarian periode 2015/2016 di ZOM 141 menggunakan 150 anggota ensemble. Bobot seperti pada Tabel 8.1 dihitung berdasarkan kesesuaian. Bobot ini digunakan untuk memprakirakan curah hujan dasarian I Desember 2015 hingga dasarian III November 2016. Bobot tersebut dikalikan dengan curah hujan luaran masing-masing model.

Tabel 8.1 Bobot model ke-1 hingga ke-150 untuk memprakirakan curah hujan periode 2015/2016 di ZOM 141 menggunakan ensemble kesesuaian-based n=150


MODEL KE-	BOBOT	MODEL KE-	BOBOT	MODEL KE-	BOBOT	MODEL KE-	BOBOT	MODEL KE-	BOBOT	MODEL KE-	BOBOT
1	0.0063354	26	0.0063013	51	0.0072039	76	0.0063865	101	0.0064375	126	0.0062843
2	0.0051262	27	0.0064035	52	0.0074934	77	0.0064205	102	0.0063354	127	0.0064886
3	0.0052795	28	0.0068974	53	0.0072891	78	0.0063694	103	0.0081236	128	0.0070166
4	0.0057563	29	0.0068122	54	0.0076978	79	0.0065568	104	0.0064375	129	0.0066079
5	0.005569	30	0.0062332	55	0.0068803	80	0.0067782	105	0.0062162	130	0.0063865
6	0.0059437	31	0.0063354	56	0.008379	81	0.0066079	106	0.0064546	131	0.0062672
7	0.0063865	32	0.0067611	57	0.0082428	82	0.0066249	107	0.0064546	132	0.0063524
8	0.0063524	33	0.0064886	58	0.008345	83	0.0064375	108	0.0063183	133	0.0063865
9	0.0063524	34	0.00671	59	0.0074594	84	0.0064035	109	0.0064035	134	0.0063694
10	0.0063865	35	0.006676	60	0.0071528	85	0.0068122	110	0.0063694	135	0.0067782
11	0.0064205	36	0.0065227	61	0.0072039	86	0.0083109	111	0.0063524	136	0.0063183
12	0.0064716	37	0.0063354	62	0.0070166	87	0.0098607	112	0.0063524	137	0.0063354
13	0.0063524	38	0.0063013	63	0.0071188	88	0.008941	113	0.0062502	138	0.0068293
14	0.0062843	39	0.006131	64	0.0069485	89	0.0092306	114	0.0065397	139	0.007255
15	0.0068633	40	0.0063013	65	0.0073913	90	0.0085153	115	0.0077148	140	0.0064546
16	0.0071699	41	0.0062672	66	0.0072039	91	0.0071699	116	0.0063354	141	0.006148
17	0.0065397	42	0.0063183	67	0.0064205	92	0.0065057	117	0.0064375	142	0.006131
18	0.0065568	43	0.0063865	68	0.0063524	93	0.0064375	118	0.006693	143	0.0062332
19	0.0062332	44	0.0062843	69	0.0063524	94	0.0064716	119	0.0075275	144	0.0063354
20	0.0065057	45	0.0062672	70	0.0062672	95	0.0067611	120	0.0077319	145	0.0064375
21	0.006693	46	0.0062162	71	0.0063694	96	0.0068122	121	0.0074764	146	0.0066589
22	0.0074083	47	0.0061991	72	0.0063354	97	0.0066249	122	0.0068122	147	0.0063013
23	0.0063354	48	0.0062332	73	0.0062843	98	0.0063694	123	0.0067952	148	0.0061651
24	0.0067271	49	0.0063524	74	0.0061991	99	0.0064546	124	0.0064716	149	0.0065568
25	0.0063694	50	0.0066589	75	0.0062672	100	0.0063865	125	0.0062672	150	0.0066589

Selain kesesuaian, bobot juga dihitung berdasarkan MAE membentuk ensemble yang berbeda. Tabel 8.2 adalah bobot berdasarkan MAE untuk memprakirakan curah hujan periode 2015/2016 di ZOM 141 menggunakan 10 anggota ensemble. Pemilihan 10 anggota memperhatikan bobot yang tertinggi diantara semuanya. Selain 10 model terbaik memiliki bobot 0. Pada Tabel 8.2 dapat diketahui bahwa 10 model terbaik dengan bobot tertinggi adalah model ke-1, 2, 70, 71, 72, 73, 74, 75, 76, dan 77.

Tabel 8.2 Bobot model ke-1 hingga ke-150 untuk memprakirakan curah hujan dasarian 1 Desember 2014/2015 di ZOM 141 menggunakan ensemble kesesuaian-based n=10

MODEL KE-	BOBOT	MODEL KE-	BOBOT	MODEL KE-	BOBOT	MODEL KE-	BOBOT	MODEL KE-	BOBOT	MODEL KE-	BOBOT
1	0.0952544	26	0	51	0	76	0.0994568	101	0	126	0
2	0.0999467	27	0	52	0	77	0.0934986	102	0	127	0
3	0	28	0	53	0	78	0	103	0	128	0
4	0	29	0	54	0	79	0	104	0	129	0
5	0	30	0	55	0	80	0	105	0	130	0
6	0	31	0	56	0	81	0	106	0	131	0
7	0	32	0	57	0	82	0	107	0	132	0
8	0	33	0	58	0	83	0	108	0	133	0
9	0	34	0	59	0	84	0	109	0	134	0
10	0	35	0	60	0	85	0	110	0	135	0
11	0	36	0	61	0	86	0	111	0	136	0
12	0	37	0	62	0	87	0	112	0	137	0
13	0	38	0	63	0	88	0	113	0	138	0
14	0	39	0	64	0	89	0	114	0	139	0
15	0	40	0	65	0	90	0	115	0	140	0
16	0	41	0	66	0	91	0	116	0	141	0
17	0	42	0	67	0	92	0	117	0	142	0
18	0	43	0	68	0	93	0	118	0	143	0
19	0	44	0	69	0	94	0	119	0	144	0
20	0	45	0	70	0.0943683	95	0	120	0	145	0
21	0	46	0	71	0.0989717	96	0	121	0	146	0
22	0	47	0	72	0.1029908	97	0	122	0	147	0
23	0	48	0	73	0.1096713	98	0	123	0	148	0
24	0	49	0	74	0.1073502	99	0	124	0	149	0
25	0	50	0	75	0.0984912	100	0	125	0	150	0


Pada penelitian ini, ensemble dibangun menggunakan hasil verifikasi masing-masing model dasar, yaitu MAE dan kesesuaian. Sehingga, terdapat dua jenis ensemble yang dihasilkan. Besarnya nilai MAE dan kesesuaian menjadi dasar besarnya kontribusi masing-masing model yang diwujudkan dalam bentuk bobot model. Gambar 8.1 adalah hasil prakiraan curah hujan periode 2015/2016 menggunakan 2 model sampel yang disampaikan sebelumnya. Gambar 8.1 menunjukkan adanya perbedaan hasil prakiraan sehingga perlu adanya verifikasi untuk menentukan mana yang lebih baik diantara semua model.



Gambar 8.1 Prakiraan curah hujan 2015/2016 di ZOM 141 menggunakan beberapa model


8.2 Verifikasi Prakiraan Curah Hujan Luaran Model Ensemble

Pendekatan multi-model yang memberikan banyak luaran model dan hasil verifikasi ditangani dengan mengajukan suatu format standar penyajian sebagaimana gambar 8.2. Garis hijau dan hitam akan mewakili penambahan jumlah anggota ensemble, sedangkan garis merah menunjukkan verifikasi luaran non-ensemble. Karena model dianggap lebih baik jika indeks kesesuaian tinggi namun MAE rendah, sumbu Y yang dibalik digunakan untuk memploting MAE sehingga pembacaan seragam dan lebih mudah, yaitu semakin mendekati bagian atas semakin baik verifikasi modelnya.



Gambar 8.2 Grafik visualisasi luaran model dan hasil verifikasi

Adapun perbandingan divisualisasikan dalam bentuk gambar kumpulan grafik seperti Gambar 8.2. Dengan mengamati garis dalam grafik, performa ensemble dapat langsung dinilai apakah lebih baik atau tidak dibandingkan dengan model dasar. Ensemble dikatakan berhasil meningkatkan kualitas prakiraan ketika terdapat salah satu dari empat parameter verifikasi yang lebih unggul dari seluruh model dasar. Skema grafik yang akan digunakan adalah seperti pada Gambar 8.3.




Gambar 8.3 Grafik perbandingan hasil verifikasi prakiraan ensemble MAE-based (garis hijau) dan ensemble Kesesuaian-based (garis hitam) terhadap model tunggal (urut dari kiri ke kanan: skenario dasar RTOW, ARIMA, ECMWF, regresi ONI-DMI, dan regresi ERSST)

Pada Gambar 8.3, terdapat lima grafik yang masing-masing menggambarkan hasil verifikasi prakiraan curah hujan berdasarkan model tunggal dan ensemble yang digunakan dalam penelitian ini. Ensemble disusun berdasarkan parameter MAE dan kesesuaian. Garis hitam dan hijau adalah kesesuaian hasil prakiraan dari model ensemble MAE-based (hijau) dan kesesuaian-based (hitam). Garis merah adalah kesesuaian hasil prakiraan tiap model dasar. Pada gambar tersebut, terdapat 4 baris grafik. Baris pertama, paling atas, adalah grafik perbandingan kesesuaian rata-rata tiap model. Baris kedua adalah grafik perbandingan kesesuaian minimum tiap model. Baris ketiga adalah perbandingan MAE rata-rata tiap model. Baris keempat adalah perbandingan MAE maksimum tiap model. Di setiap grafik terdapat garis hitam dan hijau. Garis tersebut adalah performa dari model ensemble MAE-based (garis hijau) dan kesesuaian-based (garis hitam). Sedangkan garis merah adalah performa model dasar.

Berdasarkan Gambar 8.4, diketahui bahwa ensemble *MAE-based* mempunyai performa lebih baik dibanding kesesuaian-based. Lebih lanjut, pembahasan hasil ensemble di ZOM 20 akan fokus pada ensemble MAE-based. Rata-rata kesesuaian ensemble MAE-based berhasil mengungguli seluruh model tunggal. Kesesuaian minimum ensemble MAE-based juga lebih tinggi dibanding ARIMA dan regresi ONI-DMI, dan sama dengan kesesuaian minimum model skenario dasar RTOW, ECMWF, dan ERSST. Ditinjau dari MAE rata-rata, ensemble MAE-based lebih baik dibanding model regresi ERSST dan ONI-DMI, namun tidak lebih baik dari 3 model lainnya. Menurut MAE maksimum yang dicapai, ensemble MAE-based tidak lebih baik dibanding model regresi ONI-DMI


dan ERSST. Secara umum dapat dikatakan bahwa adanya ensemble berdasarkan MAE dapat meningkatkan kualitas hasil prakiraan curah hujan dasarian di ZOM 20.



Gambar 8.4 Grafik perbandingan hasil verifikasi prakiraan ensemble MAE-based (garis hijau) dan ensemble Kesesuaian-based (garis hitam) terhadap model tunggal (urut dari kiri ke kanan: skenario dasar RTOW, ARIMA, ECMWF, regresi ONI-DMI, dan regresi ERSST) di ZOM 20

Penggunaan empat kriteria juga dapat dijustifikasi dengan melihat Gambar 8.5 yang menunjukkan bahwa pendekatan menggunakan indeks kesesuaian minimum dapat memberikan gambaran model yang memiliki rentang kegagalan prediksi yang lebih rendah di setiap tahunnya. Gambar 8.5 merupakan plot kesesuaian setiap tahun dari ZOM 41. Garis biru mewakili nilai dari indeks kesesuaian setiap tahun. Dapat terlihat bahwa pendekatan ini mampu

menghadirkan kondisi di mana nilai indeks kesesuaian tidak akan menyentuh nilai di bawah 60%. Di sisi lain, pendekatan menggunakan MAE maksimum menunjukkan bahwa pendekatan ini (digambarkan dari garis orange) dapat menghasilkan prakiraan yang secara konsisten dapat memiliki MAE yang tidak menyentuh batas 40 mm. Hal ini menjadi penting karena pada dasarnya sekalipun model memiliki rata-rata indeks kesesuaian atau rata-rata MAE yang bagus, ketika mengalami down performance pada waktu-waktu tertentu, hal tersebut dapat menjadi catatan khusus. Pada kasus ZOM=41, down performance terjadi pada tahun 2022 dapat sedikit dijelaskan karena fenomena triple dip La Nina. Ternyata metode Regresi ERSST yang mengandalkan telekoneksi atmosfer-lautan dan Ensemble mampu menghasilkan prakiraan yang lebih reliable dari ECMWF.



Gambar 8.5 Hasil verifikasi berbasis kesesuaian (atas) dan MAE (bawah) hasil prakiraan ensembl di ZOM=41

Analisis serupa dilakukan kepada 11 ZOM lain pengisi Bendungan Sutami-Lahor, yaitu ZOM 30, 31, 33, 34, 35, 36, 37, 38, 39, 40, dan 41. Untuk ZOM 30, ensemble tidak lebih baik dari model dasar yang ada, dimana tidak ada 1 pun hasil verifikasi di empat parameter yang menunjukkan ensemble konsisten paling baik. Demikian halnya di ZOM 31, ensemble belum menjadi opsi model paling baik dibanding model yang sudah ada. Namun dari segi hasil verifikasi, dapat dilihat adanya peningkatan kualitas prakiraan. Kondisi serupa dengan ZOM 20, 30, dan 31 terjadi pula di ZOM 34, 35, 37, 38, 39, dan 40. Ensemble berhasil meningkatkan kualitas hasil prakiraan di ZOM 33, khususnya saat ditinjau dari MAE maksimum yang dihasilkan. Ensemble terbukti mampu memperkecil kesalahan prakiraan yang dihasilkan. Demikian halnya kondisi di ZOM 41, ensemble berhasil meningkatkan rata-rata kesesuaian prakiraan yang dihasilkan.

BAB IX

EVALUASI MODEL

9.1 Rekomendasi Model Terbaik Tiap Zona Musim (ZOM)

Terdapat setidaknya 450 model prakiraan yang tersedia di setiap ZOM. Secara otomatis, sistem akan membuat rekomendasi model terbaik yang dapat diberikan ke prakirawan. Rekomendasi ini disusun dengan mempertimbangkan model dengan kesesuaian tertinggi dan MAE terendah. Berikut adalah cara penentuan model yang direkomendasikan.

```
ZOM=1
AFU="C:\\TEMP\\20241023_TRTOW_SUSUN_ULANG\\"
OBS=read.csv(paste(AFU,"CURAH_HUJAN.csv",sep=""))
while(ZOM<=74){
  DATA=read.csv(paste(AFU,"24_RANGKUM\\ZOM",100+ZOM,".csv",sep=""))
  KESESUAIAN_RATA2=DATA[, "KSAVG_2016_2023"]
  MAKS=as.numeric(unique((KESESUAIAN_RATA2==max(KESESUAIAN_RATA2))*1:length(KESESUAIAN_RATA2)))
  ID1=sort(MAKS,decreasing=T)
  KESESUAIAN_MINIMUM=DATA[, "KSMIN_2016_2023"]
  MAKS=as.numeric(unique((KESESUAIAN_MINIMUM==max(KESESUAIAN_MINIMUM))*1:length(KESESUAIAN_MINIMUM)))
  ID2=sort(MAKS,decreasing=T)
  MAE_RATA2=DATA[, "MAEAVG_2016_2023"]
  MIN=as.numeric(unique((MAE_RATA2==min(MAE_RATA2))*1:length(MAE_RATA2)))
  ID3=sort(MIN,decreasing=T)
  MAE_MAKSIMUM=DATA[, "MAEMAX_2016_2023"]
  MIN=as.numeric(unique((MAE_MAKSIMUM==min(MAE_MAKSIMUM))*1:length(MAE_MAKSIMUM)))
  ID4=sort(MIN,decreasing=T)
  IDALL=unique(c(ID1,ID2,ID3,ID4))
  IDALL=IDALL[IDALL>0]
  IDALL=sort(IDALL,decreasing=T)
  TABEL=DATA[IDALL,c(12:13,23:24,4:11,15:22)]
  rownames(TABEL)=as.character(DATA[IDALL,2])
  write.csv(TABEL,paste(AFU,"27_TABEL_4_KRITERIA\\ZOM",100+ZOM,".csv",sep=""))
  ZOM=ZOM+1
}
ZOM=1
AFU="C:\\TEMP\\20241023_TRTOW_SUSUN_ULANG\\"
RKP=c()
while(ZOM<=74){
  DATA=read.csv(paste(AFU,"27_TABEL_4_KRITERIA\\ZOM",ZOM+100,".csv",sep=""))
  RKP=cbind(RKP,c(DATA[,1],rep(NA,452-nrow(DATA))))
  ZOM=ZOM+1
}
write.csv(RKP,paste(AFU,"27_TABEL_4_KRITERIA\\ALL.csv",sep=""))
```

Gambar 9.1 Penentuan rekomendasi model

Sebuah kelaziman di operasional klimatologi bahwa penentuan akhir sebuah pemodelan iklim diserahkan ke prakirawan karena informasi iklim terkadang memiliki implikasi sosial-ekonomi sehingga pertanyaan seperti dari 4 kriteria yang digunakan mana yang lebih penting menjadi kurang relevan. Kepentingan dari proses otomatisasi ini adalah mencari model paling sesuai tiap ZOM bukan untuk menjalankan satu model yang dianggap dapat mewakili mayoritas dengan mengorbankan kepentingan ZOM tertentu. Tabel 9.1 berikut memuat rekomendasi model terbaik untuk masing-masing ZOM dimana urutan penulisan tidak menunjukkan prioritas model terbaik. Jumlah model rekomendasi bisa berbeda-beda karena memperhatikan hasil verifikasi di masing-masing ZOM. Hal ini dapat dipengaruhi oleh karakteristik iklim di ZOM bersangkutan.

Tabel 9.1 Rekomendasi model terbaik tiap ZOM

ZOM 20				ZOM 30			
NO.	MODEL	NO.	MODEL	NO.	MODEL	NO.	MODEL
1	Ens_MAE_n=115	18	Ens_MAE_n=31	1	Ens_Kes_n=118	18	Ens_Kes_n=92
2	Ens_MAE_n=114	19	Ens_MAE_n=30	2	Ens_Kes_n=117	19	Ens_Kes_n=91
3	Ens_MAE_n=113	20	Ens_MAE_n=29	3	Ens_Kes_n=107	20	Ens_Kes_n=90
4	Ens_MAE_n=112	21	Ens_MAE_n=28	4	Ens_Kes_n=106	21	Ens_Kes_n=89
5	Ens_MAE_n=111	22	Ens_MAE_n=27	5	Ens_Kes_n=105	22	Ens_Kes_n=88
6	Ens_MAE_n=110	23	Ens_MAE_n=26	6	Ens_Kes_n=104	23	Ens_Kes_n=87
7	Ens_MAE_n=109	24	Ens_MAE_n=8	7	Ens_Kes_n=103	24	Ens_Kes_n=86
8	Ens_MAE_n=108	25	Ens_MAE_n=4	8	Ens_Kes_n=102	25	Ens_Kes_n=85
9	Ens_MAE_n=107	26	Ens_MAE_n=3	9	Ens_Kes_n=101	26	PC_7_FEB
10	Ens_MAE_n=106	27	PC_9_DES	10	Ens_Kes_n=100	27	DMI_JUL
11	Ens_MAE_n=105	28	PC_5_APR	11	Ens_Kes_n=99	28	EcARIMA
12	Ens_MAE_n=37	29	PC_4_JUN	12	Ens_Kes_n=98	29	Basah
13	Ens_MAE_n=36	30	ARIMA	13	Ens_Kes_n=97		
14	Ens_MAE_n=35	31	ErARIMA	14	Ens_Kes_n=96		
15	Ens_MAE_n=34	32	EcARIMA	15	Ens_Kes_n=95		
16	Ens_MAE_n=33	33	Basah	16	Ens_Kes_n=94		
17	Ens_MAE_n=32			17	Ens_Kes_n=93		

Tabel 9.1 lanjutan

ZOM 31		ZOM 33		ZOM 34		ZOM 35	
NO.	MODEL	NO.	MODEL	NO.	MODEL	NO.	MODEL
1	Ens_MAE_n=31	1	Ens_MAE_n=10	1	PC_9_JAN	1	Ens_MAE_n=9
2	Ens_MAE_n=19	2	Ens_MAE_n=4	2	PC_8_NOV	2	Ens_MAE_n=7
3	Ens_MAE_n=18	3	Ens_Kes_n=41	3	PC_5_SEP	3	PC_9_NOV
4	Ens_MAE_n=16	4	Ens_Kes_n=40	4	PC_5_OKT	4	PC_4_AGU
5	Ens_MAE_n=15	5	PC_8_JUL	5	EcARIMA	5	PC_3_MEI
6	Ens_MAE_n=14	6	EcARIMA			6	DMI_AUG
7	Ens_MAE_n=13	7	Normal			7	Basah
8	PC_3_AGU						
9	EcARIMA						
10	Basah						
ZOM 39						ZOM 40	
NO.	MODEL	NO.	MODEL	NO.	MODEL	NO.	MODEL
1	Ens_MAE_n=127	22	Ens_MAE_n=106	43	Ens_MAE_n=85	1	Ens_MAE_n=11
2	Ens_MAE_n=126	23	Ens_MAE_n=105	44	Ens_MAE_n=84	2	Ens_MAE_n=9
3	Ens_MAE_n=125	24	Ens_MAE_n=104	45	Ens_MAE_n=83	3	Ens_MAE_n=8
4	Ens_MAE_n=124	25	Ens_MAE_n=103	46	Ens_MAE_n=82	4	PC_8_JUN
5	Ens_MAE_n=123	26	Ens_MAE_n=102	47	Ens_MAE_n=81	5	PC_6_NOV
6	Ens_MAE_n=122	27	Ens_MAE_n=101	48	Ens_MAE_n=80	6	PC_4_SEP
7	Ens_MAE_n=121	28	Ens_MAE_n=100	49	Ens_MAE_n=77	7	PC_4_JUL
8	Ens_MAE_n=120	29	Ens_MAE_n=99	50	Ens_MAE_n=76	8	ARIMA
9	Ens_MAE_n=119	30	Ens_MAE_n=98	51	Ens_MAE_n=70	9	EcARIMA
10	Ens_MAE_n=118	31	Ens_MAE_n=97	52	Ens_MAE_n=68		
11	Ens_MAE_n=117	32	Ens_MAE_n=96	53	Ens_MAE_n=67		
12	Ens_MAE_n=116	33	Ens_MAE_n=95	54	Ens_MAE_n=9		
13	Ens_MAE_n=115	34	Ens_MAE_n=94	55	Ens_MAE_n=8		
14	Ens_MAE_n=114	35	Ens_MAE_n=93	56	Ens_MAE_n=7		
15	Ens_MAE_n=113	36	Ens_MAE_n=92	57	PC_8_JUN		
16	Ens_MAE_n=112	37	Ens_MAE_n=91	58	PC_6_DES		
17	Ens_MAE_n=111	38	Ens_MAE_n=90	59	ONI_SON		
18	Ens_MAE_n=110	39	Ens_MAE_n=89	60	ARIMA		
19	Ens_MAE_n=109	40	Ens_MAE_n=88	61	EcARIMA		
20	Ens_MAE_n=108	41	Ens_MAE_n=87	62	Basah		
21	Ens_MAE_n=107	42	Ens_MAE_n=86				

Tabel 9.1 lanjutan

ZOM 36		ZOM 37		ZOM 38		ZOM 41	
NO.	MODEL	NO.	MODEL	NO.	MODEL	NO.	MODEL
1	Ens_Kes_n=4	1	PC_8_JUL	1	PC_8_JUL	1	Ens_MAE_n=2
2	DMI_AUG	2	PC_8_JUN	2	PC_8_JUN	2	PC_10_DES
3	EcARIMA	3	EcARIMA	3	EcARIMA	3	PC_9_OKT
						4	Normal

Keputusan rekomendasi dibuat dengan mempertimbangkan hasil verifikasi tiap model di tiap ZOM. Model yang direkomendasikan artinya memiliki nilai verifikasi tertinggi diantara semua model, setidaknya pada 1 dari 4 parameter verifikasi yang digunakan. Dari beberapa rekomendasi yang ada, keputusan pemilihan model dapat diserahkan kepada prakirawan yang akan menggunakan karena biasanya masih terdapat faktor dinamis yang dipertimbangkan. Dengan adanya pilihan metode ini, diharapkan hasil prakiraan dapat lebih baik dan menghasilkan masukan yang lebih baik dalam kegiatan operasional BMKG, khususnya dalam mendukung perencanaan operasional waduk. Sebagaimana Hadits Riwayat Bukhari, Shahîh al-Bukhâriy, juz III, hal. 168, hadits no. 2442 dan Muslim, Shahîh Muslim, juz VIII, hal. 18, hadits no. 6743 dari Abdullah bin Umar r.a.

وَمَنْ كَانَ فِي حَاجَةٍ أَخِيهِ كَانَ اللَّهُ فِي حَاجَتِهِ ...

Artinya: ... dan barangsiapa (yang bersedia) membantu keperluan saudaranya, maka Allah (akan senantiasa) membantu keperluannya.

9.2 Studi Kasus

Tabel 9.2 menunjukkan bahwa pendekatan prakiraan berbasis persentil ternyata bukanlah pendekatan yang optimal, meski pendekatan ini menjadi terbaik

berdasarkan 4 kriteria di 7 ZOM atau 58% tapi metode persentil tidak optimal digunakan di 3 ZOM dengan proporsi penyusun daerah pengisi waduk paling tinggi (34, 36, dan 40). Tiga metode yang justru dapat dianggap paling optimal dalam memprakirakan curah hujan 36 dasarian ke depan adalah Reg-ERSST (11 ZOM), ECMWF (10 ZOM) dan Ensemble (9 ZOM). Terkait dengan 3 ZOM berproporsi tertinggi, metode ECMWF menjadi pendekatan yang paling dapat digunakan, disusul Ensemble dan Reg-ERSST.

Tabel 9.2 Rangkuman Verifikasi Prakiraan di Tiap ZOM

ZOM	Skenario Dasar RTOW	ARIMA	ECMWF	Reg. ONI-DMI	Reg. ERSST	ENS
20	1	1	1	0	1	1
30	1	0	1	1	1	1
31	1	0	1	0	1	1
33	1	0	1	0	1	1
34	0	0	1	0	1	0
35	1	0	0	1	1	1
36	0	0	1	1	0	1
37	0	0	1	0	1	0
38	0	0	1	0	1	0
39	1	1	1	1	1	1
40	0	1	1	0	1	1
41	1	0	0	0	1	1
TOTAL	7	3	10	4	11	9
%	58%	25%	83%	33%	92%	75%

Tabel 9.2 juga menunjukkan bahwa informasi analisis atau informasi yang ada pada saat penyusunan (bukan prediksinya) dari ONI dan DMI tidak terlalu penting dalam prediksi curah hujan 36 dasarian ke depan. Justru pola telekoneksi


SST yang perlu dikaji lebih lanjut terkait prediksi jangka panjang ini. Pertanyaan selanjutnya adalah model ECMWF apa yang lebih optimal digunakan. Berdasarkan evaluasi 4 kriteria, pendekatan EMCWF corrected hanya tidak optimal di ZOM=35 sebaliknya ECMWF raw hanya optimal di ZOM=20. Hal ini semakin membuktikan pentingnya koreksi model sesuai dengan studi-studi terdahulu.

Untuk mendemonstrasikan bagaimana curah hujan 36 dasarian hasil optimalisasi mampu memberikan penambahan nilai ke rencana operasional waduk, studi kasus waduk Sutami-Lahor dilakukan. Bendung Sutami-Lahor merupakan bendungan yang dapat diasumsikan tidak mendapat aliran dari bendung lainnya sehingga curah hujan dasarian berpengaruh terhadap debit inflow bendungan. Data yang digunakan dalam studi kasus adalah data Rencana Operasional Waduk Tahunan (RTOW) dan evaluasinya yang ada dalam Rencana Alokasi Air Tahunan (RAAT) 2022/2023. Simulasi penyusunan RTOW 2022/2023 kemudian dilakukan dengan menghitung median kemungkinan acak pemilihan model yang dianggap baik berdasarkan 4 kriteria (indeks kesesuaian rata-rata, indeks kesesuaian minimum, MAE rata-rata, dan MAE maksimum) yang diulang perhitungannya sampai dengan batas tahun 2021 saja untuk mendekati prinsip simulasi operasional. Tujuan dari demonstrasi ini adalah memotivasi pihak terkait agar meningkatkan upaya kolaborasi data guna mendukung perencanaan yang lebih matang dan relevan terhadap kebutuhan. Perencanaan yang matang dan relevan sangat dibutuhkan agar dampak negatif dari fluktuasi ketersediaan air dapat diantisipasi sehingga tidak menimbulkan kerusakan, sebagaimana firman Allah SWT dalam Surat Al-A'raf ayat 56.

وَلَا تُفْسِدُوا فِي الْأَرْضِ بَعْدَ إِصْلَاحِهَا وَادْعُوهُ خَوْفًا وَطَمَعًا إِنَّ رَحْمَتَ اللَّهِ
قَرِيبٌ مِّنَ الْمُحْسِنِينَ ﴿٥٦﴾

Artinya: Janganlah kamu berbuat kerusakan di bumi setelah diatur dengan baik. Berdoalah kepada-Nya dengan rasa takut dan penuh harap. Sesungguhnya rahmat Allah sangat dekat dengan orang-orang yang berbuat baik. (QS. Ql-A'raf: 56).


Hasil curah hujan tiap ZOM kemudian dikalikan tiap bobot dan diakumulasikan menjadi prakiraan curah hujan 2022/2023 sepanjang 36 dasarian. Perkalian bobot dan nilai curah hujan tiap ZOM juga dilakukan ke data observasi sehingga dapat dilakukan perbandingan seperti pada Gambar 9.2. Dapat terlihat bahwa nilai prakiraan dan observasi memiliki pola yang identik. Terlihat perbedaan yang cenderung melebar dan konstan pada dasarian 21 sampai dengan 33. Namun, pertanyaan yang selanjutnya perlu dijawab adalah apakah prakiraan ini lebih baik dibandingkan dengan *existingplan* yang sudah dilaksanakan.



Gambar 9.2 Perbandingan prakiraan (garis orange) dan observasi (garis biru) curah hujan di Bendungan Sutami-Lahor

Dalam RTOW, nilai yang diperlukan bukanlah curah hujan tetapi debit masukan (Q inflow dalam satuan m^3/detik), dalam studi ini digunakan rumus empiris regresi untuk merubah curah hujan dasarian dalam milimeter per dasarian menjadi debit *inflow* dalam meter kubik per detik. Karena dalam RTOW


digunakan pemisahan periode hujan (Desember-Mei) dan periode kemarau (Juni-November), maka dibagi pula pembentukan rumus empirisnya. Karena keterbatasan informasi, data yang dipakai adalah curah hujan dasarian dan debit pada RAAT 2022/2023. Regresi empiris yang digunakan dalam studi ini dapat terlihat pada Gambar 9.3. Dapat terlihat bahwa hubungan antara curah hujan dasarian dengan *inflow* pada wet periode berbeda dengan dry period. Dua konstanta regresi linier menunjukkan bahwa dalam kondisi basah, tanpa hujan debit akan mengalir sekitar 116 m^3 per detik, jauh dibandingkan dengan periode kering yang berada di kisaran 57 m^3 per detik. Penelitian ini juga sekaligus mendorong penelitian lebih lanjut terkait hubungan curah hujan dengan debit dengan data yang lebih panjang, dengan metode interpolasi yang lebih komprehensif.



Gambar 9.3 Hubungan antara curah hujan dasarian dengan debit masuk (*inflow*) pada periode musim hujan (kiri) dan kemarau (kanan) di Bendungan Sutami-Lahor

Curah hujan prakiraan yang telah diubah menjadi debit kemudian dibandingkan dengan *existing plan*. Dapat terlihat pada Gambar 9.4 bahwa RTOW tahun 2022/2023 akan memiliki selisih absolut yang lebih kecil jika prakiraan curah hujan 36 dasarian berbasis multi-model yang telah diverifikasi secara otomatis digunakan. Dari 36 dasarian yang direncanakan debitnya, hasil dari multi-model hanya lebih buruk pada 8 dari 36 dasarian masa perencanaan, yaitu

dasarian ke-15 dan 27-33 atau ujung waktu prakiraan. Perhitungan debit menggunakan model persentil (*existing plan*) menghasilkan standar deviasi ± 34.5 , sedangkan model rekomendasi memiliki standar deviasi ± 46.6 . Perhitungan debit menggunakan model rekomendasi memiliki standar deviasi yang lebih mendekati debit hasil observasi yaitu 51.0. Model yang baik adalah model yang mampu menyerupai standar deviasi observasi (Taylor, 2001). Hal ini mendemonstrasikan adanya potensi perencanaan yang lebih tepat ketika prakiraan curah hujan 36 dasarian yang telah dioptimalkan digunakan.



Gambar 9.4 Perbandingan debit masuk/*inflow* (atas) dan selisih prakiraan absolut (bawah) berdasarkan hasil prakiraan multimodel dan skenario dasar RTOW

Terdapat beberapa pola lonjakan di curah hujan observasi yang terjadi, yang dapat dilihat pada Gambar 6.1. Hal ini adalah hal yang wajar, seperti pada kajian sebelumnya yang dilakukan oleh Purwaningsih et al. (2020), karena curah hujan di Jawa Timur dipengaruhi pola gangguan *Madden-Julian Oscillation* yang memberikan pola lonjakan. Propagasi MJO memicu peningkatan aktifitas konveksi yang menyebabkan kenaikan probabilitas hujan. Proses pembentukan

hujan ini telah diwahyukan oleh Allah SWT dalam Al-Quran Surat An-Nur ayat 43 sebagai berikut.

أَلَمْ تَرَ أَنَّ اللَّهَ يَرْجِي سَحَابًا ثُمَّ يُؤَلِّفُ بَيْنَهُ ثُمَّ يَجْعَلُهُ رُكَامًا فَتَرَى الْوَدْقَ يَخْرُجُ
مِنْ خِلَالِهِ وَيُنَزِّلُ مِنَ السَّمَاءِ مِنْ جِبَالٍ فِيهَا مِنْ بَرَدٍ فَيُصِيبُ بِهِ مَنْ يَشَاءُ
وَيَصْرِفُهُ عَنِ مَنْ يَشَاءُ يَكَادُ سَنَا بَرْقِهِ يَذْهَبَ بِالْأَبْصَارِ ﴿٤٣﴾

Artinya: Tidakkah engkau melihat bahwa sesungguhnya Allah mengarahkan awan secara perlahan, kemudian mengumpulkannya, lalu menjadikannya bertumpuk-tumpuk. Maka, engkau melihat hujan keluar dari celah-celahnya. Dia (juga) menurunkan (butiran-butiran) es dari langit, (yaitu) dari (gumpalan-gumpalan awan seperti) gunung-gunung. Maka, Dia menyimpakannya (butiran-butiran es itu) kepada siapa yang Dia kehendaki dan memalingkannya dari siapa yang Dia kehendaki. Kilauan kilatnya hampir-hampir menghilangkan penglihatan. (An-Nur:43)

Menurut tafsir Jalalain, ayat ini menjelaskan bagaimana proses yang terjadi pada pembentukan hujan. (Tidaklah kamu melihat bahwa Allah mengarahkan awan) menggiringnya secara lembut (kemudian mengumpulkan antara bagian-bagiannya) dengan menghimpun sebagiannya dengan sebagian yang lain, sehingga yang tadinya tersebar kini menjadi satu kumpulan (kemudian menjadikannya bertindih-tindih) yakni sebagiannya di atas sebagian yang lain (maka kelihatanlah olehmu air) hujan (keluar dari celah-celahnya) yakni melalui celah-celahnya (dan Allah juga menurunkan dari langit). Huruf Min yang kedua ini berfungsi menjadi Shilah atau kata penghubung (yakni dari gunung-gunung yang menjulang padanya) menjulang ke langit; Min Jibalin menjadi Badal daripada lafal Minas Samaa-i dengan mengulangi huruf Jarnya (berupa es) sebagiannya terdiri dari es (maka ditimpakannya es tersebut kepada siapa yang dikehendaki-Nya dan dipalingkan-Nya dari siapa yang dikehendaki-Nya. Hampir-

hampir) hampir saja (kilauan kilat awan itu) yakni cahayanya yang berkilauan (menghilangkan penglihatan) mata yang memandangnya, karena silau olehnya.

Prakiraan hujan yang akurat dan tepat waktu sangat penting dalam mendukung perencanaan operasional waduk yang lebih baik. Dengan memiliki informasi yang jelas tentang kondisi cuaca, seperti curah hujan, temperatur, dan pola angin, pengelola waduk dapat merencanakan pengelolaan air dengan lebih efisien. Misalnya, prediksi hujan lebat dapat memungkinkan pengelola untuk melakukan pengurangan volume air sebelum terjadi banjir, sehingga mengurangi potensi kerusakan akibat luapan air yang tidak terkontrol. Sebaliknya, jika diperkirakan terjadi kekeringan, pengelola waduk bisa menyesuaikan distribusi air untuk memenuhi kebutuhan irigasi dan pasokan air bagi masyarakat. Hal ini sesuai firman Allah SWT Surat Al-Mu'minin ayat 18 dimana air yang Allah turunkan dari langit memiliki ukuran dan dijadikan tetap di bumi.

وَأَنْزَلْنَا مِنَ السَّمَاءِ مَاءً بِقَدَرٍ فَأَسْكَنَتْهُ فِي الْأَرْضِ وَإِنَّا عَلَى ذَهَابٍ بِهِ
لَقَادِرُونَ ﴿١٨﴾

Artinya: Kami turunkan air dari langit dengan suatu ukuran. Lalu, Kami jadikan air itu menetap di bumi dan sesungguhnya Kami Mahakuasa melenyapkannya. (QS. Al Mu'minin: 18).

Menurut tafsir Kementrian Agama, ayat ini menjelaskan hal berikut. Allah SWT menurunkan dari langit air hujan dengan kadar yang diperlukan, tidak terlalu lebat sehingga menimbulkan bencana banjir dan tidak terlalu sedikit sehingga cukup untuk mengairi kebun-kebun yang memerlukannya. Ada pula tanah-tanah yang memerlukan banyak air, akan tetapi tidak tahan menerima hujan yang lebat, maka air yang diperlukan itu didatangkan dari negeri lain melalui

sungai-sungai yang besar seperti sungai Nil di Mesir yang bersumber di tengah-tengah benua Afrika. Di samping membawa air yang diperlukan, juga membawa lumpur yang sangat bermanfaat untuk menambah kesuburan. Air dapat tersimpan baik sebagai sungai-sungai, danau-danau dan bahkan sebagian tersimpan dalam bumi sebagai air tanah dangkal maupun air tanah dalam atau sering disebut sebagai *groundwater*. Sebagian dari air itu dijadikan Allah menetap dalam bumi untuk mengisi sumur-sumur dan parit-parit yang berfungsi dalam bidang irigasi, dan karena air dalam bumi itu bersentuhan pula dengan lapisan-lapisan logam dan zat kimia lainnya, air itu mengandung unsur-unsur kimiawi yang menambah kesuburan tanah, dan bila lewat di lereng gunung-gunung berapi dapat pula menjadi sumber-sumber air panas yang mengandung belerang, dan dapat dijadikan tempat pemandian air panas yang sangat berguna untuk menyembuhkan penyakit kulit dan sebagainya. Semua sumber penggunaan air itu, jika dimanfaatkan dengan rasa syukur kehadiran Allah, niscaya akan dapat dinikmati, akan tetapi jika manusia serakah dan merusaknya, maka sesungguhnya Allah berkuasa pula untuk menghilangkannya, terutama bila tempat-tempat itu dipakai untuk perbuatan maksiat.

Integrasi data prakiraan cuaca dalam perencanaan operasional waduk, memungkinkan pengelola waduk dapat merancang sistem pemantauan dan peringatan dini yang lebih efektif. Hal ini dapat memungkinkan pengurangan dampak negatif terhadap lingkungan dan masyarakat sekitar. Secara keseluruhan, penerapan prakiraan yang baik tidak hanya mencegah kerusakan fisik pada waduk, tetapi juga mendukung keberlanjutan sosial dan ekonomi di wilayah yang bergantung pada waduk tersebut.

BAB X

PENUTUP

10.1 Kesimpulan

Berdasarkan hasil penelitian yang sudah dilakukan dapat disimpulkan bahwa:

- a. Model *existing* yang menghubungkan informasi prakiraan sifat musim menjadi dasar penentuan kondisi debit terbukti tidak lebih baik dari pada pendekatan multi model ensemble prakiraan curah hujan 36 dasarian ke depan. Prakiraan berdasarkan persentil 35, 50, dan 65 masuk sebagai pendekatan terbaik hanya di beberapa Zona Musim (ZOM) saja. Luaran model EMCWF-ARIMA, regresi ERSST, dan pendekatan ensemble memberikan hasil yang lebih baik berdasarkan kriteria kesesuaian (rata-rata dan minimum) dan *Mean Absolute Error* (MAE, rata-rata dan maksimum). Rekomendasi model terbaik di tiap ZOM disajikan secara rinci untuk memberi opsi prakirawan. Simulasi langsung berbasis forecaster acak yang diberi rekomendasi model hasil evaluasi menunjukkan selisih absolut yang lebih rendah dibandingkan dengan rencana tahunan yang digunakan pada tahun 2022/2023. Penggunaan pendekatan simulasi operasional dalam studi ini menggambarkan kondisi nyata dengan tepat dan menggunakan segmentasi data pelatihan-pengujian yang konsisten dengan kondisi pada bulan November setiap tahun (termasuk tahun 2022).
- b. Adanya ensemble berdampak pada penurunan deviasi kesesuaian dan Mean Absolut Error atau dapat dikatakan hasil prakiraan lebih stabil. Sebagai

kompensasinya, proses ensemble menyebabkan penurunan rata-rata kesesuaian dan peningkatan rata-rata Mean Absolute Error.

10.2 Saran

Penelitian ini memberikan pandangan bagi penulis untuk memberi saran seperti berikut:

- a. Direkomendasikan untuk menggeser penggunaan informasi sifat hujan musim menjadi prakiraan curah hujan 36 dasarian guna meningkatkan nilai perencanaan operasional waduk.
- b. Penelitian lanjutan diperlukan untuk menetapkan rumus empiris yang lebih akurat mengenai hubungan curah hujan dan aliran sungai serta untuk mengintegrasikan perencanaan waduk dengan data curah hujan yang diproyeksikan (bukan prakiraan) pada skenario iklim di masa mendatang.
- c. Terkait dengan keumuman penelitian, diharapkan penelitian sejenis dapat dilakukan untuk waduk-waduk lainnya.

DAFTAR PUSTAKA

- Abdullah, S E A N. 2021. Analisis Hubungan Indeks Nino 3.4 dengan Curah Hujan di Jawa Tengah. *Buletin Meteorologi, Klimatologi, dan Geofisika***2**(5), 24-30. P-ISSN 2716-0130.
- Anggraeni, D, Kurnia, I F, dan Hadi A F. 2018. Ensemble averaging and stacking of ARIMA and GSTAR model for rainfall forecasting. *IOP Conf. Series: Journal of Physics: Conf. Series*. doi:10.1088/1742-6596/1008/1/012019.
- Ardhitama, A dan Sholihah, R. 2013. Model Simulasi Prakiraan Curah Hujan Bulanan pada Wilayah Riau dengan Menggunakan Input Data SOI, SST, NINO 3.4, dan IOD. *Jurnal Sains & Teknologi Modifikasi Cuaca***14**(2), 95-104.
- Badan Meteorologi Klimatologi dan Geofisika. 2019. Peraturan Badan Meteorologi Klimatologi dan Geofisika Nomor 7 Tahun 2019 tentang Penyediaan dan Penyebaran Prakiraan Musim. Jakarta.
- Bestari, A. 2023. Laporan Akhir: Penyusunan Alokasi Air WS Brantas. Surabaya: Balai Besar Wilayah Sungai Brantas.
- Chowdary, PSM dan M Anbarasi. 2020. Enhanced Rainfall Predictions using Stacking Technique. *Journal of Emerging Technologies and Innovative Research***7**(7).
- Deman, M H, Koppa, A, Waegeman, W, MacLeod, D A, Singer, M B, dan Miralles D G. 2022. Seasonal prediction of Horn of Africa long rains using machine learning: The pitfalls of preselecting correlated predictors. *Water***4**:1053020. doi: 10.3389/frwa.2022.1053020
- Fathi, M, Azadi, M, Kamali, G, dan Meshkatee, H. 2019. Improving Precipitation Forecasts over Iran using A Weighted Average Ensemble Technique. *J. Earth Syst. Sci.***128**(133). doi: 10.1007/s12040-019-1145-2.
- Gu, J, Liu, S, Zhou, Z, Challow, S R dan Zhuang, Q. 2022. A Stacking Ensemble Learning Model for Monthly Rainfall Prediction in the Taihu Basin, China. *Water***14**. doi: 10.3390/w14030492.
- Hyndman, R J dan Khandakar, Y. 2008. Automatic time series forecasting: The forecast package for R. *Journal of Statistical Software* **27**(1), 1–22.
- Hurkmans, R T W, Hurk, B V D, Schmeits, M S, Wetterhall, F dan Pechlivanidis, I G. 2023. Seasonal Streamflow Forecasting for Fresh Water Reservoir Management in the Netherlands: An Assessment of Multiple Prediction Systems. *Journal of Hydrometeorology***24**(7): 1275–1290. doi: 10.1175/JHM-D-22-0107.1
- Jose, D M, Vincent, A M dan Dwarakish, G S. 2022. Improving Multiple Model Ensemble Predictions of Daily Precipitation and Temperature through Machine Learning Techniques. *Scientific Reports***12**: 4678, 1-25. doi: 10.1038/s41598-022-08786-w.

- Kullahci, A G K dan Altunkaynak, A. 2023. Integrating Wavelet Decomposition and Stacking Ensemble learning for Accurate Daily Rainfall Forecasting.
- Kundu, S, Biswass, S K, Tripathi, D, Karmakar, R, Majumdar, S, dan Mandal S. 2023. A review on rainfall forecasting using ensemble learning techniques. *Advances in Electrical Engineering, Electronics and Energy* **6**. doi: 10.1016/j.prime.2023.100296.
- Kurniawan, A., Muzayanah, L. F., & Sudirman. 2022. Verifikasi Luaran HyBMG saat Kejadian El Niño dan La Niña di Jawa Timur. *Buletin GAW Bariri (BGB)***3**(2), 8-15. doiI: 10.31172/bgb.v3i2.69. P-ISSN: 2721-7752 | E-ISSN: 2721-9704.
- Mahera, U, Ilhamsyah, Y, dan Octavina, C. Pengaruh Suhu Muka Laut terhadap Awal Masuk Musim hujan di Wilayah Utara-Timur Aceh. *Jurnal Lingkungan Almuslim***2** (2),035-049. doi: 10.51179/jla.v2i2.2110
- Mahmudiah, R R, Kurniawan, A dan Makmus, E E S. 2019. Determining best East Java monthly rainfall projection using spatial-based validation. *IOP Conf. Ser.: Earth Environ. Sci.***303** 012023.
- Maulita, M., & Nurdin.2023. Pendekatan Data Mining untuk Analisis Curah Hujan Menggunakan Metode Regresi Linear Berganda (Studi Kasus: Kabupaten Aceh Utara). *Jurnal Online Manajemen Informatika***6**(2), 99-106. ISSN 2684-7280.
- Noviasari, T, Nuzula, N I, Efendy, M, Febrianto, A A, dan Darmadi, A. 2023. Peramalan Curah Hujan terhadap Produktivitas Garam di Gresik Putih Sumenep. *Jurnal Kelautan Tropis* **26** (1): 9-18. doi: 10.14710/jkt.v26i1.16139.
- Pakdaman, M, Babaeian, I, dan Bouwer, L M. 2022. Improved Monthly and Seasonal Multi-Model Ensemble Precipitation Forecasts in Southwest Asia Using Machine Learning Algorithms. *Water* **14**. doi: /10.3390/w14172632.
- Purwaningsih, A, Hardjana, T, Hermawan, E, dan Andarini, D F. 2020. Kondisi Curah Hujan dan Curah Hujan Ekstrem saat MJO Kuat dan Lemah: Distribusi Spasial dan Musiman diIndonesia. *Jurnal Sains & Teknologi Modifikasi Cuaca***21**(2): 85 – 94. doi:10.29122/jstm.v21i2.4153.
- Ruslana, Z. N., Tresnawati, R., Rosyidah, , Harmoko, I. W., & Siswanto. 2021. Reliabilitas Prakiraan Curah Hujan Dasarian Pada Kejadian Curah Hujan Ekstrem Pemicu Banjir 26 Oktober 2020 di Kebumen: Model Statistik (HyBMG) versus Model Dinamik (ECMWF). *Jurnal Geosains dan Teknologi***4**(2).
- Raju, K S dan Kumar, D N. 2020. Review of Approaches for Selection and Ensembling of GCMs. *Journal of Water and Climate Change* **11**, 577-599. doi: 10.2166/wcc.2020.128.
- Specq, D, Batte, L, Deque, M, dan Ardilouze, C. 2020. Multimodel Forecasting of Precipitation at Subseasonal Timescales Over the Southwest Tropical Pacific. *Earth and Space Science* **7**(9). doi: 10.1029/2019EA001003.

- Taylor, K E. 2001. Summarizing multiple aspects of model performance in a single diagram. *Journal of geophysical research* **106** (D7): 7183-7192. doi: 10.1029/2000JD900719.
- Tuysuzoglu, G., Birant, U K, dan Birant, D. 2023. Rainfall Prediction Using an Ensemble Machine Learning Model Based on K-Stars. *Sustainability* **15**, doi: 10.3390/su15075889.
- Wei, X, Sun, X, Sun, J, Yin, J, Sun J dan Liu, C. 2022. A Comparative Study of Multi-Model Ensemble Forecasting Accuracy between Equal and Variant Weight Techniques. *Atmosphere* **13**(4). doi: 10.3390/atmos13040526.
- Weisheimer, A dan Palmer, T. 2014. On the Reliability of Seasonal Climate Forecast. *Journal of the Royal Society Interface* **11**(96). doi: 10.1098/rsif.2013.162.
- Weyn, J A, Durran, D R, Caruana Rm dan Cresswell-Clay, N. 2021. Sub-Seasonal Forecasting With a Large Ensemble of Deep-Learning Weather Prediction Models. *Journal of Advances in Modeling Earth Systems* **13**. doi: 10.1029/2021MS002502
- Willmot, C dan Matsuura. 2005. Advantages of the Mean Absolute Error (MAE) over the Root Mean Square Error (RMSE) in assessing average model performance. *Clim. Res.* **30**: 79-82.
- Zhai, A., Fan, G., Ding, X., dan Huang G. 2022. Regression Tree Ensemble Rainfall–Runoff Forecasting Model and Its Application to Xiangxi River, China. *Water* **14**. doi: 10.3390/w14030463.

Lampiran 1. Skrip Prakiraan Curah Hujandengan Skenario Dasar, ARIMA, dan ECMWF

```
library(forecast)
AFU="F:\\20241023_TRTOW_SUSUN_ULANG\\"
Qsearcher=function(x){
ccc=quantile(x,c(0.35,0.5,0.65),na.rm=T)
}
Meannarm=function(x){
ccc=round(mean(x,na.rm=T),1)
}
CH2Kat=function(x){
r=x
r[(r>-9999)&(r<=10)]=-1
r[(r>10)&(r<=20)]=-2
r[(r>20)&(r<=50)]=-3
r[(r>50)&(r<=75)]=-4
r[(r>75)&(r<=100)]=-5
r[(r>100)&(r<=150)]=-6
r[(r>150)&(r<=200)]=-7
r[(r>200)&(r<=300)]=-8
r[(r>300)]=-9
b=r*-1
}

DATACH=read.csv(paste(AFU,"CURAH_HUJAN.csv",sep=""))

ZOM=1
while(ZOM<=74){

RKPMAC=c()
RKPMAEhujan=c()
RKPMAEkemarau=c()

RKPKesesuaian=c()
RKPKesesuaianhujan=c()
RKPKesesuaiankemarau=c()
}
```

```
RKPPRAKCH=c()
```

```
kolombatas=859 # 2014 ==> 859
```

```
tahun_inisial=2014
```

```
tahun_hujan=20142015
```

```
tahun_kemarau=2015
```

```
while(kolombatas<=(859+36*8)){
```

```
  HIST=as.numeric(DATAACH[ZOM,2:kolombatas])
```

```
  write.csv(HIST,paste(AFU,"01_HISTORI_CH_DIPAKAI\\HIST_ZOM",100+ZOM,"_T  
    BATAS=",tahun_inisial,".csv",sep=""))
```

```
  MATRIXHIST=matrix(c(HIST,rep(NA,6)),36,byrow=T)
```

```
  RATA2=apply(MATRIXHIST,2,Meannarm)
```

```
  write.csv(RATA2,paste(AFU,"02_HISTORI_CHAVG_DIPAKAI\\HIST_ZOM",100+Z  
    OM,"_TBATAS=",tahun_inisial,".csv",sep=""))
```

```
  anomHIST=HIST-rep(RATA2,nrow(MATRIXHIST))[1:length(HIST)]
```

```
  write.csv(anomHIST,paste(AFU,"03_HISTORI_CHANOM_DIPAKAI\\HIST_ZOM",10  
    0+ZOM,"_TBATAS=",tahun_inisial,".csv",sep=""))
```

```
  TARGET=as.numeric(DATAACH[ZOM,(kolombatas+4):(kolombatas+39)])
```

```
  write.csv(TARGET,paste(AFU,"04_TARGET_CH\\TARGET_ZOM",100+ZOM,"_TBA  
    TAS=",tahun_hujan,".csv",sep=""))
```

```
  TLLINES=apply(MATRIXHIST,2,Qsearcher)
```

```
  Skenario_Basah=round(TLLINES[3,c(34:36,1:33)],0)
```

```
  Skenario_Normal=round(TLLINES[2,c(34:36,1:33)],0)
```

```
  Skenario_Kering=round(TLLINES[1,c(34:36,1:33)],0)
```

```
  DATAECMWFc=read.csv(paste(AFU,"00_BAHAN_ECMWF\\PCH_ECMWF_COR_pe  
    rZOM9120_ver_",tahun_inisial,".11.01.csv",sep=""))
```

```
  DATAECMWFr=read.csv(paste(AFU,"00_BAHAN_ECMWF\\PCH_ECMWF_RAW_p  
    erZOM9120_ver_",tahun_inisial,".11.01.csv",sep=""))
```

```
  PRED1Ec=as.numeric(DATAECMWFc[ZOM,2:22])
```

```
  anomHISTEc=c(HIST,PRED1Ec)-  
    rep(RATA2,nrow(MATRIXHIST)+1)[1:length(c(HIST,PRED1Ec))]
```

```
addEc=as.numeric(forecast(auto.arima(anomHISTEc),18)$mean)+RATA2[c(16:33)]
addEc[addEc<=0]=0
PRED1EcARIMA=round(c(PRED1Ec[4:21],addEc),1)
Skenario_EcARIMA=PRED1EcARIMA
```

```
PRED2Er=as.numeric(DATAECMWFr[ZOM,2:22])
anomHISTEr=c(HIST,PRED2Er)-
  rep(RATA2,nrow(MATRIXHIST)+1)[1:length(c(HIST,PRED2Er))]
addEr=as.numeric(forecast(auto.arima(anomHISTEr),18)$mean)+RATA2[c(16:33)]
addEr[addEr<=0]=0
PRED2ErARIMA=round(c(PRED2Er[4:21],addEr),1)
Skenario_ErARIMA=PRED2ErARIMA
```

```
PRED3fARIMA=as.numeric(forecast(auto.arima(anomHIST),39)$mean)[4:39]+RATA2[
  c(34:36,1:33)]
PRED3fARIMA[PRED3fARIMA<=0]=0
Skenario_ARIMA=round(PRED3fARIMA,0)
```

```
Matriks_Skenario=rbind(Skenario_Basah,Skenario_Normal,Skenario_Kering,Skenario_E
  cARIMA,Skenario_ErARIMA,Skenario_ARIMA)
Matriks_Target=matrix(rep(TARGET,nrow(Matriks_Skenario)),,36,byrow=T)
Matriks_Selisih=abs(Matriks_Skenario-Matriks_Target)
MAE=round(rowSums(Matriks_Selisih)/36,1)
MAEhujan=round(rowSums(Matriks_Selisih[,1:18])/18,1)
MAEkmrau=round(rowSums(Matriks_Selisih[,19:36])/18,1)
```

```
Matriks_Skenario_kat=CH2Kat(Matriks_Skenario)
Matriks_Target_kat=CH2Kat(Matriks_Target)
Matriks_Selisih=abs(Matriks_Skenario_kat-Matriks_Target_kat)
Kesesuaian=round(rowSums(Matriks_Selisih<=1)/36*100,0)
```

```
RKPMAE=cbind(RKPMAE,MAE)
RKPKesesuaian=cbind(RKPKesesuaian,Kesesuaian)
RKPPRAKCH=cbind(RKPPRAKCH,Matriks_Skenario)
```

```
colnames(RKPMAE)[ncol(RKPMAE)]=tahun_hujan
colnames(RKPKesesuaian)[ncol(RKPKesesuaian)]=tahun_hujan
```

```
colnames(RKPPRAKCH)[ncol(RKPPRAKCH)]=tahun_hujan
```

```
kolombatas=kolombatas+36
```

```
tahun_inisial=tahun_inisial+1
```

```
tahun_hujan=tahun_hujan+10001
```

```
tahun_kemarau=tahun_kemarau+1
```

```
}
```

```
write.csv(RKPMAE,paste(AFU,"07_MAE_ARIMA_ECMWF\\MAE_ZOM",100+ZOM,
".csv",sep=""))
```

```
write.csv(RKPKesesuaian,paste(AFU,"06_KESESUAIAN_ARIMA_ECMWF\\KS_ZO
M",100+ZOM,".csv",sep=""))
```

```
write.csv(RKPPRAKCH,paste(AFU,"05_PRED_ARIMA_ECMWF\\PRAK_ZOM",100+
ZOM,".csv",sep=""))
```

```
print(ZOM)
```

```
flush.console()
```

```
ZOM=ZOM+1
```

```
}
```

Lampiran 2. Skrip Prakiraan Curah Hujandengan Model Regresi ONI-DMI

```
library(forecast)
```

```
AFU="F:\\20241023_TRTOW_SUSUN_ULANG\\"
```

```
data_trainX0=read.csv(paste(AFU,"ONI_DMI_20042022.csv",sep=""))
```

```
data_trainX1=t(data_trainX0[,2:ncol(data_trainX0)])
```

```
colnames(data_trainX1)=as.character(data_trainX0[,1])
```

```
CH2Kat=function(x){
```

```
  r=x
```

```
  r[(r>-9999)&(r<=10)]=-1
```

```
  r[(r>10)&(r<=20)]=-2
```

```
  r[(r>20)&(r<=50)]=-3
```

```
  r[(r>50)&(r<=75)]=-4
```

```
  r[(r>75)&(r<=100)]=-5
```

```
  r[(r>100)&(r<=150)]=-6
```

```
  r[(r>150)&(r<=200)]=-7
```

```
  r[(r>200)&(r<=300)]=-8
```

```
  r[(r>300)]=-9
```

```
  b=r*-1
```

```
}
```

```
ZOM=1
```

```
while(ZOM<=74){
```

```
  RKPMAE=c()
```

```
  RKPKesesuaian=c()
```

```
  RKPPRAKCH=c()
```

```
  tahun_inisial=2014
```

```
  tahun_hujan=20142015
```

```
  tahun_kemarau=2015
```

```
  window_range=10
```

```

while(tahun_inisial<=2022){

anomHIST=as.numeric(read.csv(paste(AFU,"03_HISTORI_CHANOM_DIPAKA
I\\HIST_ZOM",ZOM+100,"_TBATAS=",tahun_inisial,".csv",sep=""))[,2])
MATRIXanomHIST=matrix(c(anomHIST,rep(NA,6)),,36,byrow=T)

ROWDAS_34_36=(nrow(MATRIXanomHIST)-
window_range):(nrow(MATRIXanomHIST)-1)
COLDAS_34_36=34:36

ROWDAS_01_33=(nrow(MATRIXanomHIST)-(window_range-
1)):(nrow(MATRIXanomHIST))
COLDAS_01_33=1:33

data_trainY=cbind(MATRIXanomHIST[ROWDAS_34_36,COLDAS_34_36],M
ATRIXanomHIST[ROWDAS_01_33,COLDAS_01_33])
write.csv(data_trainY,paste(AFU,"08_BAHAN_REGRESI_ONI_DMI\\TRAIN_
Y\\ZOM",100+ZOM,"_TBATAS=",tahun_inisial-1,".csv",sep=""))
data_trainX=data_trainX1[(tahun_inisial-2013):(tahun_inisial-2004),]
write.csv(data_trainX,paste(AFU,"08_BAHAN_REGRESI_ONI_DMI\\TRAIN_
X\\ZOM",100+ZOM,"_TBATAS=",tahun_inisial-1,".csv",sep=""))
data_predX=data_trainX1[(tahun_inisial-2003),]
write.csv(data_predX,paste(AFU,"08_BAHAN_REGRESI_ONI_DMI\\PRED_X\\
ZOM",100+ZOM,"_TBATAS=",tahun_inisial,".csv",sep=""))

RKPREG=c()
nrk=1
while(nrk<=24){
Xs=as.numeric(data_trainX[,nrk])
Xp=as.numeric(data_predX[nrk])
RKPREG=rbind(RKPREG,as.numeric(predict(lm(data_trainY~Xs),
data.frame(Xs=c(Xp))))))
nrk=nrk+1
}

```

```

rownames(RKPREG)=as.character(data_trainX0[,1])
RATA2=read.csv(paste(AFU,"02_HISTORI_CHAVG_DIPAKAI\\HIST_ZOM",
  100+ZOM,"_TBATAS=",tahun_inisial,".csv",sep=""))
mRATA2=matrix(as.numeric(RATA2[c(34:36,1:33),2]),nrow(RKPREG),ncol(R
  KPREG),byrow=T)

PRED_REG=round(RKPREG+mRATA2,1)
PRED_REG[PRED_REG<=0]=0

Skenario_Regresi=PRED_REG

TARGET=read.csv(paste(AFU,"04_TARGET_CH\\TARGET_ZOM",100+ZOM,
  "_TBATAS=",tahun_hujan,".csv",sep=""))
TARGET=as.numeric(TARGET[,2])

Matriks_Skenario=Skenario_Regresi
Matriks_Target=matrix(rep(TARGET,nrow(Matriks_Skenario)),36,byrow=T)
Matriks_Selisih=abs(Matriks_Skenario-Matriks_Target)
MAE=round(rowSums(Matriks_Selisih)/36,1)

Matriks_Skenario_kat=CH2Kat(Matriks_Skenario)
Matriks_Target_kat=CH2Kat(Matriks_Target)
Matriks_Selisih=abs(Matriks_Skenario_kat-Matriks_Target_kat)
Kesesuaian=round(rowSums(Matriks_Selisih<=1)/36*100,0)

RKPMMAE=cbind(RKPMMAE,MAE)
RKPKesesuaian=cbind(RKPKesesuaian,Kesesuaian)
RKPPRAKCH=cbind(RKPPRAKCH,Matriks_Skenario)

colnames(RKPMMAE)[ncol(RKPMMAE)]=tahun_hujan
colnames(RKPKesesuaian)[ncol(RKPKesesuaian)]=tahun_hujan
colnames(RKPPRAKCH)[ncol(RKPPRAKCH)]=tahun_hujan

tahun_inisial=tahun_inisial+1
tahun_hujan=tahun_hujan+10001

```

```
tahun_kemarau=tahun_kemarau+1
}
```

```
write.csv(RKPMAE,paste(AFU,"11_MAE_REGRESI_ONI_DMI\\MAE_ZOM",
100+ZOM,".csv",sep=""))
```

```
write.csv(RKPKesesuaian,paste(AFU,"10_KESESUAIN_REGRESI_ONI_DMI\\
KS_ZOM",100+ZOM,".csv",sep=""))
```

```
write.csv(RKPPRAKCH,paste(AFU,"09_PRED_REGRESI_ONI_DMI\\PRAK_Z
OM",100+ZOM,".csv",sep=""))
```

```
print(ZOM)
flush.console()
```

```
ZOM=ZOM+1
}
```

Lampiran 3. Skrip Prakiraan Curah Hujandengan Model Regresi SST

```
library(raster)
```

```
nk=1
```

```
AFU="C:\\TEMP\\20241023_TRTOW_SUSUN_ULANG\\"
```

```
RKP1=c()
```

```
while(nk<=228){
```

```
  x=raster(paste(AFU,"ASST_ERSST_Oct2003_Sep2022.nc",sep=""),band=nk)
```

```
  x=round(as.numeric(as.matrix(x)),3)
```

```
  RKP1=rbind(RKP1,x)
```

```
  nk=nk+1
```

```
  print(nk)
```

```
  flush.console()
```

```
}
```

```
x=raster(paste(AFU,"ASST_ERSST_Oct2003_Sep2022.nc",sep=""),band=1)
```

```
RKP2=RKP1
```

```
RKP2[is.na(RKP2)]=0
```

```
tahun_inisial=2014
```

```
while(tahun_inisial<=2022){
```

```
  RKP4=RKP2[(1+(tahun_inisial-2014)*12):(132+(tahun_inisial-2014)*12),]
```

```
  nrow(RKP4)
```

```
  RKP5=prcomp(RKP4)
```

```
  npc=1
```

```
  AAA=round(as.numeric(RKP5$x[,npc]),3)
```

```
  RKP1=matrix(AAA,12,,)
```

```
  rownames(RKP1)=paste("PC",npc,c("OKT","NOV","DES","JAN","FEB","MAR",  
    ",","APR","MEI","JUN","JUL","AGU","SEP"),sep="_")
```

```
  colnames(RKP1)=((tahun_inisial-10):tahun_inisial)
```

```

RKPALL=rbind(t(RKP1))
npc=npc+1

while(npc<=10){
AAA=round(as.numeric(RKP5$x[,npc]),3)
RKP1=matrix(AAA,12,,)
rownames(RKP1)=paste("PC",npc,c("OKT","NOV","DES","JAN","FEB","MAR",
    "","APR","MEI","JUN","JUL","AGU","SEP"),sep="_")
colnames(RKP1)=((tahun_inisial-10):tahun_inisial)
RKPALL=cbind(RKPALL,t(RKP1))
npc=npc+1
}

ZOM=1
while(ZOM<=74){
write.csv(RKPALL[1:10,],paste(AFU,"12_BAHAN_REGRESI_PC_ERSST\\TR
    AIN_X\\ZOM",100+ZOM,"_TBATAS=",tahun_inisial-1,".csv",sep=""))
write.csv(RKPALL[11,],paste(AFU,"12_BAHAN_REGRESI_PC_ERSST\\PRE
    D_X\\ZOM",100+ZOM,"_TBATAS=",tahun_inisial,".csv",sep=""))
ZOM=ZOM+1
}

print(tahun_inisial)
flush.console()
tahun_inisial=tahun_inisial+1
}

library(forecast)

AFU="F:\\20241023_TRTOW_SUSUN_ULANG\\"

CH2Kat=function(x){
r=x
r[(r>-.9999)&(r<=10)]=-1

```

```

r[(r>10)&(r<=20)]=-2
r[(r>20)&(r<=50)]=-3
r[(r>50)&(r<=75)]=-4
r[(r>75)&(r<=100)]=-5
r[(r>100)&(r<=150)]=-6
r[(r>150)&(r<=200)]=-7
r[(r>200)&(r<=300)]=-8
r[(r>300)]=-9
b=r*-1
}

```

```
ZOM=1
```

```
while(ZOM<=74){
```

```
RKPMAE=c()
```

```
RKPKesesuaian=c()
```

```
RKPPRAKCH=c()
```

```
tahun_inisial=2014
```

```
tahun_hujan=20142015
```

```
tahun_kemarau=2015
```

```
window_range=10
```

```
while(tahun_inisial<=2022){
```

```
anomHIST=as.numeric(read.csv(paste(AFU,"03_HISTORI_CHANOM_DIPAKA
I\HIST_ZOM",ZOM+100,"_TBATAS=",tahun_inisial,".csv",sep=""))[,2])
```

```
MATRIXanomHIST=matrix(c(anomHIST,rep(NA,6)),,36,byrow=T)
```

```
ROWDAS_34_36=(nrow(MATRIXanomHIST)-
window_range):(nrow(MATRIXanomHIST)-1)
```

```
COLDAS_34_36=34:36
```

```
ROWDAS_01_33=(nrow(MATRIXanomHIST)-(window_range-
1)):(nrow(MATRIXanomHIST))
```

```
COLDAS_01_33=1:33
```

```
data_trainY=cbind(MATRIXanomHIST[ROWDAS_34_36,COLDAS_34_36],M
  ATRIXanomHIST[ROWDAS_01_33,COLDAS_01_33])
write.csv(data_trainY,paste(AFU,"12_BAHAN_REGRESI_PC_ERSST\\TRAIN_
  Y\\ZOM",100+ZOM,"_TBATAS=",tahun_inisial-1,".csv",sep=""))
```

```
dtx=read.csv(paste(AFU,"12_BAHAN_REGRESI_PC_ERSST\\TRAIN_X\\ZO
  M",100+ZOM,"_TBATAS=",tahun_inisial-1,".csv",sep=""))
data_trainX=dtx[,-1]
```

```
dpx=read.csv(paste(AFU,"12_BAHAN_REGRESI_PC_ERSST\\PRED_X\\ZOM
  ",100+ZOM,"_TBATAS=",tahun_inisial,".csv",sep=""))
data_predX=as.numeric(dpx[,2])
```

```
RKPREG=c()
nrk=1
while(nrk<=120){
  Xs=as.numeric(data_trainX[,nrk])
  Xp=as.numeric(data_predX[nrk])
  RKPREG=rbind(RKPREG,as.numeric(predict(lm(data_trainY~Xs),
    data.frame(Xs=c(Xp)))))
  nrk=nrk+1
}
```

```
rownames(RKPREG)=colnames(dtx)[2:121]
```

```
RATA2=read.csv(paste(AFU,"02_HISTORI_CHAVG_DIPAKAI\\HIST_ZOM",
  100+ZOM,"_TBATAS=",tahun_inisial,".csv",sep=""))
mRATA2=matrix(as.numeric(RATA2[c(34:36,1:33),2]),nrow(RKPREG),ncol(R
  KPREG),byrow=T)
```

```
PRED_REG=round(RKPREG+mRATA2,1)
PRED_REG[PRED_REG<=0]=0
```

```
Skenario_Regresi=PRED_REG
```

```
TARGET=read.csv(paste(AFU,"04_TARGET_CH\\TARGET_ZOM",100+ZOM,
  "_TBATAS=",tahun_hujan,".csv",sep=""))
```

```
TARGET=as.numeric(TARGET[,2])
```

```
Matriks_Skenario=Skenario_Regresi
```

```
Matriks_Target=matrix(rep(TARGET,nrow(Matriks_Skenario)),36,byrow=T)
```

```
Matriks_Selisih=abs(Matriks_Skenario-Matriks_Target)
```

```
MAE=round(rowSums(Matriks_Selisih)/36,1)
```

```
Matriks_Skenario_kat=CH2Kat(Matriks_Skenario)
```

```
Matriks_Target_kat=CH2Kat(Matriks_Target)
```

```
Matriks_Selisih=abs(Matriks_Skenario_kat-Matriks_Target_kat)
```

```
Kesesuaian=round(rowSums(Matriks_Selisih<=1)/36*100,0)
```

```
RKPMAE=cbind(RKPMAE,MAE)
```

```
RKPKesesuaian=cbind(RKPKesesuaian,Kesesuaian)
```

```
RKPPRAKCH=cbind(RKPPRAKCH,Matriks_Skenario)
```

```
colnames(RKPMAE)[ncol(RKPMAE)]=tahun_hujan
```

```
colnames(RKPKesesuaian)[ncol(RKPKesesuaian)]=tahun_hujan
```

```
colnames(RKPPRAKCH)[ncol(RKPPRAKCH)]=tahun_hujan
```

```
tahun_inisial=tahun_inisial+1
```

```
tahun_hujan=tahun_hujan+10001
```

```
tahun_kemarau=tahun_kemarau+1
```

```
}
```

```
write.csv(RKPMAE,paste(AFU,"15_MAE_REGRESI_PC_ERSST\\MAE_ZOM",
  ,100+ZOM,".csv",sep=""))
```

```
write.csv(RKPKesesuaian,paste(AFU,"14_KESESUAIAN_REGRESI_PC_ERSS
  T\\KS_ZOM",100+ZOM,".csv",sep=""))
```

```
write.csv(RKPPRAKCH,paste(AFU,"13_PRED_REGRESI_PC_ERSST\\PRAK_
  ZOM",100+ZOM,".csv",sep=""))
```

```
print(ZOM)
flush.console()

ZOM=ZOM+1
}
```

Lampiran 4. Skrip Prakiraan Curah Hujandengan Model Ensemble

```
CH2Kat=function(x){
  r=x
  r[(r>-9999)&(r<=10)]=-1
  r[(r>10)&(r<=20)]=-2
  r[(r>20)&(r<=50)]=-3
  r[(r>50)&(r<=75)]=-4
  r[(r>75)&(r<=100)]=-5
  r[(r>100)&(r<=150)]=-6
  r[(r>150)&(r<=200)]=-7
  r[(r>200)&(r<=300)]=-8
  r[(r>300)]=-9
  b=r*-1
}
```

```
AFU="F:\\20241023_TRTOW_SUSUN_ULANG\\"
TARGET0=read.csv(paste(AFU,"CURAH_HUJAN.csv",sep=""))
TARGET201412_202311=TARGET0[,863:1186]
TARGET=TARGET201412_202311
TARGETKat=CH2Kat(TARGET)
```

```
#####
##### BOBOT BERBASIS MAE
ZOM=1
```

```
while(ZOM<=74){
  MAE1=read.csv(paste(AFU,"07_MAE_ARIMA_ECMWF\\MAE_ZOM",100+Z
    OM,".csv",sep=""))
  MAE2=read.csv(paste(AFU,"11_MAE_REGRESI_ONI_DMI\\MAE_ZOM",100
    +ZOM,".csv",sep=""))
  MAE3=read.csv(paste(AFU,"15_MAE_REGRESI_PC_ERSST\\MAE_ZOM",10
    0+ZOM,".csv",sep=""))
  MAEALL=rbind(MAE1,MAE2,MAE3)
  rownames(MAEALL)=as.character(MAEALL[,1])
```

```

MAEALL=MAEALL[,2:ncol(MAEALL)]
PRAK1=read.csv(paste(AFU,"05_PRED_ARIMA_ECMWF\\PRAK_ZOM",100
+ZOM,".csv",sep=""))
PRAK2=read.csv(paste(AFU,"09_PRED_REGRESI_ONI_DMI\\PRAK_ZOM",1
00+ZOM,".csv",sep=""))
PRAK3=read.csv(paste(AFU,"13_PRED_REGRESI_PC_ERSST\\PRAK_ZOM",
100+ZOM,".csv",sep=""))
PRAKALL=rbind(PRAK1,PRAK2,PRAK3)
rownames(PRAKALL)=as.character(PRAKALL[,1])
PRAKALL=PRAKALL[,2:ncol(PRAKALL)]

```

```

aaa=MAEALL
nr=1
fxc=36
MNEW=c()
while(nr<=ncol(aaa)){
aa1=matrix(rep(aaa[,nr],fxc),,fxc)
MNEW=cbind(MNEW,aa1)
nr=nr+1
}

```

```

#Karena MAE, pakai 1/MAE
aaa=1/MNEW
RKMNEWt=aaa[(1+36*(0)):(36+36*(0))]
RKMNEW=RKMNEWt
nr=1
while(ncol(RKMNEW)<324){
RKMNEWt=RKMNEWt+aaa[(1+36*(nr)):(36+36*(nr))]
RKMNEW=cbind(RKMNEW,RKMNEWt)
nr=nr+1
}

```

```

MTXPEMBAGI=matrix(colSums(RKMNEW),nrow(RKMNEW),ncol(RKMNE
W),byrow=T)
BOBOT20152023=RKMNEW/MTXPEMBAGI

```

```

matrixawal=matrix(1,nrow(BOBOT20152023),36)/nrow(BOBOT20152023)
BOBOT=cbind(matrixawal,BOBOT20152023[,1:(324-36)])
write.csv(BOBOT,paste(AFU,"16_BOBOT_AKUMULATIF\\BOBOT_MAE_ZOM",100+ZOM,".csv",sep=""))

PRED=round(as.numeric(colSums(PRAKALL*BOBOT)),1)
PREDm=matrix(PRED,1,,)
rownames(PREDm)=paste("Skenario_Ensemble_MAE_Total",sep="")
write.csv(PREDm,paste(AFU,"17_PRED_ENS_TOTAL\\BOBOT_MAE_ZOM",100+ZOM,".csv",sep=""))

VER=TARGET[ZOM,]
SELISIH=as.numeric(abs(PRED-VER))
MAE=matrix(round(colMeans(matrix(SELISIH,36,,)),1),1,)
rownames(MAE)="Skenario_Ensemble_MAE_Total"
colnames(MAE)=c(20142015,20152016,20162017,20172018,20182019,20192020,20202021,20212022,20222023)
write.csv(MAE,paste(AFU,"19_MAE_PRED_ENS_TOTAL\\BOBOT_MAE_ZOM",100+ZOM,".csv",sep=""))

VERKat=TARGETKat[ZOM,]
PREDKat=CH2Kat(PRED)
SELISIH=as.numeric(abs(PREDKat-VERKat))
KESESUAIAN=matrix(round(100*colMeans(matrix(as.numeric((SELISIH<=1)),36,,),0),1),)
rownames(KESESUAIAN)="Skenario_Ensemble_MAE_Semua"
colnames(KESESUAIAN)=c(20142015,20152016,20162017,20172018,20182019,20192020,20202021,20212022,20222023)
write.csv(KESESUAIAN,paste(AFU,"18_KESESUAIAN_PRED_ENS_TOTAL\\BOBOT_MAE_ZOM",100+ZOM,".csv",sep=""))

print(ZOM)
flush.console()
ZOM=ZOM+1
}

```

```
#####
#####
```

```
#####
#####          BOBOT      BERBASIS
      KESESUAIAN
```

```
ZOM=1
```

```
while(ZOM<=74){
  KS1=read.csv(paste(AFU,"06_KESESUAIAN_ARIMA_ECMWF\\KS_ZOM",10
    0+ZOM,".csv",sep=""))
  KS2=read.csv(paste(AFU,"10_KESESUAIN_REGRESI_ONI_DMI\\KS_ZOM",
    100+ZOM,".csv",sep=""))
  KS3=read.csv(paste(AFU,"14_KESESUAIAN_REGRESI_PC_ERSST\\KS_ZO
    M",100+ZOM,".csv",sep=""))
  KSALL=rbind(MAE1,MAE2,MAE3)
  rownames(KSALL)=as.character(KSALL[,1])
  KSALL=KSALL[,2:ncol(KSALL)]
  PRAK1=read.csv(paste(AFU,"05_PRED_ARIMA_ECMWF\\PRAK_ZOM",100
    +ZOM,".csv",sep=""))
  PRAK2=read.csv(paste(AFU,"09_PRED_REGRESI_ONI_DMI\\PRAK_ZOM",1
    00+ZOM,".csv",sep=""))
  PRAK3=read.csv(paste(AFU,"13_PRED_REGRESI_PC_ERSST\\PRAK_ZOM",
    100+ZOM,".csv",sep=""))
  PRAKALL=rbind(PRAK1,PRAK2,PRAK3)
  rownames(PRAKALL)=as.character(PRAKALL[,1])
  PRAKALL=PRAKALL[,2:ncol(PRAKALL)]

  aaa=KSALL
```

```

nr=1
fxc=36
MNEW=c()
while(nr<=ncol(aaa)){
aa1=matrix(rep(aaa[,nr],fxc),,fxc)
MNEW=cbind(MNEW,aa1)
nr=nr+1
}

#Karena Kesesuaian, pakaiKesesuaian/1
aaa=MNEW
RKMNEWt=aaa[(1+36*(0)):(36+36*(0))]
RKMNEW=RKMNEWt
nr=1
while(ncol(RKMNEW)<324){
RKMNEWt=RKMNEWt+aaa[(1+36*(nr)):(36+36*(nr))]
RKMNEW=cbind(RKMNEW,RKMNEWt)
nr=nr+1
}

MTXPEMBAGI=matrix(colSums(RKMNEW),nrow(RKMNEW),ncol(RKMNEW),byrow=T)
BOBOT20152023=RKMNEW/MTXPEMBAGI
matrixawal=matrix(1,nrow(BOBOT20152023),36)/nrow(BOBOT20152023)
BOBOT=cbind(matrixawal,BOBOT20152023[,1:(324-36)])
write.csv(BOBOT,paste(AFU,"16_BOBOT_AKUMULATIF\\BOBOT_KESESUAIAN_ZOM",100+ZOM,".csv",sep=""))

PRED=round(as.numeric(colSums(PRAKALL*BOBOT)),1)
PREDm=matrix(PRED,1,,)
rownames(PREDm)=paste("Skenario_Ensemble_MAE_Total",sep="")
write.csv(PREDm,paste(AFU,"17_PRED_ENS_TOTAL\\BOBOT_KESESUAIAN_ZOM",100+ZOM,".csv",sep=""))

VER=TARGET[ZOM,]

```

```

SELISIH=as.numeric(abs(PRED-VER))
MAE=matrix(round(colMeans(matrix(SELISIH,36,,)),1),1,)
rownames(MAE)="Skenario_Ensemble_MAE_Total"
colnames(MAE)=c(20142015,20152016,20162017,20172018,20182019,20192020,20202021,20212022,20222023)
write.csv(MAE,paste(AFU,"19_MAE_PRED_ENS_TOTAL\\BOBOT_KESESUAIAN_ZOM",100+ZOM,".csv",sep=""))

VERKat=TARGETKat[ZOM,]
PREDKat=CH2Kat(PRED)
SELISIH=as.numeric(abs(PREDKat-VERKat))
KESESUAIAN=matrix(round(100*colMeans(matrix(as.numeric((SELISIH<=1)),36,,),0),1,)
rownames(KESESUAIAN)="Skenario_Ensemble_Kesesuaian_Semua"
colnames(KESESUAIAN)=c(20142015,20152016,20162017,20172018,20182019,20192020,20202021,20212022,20222023)
write.csv(KESESUAIAN,paste(AFU,"18_KESESUAIAN_PRED_ENS_TOTAL\\BOBOT_KESESUAIAN_ZOM",100+ZOM,".csv",sep=""))

print(ZOM)
flush.console()
ZOM=ZOM+1
}

#####
#####

```