

# MODEL PREDIKSI PROBABILISTIK DEBIT AIR MASUK WADUK KASKADE CITARUM DENGAN SEASV-ECMWF TERKOREKSI

ASRI RACHMAWATI



KLIMATOLOGI TERAPAN  
SEKOLAH PASCASARJANA  
INSTITUT PERTANIAN BOGOR  
BOGOR  
2022

@Hak cipta milik IPB University

IPB University



IPB University  
Bogor Indonesia

- Hak Cipta Dilindungi Undang-undang
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
    - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
    - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
  2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

Perpustakaan IPB University



## PERNYATAAN MENGENAI TESIS DAN SUMBER INFORMASI SERTA PELIMPAHAN HAK CIPTA

Dengan ini saya menyatakan bahwa tesis dengan judul “Model Prediksi Probabilistik Debit Air Masuk Waduk Kaskade Citarum Dengan SEASV-ECMWF Terkoreksi” adalah karya saya dengan arahan dari dosen pembimbing dan belum diajukan dalam bentuk apa pun kepada perguruan tinggi mana pun. Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka di bagian akhir tesis ini.

Dengan ini saya melimpahkan hak cipta dari karya tulis saya kepada Institut Pertanian Bogor.

Bogor, Januari 2022

Asri Rachmawati  
NIM G251190071

- Hak Cipta Dilindungi Undang-undang
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
    - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
    - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
  2. Dilarang mengumumkannya dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.



### @Hak cipta milik IPB University

Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
  - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

## RINGKASAN

ASRI RACHMAWATI. Model Prediksi Probabilistik Debit Air Masuk Waduk Kaskade Citarum Dengan SEASV-ECMWF Terkoreksi. Dibimbing oleh I PUTU SANTIKAYASA, IMPRON, dan FURQON ALFAHMI.

Indonesia sebagai negara dengan iklim tropis memiliki berkah sekaligus tantangan tersendiri pada sektor sumber daya air. Adanya waduk dan bendungan dapat menjadi solusi ketidakseimbangan antara suplai dan pemenuhan kebutuhan air. Waduk Kaskade Citarum merupakan waduk dengan sistem berjenjang terbesar di Indonesia, memiliki peran yang besar dalam perkembangan ekonomi di Indonesia. Selain sebagai *hydropower* yang menyuplai listrik untuk Pulau Jawa dan Bali, Waduk Jatiluhur merupakan waduk dengan fungsi irigasi dan menyuplai air baku untuk wilayah Jawa Barat dan DKI Jakarta. Berdasarkan pedoman Pola Operasi Waduk (POW) dan Rencana Tahunan Operasi Waduk (RTOW), prediksi *inflow* waduk merupakan tahapan fundamental untuk mencapai optimasi pengoperasian waduk. Sehingga, penelitian ini bertujuan untuk mengembangkan model prediksi probabilistik *inflow* Waduk Kaskade Citarum berbasis Artificial Neural Network dengan data *input* adalah model prediksi ensemble curah hujan *Set V model*, *Seasonal 7-month forecast* (SEASV) terkoreksi. Penelitian ini diharapkan dapat menggali lebih jauh potensi sumber daya data BMKG yang diperoleh secara eksklusif dari ECMWF, serta menambah perspektif baru bagi pemangku kebijakan yang selaras dengan program *Impact Based Forecast* (IBF) yang sedang dikembangkan secara intensif di lingkungan BMKG.

Data yang digunakan yakni data curah hujan observasi dari 57 stasiun dan pos hujan, data model prediksi curah hujan ensemble SEASV, data pengamatan debit air masuk dan keluar waduk rata-rata bulanan pada periode 1990-2019 untuk Waduk Saguling, 2003-2019 untuk Waduk Cirata, dan tahun 1994-2019 untuk Waduk Jatiluhur. Beberapa tahapan pengolahan data dan analisis dalam penelitian ini antara lain pengumpulan data, *preprocessing* data, pembangunan model, analisis statistik dengan menggunakan RMSE, korelasi Pearson dan Brier *score*, serta analisis dan simulasi prediksi berbasis probabilistik.

Hasil penelitian menunjukkan bahwa model probabilistik *inflow* Waduk Saguling dan Waduk Cirata memiliki kehandalan yang tinggi dan model mampu menyajikan skenario prediksi probabistik *inflow* untuk jangka waktu prediksi enam bulan ke depan. Waduk Jatiluhur memiliki *historical* data *inflow* yang sangat mirip dengan data *outflow* Waduk Cirata, hal ini karena masuknya air ke Waduk Jatiluhur diatur dengan ketat untuk memastikan Tinggi Muka Air Waduk Jatiluhur berada pada level optimum. Sehingga nilai *inflow* lokalnya sangat kecil dan relatif tidak signifikan atau dengan kata lain curah hujan yang terjadi di area tangkapan hujan tidak berpengaruh secara signifikan kecuali untuk presipitasi yang langsung jatuh pada permukaan waduk. Oleh karena itu, diperlukan penelititain lanjut untuk mengembangkan model probabilistik *inflow* yang dapat mengakomodir prediksi yang sesuai standar operasi prosedur pelepasan debit keluar Waduk Saguling dan Cirata.

Kata kunci: Jaringan syaraf tiruan, Model ensemble, Waduk kaskade Citarum



## SUMMARY

ASRI RACHMAWATI. Cascade Dam Citarum Inflow Probabilistic Prediction Model using Corrected SEASV-ECMWF. Supervised by I PUTU SANTIKAYASA, IMPRON, and FURQON ALFAHMI.

Indonesia as a tropical country has blessings and challenges in water resources. The reservoirs may be one of the best problem solvers of the water supply and demand imbalance. Citarum Cascade Dam is prominent for Indonesia's economic development. It supplies electricity for Java and Bali island and water for irrigation purposes. Based on the reservoir operation plans guidelines, the inflow prediction is the fundamental step to achieve reservoir operation optimization. Thus, this study aims to develop a probabilistic prediction model of Citarum Cascade Reservoir inflow based on Artificial Neural Network algorithm using corrected SEASV as the input model. The researchs were expected to enrich the usage of the BMKG's data resources that are exclusively obtained from ECMWF. As well as offering new perspectives for the decision maker that are in line with the Impact Based Forecast (IBF) program.

This study use the observational rainfall data from 57 stations and rain posts, the ensemble rainfall prediction model (SEASV), Cascade Dam Citarum inflow and outflow (between 1990-2019 for the Saguling Reservoir, 2003-2019 for the Cirata Reservoir, and 1994-2019 for Jatiluhur Reservoir). The procedures of this research are data collection, preprocessing, ANN model development, a statistical analysis using RMSE, Pearson correlation, and Brier score, and probabilistic prediction analysis and simulation.

The results show that the inflow probabilistic prediction model for Saguling and Cirata reservoirs have a good performance and it is capable to simulate the probabilistic prediction scenarios for six months ahead properly. By the historical data, Jatiluhur inflow are relatively similar with the Cirata outflow. Since, the Jatiluhur Reservoir water intake is strictly regulated to ensure the Water Level of Jatiluhur Reservoir always at the optimum level. So that the local inflow value is very small and the rainfall that occurs in the rain catchment area has no significant effect except for precipitation that directly falls on the surface of the reservoir. Therefore, further research is needed to develop a probabilistic inflow model that can accommodate standard operating procedures for predicting the outflow from the Saguling and Cirata Reservoirs.

**Keywords:** Artificial neural networks, Ensemble model, Cascade Dam Citarum



© Hak Cipta milik IPB, tahun 2022  
Hak Cipta dilindungi Undang-Undang

*Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan atau menyebutkan sumbernya. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik, atau tinjauan suatu masalah, dan pengutipan tersebut tidak merugikan kepentingan IPB.*

*Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apa pun tanpa izin IPB.*

Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
  - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.



# **MODEL PREDIKSI PROBABILISTIK DEBIT AIR MASUK WADUK KASKADE CITARUM DENGAN SEASV-ECMWF TERKOREKSI**

**ASRI RACHMAWATI**

Tesis  
sebagai salah satu syarat untuk memperoleh gelar  
Magister pada  
Program Studi Klimatologi Terapan

**KLIMATOLOGI TERAPAN  
SEKOLAH PASCASARJANA  
INSTITUT PERTANIAN BOGOR  
BOGOR  
2022**

- Hak Cipta Dilindungi Undang-undang
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
    - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
    - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
  2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.



**@Hak cipta milik IPB University**

Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
  - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.



Judul Tesis : Model Prediksi Probabilistik Debit Air Masuk Waduk Kaskade  
Citarum Dengan SEASV-ECMWF Terkoreksi  
Nama : Asri Rachmawati  
NIM : G251190071

Disetujui oleh

Pembimbing 1:  
Dr. I Putu Santikayasa, S.Si., M.Sc



Pembimbing 2:  
Dr. Ir. Impron, M. Agr.Sc



Pembimbing 3:  
Dr. Furqon Alfahmi, M.Si



Diketahui oleh

Ketua Program Studi:  
Dr. I Putu Santikayasa, M.Sc.  
NIP. 19790224200501 1 002



Dekan Fakultas Matematika dan  
Ilmu Pengetahuan Alam :  
Dr. Berry Juliandi, S.Si., M.Si  
NIP. 19780723200701 1 001



Tanggal Ujian:  
28 Desember 2021

Tanggal Lulus:  
27 Januari 2022

## PRAKATA

Puji dan syukur penulis panjatkan kepada Allah *subhanaahu wa ta'ala* atas segala karunia-Nya sehingga penulis dapat menyelesaikan tesis yang berjudul “Model Prediksi Probabilistik Debit Air Masuk Waduk Kaskade Citarum Dengan SEASV-ECMWF Terkoreksi” ini. Tesis ini disusun sebagai salah satu persyaratan dalam menyelesaikan studi Magister Sains pada Program Studi Klimatologi Terapan, Departemen Geofisika dan Meteorologi, IPB University.

Penyusunan tesis ini tidak terlepas dari bantuan, dukungan dan doa dari berbagai pihak. Oleh karena itu penulis ingin mengucapkan terimakasih kepada:

1. Dr. I Putu Santikayasa, Dr. Impran, dan Dr. Furqon Alfahmi, selaku komisi pembimbing yang telah dengan sabar membimbing dan memberi saran serta masukan dalam penyusunan tesis ini.
2. Segenap staf pengajar dan pegawai Departemen Geofisika dan Meteorologi yang telah memberikan ilmu dan bantuan proses administrasi dengan baik.
3. Jajaran Pimpinan Badan Meteorologi Klimatologi dan Geofisika yang telah memberikan kesempatan serta dukungan moril dan materil untuk melanjutkan pendidikan Magister.
4. Dr. Indra Gustari dan rekan-rekan pegawai Stasiun Klimatologi Bogor yang senantiasa memotivasi dan membantu penyelesaian studi ini. Serta Abdul Mutholib, M.Si selaku Kepala Stasiun Klimatologi Bogor tahun 2019 yang telah memberi kesempatan serta dukungan moriil untuk melanjutkan pendidikan Magister.
5. Prada Wellyantama, Mamo Supratmo, Fatimah, Suzanna, Almer, Mika dan segenap keluarga besar yang senantiasa yang telah mengizinkan dan mendoakan serta mendukung untuk melanjutkan Pendidikan Magister.
6. Siti Amanah, Anjasarie Eka, Wydya, Liliyanti yang selalu memotivasi tanpa ragu, tanpa tapi dan tanpa nanti.
7. Robi Muharsyah, M.Si dari BMKG Pusat, Andre PT. Indonesia Power Saguling POMU, Faris dari BPW Cirata dan Anita dari PJT II, yang telah banyak membantu dalam proses penyediaan data tesis.
8. Agita Vivi Wijayanti, Sri Noviati, Lisnawati, Eko Haryanto, Eko Supriyadi, Adyaksa Budi, Bony Septian sesama rekan penerima beasiswa S2 Kerjasama BMKG dan IPB University tahun 2019 yang selalu bersedia berbagi motivasi, canda tawa dan perjuangan dalam menyelesaikan studi, dan Ben Andaru dari Sekretariat Prodi KLI yang selalau kami repotkan dari awal masuk hingga diujung masa pendidikan.
9. Rekan-rekan Departemen Geofisika dan Meteorologi yang telah bersama-sama berjuang untuk menyelesaikan studi.

Semoga tesis ini bermanfaat bagi pihak yang membutuhkan dan bagi kemajuan ilmu pengetahuan.

Bogor, Januari 2022

*Asri Rachmawati*



### @Hak cipta milik IPB University

Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
  - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

## DAFTAR ISI

DAFTAR TABEL	xviii
DAFTAR GAMBAR	xviii
DAFTAR LAMPIRAN	xix
<b>I PENDAHULUAN</b>	<b>1</b>
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan	5
1.4 Manfaat	5
1.5 Ruang Lingkup	5
<b>II TINJAUAN PUSTAKA</b>	<b>6</b>
2.1 Daerah Aliran Sungai Citarum	6
2.2 Manajemen Operasi Waduk Kaskade	7
2.3 <i>Set V model Seasonal 7-month forecast (SEASV) - ECMWF</i>	9
2.4 Artificial Neural Network	10
<b>III METODE</b>	<b>13</b>
3.1 Waktu dan Tempat Penelitian	13
3.2 Alat dan Data	13
3.3 Pengolahan dan Analisis Data	14
<b>IV HASIL DAN PEMBAHASAN</b>	<b>19</b>
4.1 Kondisi Klimatologis dan Hidrologis DAS Citarum	19
4.2 Hasil Koreksi Bias dengan Metode <i>Linier Scaling</i>	21
4.3 Tahap pelatihan dan pengujian model	23
4.4 Kemampuan Prediksi Probabilistik <i>Inflow</i> Waduk Saguling	24
4.5 Kemampuan Prediksi Probabilistik <i>Inflow</i> Waduk Cirata	27
4.6 Kemampuan Prediksi Probabilistik <i>Inflow</i> Waduk Jatiluhur	28
<b>V SIMPULAN DAN SARAN</b>	<b>31</b>
5.1 Simpulan	31
5.2 Saran	32
DAFTAR PUSTAKA	33
LAMPIRAN	36
RIWAYAT HIDUP	47

Hak Cipta Dilindungi Undang-undang  
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :  
a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah  
b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.  
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.



## DAFTAR TABEL

1	Spesifikasi model curah hujan SEASV dan Set IV luaran ECMWF	9
2	Inventaris data penelitian	13
3	Interpretasi korelasi Pearson	17
4	Rekapitulasi pengukuran statistik model pada tahapan pelatihan dan pengujian model	23
5	Perhitungan probabilitas prediksi <i>inflow</i> Waduk Saguling untuk Januari-Juni 2019 dalam satuan (%)	26
6	Rekapitulasi Brier <i>score</i> prediksi <i>inflow</i> Waduk Saguling tahun 2019	27
7	Perhitungan probabilitas prediksi <i>inflow</i> Waduk Cirata untuk Januari-Juni 2019 dalam satuan (%)	28
8	Rekapitulasi Brier <i>score</i> prediksi <i>inflow</i> Waduk Cirata tahun 2019	28
9	Rekapitulasi Brier <i>score</i> prediksi <i>inflow</i> Waduk Jatiluhur tahun 2019	29
10	Perhitungan probabilitas prediksi <i>inflow</i> Waduk Jatiluhur untuk Januari-Juni 2019 dalam satuan (%)	30

## DAFTAR GAMBAR

1	Peta wilayah DAS Citarum	6
2	Prinsip dasar waduk berjenjang atau kaskade	8
3	Arsitektur model ANN dengan fungsi <i>Backpropagation</i>	11
4	Arsitektur model prediksi probabilistik debit air masuk waduk	15
5	Diagram kerja penelitian	18
6	Rerata aritmatik curah hujan tahunan DAS Citarum	19
7	Klimagram curah hujan dan debit air masuk waduk	20
8	Perbandingan antara data curah hujan bulanan observasi dan <i>ensemble mean</i> model curah hujan bulanan SEASV terkoreksi	21
9	Diagram <i>scatterplot</i> perbandingan sebaran model SEASV sebelum dan sesudah koreksi bias dengan data pos hujan	22
10	Diagram hasil koreksi bias model SEASV ECMWF dengan data Pos hujan di area tangkapan hujan Waduk Saguling (a), Waduk Cirata (b), dan Waduk Jatiluhur (c)	22
11	Prediksi deterministik <i>inflow</i> Waduk Saguling (a), Waduk Cirata (b) dan Waduk Jatiluhur (c).	24
12	Prediksi probabilistik (area abu-abu) <i>inflow</i> Waduk Saguling beserta perbandingan nilai <i>ensemble mean</i> (garis hitam) dengan data pengamatan debit (garis merah)	25
13	Prediksi probabilistik (area abu-abu) debit masuk Waduk Cirata beserta perbandingan nilai <i>ensemble mean</i> (garis hitam) dengan data pengamatan debit (garis merah)	27
14	Prediksi probabilistik (area abu-abu) debit masuk Waduk Jatiluhur beserta perbandingan nilai <i>ensemble mean</i> (garis hitam) dengan data pengamatan debit (garis merah)	29

Hak Cipta Dilindungi Undang-undang  
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :  
a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah  
b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.  
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

## DAFTAR LAMPIRAN

1	Rancang coba model prediksi <i>inflow</i> Waduk Saguling dengan data input menggunakan data curah hujan bulanan observasi di area tangkapan hujan Waduk Saguling	37
2	Perbandingan klimagram Waduk Saguling Tahun 2019 dengan klimagram normalnya (30 tahun)	38
3	Data timeseries <i>outflow</i> rata-rata bulanan Waduk Cirata dan <i>inflow</i> rata-rata bulanan Waduk Djuanda atau Jatiluhur	38
4	Lampiran 4 Contoh script koreksi bias model SEASV pada grid d5	39
5	Contoh script pembangunan model prediksi probabilistik <i>inflow</i> di Waduk Saguling	40
6	Lampiran 5 Contoh script analisis probabilistik prediksi <i>inflow</i> di Waduk Saguling	41
7	Contoh script perhitungan Brier score	42

Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :

- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
- Pengutipan tidak merugikan kepentingan yang wajar IPB University.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.



# I PENDAHULUAN

## 1.1 Latar Belakang

Indonesia sebagai negara beriklim tropis memiliki berkah sekaligus tantangan tersendiri, dengan dua musim yakni musim hujan dan musim kemarau yang menyebabkan potensi terjadinya ketidakseimbangan antara suplai dan pemenuhan akan kebutuhan air. Ditambah lagi dengan dorongan variabilitas serta perubahan iklim yang mengakibatkan pergeseran distribusi curah hujan baik dalam skala bulanan maupun musiman sehingga mengakibatkan *gap* ketersediaan air antar musim semakin jauh, musim kering dapat menjadi sangat kering dan musim hujan menjadi semakin ekstrim. Potensi ketidakseimbangan ini diindikasikan oleh seberapa besar pula potensi bencana hidrometeorologi yakni bencana banjir dan kekeringan. Salah satu solusi tantangan ini adalah dibangunnya bendungan atau waduk yang dapat meminimalisir resiko bencana hidrometeorologi serta menjadi sumber energi listrik (*hydropower*) potensial.

Kunci keberhasilan tujuan dari pembangunan waduk serta tercapainya pengelolaan sumber daya air yang berkelanjutan dan berbasis resiko adalah memprediksi kondisi sumber daya air (keadaan hidrologi) dimasa yang akan datang (Sudheer, Maheswaran, Paniraghi, & Mathur, 2014). Prediksi dibidang hidrologi dapat memberikan informasi yang berharga untuk membantu pengelola sumber daya air dalam pengoperasian infrastruktur terkait air yang efisien dan mitigasi dampak bencana alam dan variabilitas iklim (Butts *et al.* 2017). Prediksi keadaan hidrologi di masa mendatang dapat dikategorikan berdasarkan periodenya dibagi menjadi prediksi jangka pendek, menengah dan panjang. Berdasarkan pedoman Pola Operasi Waduk (POW) dan Rencana Tahunan Operasi Waduk (RTOW), prediksi *inflow* waduk merupakan tahapan fundamental untuk mencapai optimasi pengoperasian waduk (Pusdiklat SDA & Konstruksi 2017). Prediksi dengan skala waktu bulan dan musiman termasuk pada prediksi jangka panjang, prediksi inilah yang biasa dimanfaatkan secara luas dalam pengelolaan air waduk untuk keperluan irigasi dan lainnya. Perhitungan besarnya *inflow* yang akan masuk ke masing-masing waduk untuk tahun direncanakan berdasarkan prediksi kondisi musim oleh Badan Meteorologi, Klimatologi dan Geofisika (BMKG). Prinsip dasar perhitungan besarnya debit *inflow* untuk waduk kaskade sama dengan waduk tunggal namun demikian besarnya *inflow* untuk waduk kaskade yang ada dibagian hilir akan sangat dipengaruhi oleh pola *outflow* dari waduk kaskade yang ada di bagian hulu (Pusdiklat SDA & Konstruksi 2017).

Waduk Kaskade Citarum memiliki peran penting dalam pembangunan ekonomi di Indonesia. Sebagai PLTA, waduk ini menghasilkan total 1,973 MW, yang digunakan untuk memasok listrik ke pulau Jawa dan Bali. Kemudian waduk Jatiluhur yang merupakan waduk yang terbesar merupakan waduk multiguna yang berfungsi untuk memasok 240,000 ha air irigasi, air baku di Jawa Barat dan DKI Jakarta, kawasan industri, dan untuk menyiram drainase di provinsi DKI Jakarta pada musim kemarau (Mayasari dan Gunady 2015). Dengan mempertimbang betapa pentingnya Waduk Kaskade Citarum, maka penelitian ini bertujuan untuk membangun model prediksi debit air masuk rata-rata bulanan waduk di masing masing Waduk Kaskade Citarum.

Sejak awal tahun sembilan puluhan, *Artificial Neural Network* (ANN) telah banyak dimanfaatkan di berbagai bidang terkait hidrologi seperti pemodelan curah hujan-limpasan, prediksi *streamflow*, pemodelan air tanah, kualitas air, kebijakan pengelolaan air, perkiraan curah hujan, deret waktu hidrologi, dan operasi waduk (ASCE 2000). Hal ini mengingat performanya yang relatif baik serta memiliki kelebihan biaya komputasi yang relatif terjangkau (Coulibaly 2010; Pradeepakumari dan Srinivasu 2019). Seiring waktu perkembangan model berbasis ANN kian berkembang menjadi algoritma adaptif lainnya, salah satunya yakni model prediksi ensemble yang dikembangkan dari ANN konvensional atau disebut *Ensemble Neural Network* (ENN) (Aqil *et al.* 2007; Araghinejad *et al.* 2011). Coulibaly *et al.* memprakarsai penggunaan pendekatan *stop-training* untuk melatih jaringan pada model *Multi-Layer Feed-Forward Neural Networks* (FNN) dalam membangun model prediksi hidrologi dalam sistem hidro Chute-du-Diable di Quebec utara (Kanada). Hasil penelitian menunjukkan bahwa metode yang diusulkan merupakan model yang efektif untuk prediksi reservoir *inflow* secara *real-time* dengan biaya komputasi yang relatif terjangkau (Coulibaly *et al.* 2000). Penelitian lainnya yakni memanfaatkan pendekatan *reservoir computing* ANN untuk memprediksi *inflow* harian Bendungan Srisilam. Penelitian ini menunjukkan hasil model performa *reservoir computing* ANN lebih baik dari model *Auto Regressive Integrated Moving Average* (ARIMA) dan ANN konvensional yang digunakan sebagai metode pembandingan (Pradeepakumari dan Srinivasu 2019). Brath *et al.* (2002) menggunakan prediksi curah hujan jangka pendek sebagai *input* dari beberapa model hidrologi non-parametrik untuk memperbarui prediksi *discharge* dan hasilnya menunjukkan peningkatan yang luar biasa dapat dicapai dibandingkan dengan *discharge* dari model konseptual saja.

Seiring waktu perkembangan model yang berdasarkan pada ANN model kian berkembang menjadi banyak metode metode ANN adaptif lainnya, salah satunya yakni model prediksi ensemble yang dikembangkan dari ANN konvensional atau disebut *Ensemble Neural Network* (ENN). Pengembangan model ANN konvensional menjadi prediksi hidrologi probabilistik, dengan mamfaatkan tehnik ensemble yang terdiri dari 2 tahapan yakni membuat *single* ANN terlebih dahulu, baru kemudian menggabungkan luaran model-model tersebut untuk memperoleh luaran prediksi yang sesuai. Sebagai perbandingan disimulasikan juga model *K Nearest Neighbors* (KNN), ANN Multilayer Perceptron (MLP), dan MLP yang digabungkan dengan fungsi *Peak and Low Criteria* (PLC). Metode yang dikembangkan ini mampu meningkatkan *skill* prediksi probabilistik pada beberapa kasus hidrologi yang disimulasikan yakni prediksi debit puncak banjir dan prediksi aliran arus musiman (Araghinejad *et al.* 2011). Penelitian lainnta, menerapkan metode *Decomposition-Ensemble Learning* pada model berbasis algoritma *Long Short-Term Memory Neural Network* (DEL-LSTM) dalam prediksi debit air masuk waduk pada skala harian di Waduk Ankang, Cina. Data debit didekompisisi menjadi komponen trend (T), periodik (P) dan stokastik (S) dengan *Ensemble Empirical Mode Decomposition* (EEMD) dan transformasi Fourier, kemudian masing-masing komponen ini dimodelkan secara terpisah dengan menggunakan model LSTM, pada tahap akhir masing-masing komponen prediksi ini kemudian diensemble kembali untuk memperoleh nilai prediksi *inflow* yang seutuhnya. Dibandingkan dengan metode prediksi lainnya seperti *Multiscale Deep Feature Learning* (MDFL), ARIMA dan *Empirical Mode Decomposition-Deep Neural*

Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah  
b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.



*Network* (EMD-DNN), metode DEL-LSTM menunjukkan akurasi yang lebih baik, dengan nilai MAPE berkurang 13.11% dan NMSE berkurang 4% serta koefisien determinasi meningkat 5% (Qi *et al.* 2019).

Ensemble prediction system (EPS) adalah sistem prediksi cuaca numerik (NWP) yang memperkirakan ketidakpastian dalam perkiraan cuaca serta hasil yang paling mungkin. Beberapa contoh model EPS adalah *Set V, Seasonal 7 month forecast* (SEASV) dan *Set IV Ensemble System extended* dari ECMWF, *The Global Ensemble Forecast System (GEFS) weather model* dari the National Centers for Environmental Prediction (NCEP) dan *JMA's Ensemble Prediction System* yang merupakan produk *Long-Range Forecasting* dari WMC Tokyo. Berbeda dengan prediksi deterministik dimana pembangunan model NWP dijalankan dengan satu skenario rata-rata. Model probabilistik dibangun dengan menjalankan beberapa skenario dengan beragam *initial condition* yang berbeda (WMO, 2012) sehingga menghasilkan nilai prediksi yang berbeda-beda dan dapat dianalisis dengan konsep peluang dan skenario apa saja yang mungkin terjadi serta lebih jauh skenario mitigasi apa saja yang dapat dilakukan oleh pemangku kebijakan. Sehingga jika dibandingkan dengan prediksi deterministik, prediksi probabilistik memiliki kelebihan mampu menjelaskan ketidakpastian pada suatu sistem prediksi, dimana hal ini sangat penting untuk dipertimbangkan meskipun akurasi model prediksinya diyakini sangat tinggi. Dengan menggabungkan antara model prediksi probabilistik sebagai data input dari model ANN, dapat diperoleh model prediksi hidrologi yang bersifat probabilistik. Butts pada tahun 2017 mengkaji bagaimana model EPS ECMWF system 4 dimanfaatkan sebagai data masukan dalam prediksi probablistik streamflow, kemudian Visser pada tahun yang sama mengaplikasikan metode yang sama dan mengkaji lebih luas pada studi kasus di Upper Maule River Basin, Chile (Butts *et al.* 2017; Visser 2017). Zhang *et al.* (2009) menyusun algoritma sederhana namun diklaim efektif untuk prediksi *inflow* harian waduk, dengan prediktor nya adalah nilai prediksi curah hujan harian dan *discharge* pada 1-6 hari selanjutnya sebagai target yang diprediksi dalam pemodelan *multilayer perceptron artificial neural networks* (MLP-ANNs) di hydropower yang paling berperan di Provinsi Fujian dan hasilnya menunjukkan bahwa model mampu menghasilkan prediksi yang memuaskan tidak hanya pada kesesuaian modelnya atau *goodness of fit* tetapi juga untuk hasil generalisasi model (Zhang, *et al.* 2009).

Penelitian terdahulu yang berfokus di wilayah DAS Citarum diantaranya; eksperimentasi prakiraan debit masuk dengan model ARIMA di Waduk Saguling sebagai metode alternatif dalam evaluasi kegiatan modifikasi cuaca (Tikno 2000); perbandingan prediksi aliran sungai Citarum dengan menggunakan model *Neuro-Fuzzy* dan regresi linier berganda (Aqil *et al.* 2007); prediksi debit air masuk waduk dengan metode stokastik Chain Markov pada *study* kasus pengelolaan waduk Saguling (Nuraeni 2011; Marselina *et al.* 2017); verifikasi prediksi aliran sungai Citarum hulu dengan luaran model *climate forecast system version 2* (CFSv2) (Lestari *et al.* 2018); pemodelan *inflow* pada sistem waduk kaskade Citarum dengan menggunakan model Thomas dan Fearing sebagai dasar perhitungan produksi energi listrik yang diproduksi oleh masing-masing waduk (Empung *et al.* 2019); estimasi potensi debit aliran lokal Waduk Saguling menggunakan model hujan limpasan (Ferdiansyah *et al.* 2020).

Penelitian serupa yang membahas operasional waduk kaskade belum banyak ditemukan khususnya di wilayah Indonesia, hal ini karena memang tidak banyak



waduk yang memiliki sistem Kaskade. Namun untuk perkembangan pemodelan untuk operasional Waduk Kaskade di negara subtropis terus berkembang hingga dapat memodelkan faktor pengambilan keputusan pelepasan debit keluar waduk dengan menggunakan algoritma *deep learning* yang kompleks (Xu *et al.* 2020).

Berdasarkan uraian-uraian diatas maka dapat disimpulkan bahwa keberhasilan model berbasis ANN pada prediksi hidrologi telah banyak dibuktikan, namun demikian prediksi probabilistik debit air masuk waduk dengan pendekatan *machine learning* maupun *deep learning* belum banyak diterapkan khususnya pada waduk dengan karakter kaskade atau berjenjang di wilayah Indonesia. Demikian juga dengan metode probabilistik untuk prediksi *inflow* Waduk kaskade masih belum ada yang melakukan pendekatan ini di Indonesia. Selain itu pada Januari 2015, BMKG mulai menyajikan produk prakiraan probabilistik curah hujan yang dihasilkan dari *European Centre for Medium-Range Weather Forecasts* (ECMWF) (Muharsyah *et al.* 2020). Sehingga, penelitian ini bertujuan untuk mengembangkan model probabilistik *inflow* Waduk Kaskade Citarum berbasis *Artificial Neural Network* dengan data input model ensemble curah hujan *Set V model, Seasonal 7-month forecast* (SEASV) terkoreksi. Penelitian ini diharapkan dapat menggali lebih jauh potensi sumber daya data BMKG yang diperoleh secara eksklusif dari ECMWF, serta menambah perspektif baru yang selaras dengan program *Impact Based Forecast* (IBF) sehingga dapat menjadi bahan pertimbangan bagi pemangku kebijakan dalam rangka perencanaan manajemen operasional waduk.

## 1.2 Rumusan Masalah

Sesuai dengan uraian latar belakang dan kerangka berpikir penelitian ini, maka beberapa masalah yang diteliti yakni :

1. Mengkaji pengaruh curah hujan terhadap debit air masuk di Waduk Kaskade Citarum.
2. Mengevaluasi performa model SEAS V dalam mewakili distribusi curah hujan di di wilayah DAS Citarum.
3. Mengembangkan model berbasis ANN untuk memprediksi *inflow* waduk dengan sistem kaskade.
4. Mengembangkan model probabilistik dalam memprediksi *inflow* di masing-masing waduk kaskade Citarum yakni Waduk Saguling, Waduk Cirata dan Waduk Jatiluhur.

### 1.3 Tujuan

Penelitian ini bertujuan untuk mendukung manajemen pengelolaan air waduk dalam rangka mitigasi bencana hidrometeorologi di wilayah Jawa Barat dan sekitarnya. Adapun tujuan tersebut dapat dikembangkan berdasarkan rumusan masalah sebagai berikut :

1. Menjelaskan karakteristik pengaruh curah hujan terhadap debit air masuk waduk di Waduk Kaskade Citarum.
2. Mengevaluasi pemanfaatan model prediksi curah hujan SEASV
3. Mengevaluasi implementasi model SEASV sebagai masukan model berbasis algoritma ANN untuk prediksi debit air masuk di lokasi penelitian mulai dari pemodelan deterministik hingga probabilistik.
4. Mengevaluasi penerapan model prediksi dengan konsep *machine learning* sebagai jembatan dari salah satu produk berkonsep IBF.

### 1.4 Manfaat

Penelitian ini diharapkan dapat mengevaluasi serta memperkaya sisi pemanfaatan model prediksi ensemble SEASV. Kemudian juga mengevaluasi pemanfaatan metode *machine learning* khususnya ANN dalam rangka pencapaian tujuan IBF di bidang hidrologi, sehingga dapat memberikan perspektif lain dalam prediksi berbasis probabilistik untuk mendukung peran BMKG dalam Tim Koordinasi Pengelolaan Bendungan Kaskade Citarum (TKPBKC) khususnya dalam manajemen pengelolaan waduk yang bersifat musiman atau jangka panjang.

### 1.5 Ruang Lingkup

Penelitian ini merupakan studi kasus dengan batasan ruang adalah area tangkapan hujan tiga waduk yang berada di Bendung Kaskade Citarum yaitu Waduk Saguling, Cirata dan Jatiluhur. Periode data yang digunakan pada penelitian adalah periode tiga puluh tahun terakhir yang dimulai dari 1990 hingga 2019. Skala waktu penelitian adalah bulanan dengan ketentuan curah hujan merupakan akumulasi curah hujan dalam periode satu bulan dengan satuan mm/bulan sedangkan data debit baik *inflow* maupun *outflow* merupakan data rata-rata bulanan yang diperhitungkan oleh pengelola waduk dengan satuan  $m^3/s$ . Ketidaksetaraan satuan dalam model tidak menjadi masalah dalam penggunaan metode ANN, karena proses-proses yang ada didalam model salah satunya adalah tahapan normalisasi variabel *input* dan target di awal pemodelan.

Model yang dibangun dalam penelitian ini menggunakan *single input variable*, dimana data curah hujan SEASV terkoreksi menjadi satu-satunya *input* model prediksi probabilistik *inflow* waduk ini. Adapun faktor-faktor lain yang biasanya digunakan dalam model fisis seperti penguapan, keadaan tanah dan lain sebagainya dianggap memiliki pengaruh yang konstan pada skala waktu bulanan, hal ini sesuai dengan tujuan pemanfaatan dari metode ANN ini sendiri yakni mengembangkan model yang efisien dan tidak membutuhkan variabel data yang banyak dan terkadang sulit didapatkan.






## II TINJAUAN PUSTAKA

### 2.1 Daerah Aliran Sungai Citarum

Sungai Citarum merupakan sungai terpanjang di Provinsi Jawa Barat yang mengalir sepanjang 297 km dari hulu Situ Cisanti di kaki Gunung Wayang sebelah selatan Kota Bandung, bermuara di pantai selatan Pulau Jawa tepatnya di Muara Gembong Kabupaten Bekasi (BBWS Citarum). Secara geografis, Wilayah Sungai Citarum berada di 106° 51'36" - 107° 51' BT dan 7° 19' - 6° 24' LS. Wilayah Sungai Citarum merupakan Wilayah Sungai terbesar di Provinsi Jawa Barat dan mempunyai luas kurang lebih 12.000 Km<sup>2</sup>, mencakup 13 wilayah administrasi Kabupaten/Kota di lingkungan Provinsi Jawa Barat, yaitu: Kab. Bandung, Kab. Bandung Barat, Kab. Bekasi, Kab. Cianjur, Kab. Bogor, Kab. Indramayu, Kab. Karawang, Kab. Purwakarta, Kab. Subang, Kab. Sumedang, Kota Bandung, Kota Bekasi dan Kota Cimahi, dengan batas wilayah sebagai berikut :

- Sebelah Utara berbatasan dengan Laut Jawa
- Sebelah Timur berbatasan dengan Kabupaten Garut, sebagian Kabupaten Indramayu dan sebagian Kabupaten Sumedang
- Sebelah Selatan berbatasan dengan sebagian Kabupaten Cianjur dan sebagian Kabupaten Bandung
- Sebelah Barat berbatasan dengan Kabupaten Sukabumi, sebagian Kabupaten Bogor dan sebagian Kabupaten Bekasi (Bappenas, 2012).



Gambar 1 Peta wilayah DAS Citarum

Lokasi penelitian merupakan DS Citarum hulu dan DS Citarum tengah yang kemudian dibagi kembali menjadi tiga area sesuai dengan deliniasi *catchment area* masing-masing waduk, tahapan ini sangat penting untuk

@Hak cipta milik IPB University

Hak Cipta Dilindungi Undang-undang  
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :  
a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah  
b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.  
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

memisahkan secara efektif data pos hujan mana saja yang memberi pengaruh untuk *inflow* masing-masing waduk kaskade Citarum. DAS Citarum hulu terbagi menjadi area yang berwarna ungu yang merupakan *catchment area* untuk Waduk Saguling dan area dengan polygon berwarna hijau merupakan *catchment area* Waduk Cirata. Sedangkan DS Citarum tengah dengan warna kuning adalah *catchment area* Waduk Jatiluhur. Data curah hujan pada masing-masing area akan menjadi faktor koreksi untuk data grid SEASV. Dan data grid pada area tersebutlah yang akan menjadi masukan model prediksi probabilistik *inflow* masing-masing waduk kaskade Citarum.

Topografi DAS Sungai Citarum digambarkan dalam bentuk lahan atau morfologi yang dapat dikelompokkan dalam 3 bagian, yaitu bagian hulu, tengah dan hilir. Wilayah Sungai Citarum bagian hulu nampak seperti cekungan raksasa yang lebih dikenal sebagai Cekungan Bandung, dengan elevasi berkisar antara 625 - 2.600 mdpl. DAS Citarum bagian tengah morfologi bervariasi antara dataran (elevasi 250 - 400m dpl), perbukitan bergelombang lemah (elevasi 200-800 mdpl), perbukitan terjal (elevasi 1.400 - 2400 mdpl) dan morfologi tubuh gunung api. DAS Citarum bagian hilir lebih didominasi oleh dataran, perbukitan bergelombang lemah dan terjal dengan variasi elevasi antara 200 - 1.200 mdpl. Topografi ini memberi pengaruh cuaca pada skala lokal yang berkontribusi membentuk kondisi klimatologis wilayah DAS Citarum. Meskipun demikian, iklim DAS Citarum memiliki karakter sebagaimana umumnya iklim di wilayah di Jawa Barat yakni iklim tropis monsoon dengan suhu dan kelembaban udara yang relatif konstan sepanjang tahun. Iklim tropis monsoon dicirikan dengan terjadinya dua musim, yaitu musim hujan dan kemarau. Musim hujan terjadi pada bulan-bulan Oktober hingga Maret, sedangkan untuk musim kemarau terjadi pada bulan-bulan Juni hingga September. bulan-bulan lainnya merupakan masa transisi atau pancaroba. Hampir 70% dari curah hujan tahunan terjadi selama musim hujan. Curah hujan di sekitar area bendungan kaskade memegang peranan penting pada ketersediaan air serta menjadi pertimbangan penting dalam perencanaan pengoperasian bendungan kaskade (BBWS Citarum).


## 2.2 Manajemen Operasi Waduk Kaskade

Waduk kaskade adalah beberapa waduk yang dibangun pada satu sungai yang sama dan biasanya beroperasi dalam satu sistem integrasi (Syariman dan Lubis 2004) (Gambar 2). Waduk kaskade Citarum terdiri dari Waduk Saguling, Cirata dan Jatiluhur. Waduk ini memiliki peran penting dalam pembangunan ekonomi di Indonesia. Waduk Saguling dan Cirata merupakan reservoir tenaga air yang menghasilkan total 1.973 MW untuk pasokan listrik di Pulau Jawa dan Bali, sedangkan Waduk Jatiluhur merupakan waduk multiguna yang berfungsi untuk memasok 240.000 ha air irigasi, air baku di Jawa Barat dan DKI Jakarta, kawasan industri, dan untuk menyiram drainase di provinsi DKI Jakarta pada musim kemarau (Mayasari dan Gunady 2015).

Pengukuran *inflow* dilakukan melalui pos duga air yang berada disekitar waduk, untuk mendapatkan data debit sungai pada suatu lokasi pos duga air diperlukan lima tahap pelaksanaan pekerjaan, yaitu pengumpulan data tinggi muka air, pengukuran debit sungai, perhitungan debit sungai, pembuatan lengkung debit, perhitungan dan evaluasi data debit. Pada waduk dengan tipe kaskade hasil pengukuran dan perhitungan *inflow* pada waduk yang berada di



tengah dan hilir merupakan besaran nilai debit total yang terdiri dari *outflow* waduk yang berada di hulunya dan *inflow* lokal dari sungai (Gambar 2). Sistem waduk kaskade yang terintegrasi ini bukan merupakan system yang tertutup melainkan terdapat kemungkinan adanya debit air masuk yang melewati subDAS maupun curahan hujan yang jatuh diatas waduk.



Gambar 2 Prinsip dasar waduk berjenjang atau kaskade

Prediksi debit air masuk atau *inflow* merupakan dasar atau permulaan prosedur operasi waduk. Debit sendiri merupakan laju aliran air yang melewati suatu penampang melintang sungai atau aliran air per satuan waktu (Askdak, 1995). Satuan debit yang lazim digunakan ialah  $m^3/detik$ . Perhitungan besarnya *inflow* yang akan masuk ke masing-masing waduk untuk tahun direncanakan berdasarkan prediksi kondisi musim oleh Badan Meteorologi, Klimatologi dan Geofisika. Prinsip dasar perhitungan besarnya debit *inflow* untuk waduk kaskade sama dengan waduk tunggal namun demikian besarnya inflow untuk waduk kaskade yang ada dibagian hilir akan sangat dipengaruhi oleh pola outflow dari waduk kaskade yang ada di bagian hulu.

Pola operasi waduk adalah patokan operasional bulanan suatu waduk saat debit air yang dikeluarkan oleh waduk harus sesuai dengan ketentuan agar tinggi muka airnya (TMA) terjaga sesuai dengan rancangan, hal ini bertujuan untuk memenuhi berbagai kebutuhan air dan pengendalian banjir di hilir sesuai dengan pola dan rencana operasi yang telah ditetapkan. Kegiatan operasi waduk meliputi pengumpulan dan pengolahan data hidrologi, penyusunan Pola Operasi Waduk (POW) dan Rencana Tahunan Operasi Waduk (ROTW), pelaksanaan operasi waduk pada berbagai kondisi (normal, banjir dan darurat), pelaksanaan kegiatan monitoring, pengendalian operasional dan evaluasi pelaksanaan operasi waduk , serta penyusunan laporan dan dokumentasi.

Salah satu pedoman operasi waduk kaskade adalah adanya ketentuan pembagian berimbang atau *equal sharing* di antara waduk-waduk sesuai dengan fungsi masing-masing waduk. Namun, kelemahan dari sistem ini adalah waduk menjadi tidak dapat beroperasi secara optimum karena yang menjadi prioritas operasional utama dari waduk kaskade dengan fungsi multiguna adalah mengamankan kebutuhan pengairan di daerah hilir untuk irigasi, air minum, rumah tangga, dan produksi listrik. Dalam operasionalnya waduk kaskade beroperasi secara proporsional berdasarkan volume efektif dari masing-masing waduk terhadap volume efektif totalnya (semua waduk) atau persentase volume efektif tiap bulan masing-masing waduk selalu sama. Contoh, tiga buah waduk yaitu waduk A, B dan C, dari hulu ke hilir berturut-turut mempunyai volume efektif 500 juta  $m^3$ , 650 juta  $m^3$ , dan 850 juta  $m^3$ . Volume efektif totalnya adalah 2000 juta  $m^3$ .



Berdasarkan pembagian berimbang dalam operasional bulanannya tiap waduk mempunyai volume efektif sebagai berikut :

$$\begin{aligned}
 500 \text{ Volume efektif waduk A} &= \text{-----} \times 100\% = \mathbf{25,00 \%} \times 2.000 \\
 650 \text{ Volume efektif waduk B} &= \text{-----} \times 100\% = \mathbf{32,50 \%} \times 2.000 \\
 850 \text{ Volume efektif waduk C} &= \text{-----} \times 100\% = \mathbf{42,50 \%} \times 2.000 \\
 \mathbf{Total} &= \mathbf{100,00 \%}.
 \end{aligned}$$

### 2.3 Set V model Seasonal 7-month forecast (SEASV) - ECMWF

*Ensemble prediction system* (EPS) adalah sistem prediksi cuaca numerik (NWP) yang memperkirakan ketidakpastian dalam perkiraan cuaca serta hasil yang paling mungkin. Jika pada model deterministik model hanya dijalankan untuk satu kali, pada model probabilistik model dijalankan berkali-kali dengan beragam *initial condition* yang sedikit berbeda (WMO 2012). Dibandingkan prediksi deterministik, prediksi probabilistik memiliki kelebihan mampu menjelaskan ketidakpastian pada suatu sistem prediksi, dimana hal ini sangat penting untuk dipertimbangkan meskipun akurasi suatu model diyakini sangat tinggi sehingga dapat diketahui peluang-peluang yang mungkin terjadi pada tingkat probabilitas yang beragam..

*Set V model Seasonal 7-month forecast* atau disingkat dengan SEASV merupakan model prediksi curah hujan yang bersumber dari *the European Centre for Medium-Range Weather Forecasts* (ECMWF) . terdiri dari ensembel prakiraan individu yang digabungkan dengan model laut dan produk *post-process* dari kondisi rata-ratanya (misalnya rata-rata bulanan) dengan ketidakpastian terkait (ECMWF 2017).

Spesifikasi model SEASV ditampilkan pada Tabel 1:

Tabel 1 Spesifikasi model curah hujan SEASV dan Set IV luaran ECMWF

Info	Prediksi Bulanan	Prediksi Dasarian
Tipe Data	Set V, <i>Seasonal 7 month forecast</i> (SEAS)	Set IV, <i>ES extended</i>
Resolusi Spasial	~0.75 <sup>0</sup>	~0.25 <sup>0</sup> (10 hari pertama) ~0.50 <sup>0</sup> ( hari ke 11-46)
Resolusi Temporal	Basis harian sampai 7 bulan (216 hari)	Basis harian hingga 46 hari
Initial Forecast	2 kali 1 minggu	Setiap tanggal 8
Peruntukan	Dekadal dan Bulanan	Bulanan, Musiman sampai bulan ke 7.
Format	GRIB 1	GRIB1
Variabel	TP ( <i>Total Precipitation</i> )	TP ( <i>Total Precipitation</i> )

Sumber : <http://www.ecmwf.int/en/forecasts>

Model SEASV yang digunakan dalam penelitian ini adalah model yang berskala bulanan dengan jangkauan prediksi hingga tujuh bulan ke depan atau memiliki *leadtime* nol hingga enam bulan. Istilah *lead time* merupakan jeda waktu antara waktu penerbitan prediksi dengan waktu prediksi itu sendiri. Jumlah member yang digunakan pada penelitian ini yakni dua puluh lima member untuk data

*reforecast* (periode 1990-2018) dan lima puluh satu member model untuk data *forecast* (periode tahun 2019). 25 member model *reforecast* pada *lead time* 0 pertama-tama dirata-ratakan sehingga diperoleh nilai rata-rata ensembel yang dapat digunakan untuk tahapan pelatihan dan pengujian model ANN pada tahap awal. Sedangkan luaran model SEASV pada *lead time* 1 hingga 6 bulan ke depan digunakan sebagai *initial condition* pada prediksi probabilistik *inflow* pada masing-masing waduk.

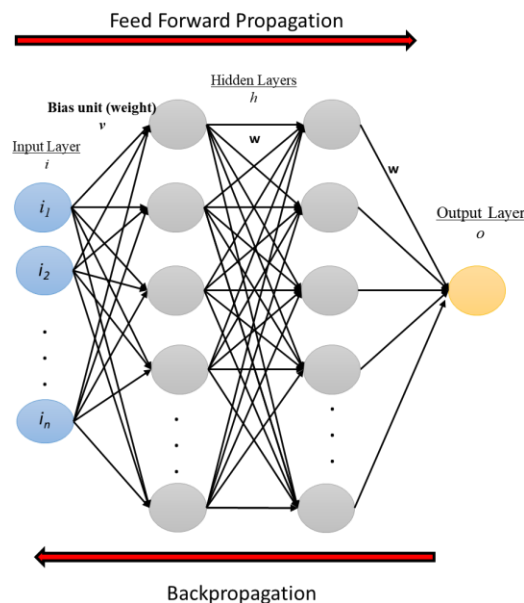
## 2.4 Artificial Neural Network

Selama beberapa dekade terakhir, telah banyak penelitian yang dikhususkan untuk perumusan dan pengembangan pendekatan dan model untuk meningkatkan kualitas prediksi hidrologi, termasuk model mekanistik dan model *black-box*. Model mekanistik yang menekankan pada penjabaran hukum-hukum alam dan fisika serta mencoba untuk membuat pemahaman yang komprehensif dan tajam dari setiap langkah dalam proses curah hujan, memiliki keterbatasan akan kebutuhan jumlah data besar dan berkualitas tinggi yang terkait dengan karakteristik hidrologi, meteorologi, geografis alami serta aktivitas manusia. Untuk sistem hydropower skala besar, memilih salah satu model mekanistik akan sulit karena kurangnya ketersediaan data (Irvine & Eberhardt, 1992). Di sisi lain terdapat pilihan model *machine learning*, *deep learning*, *artificial neural network* (ANN) dan lainnya yang merupakan model *black box* di mana struktur internal dari proses yang terlibat tidak dapat dipahami.

Model *machine learning* dan sejenisnya memiliki banyak keuntungan dari sudut pandang aplikasi praktis. Pertama, ia mampu mengenali hubungan antara variabel *input* dan *output* tanpa pertimbangan fisik eksplisit. Kelebihan yang kedua adalah sangat mudah untuk meninjau model ketika data *input*nya mengalami perubahan, sehingga dapat dihitung ulang segera setelah data baru tersedia dengan biaya rendah dan waktu relatif cepat. Ketiga, begitu model dikembangkan, dapat diadaptasi dengan sangat fleksibel ke area lain atau untuk tujuan lain (ASCE 2000b). Namun demikian, sesuai dengan studi literatur serta praktik terkait pemanfaatan metode ANN, metode ANN memiliki beberapa kekurangan diantaranya yakni membutuhkan set data *input* dan *target* yang sangat Panjang untuk memperoleh performa yang baik, dibutuhkan waktu relatif lama untuk proses *trial* desain arsitektur yang sesuai dalam menguji coba nilai bobot dan bias yang dapat membentuk pola model yang sesuai, pada kasus tertentu model sangat rentang menjadi *overfitting* dan tidak *robust*.

ANN didefinisikan sebagai suatu sistem pemrosesan informasi paralel yang didistribusikan secara masif yang memiliki karakteristik kinerja tertentu menyerupai jaringan saraf biologis otak manusia (Haykin, 2004). ANN dibentuk dengan tujuan untuk meniru kemampuan sistem syaraf makhluk hidup dalam melakukan berbagai tugas, meliputi mempelajari, mengingat dan mengeneralisir informasi-informasi yang disalurkan ke dalam sistem syaraf (Engelbrecht, 2007). Komponen utama model ANN adalah data *input*, pemrosesan informasi antar neuron, dan luaran model yang dibandingkan dengan target (Gambar 3). Komponen ini dapat diatur secara bebas untuk mendapatkan performa model terbaik (Irvine dan Eberhardt 1992).





Gambar 3 Arsitektur model ANN dengan fungsi *Backpropagation*

Gambar 3 adalah ilustrasi arsitektur jaringan saraf multi-layer metode *backpropagation* dengan satu lapisan tersembunyi. Elemen-elemen dalam vektor *input* diberi bobot oleh elemen-elemen matriks bobot masing-masing  $w$ . Setiap lapisan neuron memiliki bias  $b$  yang dijumlahkan dengan *input* berbobot untuk membentuk *input* jaringan ke- $n$ . Setiap node biasanya menerapkan transformasi nonlinier disebut fungsi aktivasi untuk input net untuk menentukan sinyal outputnya (ASCE, 2000). Unit luaran dan unit tersembunyi juga mungkin memiliki bias. Bias pada unit keluaran dilambangkan oleh  $w$ ; bias pada unit tersembunyi dilambangkan sebagai  $v$ . Bias ini bertindak seperti bobot pada koneksi dari unit-unit yang outputnya selalu 1 (biasanya tidak ditampilkan secara eksplisit pada ilustrasi). Kemudian sinyal dari bobot dan bias dikirim dalam arah sebaliknya untuk mengoreksi luaran nya agar serepresentatif mungkin dengan target. Algoritma yang digunakan dalam proses pelatihan jaringan dalam penelitian ini adalah algoritma *Backpropagation* Levenberg-Marquardt yang merupakan turunan dari dari metode Newton (Persamaan 1) yang dirancang untuk meminimalkan fungsi yang merupakan jumlah kuadrat dari fungsi nonlinier (Bharadwaj *et al.* 2021).

$$\Delta x_k = -[J^T(x_k)J(x_k)]^{-1} J^T(x_k) v(x_k) \quad (1)$$

satu-satunya masalah dengan metode Gauss-Newton adalah bahwa matriks mungkin bersifat *invertible*. Hal ini dapat diatasi dengan menggunakan modifikasi berikut pada perkiraan matriks Hessian ( $H$ ):

$$G = H + \mu I \quad (2)$$

sehingga, diperoleh algoritma Levenberg-Marquardt:

$$\Delta x_k = -[J^T(x_k)J(x_k) + \mu_k I]^{-1} J^T(x_k) v(x_k) \quad (3)$$

Dimana  $x_k$  merupakan aproksimasi algoritma Levenberg-Marquardt,  $J$  adalah lambing matriks Jacobian yang berisi turunan pertama dari kesalahan jaringan sehubungan dengan bobot dan bias ( $v, w$ ), kemudian  $H$  adalah matriks Hessian dan  $I$  adalah matriks Identitas. Dengan menggunakan arah gradien ini dan menghitung ulang aproksimasi indeks kinerja, jika diperoleh nilai yang lebih kecil, maka prosedur dilanjutkan dengan  $\mu_k$  dibagi beberapa faktor  $\vartheta > 1$ . Jika nilai performance index tidak dikurangi, maka  $k$  dikalikan dengan untuk langkah iterasi (Lv et al. 2018). Metode Newton lebih cepat dan lebih akurat mendekati kesalahan minimum. Dengan demikian, nilai  $\mu$  relatif menurun setelah setiap periode pelatihan selesai dan meningkat ketika langkah dapat meningkatkan fungsi kinerja. Dengan demikian, kinerja fungsi akan menurun pada setiap epoch atau iterasi dari algoritma.

Algoritma *Backpropagation* Levenberg-Marquardt dioperasikan dengan fungsi aktifasi  $f$ , yang menghasilkan output neuron  $a$  (Persamaan 4) (Lv et al., 2018)

$$a = f \left( \sum_{j=1}^n w_j P_j + b \right) \quad (4)$$

Dimana  $a$  menunjukkan luaran jaringan,  $w$  adalah *bobot*,  $j$  menunjukkan urutan ke- $j$  hingga ke  $n$ ,  $P$  adalah vector input,  $b$  adalah bias dari neuron dan  $f$  adalah fungsi aktivasi yang diadopsi ke model, fungsi aktivasi log-sigmoid diberikan oleh Persamaan 5:

$$f(x) = \frac{1}{1+e^{-x}} \quad (5)$$

variabel bobot dan bias disesuaikan menurut metode Levenberg-Marquardt, dan algoritma *backpropagation* digunakan untuk menghitung matriks Jacobian dari fungsi aktivasi sehubungan dengan variabel bobot dan bias. Dengan bobot dan bias yang diperbarui, ANN selanjutnya memperkirakan debit waduk sebagai luaran model ANN. Atas dasar proses berulang di atas, model prediksi debit dapat di *training* dengan baik (Lv et al. 2018). Fungsi log-sigmoid bukan satu-satunya pilihan fungsi aktifasi namun demikian fungsi ini yang lebih umum digunakan sebagai fungsi aktivasi *default*.

### III METODE

#### 3.1 Waktu dan Tempat Penelitian

Penelitian dilaksanakan di Stasiun Klimatologi Bogor yang merupakan UPT BMKG yang tergabung dalam Tim Koordinasi Pengelolaan Bendungan Kaskade Citarum (TKPBKC) dan di IPB University, pada rentang waktu antara Juli 2020 hingga Oktober 2021. Obyek penelitian adalah wilayah DAS Citarum dimana terdapat waduk kaskade Citarum yakni Waduk Saguling, Waduk Cirata dan Waduk Jatiluhur. Area yang diteliti juga dibatasi pada area hulu dan tengah hal ini mempertimbangkan faktor curah hujan di hulu masing-masing waduk yang memiliki pengaruh besar terhadap debit air masuk waduk.

#### 3.2 Alat dan Data

Pengelolaan data serta penyusunan penelitian dilaksanakan dengan menggunakan perangkat laptop dengan Operating System Windows 10. Dilengkapi dengan perangkat lunak Matlab R2019b, Arcgis 10.8, dan Microsoft Office 2016. Data yang digunakan dalam penelitian ini yakni;

Tabel 2 Inventaris data penelitian

No	Data	Satuan	Sumber
1.	Curah hujan	mm/bulan	Stasiun Klimatologi Bogor
2.	Curah hujan	mm/bulan	SEASV-ECMWF
3.	Debit masuk waduk	m <sup>3</sup> /bulan	PT. Indonesia power Saguling POMU Perum Jasa Tirta II BPW Cirata
4.	Debit keluar waduk	m <sup>3</sup> /bulan	PT. Indonesia power Saguling POMU Perum Jasa Tirta II BPW Cirata

Data curah hujan observasi dari 57 stasiun dan pos hujan, data ini digunakan untuk mengetahui kondisi klimatologis khususnya karakteristik curah hujan di wilayah DAS Citarum hulu dan tengah. Selain itu data ini juga digunakan dalam proses evaluasi dan koreksi data model curah hujan ensemble SEASV. Data curah hujan ensemble SEASV merupakan data prediksi curah hujan bersifat *reforecast* prediksi curah hujan ensemble SEASV dari ECMWF, data yang digunakan memiliki resolusi spasial 0.4 derajat dengan jangkauan prediksi 7 bulan (*leadtime* 0-6 bulan).

Data pengamatan debit air masuk dan keluar waduk rata-rata bulanan yang diperoleh dari pengelola waduk yakni PT. Indonesia power Saguling POMU, Badan Pengelola Waduk Cirata dan Perum Jasa Tirta II. Periode data-data tersebut disesuaikan dengan ketersediaan data debit air masuk yang diperoleh dari masing-masing pengelola waduk yakni 1990-2019 untuk Waduk Saguling, 2003-2019 untuk Waduk Cirata, dan tahun 1994-2019 untuk Waduk Jatiluhur.

### 3.3 Pengolahan dan Analisis Data

Ada beberapa tahap pengolahan data yang dilakukan dalam penelitian ini, antara lain *preprocessing* data observasi dan model, koreksi bias, pembangunan model deterministik, pembangunan model deterministik, serta analisis statistik.

@Hak cipta milik IPB University

#### 3.3.1 Preprocessing data

*Preprocessing* data merupakan proses awal memperlakukan data dengan sedemikian rupa supaya data siap digunakan dalam tahap pemodelan selanjutnya. Tujuannya adalah supaya data yang digunakan sesuai baik dari segi format, kesetaraan satuan dan kelengkapan datanya. Tahapan ini meliputi uji kualitas dan kuantitas data curah hujan observasi, dan untuk model SEASV meliputi ekstraksi data sesuai dengan domain penelitian, koreksi bias dan menghitung nilai rerata model atau *ensemble mean value*.

#### 3.3.2 Koreksi bias

Data model SEASV terlebih dahulu dikoreksi bias atau dikalibrasi dengan data observasi untuk menghilangkan bias atau error (Wang et al. 2018). Bias disebabkan oleh sifat umum dari keluaran model prediksi dinamis cuaca dan iklim akibatnya nilai prediksi berbeda dari observasi (L'Heureux et al. 2017). Di sisi lain, kesalahan dispersi disebabkan oleh prediksi ensemble yang over confidence, ditandai oleh sebaran anggota ensemble yang berkumpul pada satu nilai tertentu dan jauh dari observasi. Kesalahan dispersi seperti ini disebut juga underdispersive yang menyebabkan prediksi probabilistik menjadi tidak reliable dan kehandalannya buruk (Berner et al. 2015). Koreksi bias yang digunakan dalam penelitian ini adalah metode linier scaling. Metode ini mengoreksi nilai raw model dengan faktor koreksi yakni perbandingan antara nilai rerata observasi dan rerata ensemble model itu sendiri (Persamaan 6) (Lenderink et al. 2007).

$$P_{cor,m} = P_{raw,m} \frac{(\bar{P}_{obs,m})}{(\bar{P}_{raw,m})} \tag{6}$$

dimana  $P_{cor,m}$  adalah model terkoreksi,  $P_{raw,m}$  adalah data asli model sebelum dikoreksi,  $m_{th}$  adalah bulan (waktu).  $\bar{P}$  nilai rata-rata curah hujan sesuai (misal  $(\bar{P}_{obs,m})$  adalah nilai rerata dari curah hujan observasi pada bulan  $m$ ).

Untuk nilai rata-rata ensemble diperoleh dari menggabungkan hasil prediksi dengan rata-rata hasil prediksi dari seluruh *member* model

$$\bar{\psi}(\lambda, \phi) = \frac{1}{N} \sum_{j=1}^N \psi_j \tag{7}$$

dimana  $\psi(\lambda, \phi)$ , merupakan hasil gabungan dari N member prediksi yang ada dengan rata-rata  $\lambda$  dan varians  $\phi$  (Persamaan 7).


Hak Cipta Dilindungi Undang-undang  
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :  
a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah  
b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.  
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

### 3.3.3 Pembangunan model prediksi probabilistik *inflow*

Pembangunan model diawali dengan rancangan percobaan model dengan desain menggunakan data *input* model adalah murni data observasi curah hujan dan *inflow* itu sendiri (Lampiran 1), baru kemudian setelah hasil rancangan percobaan ini memperoleh hasil yang relatif baik, algoritma model prediksi *inflow* ini disesuaikan dengan karakter data SEASV terkoreksi. Pada rancangan percobaan juga dilakukan beberapa simulasi, baik simulasi variabel *input* maupun simulasi pengelompokan data berdasarkan periode bulan basah, kering atau normal yang kemudian diketahui bahwa tidak memberi pengaruh signifikan pada metode berbasis *machine learning* ini. Berdasarkan hasil-hasil simulasi ini lah desain awal model probabilistik ini ditentukan.

Matriks set data awal terdiri dari [*input*, *target*], *input* awal model adalah nilai rerata ensemble dan targetnya adalah nilai *inflow* untuk Waduk Saguling, atau nilai *inflow* lokal untuk Waduk Cirata dan Jatiluhur. Set data dipisahkan berdasarkan pembagian tahapan dasar pemodelan yakni tahap pelatihan atau *training*, tahap pengujian atau *testing*, dengan proporsi pembagaian adalah 80% data digunakan sebagai data training dan 20% set data digunakan pada tahap pengujian. Meskipun kebanyakan penggunaan ANN menggunakan dua dasar tahapan tersebut, namun pada penelitian ini ditambahkan periode validasi untuk simulasi prakiraan tahun 2019 sebagai simulasi penggunaan model dengan data berurutan dan tidak *random*.

Kemudian tahap akhir mensimulasikan model ANN pada semua member SEASV terkoreksi. Data dibagi sesuai dengan jumlah tahapan dalam proses pembangunan model yakni tahap pelatihan, pengujian dan validasi (prediksi). Proporsi pembagian datanya adalah 80% sebagai data latih, 20% sebagai data uji dan data selama tahun 2019 digunakan sebagai validasi prediksi. Setelah model memperoleh performa yang baik secara general melalui nilai reratanya, kemudian ANN disimulasikan pada seluruh member (51 member) *forecast SEASV*, dan dianalisis sebagai prediksi *inflow* probabilistik. Arsitektur model dari keseluruhan model prediksi yang digunakan pada penelitian ini ditunjukkan pada Gambar 4.



Gambar 4 Arsitektur model prediksi probabilistik debit air masuk waduk

Setelah diperoleh hasil prediksi dengan 51 *initial condition* yang berbeda, kemudian ditentukan klasifikasi interval kelas *inflow* serta peruntukan prediksi yang lebih lanjut digunakan. Untuk kemudian dianalisis sesuai dengan konsep



peluang dengan Persamaan 8 dimana peluang kejadian  $P(k)$  adalah perbandingan antara jumlah  $n(k)$  kejadian dengan total seluruh sample  $n(s)$  kejadian:

$$P(k) = \frac{n(k)}{n(s)} \tag{8}$$

Prediksi probabilistik *inflow* disajikan dengan format simulasi hingga enam bulan ke depan, sehingga dapat memberikan informasi prediksi atau kecenderungan *inflow* selama jangka waktu prediksi dan disesuaikan dengan analisis resiko prakiraan berbasis dampak (ekstrim) yang dibutuhkan pada saat itu.

### 3.3.4 Uji statistik

Penelitian ini menggunakan tiga indikator performansi model, yaitu korelasi Pearson, *Root mean Square Error* (RMSE) untuk prediksi deterministik, dan *Brier score* (BS) pada prediksi probabilistik. RMSE merupakan indikator statistik yang digunakan untuk mengestimasi nilai error dari model data (Harwell, 2019). Nilai RMSE menunjukkan kesalahan rata-rata atau perbedaan nilai rata-rata luara model atau prediksi dengan targetnya yakni data observasi debit. Kualitas dan akurasi model akan semakin baik jika nilai error semakin kecil yang ditunjukkan dengan semakin rendahnya nilai RMSE. RMSE dihitung dengan Persamaan 9:

$$RMSE = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \tag{9}$$

Korelasi Pearson ( $r$ ) dihitung menggunakan Persamaan 10, nilainya berada pada rentang -1 sampai 1. Semakin mendekati 1 atau -1 maka korelasi atau hubungan antara model dan observasi semakin kuat, sedangkan semakin mendekati 0 hubungan semakin lemah. (Johnson dan Bhattacharyya 2010)

$$r = \sqrt{1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \tag{10}$$

Variabel  $r$  memiliki rentang nilai antara -1 hingga 1. Semakin mendekati +1, semakin besar nilai  $x$  (observasi) yang terkait dengan nilai  $y$  (model). Nilai mendekati -1 menunjukkan hubungan yang berkebalikan. Hubungan antara variabel dari nilai korelasi ini dikategorikan secara lebih jelas pada Tabel 3. Simbol  $d_i$  pada formula korelasi Pearson manunjukkan selisih *rank* antara data observasi dan model ke- $i$ , sedangkan  $e_i$  pada perhitungan RMSE menunjukkan galat model sebanyak  $i$  dan  $n$  sebagai jumlah data. Semakin tinggi RMSE menunjukkan galat yang semakin besar, sehingga kemampuan model menjadi dipertanyakan.

Tabel 3 Interpretasi korelasi Pearson

Nilai korelasi absolut	Interpretasi
0.00 - 0.10	Dapat diabaikan
0.10 - 0.39	Lemah
0.40 - 0.69	Sedang
0.70 - 0.89	Kuat
0.90 - 1.00	Sangat Kuat

**Sumber:** Schober dan Schwarte 2018


Untuk mengukur kehandalan prediksi probabilitas maka digunakan *Brier score* (BS) sangat mirip dengan *mean squared error*, tetapi hanya diterapkan untuk skor probabilitas prediksi, yang nilainya berkisar antara 0 dan 1. BS dihitung berdasarkan Persamaan 11:

$$BS = \frac{1}{N} \sum_{t=1}^N (f_t - o_t)^2 \quad (11)$$

di mana  $f_t$  adalah probabilitas yang diprediksi dari peristiwa yang terjadi menurut prediksi ke- $t$  dan  $o_t$  sama dengan 1 atau 0, tergantung pada apakah peristiwa yang diprediksi itu terjadi kemudian (1) atau tidak (0). Seperti yang didefinisikan dalam persamaan 9,  $o_t$  berorientasi negatif, yang berarti nilai BS yang makin mendekati nol maka kualitas prediksi dianggap lebih baik (Ward 1900).



Secara sederhana prosedur kerja pada penelitian ini tergambar melalui diagram alir pada Gambar 5.



Gambar 5 Diagram kerja penelitian

Hak Cipta Dilindungi Undang-undang  
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :  
a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah  
b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.  
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

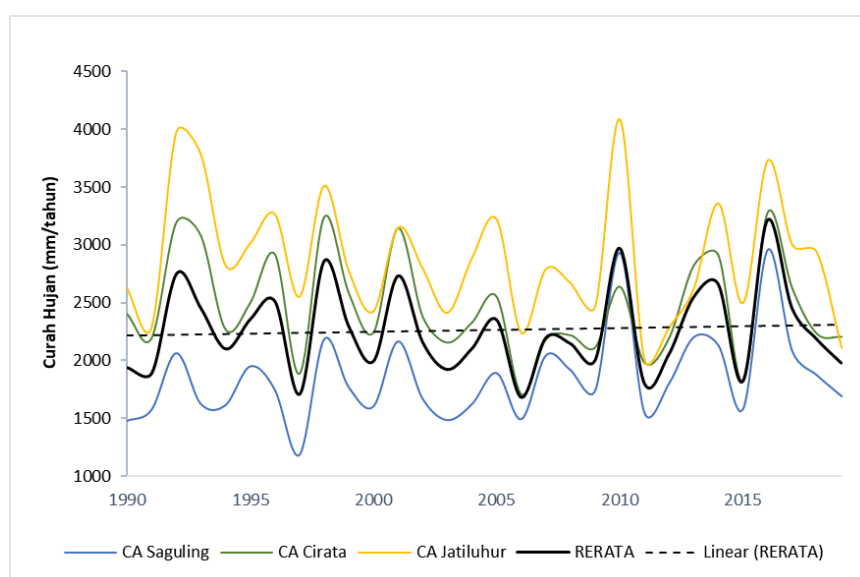


## IV HASIL DAN PEMBAHASAN

### 4.1 Kondisi Klimatologis dan Hidrologis DAS Citarum

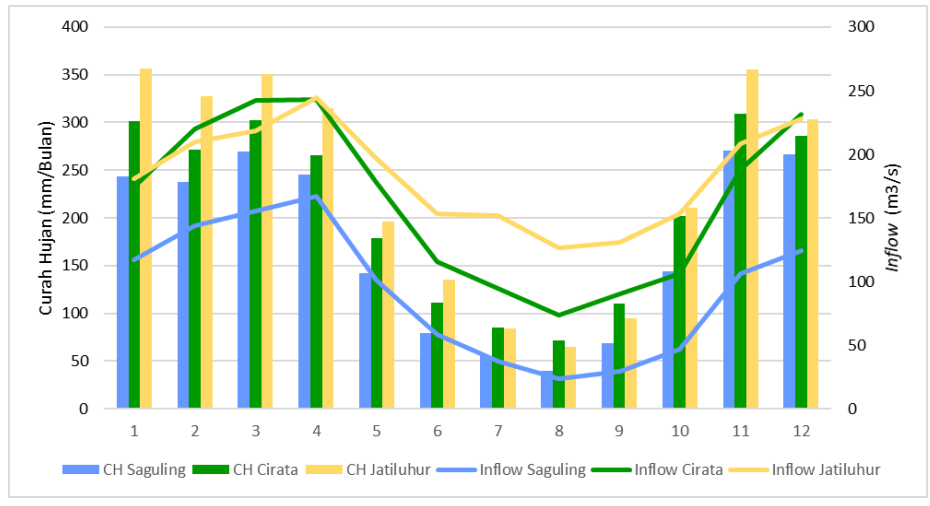
Setelah proses pengumpulan data serta kendali mutu selesai di lakukan, tahapan berikutnya adalah proses analisis fisis yang berkaitan dengan kondisi klimatologis serta hidrologis lokasi penelitian. Stasiun dan pos pengamatan curah hujan yang berada di area penelitian terlebih dahulu dipilih sesuai dengan letak koordinatnya dengan menggunakan metode delineasi waduk atau mengelompokkan area-area hulu masing-masing waduk dan menggolongkan pos hujan tersebut sesuai dengan area tangkapan hujan atau *catchment area* waduk untuk kemudian dianalisis secara lebih lanjut. Hal ini berguna untuk efisiensi dan ketepatan data pos hujan tersebut sebagai data input dalam pemodelan maupun sebagai data koreksi dalam proses koreksi bias model SEASV.

Berdasarkan pengolahan rerata aritmatik data pos hujan disekitar DAS Citarum diketahui bahwa curah hujan tahunan DAS Citarum tengah relatif lebih tinggi daripada DAS Citarum hulu. Ditinjau dari aspek meteorologis ada dua faktor pembentuk utama yakni pembentukan awan orografis di area perbukitan DAS Citarum dan faktor pendorong angin laut yang mengakibatkan kenaikan massa udara yang masuk dari pesisir utara saat bertemu *obstacle* berupa area perbukitan dan area-area konvergensi yang diakibatkan oleh kedua faktor ini pada keadaan-keadaan tertentu. Faktor ini secara dominan mengakibatkan awan orografi di area *catchment* Waduk Jatiluhur, ditambah dengan suplai masa uap air yang melimpah di Waduk Jatiluhur yang merupakan waduk yang paling besar, sehingga ditinjau dari aspek klimatologis curah hujan bulanan dan tahunannya lebih basah dibanding area *catchment* Waduk Cirata dan Saguling (Gambar 5 dan 6). Secara umum selama periode 30 tahun, trend curah hujan di DAS Citarum mengalami kenaikan atau semakin basah, namun perlu ditinjau kembali apakah hal ini diakibatkan oleh adanya kegiatan Teknik Modifikasi Cuaca (TMC) yang dilaksanakan secara rutin selama beberapa tahun terakhir.



Gambar 6 Rerata aritmatik curah hujan tahunan DAS Citarum

Rata-rata curah hujan bulanan dari Januari hingga Desember selama periode 30 tahun yakni 1990 hingga 2019 yang bersumber dari stasiun dan pos hujan yang tersebar di DAS Citrum hulu dan tengah (Gambar 7) dapat digunakan untuk mengetahui karakteristik dari siklus tahunan curah hujan wilayah DAS Citarum hulu dan tengah. Dengan pola hujan monsunial, wilayah ini memiliki satu puncak musim hujan dan satu puncak musim kemarau. Musim hujan secara umum terjadi pada sekitar bulan Oktober hingga April, sedangkan musim kemarau terjadi pada sekitar bulan Mei sampai September, dan terdapat masa transisi atau pancaroba di tiap pergantian musim. Pola ini merupakan pola rata-rata yang terjadi selama 30 tahun, dengan tidak menutup kemungkinan adanya perubahan atau pergeseran awal musim tergantung pada dinamika atmosfer yang terjadi pada saat itu. Sehingga penggunaan parameter curah hujan sebagai indikator atau dasar dari perencanaan operasi waduk akan terus dievaluasi baik secara tahunan, musiman maupun dalam skala bulanan. Sehingga prediksi curah hujan pada skala bulanan harus terus *diupdate* untuk memperoleh prediksi *inflow* yang lebih akurat.




Gambar 7 Klimagram curah hujan dan debit air masuk waduk

Rata-rata *inflow* bulanan di Waduk Saguling lebih kecil dibandingkan dengan waduk lainnya, hal ini terjadi karena pada Waduk Cirata dan Jatiluhur mendapatkan pengaruh *outflow* dari masing-masing hulu waduk selain dari *inflow* lokal waduk itu sendiri. Meskipun demikian pola siklus tahunan *inflow* pada seluruh waduk relatif selaras dengan pola presipitasi rata-ratanya. Kesamaan siklus tersebut merupakan landasan pertama dalam pembangunan rancangan percobaan arsitektur model yang dibangun dalam penelitian ini. Dengan skenario awal adalah penggunaan data curah hujan bulanan observasi yang berada di wilayah *cathment area* atau daerah tangkapan hujan untuk Waduk Saguling sebagai data *input* dalam prediksi *inflow* Waduk Saguling (Lampiran 1). Berdasarkan rancangan uji coba model awal inilah kemudian model probabilistik *inflow* dikembangkan dengan menggunakan algoritma yang sama namun *input* model yang berbeda.

Hak Cipta Dilindungi Undang-undang  
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :  
a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah  
b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.  
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.


#### 4.2 Hasil Koreksi Bias dengan Metode *Linier Scaling*

Berdasarkan perbandingan nilai *ensemble mean* prediksi curah hujan bulanan model SEASV dengan data rerata curah hujan bulanan observasi pada masing-masing area tangkapan hujan waduk dapat diketahui bahwa secara umum model SEASV memiliki karakteristik *overforecast*. Rerata ensemble SEASV cenderung selalu lebih tinggi dibandingkan dengan curah hujan observasi baik pada musim hujan, transisi maupun kemarau (Gambar 8). Sehingga pada penelitian ini penggunaan SEASV diawali dengan proses koreksi bias dan selanjutnya disebut sebagai SEASV terkoreksi. Koreksi bias dapat digunakan untuk mengukur dan mengevaluasi performa luaran suatu model dan kemudian menyesuaikannya dengan kondisi sebenarnya yang diwakili oleh data observasi seperti yang dilakukan oleh Muharsyah *et al.* 2020 dalam mengoreksi bias model luaran ECMWF System 4 dengan metode *Bayesian Moving Average* (BMA).




Gambar 8 Perbandingan antara data curah hujan bulanan observasi dan *ensemble mean* model curah hujan bulanan SEASV terkoreksi

Metode bias koreksi dengan metode *linier scaling* relatif efektif untuk digunakan dalam proses penyiapan data yang akan digunakan secara lebih lanjut. Gambar 8 menyajikan perbedaan sebaran data antara SEAS V dan SEASV terkoreksi, dimana data prediksi SEASV yang diwakili oleh titik merah memiliki sebaran yang berada di atas garis hitam (data hujan observasi), kemudian untuk sebaran data model prediksi SEASV terkoreksi yang diwakili oleh titik -titik biru berada disekitaran garis hitam atau berada dibawah sebaran SEASV. Secara kuantitatif koreksi bias LSM menurunkan RMSE nilai rerata ensemble SEASV dari 93.1 menjadi 66.7. Metode sederhana ini mampu mengoreksi data klimatologis secara umum, namun demikian tetap memepertahankan karakter sebaran masing-masing *member* model. Diagram hasil koreksi secara lebih detail untuk setiap masing-masing waduk dtampilkan oleh Gambar 10.



Gambar 9 Diagram *scatterplot* perbandingan sebaran model SEASV sebelum dan sesudah koreksi bias dengan data pos hujan



Gambar 10 Diagram hasil koreksi bias model SEASV ECMWF dengan data Pos hujan di area tangkapan hujan Waduk Saguling (a), Waduk Cirata (b), dan Waduk Jatiluhur (c)

Hak Cipta Dilindungi Undang-undang  
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :  
a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah  
b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.  
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.



### 4.3 Tahap pelatihan dan pengujian model

Pelatihan model atau biasa dikenal dengan istilah *learning* model merupakan langkah awal dalam arsitektur model probabilistik *inflow* ini. Pada tahapan ini masih menggunakan data rerata ensemble model SEASV terkoreksi pada *leadtime* 0, dengan proporsi data adalah 80% data yang dipilih secara acak. Data ini kemudian dipasangkan dengan nilai rerata *inflow* pada waktu yang sama hingga membentuk satu dataset yakni dataset *input* dan target. Tahapan ini berguna untuk memperoleh pola umum atau generalisasi jaringan model yang mampu mewakili sebagian besar karakteristik member model yang direpresentasikan dengan perhitungan nilai RMSE yang relatif kecil dan nilai korelasi Pearson yang mendekati satu antara luaran model dengan targetnya.

Tahap pengujian merupakan tahap menguji *robustness* algoritma jaringan yang dibangun saat tahap pelatihan. Tahap ini menggunakan 20% data yang sebelumnya tidak masuk dalam tahap pelatihan. Pada tahap pelatihan biasanya relatif mudah mencapai skor RMSE dan *r* yang relatif baik karena dalam algoritma *Backpropagation* dilakukan *updating* bobot dan bias dua kali yakni dengan perambatan maju dan kemudian dengan perambatan mundur dengan beberapa *epoch*. Jika pada tahap pengujian skor RMSE dan *r* nya belum baik maka harus dilakukan proses pelatihan kembali, karena berarti model sebelumnya masih bersifat *overfitting* dan atau tidak *robust*. Melalui proses pelatihan dan pengujian yang berulang maka diperoleh skor RMSE dan *r* terbaik yang ditampilkan pada Tabel 4.


Tabel 4 Rekapitulasi pengukuran statistik model pada tahapan pelatihan dan pengujian model

Prediksi Inflow Waduk	Tahap Pelatihan		Tahap Pengujian	
	RMSE	r	RMSE	r
Saguling	35,65	0,82	31,13	0,93
Cirata	26,16	0,82	38,78	0,83
Jatiluhur	9,2	0,72	8,29	0,74

Perhitungan RMSE dan *r* pada kedua tahapan ini dapat menjadi acuan untuk membangun prediksi *inflow* berbasis deterministik seperti yang ditampilkan pada Gambar 11. Model prediksi *inflow* di Waduk Saguling memiliki kemampuan yang lebih tinggi dibandingkan dengan kemampuan model dalam memprediksi *inflow* Waduk Cirata dan Jatiluhur, dengan nilai *r* pada tahap pengujian 0.93. Sebaliknya kemampuan prediksi *inflow* waduk di Waduk Jatiluhur relatif kurang handal dibandingkan dengan dua waduk yang berada di hulunya. Hal ini diduga karena pada waduk dengan sistem kaskade terpengaruh oleh adanya faktor kebijakan operator dalam operasional rutin dalam menentukan berapa debit air yang dikeluarkan dari waduk sesuai dengan keadaan yang dipertimbangkan pada saat itu.

Berbagai skenario dilakukan untuk dapat mengakomodir adanya *human factor* yang mempengaruhi nilai *outflow* waduk. Skenario pertama adalah dengan memasukan nilai *outflow* sebagai prediktor, skenario kedua adalah

dengan mengoreksi nilai *inflow* dengan nilai *outflow* waduk yang berada di hulunya sehingga yang dimodelkan adalah nilai *outflow* lokal saja, untuk kemudian dikembalikan lagi dengan menambahkan nilai *outflow* pada hasil pemodelan *outflow* lokal. Berdasarkan simulasi kedua skenario ini hasil yang memungkinkan adalah skenario kedua dengan hasil yang ditampilkan pada Gambar 11.



Gambar 11 Prediksi deterministik *inflow* Waduk Saguling (a), Waduk Cirata (b) dan Waduk Jatiluhur (c).

Secara statistik, model prediksi deterministik *inflow* Waduk Kaskade Citarum dengan menggunakan *input* model data curah hujan observasi maupun *input* model dengan nilai rerata ensembel luaran model *reforecast* SEASV terkoreksi memiliki kehandalan yang baik namun demikian namun demikian untuk beberapa kejadian *inflow* yang relatif tinggi model belum dapat mendekati nilai prediksi yang akurat. Karena secara umum kehandalan metode *machine learning* khususnya ANN akan sangat bergantung dari jumlah pembelajaran yang diberikan pada tahap *learning*, sedangkan kasus-kasus ekstrim memiliki jumlah kejadian yang relatif sedikit dibandingkan jumlah kejadian normal.

**4.4 Kemampuan Prediksi Probabilistik *Inflow* Waduk Saguling**

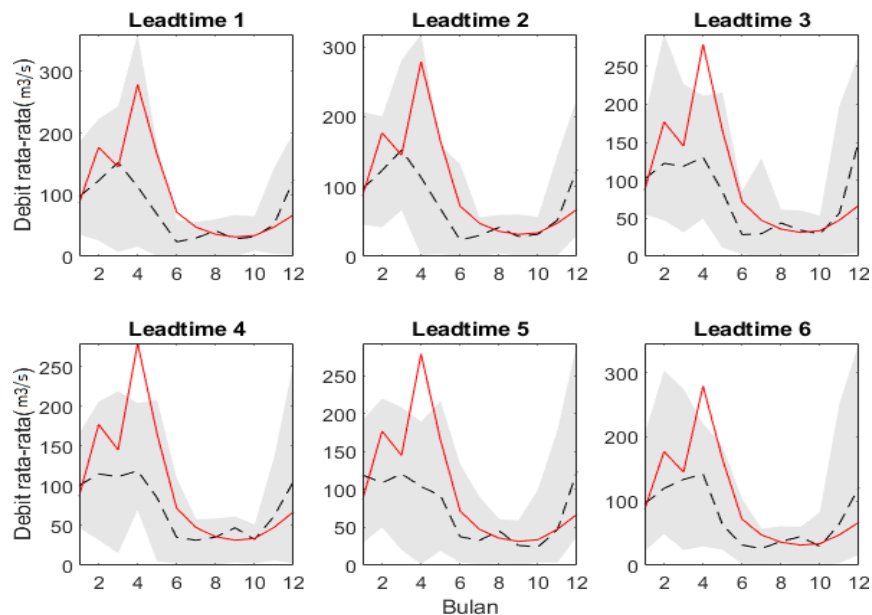
Prediksi probabilistik memiliki kelebihan mampu menjelaskan ketidakpastian pada suatu sistem prediksi, dimana hal ini sangat penting untuk dipertimbangkan meskipun model tersebut memiliki keyakinan atau tingkat akurasi yang sangat tinggi (WMO 2012). Dengan menggabungkan 51 member model SEASV pada tahun 2019 sebagai data masukan dari algoritma model akhir yang telah melalui tahap pelatihan dan pengujian, diperoleh model prediksi debit air

Hak Cipta Dilindungi Undang-undang  
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :  
a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah  
b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.  
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

masuk yang bersifat probabilistik pada berbagai jangkauan waktu prediksi mulai dari *leadtime* 1 atau prediksi satu bulan ke depan hingga *leadtime* 6 atau 6 bulan ke depan.

Berdasarkan pengaturan perundangan tentang operasi waduk yakni Permen PUPR Nomor: 27/PRT/M/2015 tentang Bendungan, khususnya pada Pasal 46 sampai dengan Pasal 52, *inflow* dibagi menjadi tiga kategori yakni tahun basah, tahun normal dan tahun kering. Tahun basah adalah apabila *inflow* berada pada nilai lebih besar dari 115 % dari rerata atau normalnya, sedangkan tahun kering adalah tahun dimana *inflow* berada pada nilai dibawah 85% dari rerata atau normalnya. Namun demikian dengan alasan penjabaran yang lebih presisi ataupun analisis peluang yang lebih baik untuk perencanaan operasional maka nilai prediksi *inflow* pada penelitian ini menggunakan rentang klasifikasi yakni 0-50 m<sup>3</sup>/s , 51-100 m<sup>3</sup>/s, 101-200 m<sup>3</sup>/s dan >200 m<sup>3</sup>/s . Kemudian dilakukan analisis perhitungan peluang untuk masing-masing interval kelas nilai prediksi *inflow* rata-rata bulanan waduk. Kedepannya rentang klasifikasi ini dapat disesuaikan dengan kebutuhan dan karakteristik *inflow* waduk pada musim-musim tertentu dan sesuai dengan peruntukan analisisnya (Tabel 4, Tabel 5 dan Tabel 6).

Gambar 12, Gambar 13 dan Gambar 14 merupakan hasil dari simulasi model prediksi *inflow* terbaik yang diperoleh berdasarkan tahapan sebelumnya yang diterapkan pada 51 member model SEASV terkoreksi dan menghasilkan 51 member model prediksi ensemble *inflow* rata-rata bulanan untuk masing-masing waduk pada rentang prediksi 1 hingga 6 bulan ke depan (*leadtime* 1-6). Area berwarna abu-abu muda menerangkan rentang sebaran prediksi 51 member model probabilistik *inflow* dari nilai terkecil hingga nilai terbesar, garis hitam putus-putus menerangkan rerata ensemble model probabilistik *inflow*, sedangkan garis berwarna merah merupakan data observasi *inflow* rata-rata bulanan waduk pada Januari hingga Desember 2019.



Gambar 12 Prediksi probabilistik (area abu-abu) *inflow* Waduk Saguling beserta perbandingan nilai *ensemble mean* (garis hitam) dengan data pengamatan debit (garis merah)

Prediksi *inflow* di Waduk Saguling mencapai nilai yang sangat baik, dapat kita lihat rentang prediksi ensemble *inflow* mampu menjangkau nilai ekstrim pada *leadtime* 1 dan 2 dalam artian model mampu mendeteksi peluang potensi ekstrim dengan baik, demikian pula pada *leadtime* selanjutnya yakni prediksi 3 hingga 6 bulan ke depan performa ensemble meannya cukup baik dalam mengenali pola debit *inflow* hanya saja kemampuan mendeteksi kejadian ekstrim menjadi menurun. Nilai rerata ensemble prediksi *inflow* biasanya juga menunjukkan kategori mana yang memiliki peluang terbesar, meski akan lebih baik jika diinvestigasi lebih jauh untuk semua peluang yang mungkin saja terjadi sebagai upaya mitigasi dan perencanaan operasional waduk seperti yang ditampilkan pada Tabel 4 hingga 6. Pada ketiga tabel ini disajikan nilai peluang prediksi model *inflow* yang dirilis pada bulan Desember 2018 untuk prediksi *inflow* rata-rata bulan Januari hingga Juni 2019 untuk masing-masing waduk.

Berdasarkan evaluasi dengan nilai observasinya peluang terbesar mampu menangkap karakteristik *inflow* observasi namun demikian tetap memberikan informasi potensi kejadian ekstrim seperti yang terjadi pada bulan April peluang terbesar berada pada debit kelas 100-200 m<sup>3</sup>/s, namun kejadian yang sebenarnya adalah 279 m<sup>3</sup>/s. Meskipun secara kualitatif masih jauh dari nilai observasi, namun dengan prediksi probabilistik dapat diketahui peluang terjadinya debit dengan kategori mendekati nilai observasi, bahkan mampu mendeteksi terjadinya kejadian ekstrim ini dengan peluang 4%, perlu diingat kembali bahwa peluang terjadinya nilai ekstrim ini sepanjang 30 tahun hanya 1.9% (Tabel 4).

Keadaan ekstrim relatif sulit untuk diprediksi oleh model, karena proporsi kejadian ekstrim dari keseluruhan data tidak besar, hal ini menjadikan jumlah bahan *learning* model ini juga menjadi lebih sedikit dibanding pada kondisi rata-rata. Pada model dengan jenis *supervised learning* seperti ini ketersediaan histori data yang lebih panjang dapat meningkatkan kemampuan model dalam mengenali keadaan-keadaan yang telah terjadi dan mengalgoritmakan prediksi yang akan terjadi berdasarkan apa yang telah dilatih sebelumnya.

Tabel 5 Perhitungan probabilitas prediksi *inflow* Waduk Saguling untuk Januari-Juni 2019 dalam satuan (%)

Leadtime/ Bulan	1 Jan	2 Feb	3 Mar	4 Apr	5 Mei	6 Jun
<b>Prob &lt; 50</b>	4	0	0	0	25	60
<b>Prob 50 – 100</b>	48	36	20	30	49	40
<b>Prob 100-200</b>	48	60	76	68	22	0
<b>Prob &gt; 200</b>	0	4	4	2	4	0
<b>Inflow (m<sup>3</sup>/s)</b>	<b>87</b>	<b>177</b>	<b>145</b>	<b>279</b>	<b>165</b>	<b>72</b>

Berdasarkan hasil perhitungan *Brier score* yang ditampilkan pada Tabel 5 secara umum model probabilistik *inflow* cukup handal dengan rentang nilai rata-rata *Brier score* pada seluruh jangka waktu prediksi berkisar anatar 0,12 – 0,15. Sedangkan pada bulan April dan Juni 2019 kehandalan model relatif menurun dengan meningkatnya *Brier score* hal ini dapat terjadi karena fluktuasi curah hujan pada masa transisi cenderung lebih tidak menentu dibandingkan ditengah musim (lampiran 2).




Tabel 6 Rekapitulasi Brier score prediksi *inflow* Waduk Saguling tahun 2019

Leadtime	1	2	3	4	5	6	7	8	9	10	11	12	Rerata
1	0,12	0,02	0,01	0,35	0,28	0,45	0,003	0,08	0,01	0,001	0,22	0,23	0,15
2	0,12	0,06	0,0	0,30	0,24	0,30	0,005	0,06	0,01	0,001	0,19	0,21	0,13
3	0,28	0,04	0,02	0,38	0,21	0,44	0,001	0,06	0,04	0,001	0,14	0,14	0,15
4	0,21	0,02	0,01	0,39	0,20	0,27	0,007	0,01	0,08	0,001	0,20	0,16	0,13
5	0,25	0,06	0,01	0,31	0,24	0,22	0,003	0,07	0,02	0,001	0,11	0,24	0,13
6	0,13	0,04	0,03	0,35	0,17	0,18	0,001	0,03	0,08	0,01	0,22	0,21	0,12

#### 4.5 Kemampuan Prediksi Probabilistik *Inflow* Waduk Cirata

Seperti diterangkan pada bagian sebelumnya, *inflow* Waduk Cirata dipengaruhi oleh adanya *human factor* dalam keputusan pelepasan air dari Waduk Saguling. Sehingga model *inflow* yang dibangun adalah model probabilistik *inflow* lokal untuk kemudian di koreksi ulang dengan jumlah *outflow* Waduk Saguling untuk dianalisis secara lebih lanjut. Gambar 13 menyajikan perbandingan luaran model prediksi *inflow* yang relatif baik dengan pada semua jangka waktu prediksi, secara umum terlihat fluktuasi *inflow* baik ensemble maupun nilai rerata ensemblenya mengikuti fluktuasi data observasi *inflow* Waduk Cirata.



Gambar 13 Prediksi probabilistik (area abu-abu) debit masuk Waduk Cirata beserta perbandingan nilai *ensemble mean* (garis hitam) dengan data pengamatan debit (garis merah)

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :  
 a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah  
 b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.  
 2. Dilarang mengumunkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

Lebih detail pada Tabel 6 menampilkan simulasi model prediksi *inflow* yang dirilis pada bulan Desember 2018 dengan periode prediksi dari Januari hingga Juni 2019 mampu memprediksi dengan baik pada interval kelas mana peluang terbesar ditangkap, namun tetap memprediksi potensi adanya kejadian lain sehingga dapat menambah pertimbangan dalam operasional Waduk Cirata serta langkah apa yang sekiranya harus dicadangkan dalam rangka mitigasi dan efektifitas manajemen operasional waduk.

Tabel 7 Perhitungan probabilitas prediksi *inflow* Waduk Cirata untuk Januari- Juni 2019 dalam satuan (%)

Leadtime/ Bulan	1 Jan	2 Feb	3 Mar	4 Apr	5 Mei	6 Jun
Prob < 50	0	1	0	0	0	4
Prob 50 – 100	0	1	1	1	4	52
Prob 100-200	100	16	1	1	96	44
Prob > 200	0	92	98	98	2	0
Inflow (m <sup>3</sup> /s)	171	225	254	320	168	60

Kehandalan model prediksi ini didukung pula dengan hasil pengukuran statistik dengan Brier *score* (Tabel 8) dengan nilai rata-rata Bier *score* berada pada rentang 0.04-0.05. Akurasi model yang cukup tinggi ini dipengaruhi oleh faktor *outflow* yang lebih dominan daripada *inflow* lokal yang masuk ke Waduk Cirata. Dapat kita lihat pada Tabel 4 performa model deterministiknya tidak lebih baik dari model yang digunakan di Waduk Saguling, tetapi performa prediksi probalistiknya menjadi relatif lebih baik ini tercapai ketika nilai *inflow* lokal dirubah kembali menjadi nilai *inflow* total kemudian dihitung skor Briernya.

Tabel 8 Rekapitulasi Brier *score* prediksi *inflow* Waduk Cirata tahun 2019

Leadtime	1	2	3	4	5	6	7	8	9	10	11	12	Rata
1	0,001	0,001	0,001	0,002	0,001	0,01	0,002	0,001	0,001	0,3	0,09	0,001	0,04
2	0,001	0,013	0,001	0,001	0,001	0,04	0,016	0,001	0,003	0,2	0,13	0,01	0,04
3	0,001	0,003	0,001	0,001	0,001	0,018	0,016	0,001	0,001	0,2	0,19	0,013	0,04
4	0,001	0,001	0,001	0,001	0,001	0,04	0,003	0,009	0,001	0,3	0,15	0,002	0,04
5	0,001	0,003	0,001	0,003	0,001	0,08	0,09	0,001	0,001	0,3	0,15	0,002	0,05
6	0,001	0,007	0,003	0,001	0,001	0,1	0,05	0,009	0,001	0,17	0,11	0,008	0,04

#### 4.6 Kemampuan Prediksi Probabilistik *Inflow* Waduk Jatiluhur


Waduk Jatiluhur yang merupakan hilir dari sistem Waduk Kaskade Citarum memiliki *historical data inflow* data *inflow* yang sangat mirip dengan data *outflow* Waduk Cirata, hal ini karena masuknya air ke Waduk Jatiluhur diatur dengan ketat untuk memastikan Tinggi Muka Air Waduk Jatiluhur berada pada level optimum (Lampiran 3). Sehingga nilai *inflow* lokalnya sangat kecil dan relatif tidak signifikan atau dengan kata lain curah hujan yang terjadi di area tangkapan hujan

tidak berpengaruh secara signifikan kecuali untuk presipitasi yang langsung jatuh pada permukaan waduk. Oleh karena itu model probabilistik *inflow* lokal di Waduk Jatiluhur dengan menggunakan data *input* yakni luaran model SEASV terkoreksi menjadi turun keandalannya dengan nilai pengukuran Brier *score* antara 0.001 hingga 0.5 dengan rata-rata 0,33 – 0,34 (Tabel 9).

Tabel 9 Rekapitulasi Brier *score* prediksi *inflow* Waduk Jatiluhur tahun 2019

Leadtime	1	2	3	4	5	6	7	8	9	10	11	12	Rata
1	0,48	0,50	0,50	0,50	0,39	0,001	0,50	0,50	0,01	0,001	0,11	0,42	0,33
2	0,48	0,50	0,50	0,48	0,41	0,10	0,50	0,50	0,001	0,001	0,15	0,38	0,33
3	0,46	0,50	0,50	0,49	0,40	0,03	0,50	0,50	0,01	0,001	0,07	0,42	0,33
4	0,46	0,50	0,50	0,50	0,41	0,13	0,50	0,50	0,001	0,001	0,14	0,40	0,34
5	0,44	0,50	0,50	0,48	0,43	0,19	0,50	0,50	0,009	0,001	0,08	0,42	0,34
6	0,50	0,50	0,50	0,48	0,39	0,16	0,50	0,50	0,003	0,001	0,10	0,41	0,34

Pada Gambar 14 ditampilkan evaluasi luaran model probabilistik *inflow* Waduk Jatiluhur, dimana fluktuasi *inflow* lokalnya relatif kecil berkisar hanya antara 5.2 hingga 46.9 m<sup>3</sup>/s dan rata-rata *inflow* lokal sebesar 18.3 m<sup>3</sup>/s. Model tidak kesulitan untuk menangkap peluang interval kelas maksimum namun demikian secara umum probabilitas interval kelas terbesar kurang tepat dalam memprediksi pada interval kelas mana *inflow* observasi berada (Tabel 10).



Gambar 14 Prediksi probabilistik (area abu-abu) debit masuk Waduk Jatiluhur beserta perbandingan nilai *ensemble mean* (garis hitam) dengan data pengamatan debit (garis merah)

Tabel 10 Perhitungan probabilitas prediksi *inflow* Waduk Jatiluhur untuk Januari-Juni 2019 dalam satuan (%)

	1	2	3	4	5	6
Bulan	Jan	Feb	Mar	Apr	Mei	Jun
<b>Prob &lt; 50</b>	0	0	0	0	0	44
<b>Prob 50 – 100</b>	96	0	0	0	84	56
<b>Prob 100-200</b>	4	100	100	100	16	0
<b>Prob &gt; 200</b>	0	0	0	0	0	0
<b>Debit Obs</b>	<b>148</b>	<b>215</b>	<b>234</b>	<b>286</b>	<b>208</b>	<b>80</b>

Secara keseluruhan tidak ada perbedaan mencolok antara kehandalan model prediksi probabilistik *inflow* baik pada *leadtime* awal yakni 1 maupun *leadtime* yang paling jauh yakni 6 bulan ke depan, namun demikian mayoritas prakiraan hidrologi musiman terbatas pada prakiraan waktu tunggu 1 hingga 3 bulan, terutama karena keterampilan prakiraan meteorologis yang terbatas pada waktu yang lebih lama. Oleh karena itu, keberhasilan kinerja sistem prakiraan hidrologi musiman sangat bergantung pada keakuratan prakiraan meteorologis dan akurat representasi kondisi tangkapan awal yang mengandung memori yang terkait dengan misalnya, kondisi kelembaban permukaan tanah (Shukla & Lettenmaier, 2011). Hasil simulasi pada ketiga waduk juga menunjukkan tidak ada perbedaan performa yang signifikan terkait dengan adanya perbedaan periode musim, ditambah lagi jika secara operasional *history* data sebagai dasar dari proses *learning* model dapat diupdate secara berkala khususnya ketika peralihan musim sehingga hal ini dapat mengurangi bias dan menambah kemampuan model.

## V SIMPULAN DAN SARAN

### 5.1 Simpulan

Pola siklus tahunan *inflow* pada seluruh waduk relatif selaras dengan pola presipitasi rata-ratanya. Kesamaan siklus tersebut merupakan landasan pertama dalam pembangunan rancangan percobaan arsitektur model yang dibangun dalam penelitian ini. Penggunaan parameter curah hujan sebagai indikator atau dasar dari perencanaan operasi waduk harus terus dievaluasi baik secara tahunan, musiman maupun dalam skala bulanan. Sehingga prediksi curah hujan pada skala bulanan harus terus di *update* untuk memperoleh prediksi *inflow* yang lebih akurat.

Berdasarkan perbandingan nilai *ensemble mean* prediksi curah hujan bulanan model SEASV dengan data rerata curah hujan bulanan observasi pada masing-masing area tangkapan hujan waduk dapat diketahui bahwa secara umum model SEASV memiliki karakteristik cenderung lebih tinggi dibandingkan dengan curah hujan observasi baik pada musim hujan, transisi maupun kemarau. Sehingga pada penelitian ini penggunaan SEASV diawali dengan proses koreksi bias dan selanjutnya disebut sebagai SEASV terkoreksi.

Secara statistik, model prediksi deterministik *inflow* Waduk Kaskade Citarum dengan menggunakan *input* model data curah hujan observasi maupun *input* model dengan nilai rerata ensembel luaran model *reforecast* SEASV terkoreksi memiliki kehandalan yang baik namun demikian untuk beberapa kejadian *inflow* yang relatif tinggi model belum dapat mendekati nilai prediksi deterministik yang akurat.

Berdasarkan hasil perhitungan Brier *score* secara umum model probabilistik *inflow* di Waduk Saguling dan Waduk Cirata cukup handal dengan nilai Brier *score* secara berurutan berada pada rentang 0,12 – 0,15 dan 0.04-0.05. Akurasi model yang cukup tinggi pada prediksi *inflow* Waduk Cirata dipengaruhi oleh faktor *outflow* yang lebih dominan daripada *inflow* lokal yang masuk ke Waduk Cirata. Waduk Jatiluhur memiliki historikal data *inflow* yang sangat mirip dengan data *outflow* Waduk Cirata, hal ini karena masuknya air ke Waduk Jatiluhur diatur dengan ketat untuk memastikan Tinggi Muka Air Waduk Jatiluhur berada pada level optimum. Sehingga nilai *inflow* lokalnya sangat kecil dan relatif tidak signifikan atau dengan kata lain curah hujan yang terjadi di area tangkapan hujan tidak berpengaruh secara signifikan kecuali untuk presipitasi yang langsung jatuh pada permukaan waduk. Oleh karena itu model probabilistik *inflow* lokal di Waduk Jatiluhur dengan menggunakan data input yakni luaran model SEASV terkoreksi menjadi turun kehandalannya dengan nilai pengukuran Brier *score* antara 0.001 hingga 0.5.

Berdasarkan semua hasil yang dicapai pada penelitian ini maka dapat diketahui metode *machine learning* dapat menjadi pilihan dari sekian banyak metode yang dapat digunakan dalam program IBF, mengingat kelebihan dalam kemudahan ketersediaan variabel prediktor yang relatif sedikit, dari sisi praktis juga relatif terjangkau karna model dapat dibangun dengan komputasi yang tidak memerlukan spesifikasi yang sangat tinggi dan juga mudah diaplikasikan sesuai dengan kebutuhan algoritma model yang dibutuhkan.



## 5.2 Saran

Sistem waduk berjenjang memiliki prinsip operasional untuk menjaga kondisi waduk dalam keadaan efektif dan beroperasi secara optimum, sehingga dibutuhkan pertimbangan-pertimbangan khusus terkait pengendalian *outflow*. Sehingga pembangunan model yang berkelanjutan perlu mempertimbangkan aspek-aspek tersebut sebagai dasar penyusunan rancangan yang dapat menghasilkan model dengan satu kesatuan mulai dari prediksi *inflow* Waduk yang berada di hulu hingga *outflow* Waduk yang berada di paling hilir. Lebih jauh lagi, keberlangsungan penggunaan model dalam operasional memerlukan kerjasama dari BMKG selaku koordinator data curah hujan serta instansi pengelola waduk sebagai pemangku kebijakan utama operasional waduk. Kerjasama ini harus terus berlanjut mengingat dibutuhkan data yang terus *update* secara kontinyu, dan ketentuan yang harus dipertimbangkan dalam pengembangan model, agar model dapat menyesuaikan dengan tujuan optimisasi pengelolaan waduk berjenjang.

Hak Cipta Dilindungi Undang-undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
  - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.



## DAFTAR PUSTAKA

- Aqil M, Kita I, Yano A, Nishiyama S. 2007. Analysis and prediction of flow from local source in a river basin using a Neuro-fuzzy modeling tool. *J. Environ. Manage.* 85(1):215–223.doi:10.1016/j.jenvman.2006.09.009.
- Araghinejad S, Azmi M, Kholghi M. 2011. Application of artificial neural network ensembles in probabilistic hydrological forecasting. *J. Hydrol.* 407(1–4):94–104.doi:10.1016/j.jhydrol.2011.07.011.
- ASCE. 2000a. No Title. *J. Hydrol. Eng.* 5(ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. Artificial neural networks in hydrologi, I: Preliminary concepts.):115–123.
- ASCE. 2000b. Task Committee on Application of Artificial Neural Networks in Hydrology, Artificial Neural Networks in Hydrology. II:Hydrologic Application. *J. Hydrol. Eng.* 5(2):124–137.
- Berner J, Fossell KR, Ha SY, Hacker JP, Snyder C. 2015. Increasing the skill of probabilistic forecasts: Understanding performance improvements from model-error representations. *Mon. Weather Rev.* 143(4):1295–1320.doi:10.1175/MWR-D-14-00091.1.
- Bharadwaj, Prakash KB, Kanagachidambaresan GR. 2021. *Pattern Recognition and Machine Learning*.
- Butts M, Jensen R, Larsen J, Mueller H, Richaud B, Larsen P, Draw B, Alejandro E. 2017. Seasonal Forecasting of Reservoir Inflows and Their Uncertainties. 6865(1):4431–4437.
- Coulibaly P. 2010. Reservoir Computing approach to Great Lakes water level forecasting. *J. Hydrol.* 381(1–2):76–88.doi:10.1016/j.jhydrol.2009.11.027.
- Coulibaly P, Anctil F, Bobée B. 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *J. Hydrol.*.doi:10.1016/S0022-1694(00)00214-6.
- ECMWF. 2017. SEAS5 user guide. :1–43.
- Empung, Hiron N, Norken IN, Infantriyekti M, Putera IGAA. 2019. The Validation of Linear Method in Cascade Reservoir System for Prediction of Energy Production. *ICSECC 2019 - Int. Conf. Sustain. Eng. Creat. Comput. New Idea, New Innov. Proc.*:190–194.doi:10.1109/ICSECC.2019.8907223.
- Ferdiansyah A, Yuningsih SM, Ginanjar MR, Akrom IF. 2020. Potensi Debit Aliran Lokal Waduk Saguling Menggunakan Model Hujan Limpasan. *J. Sumber Daya Air.* 16(1):35–50.doi:10.32679/jsda.v16i1.606.
- Haykin S, Network N. 2004. *A comprehensive foundation*.
- Irvine KN, Eberhardt AJ. 1992. MULTIPLICATIVE, SEASONAL ARIMA MODELS FOR LAKE ERIE AND LAKE ONTARIO WATER LEVELS. *JAWRA J. Am. Water Resour. Assoc.*.doi:10.1111/j.1752-1688.1992.tb04004.x.
- Johnson RA., Bhattacharyya GK. 2010. *Statistics: Principle and Methods*. Ed ke-6. John Wiley & Sons, Inc.
- L’Heureux ML, Takahashi K, Watkins AB, Barnston AG, Becker EJ, Di Liberto TE, Gamble F, Gottschalck J, Halpert MS, Huang B, *et al.* 2017. Observing and predicting the 2015/16 El Niño. *Bull. Am. Meteorol. Soc.* 98(7):1363–1382.doi:10.1175/BAMS-D-16-0009.1.

- Lenderink G, Buishand A, Van Deursen W. 2007. Estimates of future discharges of the river Rhine using two scenario methodologies: Direct versus delta approach. *Hydrol. Earth Syst. Sci.* 11(3):1145–1159.doi:10.5194/hess-11-1145-2007.
- Lestari LPP, Arya DK, Suwarman R, Syahputra MR. 2018. Verification of upper Citarum River discharge prediction using climate forecast system version 2 (CFSv2) output. *AIP Conf. Proc.* 1987.doi:10.1063/1.5047325.
- Lv C, Xing Y, Zhang J, Na X, Li Y, Liu T, Cao D, Wang FY. 2018. Levenberg-marquardt backpropagation training of multilayer neural networks for state estimation of a safety-critical cyber-physical system. *IEEE Trans. Ind. Informatics.* 14(8):3436–3446.doi:10.1109/TII.2017.2777460.
- Mayasari R, Gunady B. 2015. Cascade Reservoirs Optimization in Citarum River – Indonesia. (June).
- Muharsyah R, Hadi TW, Indratno SW. 2020. Calibration Of Rainfall Ensemble Prediction Of ECMWF System 4 Using Bayesian Model Averaging. *Agromet.* 34(1):20–33.doi:10.29244/j.agromet.34.1.20-33.
- Nuraeni Y. 2011. Metode Memperkirakan Debit Air yang Masuk ke Waduk dengan Metode Stokastik Chain Markov (Contoh Kasus: Pengoperasian Waduk Air Saguling). *J. Tek. Sipil.* 18(2):1.doi:10.5614/jts.2011.18.2.2.
- Pradeepakumari B, Srinivasu K. 2019. Dam Inflow Prediction by using Artificial Neural Network Reservoir Computing. *Int. J. Eng. Adv. Technol.* 9(2):662–667.doi:10.35940/ijeat.b2990.129219.
- Pusdiklat SDA & Konstruksi. 2017. Modul Operasi Waduk. :67.
- Qi Y, Zhou Z, Yang L, Quan Y, Miao Q. 2019. A Decomposition-Ensemble Learning Model Based on LSTM Neural Network for Daily Reservoir Inflow Forecasting. *Water Resour. Manag.* 33(12):4123–4139.doi:10.1007/s11269-019-02345-1.
- Schober P, Schwarte LA. 2018. Correlation coefficients: Appropriate use and interpretation. *Anesth. Analg.* 126(5):1763–1768.doi:10.1213/ANE.0000000000002864.
- Sumber P, Air D, Citarum WS. 2012. Agenda Pengelolaan Sumber Daya Air Terpadu Wilayah Sungai Citarum. :1 atlas (1 v. (various foliations)).
- Syariman P, Lubis RS. 2004. Pedoman Pengoperasian Waduk Kaskade Berpola Listrik-Listrik-Multiguna - Pd T-21-2004-A.
- Teknik F, Bandung IT, Ganesha J, Bandung N, Marselina M. 2017. Model Prakiraan Debit Air dalam Rangka Optimalisasi Pengelolaan Waduk Saguling – Kaskade Citarum. *J. Tek. Sipil.* 24(1):99–108.doi:10.5614/jts.2017.24.1.12.
- Tikno S. 2000. Eksperimentasi Prakiraan Debit Aliran ( Inflow ) Dengan Model Arima Dan Kemungkinan.
- Visser J. 2017. Evaluation of Seasonal Inflow Forecasting to Support Multipurpose Reservoir Management Evaluation of Seasonal Inflow Forecasting to Support Multipurpose Reservoir Management A case study for the.
- Wang L, Wang Z, Liu C, Bai P, Liu X. 2018. A flexible framework Hydroinformatic Modeling System-HIMS. *Water (Switzerland).* 10(7).doi:10.3390/w10070962.

- Ward RD. 1900. Monthly weather review. *Science* (80-. ). 12(306):731–732.doi:10.1126/science.12.306.731-a.
- WMO. 2012. *Guidelines on Ensemble Prediction Systems and Forecasting*. Volume ke-1091.
- Xu W, Zhang X, Peng A, Liang Y. 2020. Deep Reinforcement Learning for Cascaded Hydropower Reservoirs Considering Inflow Forecasts. *Water Resour. Manag.* 34(9):3003–3018.doi:10.1007/s11269-020-02600-w.

@Hak cipta milik IPB University

IPB University



- Hak Cipta Dilindungi Undang-undang
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber :
    - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah
    - b. Pengutipan tidak merugikan kepentingan yang wajar IPB University.
  2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin IPB University.

## RIWAYAT HIDUP

Penulis dilahirkan di Kabupaten Brebes pada tanggal tiga bulan Desember tahun 1989 sebagai anak ke dua dari pasangan bapak Mamo Supratmo dan ibu Fatimah.

Pendidikan Diploma III ditempuh di Program Studi Meteorologi Akademi Meteorologi dan Geofisika Jakarta (AMG Jakarta), dan lulus pada tahun 2010. Pendidikan sarjana ditempuh di Program Studi Fisika, Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Tanjungura, dan lulus pada tahun 2015. Pada tahun 2020, penulis diterima sebagai mahasiswa program magister (S-2) di Program Studi Klimatologi Terapan pada Sekolah Pascasarjana Universitas IPB University dan menamatkannya pada tahun 2021 dengan biaya beasiswa pendidikan pascasarjana yang diperoleh dari Pusat Pendidikan dan Pelatihan Badan Meteorologi Klimatologi dan Geofisika (Pusdiklat BMKG).

Penulis bekerja sebagai *Observer* cuaca di BMKG sejak tahun 2010 dan pertama kali ditempatkan di Stasiun Meteorologi Supadio Pontianak. Kemudian pindah tugas di Stasiun Klimatologi Bogor dan bertugas sebagai *Forecaster* cuaca dan iklim hingga saat ini.

Karya ilmiah berjudul *Monthly Reservoir Inflow Prediction Based on Artificial Neural Network over Saguling Catchment Area* telah disajikan secara lisan pada seminar *International Conference on Tropical Meteorology & Atmospheric Science (ICTMAS)* dan dipublikasi di jurnal *IOP Conference Series : Earth Environmental Science* 893 012039.

Karya ilmiah tersebut merupakan bagian dari program S-2 penulis.