



# Analisis Performansi Prakiraan Cuaca Menggunakan Algoritma *Machine Learning*

## *Performance Analysis of Weather Forecasting using Machine Learning Algorithms*

Indo Intan<sup>1)</sup>, Rismayani<sup>2)</sup>, St. Aminah Dinayati Ghani<sup>3)</sup>, Nurdin<sup>4)</sup>, Aswar T.C. Koswara<sup>5)</sup>

<sup>1,2,3,4</sup> Universitas Dipa Makassar

<sup>5</sup> Kementerian Arsip Nasional Republik Indonesia

<sup>1,2,3,4</sup> Jl. P. Kemerdekaan Km. 9 Makassar Telp/Fax: 0411-587194/0411-587266

<sup>5</sup>Jl. Ampera Raya No. 7 Jakarta 12560

indo.intan@dipanegara.ac.id<sup>1)</sup>, rismayani@dipanegara.ac.id<sup>2)</sup>, dinayati.amy@dipanegara.ac.id<sup>3)</sup>, nurdin@dipanegara.ac.id<sup>4)</sup>, aswar@gmail.com<sup>5)</sup>

Diterima : 09 Agustus 2021 || Revisi : 19 September 2021 || Disetujui: 30 Oktober 2021

**Abstrak** – Prakiraan cuaca menjadi sangat urgent dalam berbagai bidang kehidupan manusia, termasuk di kota-kota besar. Kebutuhan akan akurasi prakiraan cuaca akan efektif dan efisien dalam mengelola kualitas peradaban secara fleksibel. Pada banyak kasus didapati bahwa hasil prakiraan cuaca dalam kota yang sama berbeda bergantung pada radiusnya. Hal ini tentu saja membutuhkan algoritma yang presisi dan akurat untuk menentukannya. Algoritma yang digunakan berbasiskan machine learning jenis jaringan saraf tiruan yang mengkomparasikan antara backpropagation dan bayesian regularization. Hasil yang diperoleh menunjukkan bahwa bayesian regularization mengungguli backpropagation dengan MSE terkecil dan akurasi tertinggi serta waktu komputasi tersingkat untuk menentukan prakiraan cuaca cerah, berawan, hujan ringan dan hujan berat. Distribusi data yang tidak seimbang berakibat pada fluktuasi naik-turun pada perhitungan MSE dan akurasi. Penambahan data latih akan meningkatkan kinerja sistem yang ditunjukkan dengan peningkatan akurasi yang signifikan. Demikian juga, penurunan MSE dapat meningkatkan akurasi sistem untuk mencapai titik stabilitas konvergensi. Hal ini menjadi indikator bahwa performansi bayesian regularization menjadi algoritma yang direkomendasikan untuk perkiraan cuaca di dalam kota dan sekitarnya, bahkan antar provinsi atau antar negara.

**Kata Kunci:** prakiraan cuaca, *backpropagation*, *bayesian regularization*, *machine learning*, akurasi.

**Abstract** – Weather forecasting is critical in various fields of human life, including in big cities. The need for accurate weather forecasts will be effective and efficient in managing the quality of civilization flexibly. In many cases, the results of weather forecasting in the same city differ depending on the radius. The classification process includes sunny, cloudy, light rain, and heavy rain on the dataset and approach. The approach used in this study is machine learning which has better precision and accuracy than others. The machine learning algorithms used to investigate the performance of weather forecasting are Backpropagation and Bayesian Regularization. The results showed that Bayesian Regularization is better than others. It produces the smallest MSE, highest accuracy, and fastest computational speed. The addition of training data will improve machine learning performance by significantly improved accuracy. Likewise, decreasing the MSE can increase the accuracy of the system to reach the point of convergence. It is an indicator that the performance of Bayesian regularization is the recommended algorithm for weather forecasting in cities and their surroundings, even between provinces or between countries.

**Keywords:** weather forecasting, *backpropagation*, *bayesian regularization*, *machine learning*, accuracy.

## PENDAHULUAN

Data cuaca berperan penting dalam pertanian, transportasi, industri makanan, sistem di bandara, data mining, ketersediaan daya listrik, pencarian energi baru dan terbarukan, dan prediksi kebakaran hutan (Holmstrom et al., n.d.). Prakiraan cuaca merupakan kajian yang menarik untuk dikerjakan apalagi dengan perkembangan kecerdasan buatan yang pesat penggunaannya di tengah masyarakat global. Dataset

cuaca tersedia secara open akses sehingga memudahkan untuk mencari metode terbaik dalam mengklasifikasinya.

Area kota menjadi salah satu objek yang cukup menarik karena sering terjadi perbedaan cuaca secara signifikan di kota yang sama dalam radius yang berbeda. Di bagian barat kota terjadi hujan deras sementara di bagian timur masih berawan sehingga penyajian data cuaca secara akurat merupakan tantangan dalam kajian ini. Informasi yang dihasilkan

apabila akurat dan terpercaya maka bermanfaat bagi aktivitas seluruh warga kota dan sekitarnya, secara nasional maupun secara internasional.

Permasalahan yang dihadapi dalam prakiraan cuaca antara lain kondisi atmosfer yang berubah-ubah tidak stabil, kesalahan pengukuran, data yang terlalu besar, dan pemahaman yang tidak lengkap terhadap performansi prakiraan cuaca yang dihasilkan.

Penentuan cuaca sangat penting karena merupakan proses kolaborasi antara ilmu pengetahuan dan teknologi untuk menentukan atmosfer bumi (Herwanto et al., n.d.) untuk menyajikan data (Jaseena & Kovoov, 2020). Faktor-faktor penting yang mempengaruhi cuaca, antara lain suhu (maksimum-minimum), kelembaban rata-rata, titik embun, kecepatan angin, tekanan atmosfer rata-rata, radiasi, dan kemungkinan terjadinya presipitasi di lokasi-lokasi di seluruh dunia (Holmstrom et al., n.d.). Akibatnya, prakiraan cuaca dalam informasi periodik harian, mingguan, bulanan, dan bahkan tahunan digunakan dalam pengambilan keputusan yang efektif. Dalam kasus khusus, akurasi prakiraan cuaca membantu untuk mempersiapkan menghadapi banjir dan kekeringan (Salman et al., 2016) serta mengoptimalkan irigasi lahan pertanian (Chen et al., 2021).

Teknik yang digunakan dalam prakiraan cuaca juga sangat bervariasi tergantung pada ilmu pengetahuan dan teknologi lampau dan kekinian, di antaranya adalah teknik numerik (Jung & Matsueda, 2016; Schulz et al., 2021) yang menggunakan komputer skala besar (Schalkwijk et al., 2015), kemudian dikembangkan menggunakan teknik machine learning dengan regresi linier (Holmstrom et al., n.d.), jaringan syaraf tiruan (Abhishek et al., 2012; Dalipi & Yayilgan, 2015; Kim et al., 2021; Matouq et al., 2013; Narvekar & Fargose, 2015; Nayak et al., 2012; Rodríguez et al., 2018; Vandegriff et al., 2005) dan pembelajaran mendalam (Fathi et al., n.d.; Hewage et al., 2020, 2021; Rodrigues et al., n.d.; Salman et al., 2018; Zuraidin Mohd-Safar et al., n.d.) Kerugian menggunakan regresi linier dalam prakiraan cuaca adalah regresi linier sebagai model variasi yang tinggi karena tidak stabil terhadap outlier sehingga untuk memperbaikinya diperlukan data yang lebih banyak. Penggunaan regresi fungsional memiliki hasil prediksi yang kurang baik karena interval data dalam dua hari terlalu pendek. Teknik ini membutuhkan banyak data tetapi waktu komputasinya juga lebih lama.

Menurut Abhishek et al (2012) dalam penelitiannya bahwa data non-linier pada data cuaca memerlukan statistik non-linier, hanya saja model non-linier ditentukan sebelum dilakukan estimasi. Hal ini tentu saja sulit karena data cuaca mengikuti tren yang sangat tidak teratur sehingga solusinya memungkinkan untuk menggunakan jaringan saraf tiruan dengan membandingkan dan menguji kinerja model yang dikembangkan menggunakan fungsi transfer yang berbeda. Kelebihan model jaringan saraf tiruan berdasarkan penelitian (Abhishek et al., 2012) dapat mengurangi biaya proses saat membaca data mentah yang dimodelkan dalam 10 input, 5 lapisan tersembunyi menggunakan 10 atau 16 neuron. Prediksi suhu maksimum diperluas ke faktor cuaca lain seperti kelembaban, kecepatan angin untuk dikembangkan pada konsentrasi tren cuaca jangka panjang di area kecil.

Penelitian berbasis deep learning (Rodrigues et al., n.d.) yang mengatasi penggunaan komputer resolusi tinggi karena sudah menggunakan unit pengolah umum. Hal ini memudahkan proses penelitian dengan menggunakan perpustakaan yang sesuai karena menggunakan jaringan yang terdistribusi secara global. Fitur cuaca juga dapat diinput secara otomatis menggunakan model deep learning melalui penskalaan menggunakan pengembangan jaringan syaraf tiruan. Sistem pembelajaran didasarkan pada pembelajaran terawasi.

Berdasarkan penelitian (Hewage et al., 2021) yang membuat model menggunakan 10 parameter cuaca dengan rentang prakiraan 12 jam. Model ini mengungguli riset dan peramalan cuaca hingga 12 jam. Keuntungan dari model ini adalah dapat berjalan pada komputer yang berdiri sendiri dan untuk prediksi cuaca jangka pendek hingga menengah di wilayah geografis. Model ini juga mampu mengatasi beberapa tantangan WRF, seperti memahami model dan instalasinya serta eksekusi dan probabilitas model.

Penggunaan Bayesian Regularization dan Levenberg Marquardt berhasil mempercepat pencapaian epoch maksimal dengan akurasi yang lebih baik dan jumlah data yang berkang (Dalipi & Yayilgan, 2015). Untuk mengatasi masalah overfitting, (Research & 2008, n.d.) meningkatkan learning rate diikuti dengan menghentikan pelatihan selama validasi dengan kesalahan minimum.

BESN memiliki akurasi yang memenuhi persyaratan operasional kelayakan pasokan listrik lebih

dari 90% (Li et al., 2015) yang sejalan dengan (Jazayeri et al., 2016) yang juga menghasilkan kinerja keseluruhan model jaringan saraf LM dan BR dalam waktu dan interval input yang berbeda menunjukkan kinerja trade off terbaik dalam memperkirakan daya.

Sejalan dengan hasil penelitian sebelumnya, (Alomari et al., 2018) menemukan bahwa kinerja peramalan memiliki RMSE sekitar 0,0753-0,0706 dengan 23-28 lapisan tersembunyi pada input pembelajaran yang sama, baik secara realtime maupun offline. Secara keseluruhan menurut (Yue et al., n.d.) bahwa hasil BRBPNN memiliki kinerja komprehensif yang lebih baik dan memiliki kemampuan untuk memilih parameter pengaturan otomatis dan dapat memastikan kemampuan beradaptasi dan keandalan yang baik.

Dari penelitian-penelitian sebelumnya menjadi tantangan bagi peneliti bahwa prakiraan cuaca merupakan masalah yang terus berkembang dari waktu ke waktu sesuai dengan revolusi ilmu pengetahuan dan teknologi yang mengadaptasinya. Pesatnya perkembangan teknologi internet of things, wireless sensor network, cloud computing dan artificial intelligence telah menjadi era kemajuan Big Data. Data dalam jumlah besar yang disajikan berpotensi menghasilkan informasi yang lebih akurat menggunakan pembelajaran mesin atau jaringan saraf.

Melalui sistem pembelajaran, jaringan saraf akan mengekstrak dan mengidentifikasi pola dari sekumpulan data cuaca. Beberapa metode yang digunakan sebelumnya masih memerlukan perbaikan akurasi yang tinggi, antara lain dalam mengatasi parameter jumlah data yang besar, kecepatan, akurasi prediksi, dan periode waktu peramalan dalam skala 3 jam sehari maupun dalam skala wilayah perkotaan yang lebih sempit. Dalam hal ini, kajian prakiraan cuaca masih memerlukan kontribusi penelitian yang berbeda. Untuk itu penulis fokus pada pengolahan data cuaca yang disajikan setiap tiga jam sekali menggunakan metode jaringan syaraf tiruan Bayesian Regularization.

Kajian ini bertujuan untuk melakukan investigasi terhadap performansi kedua algoritma machine learning, baik pada algoritma backpropagation maupun pada bayesian regularization.

## METODOLOGI PENELITIAN

Metode penelitian yang digunakan dalam penelitian ini adalah penelitian kuantitatif-eksperimental dengan

membandingkan algoritma backpropagation dan *bayessian regularization*. Kedua algoritma tersebut merupakan pengklasifikasi untuk meramalkan cuaca. Tahapan penelitian ini adalah pengumpulan data, eksperimentasi, pengujian dan evaluasi hasil penelitian.

**Pengumpulan Data,** Data ini bersumber dari website rp5.ru pada Class I Hasanuddin Makassar Meteorological Station Balai Besar Region IV Makassar yang berlokasi pada Bandara Sultan Hasanuddin Makassar yang berjarak 100 meter dari titik observasi dalam berformat *comma-separated vector (\*.csv)*.

Data yang digunakan yaitu data cuaca periode 3 jam/hari dalam jangka waktu 3 tahun (1 Januari 2016 – 31 Desember 2018) selama dua musim, yaitu musim hujan (Oktober-Maret) dan musim kemarau (April-September). Terdapat 7 parameter yaitu: Temperatur (T), Tekanan Udara (Po), Kelembaban Udara (P), Tudung Awan (Pa), Kecepatan Angin (U), Presipitasi (DD), Klasifikasi (Ff) dan 8656 baris data (4311 data musim hujan dan 4345 data musim kemarau) berdasarkan data mentah pada tabel 1a-1b.

**Tabel 1a** Fitur Cuaca pada data Mentah

Local time	T	Po	P	Pa	U	DD	Ff	N
01.01.2017 11:00	27	756	757	0,5	96	Wind blowing from the north-northwest	2	70–80%.
01.01.2017 14:00	32	754	756	1,4	70	Wind blowing from the west-northwest	3	70–80%.
01.01.2017 17:00	27	754	755	0,3	96	Wind blowing from the east-northeast	2	90 or more, but not 100%
01.01.2017 20:00	25	755	757	1,2	100	Wind blowing from the east-northeast	2	70–80%.

**Tabel 1b** Fitur Cuaca pada data Mentah

Local time	WW	W1/W2	RR
01.01.2017 11:00	Rain (not freezing) not falling as shower(s).	Cloud covering more than 1/2 of the sky during part of the appropriate period and covering 1/2 or less during part of the period.	1
01.01.2017 14:00	Clouds generally forming or developing.	Cloud covering more than 1/2 of the sky throughout the appropriate period.	1
01.01.2017 17:00	Clouds generally forming or developing.	Cloud covering more than 1/2 of the sky throughout the appropriate period.	3
01.01.2017 20:00	Clouds generally dissolving or becoming less developed.	Cloud covering more than 1/2 of the sky throughout the appropriate period.	0,2

**Akuisisi Data,** proses untuk membersihkan data mentah yang berasal dari sumber data menjadi data yang sudah diklaster berdasarkan klasifikasi output dari data yang diinginkan, yaitu: cerah (0), berawan (1), hujan ringan (2), dan hujan lebat (3). **Analisis Data,** menganalisis data dan membagi data ke dalam dua kategori: data training dan data

testing. Distribusi datanya melalui tiga skenario, yaitu 30%, 60% dan 100% pada kedua musim. Rasio data menggunakan 5 blok (4 data training: 1 data testing).

**Tabel 2** Klasifikasi berdasarkan *Threshold* Fitur Cuaca

Klasifikasi	Kondisi	Nilai
Cerah	Tudung Awan < 50%, Presipitasi < 1 mm	0
Berawan	Tudung Awan <= 100%, Presipitasi < 1 mm	1
Hujan Ringan	Tudung Awan <= 100%, Presipitasi < 10 mm	2
Hujan Lebat	Tudung Awan <= 100%, Presipitasi >= 10 mm	3

**Tabel 3** Hasil Akuisisi Data Cuaca

Waktu	T	Po	U	N	Ff	RRR	Klasifikasi	No
01.01.2016 11:00	32,3	758,5	70	50	2	0	Cerah	0
02.01.2016 02:00	25,8	757,9	100	40	1	0	Cerah	0
03.01.2016 02:00	25,6	757,8	100	25	2	0,2	Cerah	0
01.01.2016 02:00	26,9	758,5	100	75	1	0	Berawan	1
02.01.2016 11:00	31	758,8	79	75	3	0	Berawan	1
03.01.2016 17:00	31,9	757,1	72	60	5	0	Berawan	1
02.01.2016 23:00	26,3	758,8	100	60	2	5	Hujan R	2
11.01.2016 17:00	25,9	757,1	100	75	6	6	Hujan R	2
18.01.2016 17:00	25,9	755,5	100	95	5	5	Hujan R	2
01.01.2016 08:00	27,9	759,1	91	50	2	6	Hujan L	3
08.01.2016 08:00	28,2	758,7	85	10	2	2	Hujan L	3
13.01.2016 20:00	27,1	756,7	100	75	3	12	Hujan L	3

**Tabel 4** Distribusi Data Cuaca

Weather	Musim Hujan			Musim Kemarau		
	30%	60%	100%	30%	60%	100%
Cerah	349	569	905	682	1097	2028
Berawan	589	1250	2027	460	1171	1767
Hujan ringan	220	506	897	98	229	373
Hujan lebat	135	261	481	64	109	176
<b>Total</b>	<b>1293</b>	<b>2587</b>	<b>4311</b>	<b>1304</b>	<b>2607</b>	<b>4345</b>

*Eksprimen*, melakukan implementasi jaringan saraf tiruan pada kedua model, baik Backpropagation maupun pada Bayessian Regularization. Menentukan inisialisasi jaringan saraf melalui parameter maksimum epoch, error, *learning rate*, dan bias, dilanjutkan dengan menggambarkan arsitekturnya berupa jumlah neuron dan node pada jaringan input, tersembunyi maupun luarannya (Gambar 1).

Pada algoritma *backpropagation* menggunakan (pers. 1-8). Tahap feed forward, input jaringan ( $x_i = x_1..x_7$ ) merupakan fitur cuaca berupa temperature, tekanan udara, kelembaban udara, tudung awan, kecepatan angin, dan presipitasi. Pada bagian lapisan input, proses mengoperasikan sinyal input  $x_i$  dengan semua bias dan bobot lapisan input (pers 1). Fungsi aktivasi untuk memilih output lapisan tersembunyi berada pada range  $-1 \leq z_{inj} < 1$  (pers. 2). Output lapisan tersembunyi menjadi masukan lapisan

output mengoperasikan semua bias dan bobot lapisan output (pers 3), selanjutnya hasil ini dilewatkan pada fungsi aktivasi hingga diperoleh output jaringan saraf (pers 4).

$$z_{inj} = v_{oj} + \sum_{i=1}^n x_i v_{ij} \quad (1)$$

$$z_j = f(z_{inj}) \quad (2)$$

$$y_{inj} = v_{ok} + \sum_{i=1}^p z_i w_{jk} \quad (3)$$

$$y_k = f(y_{inj}) \quad (4)$$

Tahap berikutnya merupakan tahap koreksi error untuk memperbaiki nilai  $v_{ij}$  (pers. 5) dan nilai  $v_{oj}$  (pers. 6). Dan tahap akhir diperoleh nilai  $w_{jk}$  baru (pers. 7) dan  $v_{ij}$  (pers. 8) baru sebagai update terhadap bias dan bobot di setiap tahapan iterasi, epoch jaringan.

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (5)$$

$$\Delta v_{0j} = \alpha \delta_j \quad (6)$$

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (7)$$

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (8)$$

Pada algoritma bayessian regularization menggunakan persamaan (9)-(10).

$$(J^T J + \lambda I) \delta = J^T E \quad (9)$$

dimana  $J$  adalah matriks *Jacobian* ( $J$ ), pengurangan ( $\lambda$ ) dan update bobot ( $\delta$ ) agar diperoleh performa terbaik. Matriks  $J^T E$  setara dengan Hessian yang memperhitungkan Error pada outputnya. Perubahan bobot (pers 10) dan perbaikan bobot(pers. 11)

Perhitungan jumlah luaran sinyal kemudian mengupdate bias dan bobot. Perhitungan MSE sebagai hasil selisih antara nilai luaran dan target jaringan. Jika error dan ambang batas epoch tercapai, maka iterasi dihentikan, akan tetapi jika belum tercapai akan terus dilakukan hingga dicapai nilai terkecil pada daerah konvergen.

$$\Delta X = [J^T J + \mu I] - J^T e \quad (10)$$

$$X = X + \Delta X \quad (11)$$

Proses pada kedua algoritma akan dilakukan epoch, pembaruan bobot hingga tercapainya error sesuai dengan nilai pada tahapan training.

Mean Square Error (MSE) sebagai formula untuk mengukur error peramalan [15] sebagaimana persamaan (12).

$$\sum_{t=1}^n \frac{(X_t - F_t)^2}{n} \quad (12)$$

$X_t$  merupakan data factual dalam periode  $t$ ,  $F_t$  sebagai nilai peramalan dalam periode  $t$  dan  $n$  sebagai jumlah data. Oleh karena itu, pengujian akan membandingkan data probe dengan data training. Jika nilai error dan epoch tercapai sesuai

inisialisasi, maka dilakukan perbandingan antara nilai testing dan training. peramalan menghasilkan output nilai dalam bentuk cuaca cerah, berawan, hujan ringan, dan hujan berat.



**Gambar 1** Weather forecasting algorithms

*Pengujian dan evaluasi*, pengujian dilakukan untuk mengetahui performansi sistem yang meliputi akurasi dan kecepatan. Akurasi diperoleh melalui proses validasi antara data training dan data testing. Nilai validasi ditentukan menggunakan rumus akurasi pada pers. (13). Akurasi tinggi mengindikasikan bahwa peformansi metode yang satu lebih bagus dari metode lainnya.

$$\text{Akurasi} = \frac{\sum \text{Data yang valid}}{\sum \text{Keseluruhan Data}} \times 100\% \quad (13)$$

Kecepatan sebagai unsur performansi untuk mengukur waktu komputasi yang digunakan untuk melakukan training maupun testing dalam peramalan cuaca. Waktu yang paling lama digunakan saat proses training data karena masih dalam taraf pelatihan bagi sistem untuk menemukan error terkecil. Sedangkan pasa saat testing, tinggal membaca nilai data probe sesuai dengan hasil inisialisasi data saat proses training.

## HASIL DAN PEMBAHASAN

Proses peramalan cuaca sebagaimana dijelaskan sebelumnya menghasilkan output berupa: cerah, berawan, hujan ringan, dan hujan berat. Keseluruhan proses memberikan hasil sebagai berikut.

## Analisis Arsitektur Machine Learning

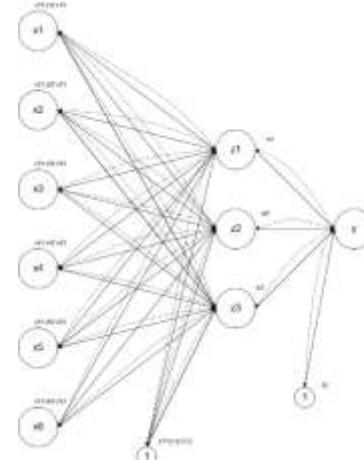
Untuk menganalisis jaringan lebih lanjut, maka dilakukan inisialisasi bias, bobot, epoch, dan learning rate untuk masing-masing jaringan saraf. Hasil yang diperoleh diperlihatkan tabel 1 dan tabel 2.

**Tabel 5** Proses Inisialisasi dan Training Data (Backpropagation)

NO	Learning rate	Hidden Neuron	Error (%)	Time (minutes)
1	0.1	3	0.103859	0.409
2	0.2	3	0.108919	0.433
3	0.3	3	0.090283	0.411
4	0.4	3	0.102711	0.427
5	0.5	3	0.110266	0.482

Pada Tabel 1 menunjukkan bahwa hasil inisialisasi algoritma backpropagation menggunakan learning rate 0.1-0.5 diperoleh error terkecil sehingga jaringan memiliki error terkecil (0.090283) dan kecepatan komputasi 24.66 detik pada record 3 dengan learning rate 0.3; dan hidden neuron (lapisan tersembunyi) berjumlah 3.

Gambar 2 menunjukkan arsitektur backpropagation yang terdiri atas 6 node neuron input ( $x_1-x_6$ ), 3 neuron lapisan tersembunyi ( $z_1-z_3$ ), dan 1 lapisan output. Kemudian pada tabel 6 digambarkan maximum epoch backpropagation sebesar 10,000 dengan learning rate 0.3 dengan goal  $10^{-3}$ ,  $10^{-4}$ , dan  $10^{-5}$ , serta bobot pada interval  $-1 \leq w_i < 1$  menghasilkan 1 output  $y$ . lapisan output akan mengakumulasi semua nilai dari hidden layer ke output layer.



**Gambar 2** Arsitektur Backpropagation

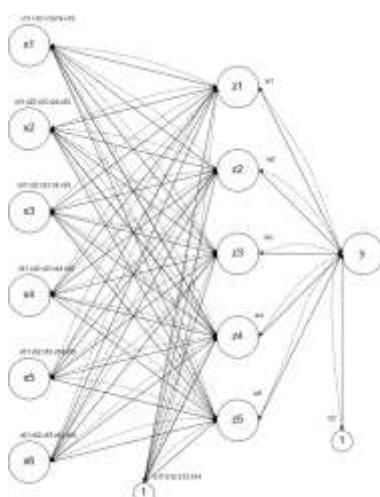
Pada tabel 6 menunjukkan bahwa hasil inisialisasi algoritma bayesian regularization menggunakan learning rate 0.001-0.009 diperoleh error terkecil sehingga jaringan memiliki error terkecil (0.00995) selama 24.66 detik waktu komputasi pada record195 dengan learning rate 0.001; dan hidden neuron (lapisan tersembunyi) berjumlah 5.

Gambar 3 menunjukkan arsitektur backpropagation yang terdiri atas 6 ( $x_1-x_6$ ) node neuron input, 5 neuron

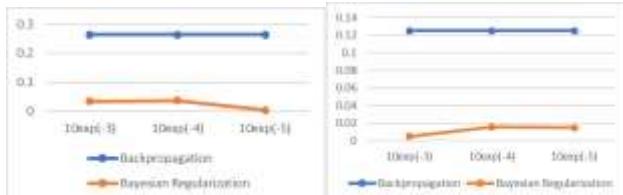
lapisan tersembunyi ( $z_1-z_5$ ), dan 1 lapisan output ( $y_k$ ). Kemudian pada tabel 6 digambarkan maximum epoch backpropagation sebesar 1,000 dengan learning rate 0.3 dengan goal  $10^{-3}$ ,  $10^{-4}$ , dan  $10^{-5}$ , serta bobot pada interval  $-1 \leq w_i < 1$  menghasilkan 1 output  $y$ . lapisan output akan mengakumulasi semua nilai dari hidden layer ke output layer.

**Tabel 6** Proses Inisialisasi dan Training Data (Bayesian Regularization)

NO	Learning rate	Hidden Neuron	Error (%)	Time (minutes)
1	0.001	3	0.0237	0.067
2	0.002	3	0.0249	0.016
3	0.003	3	0.0378	0.016
4	0.004	3	0.0389	0.016
5	0.005	3	0.0459	0.000
6	0.006	3	0.0427	0.000
7	0.007	3	0.0483	0.000
8	0.008	3	0.0427	0.033
9	0.009	3	0.0467	0.000
10	0.001	4	0.0234	0.016
11	0.002	4	0.0477	0.000
12	0.003	4	0.045	0.000
13	0.004	4	0.0446	0.016
14	0.005	4	0.0402	0.016
15	0.006	4	0.0402	0.016
16	0.007	4	0.0436	0.000
17	0.008	4	0.0312	0.000
18	0.009	4	0.0227	0.016
19	0.001	5	0.00995	0.000
20	0.002	5	0.0379	0.016



**Gambar 3** Bayessin regularization network architecture



**Gambar 4** Perbandingan MSE pada: a. Musim Hujan; b. Musim Kemarau

Hasil inisialisasi data training machine learning diperlihatkan pada tabel 7.

## Analisis Performansi Sistem

Performansi sistem sebagai indikator kinerja pada MSE, kecepatan, dan waktu komputasi digambarkan seperti penjelasan berikut. Tabel 8 menggambarkan bahwa pada backpropagation, nilai MSE lebih kecil pada musim kemarau sebesar 0.12484 selama 152.154 detik sedangkan pada musim hujan sebesar 0.264606 selama 186.9 detik. Fluktuasi MSE dari  $10^{-3}$ ,  $10^{-4}$ , dan  $10^{-5}$  secara berurutan cenderung konstan (Gambar 4). Sebaliknya pada bayessian regularization, nilai MSE pada musim hujan memiliki angka terkecil sebesar 0.00331 selama 12.030 detik; sedangkan nilai MSE pada musim kemarau mengalami fluktuasi menurun pada musim hujan meski pada musim kemarau megalami fluktuasi menanjak. Fluktuasi ini ditunjukkan pada gambar 4.

**Tabel 7** Hasil Inisialisasi Machine Learning

Net Size	Backpropagation	Bayesian Regularization
Input Layer:	6 node	6 nodes
Hidden Layer :	3 node	5 nodes
Output Layer :	1 node	1 node
Maximum epoch :	10000	1000
Show Epoch	10	10
$Mu$	0,3	0,001
Goal :	$10^{-3}$ , $10^{-4}$ , dan $10^{-5}$	$10^{-3}$ , $10^{-4}$ , dan $10^{-5}$
Weigth :	-1 sampai dengan 1	-1 sampai dengan 1
<b>Neuron Function</b>		
Hidden Layer :	Sigmoid Biner	Sigmoid Biner
Output Layer :	Linear	Linear

**Tabel 8** Hasil Pengujian Performansi terhadap MSE dan Waktu

Performansi Error dan Time	Musim Hujan		Musim Kemarau	
	BP	BR	BP	BR
MSE	0.264606	0.00331	0.12484	0.01509
time (s)	186,9	12,030	152,154	10,146

Berdasarkan nilai tersebut maka terlihat bahwa peformansi error dan masa komputasi BR lebih baik daripada BP karena kemampuan BR mengatasi over fitting selama proses klasifikasi secara presisi.

**Tabel 9** Hasil Pengujian Performansi terhadap Akurasi

Performansi Akurasi (%)	Musim Hujan		Musim Kemarau	
	BP	BR	BP	BR
Cerah	35.88%	99.89%	100.00%	99.16%
Berawan	79.54%	100.00%	67.89%	99.89%
Hujan Ringan	89.58%	100.00%	65.67%	97.05%
Hujan Berat	82.57%	97.51%	62.50%	93.75%
Total	68.33%	99.70%	87.57%	99.06%

Nilai akurasi pada backpropagation musim hujan lebih kecil sebesar 68.33% daripada pada musim kemarau sebesar 87.57%, sebaliknya bayesian regularization pada musim hujan memiliki nilai akurasi terbesar 99.70% dan menurun pada musim kemarau sebesar 99.06%. perbedaan fluktuasi kenaikan dan penurunan ini disebabkan karena distribusi data (tabel

4) yang tidak seimbang pada setiap nilai cuaca sehingga kemampuan validasi jaringan juga berfluktuasi akibat faktor noise yang terjadi selama proses distribusi data (Gambar 5-6).



**Gambar 5** Perbandingan Akurasi Backpropagation-Bayesian Regularization pada Musim Hujan



**Gambar 6** Perbandingan Akurasi Backpropagation-Bayesian Regularization pada Musim Kemarau

Berdasarkan hasil analisis dari performansi sistem maka disimpulkan bahwa: 1) nilai MSE BP musim kemarau lebih kecil daripada musim hujan karena jumlah data musim kemarau lebih besar daripada musim hujan karena semakin banyak data berarti semakin banyak pengalaman bagi sistem peramalan untuk mengenai berbagai pola cuaca; 2) Akurasi bayesian regularization cenderung stabil karena mengikuti jumlah data, semakin besar datanya maka akurasinya semakin tinggi; 3) algoritma bayesian regularization memiliki MSE terkecil dan akurasi paling tinggi dibandingkan algoritma backpropagation.

## KESIMPULAN

Prakiraan cuaca yang memiliki fitur tekanan udara, kelembaban, tudung awan, kecepatan angin dan curah hujan menggunakan jaringan saraf regularisasi bayesian memiliki kinerja yang lebih baik daripada backpropagation. Hal ini menunjukkan bahwa penggunaan metode ini memberikan akurasi yang tinggi dan kecepatan konvergensi yang baik. Untuk pengembangan selanjutnya membandingkan dengan algoritma *deep learning*, selain itu perlu dilakukan rasionalisasi secara seimbang pada dataset sehingga

akurasi dan error lebih stabil agar diperoleh performansi terbaik dan algoritma ini layak untuk direkomendasikan.

## DAFTAR PUSTAKA

- Abhishek, K., Singh, M. P., Ghosh, S., & Anand, A. (2012). Weather Forecasting Model using Artificial Neural Network. *Procedia Technology*, 4, 311–318. <https://doi.org/10.1016/j.protcy.2012.05.047>
- Alomari, M. H., Younis, O., & Hayajneh, S. M. A. (2018). A Predictive Model for Solar Photovoltaic Power using the Levenberg-Marquardt and Bayesian Regularization Algorithms and Real-Time Weather Data. In *IJACSA) International Journal of Advanced Computer Science and Applications* (Vol. 9, Issue 1). [www.ijacsa.thesai.org](http://www.ijacsa.thesai.org)
- Chen, M., Cui, Y., Wang, X., Xie, H., Liu, F., Luo, T., Zheng, S., & Luo, Y. (2021). A reinforcement learning approach to irrigation decision-making for rice using weather forecasts. *Agricultural Water Management*, 250, 106838. <https://doi.org/10.1016/j.agwat.2021.106838>
- Dalipi, F., & Yayilgan, S. Y. (2015). *The Impact of Environmental Factors to Skiing Injuries: Bayesian Regularization Neural Network Model for Predicting Skiing Injuries SEMCON: Semantic and contextual objective metric View project AEP (Academic Exchange for Progress) View project The Impact of Environmental Factors to Skiing Injuries: Bayesian Regularization Neural Network Model for Predicting Skiing Injuries*. <https://doi.org/10.1109/ICCCNT.2015.7395218>
- Fathi, M., Mostafa, ., Kashani, H., Seyed, ., Jameii, M., & Ebrahim Mahdipour, . (n.d.). Big Data Analytics in Weather Forecasting: A Systematic Review. *Archives of Computational Methods in Engineering*, 1, 3. <https://doi.org/10.1007/s11831-021-09616-4>
- Herwanto, R., on, R. P.-I. C., & 2018, undefined. (n.d.). Rainfall Prediction Using Data Mining Techniques. *Jurnal.Darmajaya.Ac.Id*. Retrieved July 30, 2021, from <https://jurnal.darmajaya.ac.id/index.php/icitb/article/view/1020>
- Hewage, P., Behera, A., Trovati, M., Pereira, E., Ghahremani, M., Palmieri, F., & Liu, Y. (2020). Temporal convolutional neural (TCN) network for an effective weather forecasting using time-series data from the local weather station. *Soft Computing*, 24(21), 16453–16482. <https://doi.org/10.1007/s00500-020-04954-0>
- Hewage, P., Trovati, M., Pereira, E., & Behera, A. (2021). Deep learning-based effective fine-grained weather forecasting model. *Pattern Analysis and Applications*, 24(1), 343–366. <https://doi.org/10.1007/s10044-020-00898-1>
- Holmstrom, M., Liu, D., Appl, C. V.-M., & 2016, undefined. (n.d.). Machine learning applied to weather

- forecasting. *Cs229.Stanford.Edu*. Retrieved July 3, 2021, from <http://cs229.stanford.edu/proj2016/report/HolmstromLiuVo-MachineLearningAppliedToWeatherForecasting-report.pdf>
- Jaseena, K. U., & Kovoor, B. C. (2020). Deterministic weather forecasting models based on intelligent predictors: A survey. In *Journal of King Saud University - Computer and Information Sciences*. King Saud bin Abdulaziz University. <https://doi.org/10.1016/j.jksuci.2020.09.009>
- Jazayeri, K., Jazayeri, M., & Uysal, S. (2016). Comparative analysis of levenberg-marquardt and bayesian regularization backpropagation algorithms in photovoltaic power estimation using artificial neural network. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9728, 80–95. [https://doi.org/10.1007/978-3-319-41561-1\\_7](https://doi.org/10.1007/978-3-319-41561-1_7)
- Jung, T., & Matsueda, M. (2016). Verification of global numerical weather forecasting systems in polar regions using TIGGE data. *Quarterly Journal of the Royal Meteorological Society*, 142(695), 574–582. <https://doi.org/10.1002/QJ.2437>
- Kim, S., Lee, J., & Yoon, T. (2021). Road surface conditions forecasting in rainy weather using artificial neural networks. *Safety Science*, 140, 105302. <https://doi.org/10.1016/j.ssci.2021.105302>
- Li, G., Li, B. J., Yu, X. G., & Cheng, C. T. (2015). Echo state network with Bayesian regularization for forecasting short-term power production of small hydropower plants. *Energies*, 8(10), 12228–12241. <https://doi.org/10.3390/en81012228>
- Matouq, M., El-Hasan, T., Al-Bilbisi, H., Abdelhadi, M., Hindiyeh, M., Eslamian, S., & Duheisat, S. (2013). The climate change implication on Jordan: A case study using GIS and Artificial Neural Networks for weather forecasting. *Journal of Taibah University for Science*, 7(2), 44–55. <https://doi.org/10.1016/J.JTUSCI.2013.04.001>
- Narvekar, M., & Fargose, P. (2015). *Daily Weather Forecasting using Artificial Neural Network*. <http://dspace.sfit.co.in:8004/xmlui/handle/123456789/937>
- Nayak, R., Patheja, P. S., & Waoo, A. (2012). An enhanced approach for weather forecasting using neural network. *Advances in Intelligent and Soft Computing*, 131 AISC(VOL. 2), 833–839. [https://doi.org/10.1007/978-81-322-0491-6\\_76](https://doi.org/10.1007/978-81-322-0491-6_76)
- Research, L. S.-E. P. S., & 2008, undefined. (n.d.). Peak load forecasting using Bayesian regularization, Resilient and adaptive backpropagation learning based artificial neural networks. *Elsevier*. Retrieved July 2, 2021, from <https://www.sciencedirect.com/science/article/pii/S0378779607002258>
- Rodríguez, F., Fleetwood, A., Galarza, A., & Fontán, L. (2018). Predicting solar energy generation through artificial neural networks using weather forecasts for microgrid control. *Renewable Energy*, 126, 855–864. <https://doi.org/10.1016/j.renene.2018.03.070>
- Salman, A. G., Heryadi, Y., Abdurahman, E., & Suparta, W. (2018). Single Layer & Multi-layer Long Short-Term Memory (LSTM) Model with Intermediate Variables for Weather Forecasting. *Procedia Computer Science*, 135, 89–98. <https://doi.org/10.1016/J.PROCS.2018.08.153>
- Salman, A. G., Kanigoro, B., & Heryadi, Y. (2016). Weather forecasting using deep learning techniques. *ICACIS 2015 - 2015 International Conference on Advanced Computer Science and Information Systems, Proceedings*, 281–285. <https://doi.org/10.1109/ICACIS.2015.7415154>
- Schalkwijk, J., Jonker, H. J. J., Siebesma, A. P., & Meijgaard, E. Van. (2015). Weather Forecasting Using GPU-Based Large-Eddy Simulations. *Bulletin of the American Meteorological Society*, 96(5), 715–723. <https://doi.org/10.1175/BAMS-D-14-00114.1>
- Schulz, B., El Ayari, M., Lerch, S., & Baran, S. (2021). Post-processing numerical weather prediction ensembles for probabilistic solar irradiance forecasting. *Solar Energy*, 220, 1016–1031. <https://doi.org/10.1016/J.SOLENER.2021.03.023>
- Vandegriff, J., Wagstaff, K., Ho, G., & Plauger, J. (2005). Forecasting space weather: Predicting interplanetary shocks using neural networks. *Advances in Space Research*, 36(12), 2323–2327. <https://doi.org/10.1016/j.asr.2004.09.022>
- Yue, Z., Songzheng, Z., ... L. T.-I. C. on, & 2011, undefined. (n.d.). Bayesian regularization BP Neural Network model for predicting oil-gas drilling cost. *Ieeexplore.Ieee.Org*. Retrieved July 2, 2021, from <https://ieeexplore.ieee.org/abstract/document/5917952/>
- Zuraidin Mohd-Safar, N., Ndzi, D., Kagalidis, I., Yang, Y., & Zakaria, A. (n.d.). Short-Term Localized Weather Forecasting By Using Different Artificial Neural Network Algorithm In Tropical Climate. In *Springer*. Retrieved July 2, 2021, from [https://link.springer.com/chapter/10.1007/978-3-319-56991-8\\_35](https://link.springer.com/chapter/10.1007/978-3-319-56991-8_35)