

Prediksi Ketinggian Air Laut untuk Pertimbangan Otomasi Buka Tutup Pintu Air Laut Menggunakan *Neural Network*

Ahsanul Hadi Nugraha, Arif Musthofa, dan Berlian Al Kindhi
Departemen Teknik Elektro Otomasi, Institut Teknologi Sepuluh Nopember (ITS)
e-mail: arif@ee.its.ac.id

Abstrak—Proses produksi garam di PT. Garam bermula dari mengalirkan air laut melalui sebuah pintu air ke dalam tambak pengeringan. Air akan masuk ke dalam tambak secara alami hanya saat ketinggian air di luar tambak lebih tinggi dibandingkan dengan ketinggian air di dalam tambak. Untuk mengoptimalkan produksi garam, PT. Garam membutuhkan kemampuan memprediksi ketinggian air laut. Kemampuan memprediksi ketinggian air laut diperuntukkan untuk pengoptimalan penggunaan pintu air laut dalam proses produksi garam seperti waktu pembukaan dan penutupan pintu air laut. Waktu pembukaan atau penutupan yang tidak tepat dapat menyebabkan air laut mengalir kembali keluar yang akan mengurangi potensial kuantitas garam yang akan dihasilkan. Proyek Akhir ini dilakukan untuk memenuhi kebutuhan dari PT. Garam dengan menggunakan metode *Feedforward Neural Network* untuk memprediksi ketinggian air laut. Model *Feedforward Neural Network* akan menggunakan nilai kecepatan angin, nilai temperatur, dan nilai derajat fase bulan untuk menghasilkan nilai prediksi ketinggian air laut. Penggunaan metode *Feedforward Neural Network* didasarkan dari jumlah data yang digunakan yang berjumlah 17.520 di mana metode peramalan konvensional dinilai kurang memadai. Hasil dari Proyek Akhir ini adalah sebuah model *FeedForward Neural Network* yang dapat memprediksi ketinggian air laut dengan nilai *mean squared error* antara nilai prediksi dan nilai nyata sebesar 0,0386.

Kata Kunci—*Feedforward Neural Network*, Jaringan Syaraf Buatan, Ketinggian Air Laut, Peramalan Jangka Sangat Pendek.

I. PENDAHULUAN

LAUTAN mencakup sekitar 70,8% dari permukaan bumi. Sebagai unit geografis dan ekosistem terbesar di Bumi, lautan dapat membawa dampak yang sangat besar bagi Bumi, bahkan dengan perubahan kecil. Salah satu dari perubahan yang terjadi pada lautan adalah ketinggian air laut atau juga dikenali dengan pasang surut air laut. Pasang surut air laut merupakan salah satu gejala alam yang dapat diartikan sebagai suatu gerakan vertikal (naik turunnya air laut secara teratur dan berulang-ulang) dari seluruh partikel massa air laut dari permukaan sampai bagian terdalam dari dasar laut. Gerakan pasang surut air laut disebabkan oleh pengaruh gravitasi (gaya tarik menarik) antara bumi, bulan, dan matahari.

Salah satu keuntungan dari mengetahui ketinggian air laut adalah kemampuan untuk memprediksi cuaca. Seperti yang dijelaskan pada paragraf sebelumnya, lautan mencakup 70,8% dari permukaan bumi yang menjadikan lautan sebagai salah satu elemen terbesar yang mempengaruhi cuaca dari suatu tempat. Data ketinggian air laut juga dapat digunakan untuk memprediksi kondisi laut berbahaya seperti badai atau gelombang tinggi [1]. Selain itu, kemampuan memprediksi

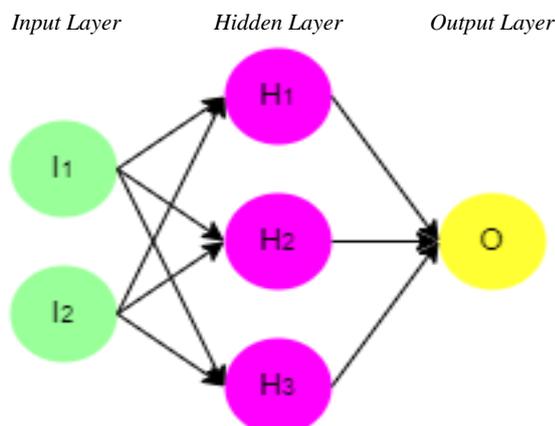
ketinggian air laut juga dapat digunakan dalam dunia industri seperti contohnya pada industri produksi garam di mana air laut digunakan sebagai bahan baku. Proses produksi garam dimulai dengan mengalirkan air laut melalui sebuah pintu air ke dalam sebuah tambak lalu mengeringkan air laut di bawah sinar matahari. Air laut akan menguap dan meninggalkan kristal-kristal garam yang siap dipanen. Proses produksi garam melalui cara ini bergantung pada kondisi air laut.

Pada penelitian ini, penulis membuat sebuah model NN yang dapat meramalkan ketinggian air laut jangka sangat pendek karena adanya kebutuhan dari sebuah mitra yang merupakan perusahaan produksi garam. Kebutuhan pada mitra ini didasarkan dari adanya kemauan untuk mengotomatisasi produksi garam terutama pada bidang pengoperasian pintu air laut. Mitra membutuhkan kemampuan untuk memprediksi ketinggian air laut untuk pengoptimalan waktu buka tutup dari pintu air laut. Berdasarkan kebutuhan dari mitra, penulis mengusulkan sebuah penelitian yang berjudul “Prediksi Ketinggian Air Laut Untuk Pertimbangan Otomasi Buka Tutup Pintu Air Laut Menggunakan *Neural Network*”. Dalam penelitian ini, peneliti akan menggunakan nilai temperatur, nilai kecepatan angin, dan nilai derajat fase bulan sebagai masukan dari model *Neural Network* (NN) prediksi ketinggian air laut. Hasil yang dikeluarkan adalah prediksi ketinggian air laut ke depan dalam periode per jam. Penelitian ini menggunakan metode NN berjenis *FeedForward Neural Network* (FFNN).

II. TINJAUAN PUSTAKA

A. Penelitian Terdahulu

River flow prediction using hybrid PSO-GSA algorithm based on feed-forward neural network meneliti mengenai penggunaan metode FFNN dalam memprediksi aliran sungai. Peneliti membuat sebuah model hibrida yang menggabungkan FFNN dengan algoritma hibrida dari *Particle Swarm Optimization and Gravitational Search Algorithms* (PSO-GSA) untuk memprediksikan aliran sungai. FFNN pada model hibrida ini menggunakan *Back-Propagation* (BP) karena kalkulasi dari FFNN dikenal dalam menangani berbagai masalah desain. PSO-GSA merupakan gabungan dari *Particle Swarm Optimization* (PSO) yang merupakan perhitungan serbaguna untuk memecahkan masalah optimasi serta terinspirasi oleh perilaku kawanan di alam dan *Gravitational Search Algorithm* (GSA) yang juga merupakan algoritma yang terinspirasi dari alam berdasarkan pemodelan matematis hukum gravitasi. Penulis menggunakan 5 indikator statistik untuk mengukur performa dari model, yaitu *Root-Mean-Square Error* (RMSE), *Mean Absolute Error* (MAE), *Nash-Sutcliffe Efficiency Coefficient* (NSE),



Gambar 1. Arsitektur neural network.

Willmott's *Index of Agreement* (WI), dan Taylor Diagram. Model ini diuji di Sungai Turkey, Iowa dan menggunakan data antara tahun 1990 sampai 2016. Hasil pengujian dari model FNN-PSOGSA dinilai dapat digunakan dengan baik untuk memprediksi aliran sungai di tempat pengujian [2].

Penelitian lain dalam kemampuan metode NN dalam memprediksi ketinggian air, yaitu *Deep Machine Learning-Based Water Level Prediction Model for Colombo Flood Detention Area* meneliti mengenai pengaplikasian teknik *deep machine-learning* untuk memprediksi ketinggian air pada sebuah lahan basah perkotaan yang berlokasi di ibu kota Sri Lanka. Penelitian ini juga mempelajari 2 tipe hubungan yaitu hubungan tradisional antara ketinggian air dan faktor lingkungan seperti temperatur, kelembaban, kecepatan angin, dan evaporasi dan hubungan sementara antara ketinggian air harian. Dua tipe NN digunakan dalam penelitian ini untuk dibandingkan, yaitu FFNN dan *Long Short-Term Memory (LSTM) Neural Network*. Pengujian model NN dilakukan di daerah penahanan banjir Colombo yang berlokasi di provinsi barat Sri Lanka. Hasil dari penelitian ini menunjukkan bahwa LSTM mampu mengungguli FFNN dan membuktikan bahwa hubungan sementara antara ketinggian air harian lebih baik dalam memprediksi ketinggian air lahan basah dibandingkan dengan hubungan tradisional [3].

B. Artificial Neural Network (ANN)

Artificial Neural Network (ANN) atau dapat dikenal juga sebagai *Neural Network* (NN) merupakan model pengkomputasian efisien yang berbentuk model matematis dan terinspirasi oleh jaringan syaraf biologis [4]. Jaringan syaraf biologis terdiri dari kumpulan-kumpulan *neuron* yang merupakan sebuah sel khusus yang berfungsi untuk memproses informasi. *Neuron* terdiri dari sebuah badan sel atau soma, sebuah akson dan sebuah dendrit. Pengkomputasian di dalam otak dilakukan oleh jaringan *neuron* yang saling berhubungan dan berkomunikasi dengan mengirimkan listrik pulsa melalui kabel saraf yang terdiri dari akson, sinapsis, dan dendrit [5].

ANN terdiri dari satu atau lebih lapisan yang terhubung satu sama lain dan terbentuk atau terstruktur dalam bentuk arsitektur tertentu. Setiap lapisan dari NN terdiri dari satu atau lebih *nodes* yang saling terhubung dengan sebuah neuron yang memiliki *weight* atau bobot tertentu. Arsitektur NN terdiri dari beberapa jenis lapisan seperti lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*). Lapisan masukan merupakan lapisan

Tabel 1.
Contoh Dataset Gabungan

Temperatur (Fahrenheit)	Derajat Bulan (Derajat)	Kecepatan Angin (Mil per Jam)	Ketinggian (Meter)
77	22,60	5	2,1
77	23,10	3	1,7
77	23,60	3	1,2
77	24,10	3	0,8
77	24,60	3	0,5
...
...
...
79	69,00	13	1,9
79	68,40	12	1,7
79	68,00	12	1,6
79	67,50	14	1,4
79	67,00	12	1,3

Tabel 2.

Dampak Persentase Pemisahan Data Terhadap MSE pada FFNN	
Persentase Pemisahan Data Latihan/Tes (Persentase)	Mean Squared Error
60/40	0,0390
70/30	0,0413
80/20	0,0396
90/10	0,0440

Tabel 3.

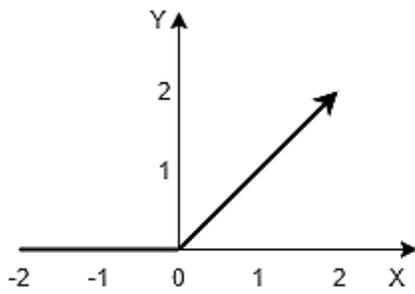
Dampak Persentase Pemisahan Data Terhadap MSE pada RNN	
Persentase Pemisahan Data Latihan/Tes (Persentase)	Mean Squared Error
60/40	0,0394
70/30	0,0414
80/20	0,0396
90/10	0,0433

pertama dalam NN yang bertugas menerima masukan dari luar sedangkan lapisan keluaran merupakan lapisan terakhir yang bertugas memberikan hasil keluaran dari NN. Lapisan tersembunyi merupakan lapisan di antara lapisan masukan dan lapisan keluaran. Lapisan ini merupakan lapisan yang bertanggung jawab untuk memproses setiap masukan dari lapisan masukan.

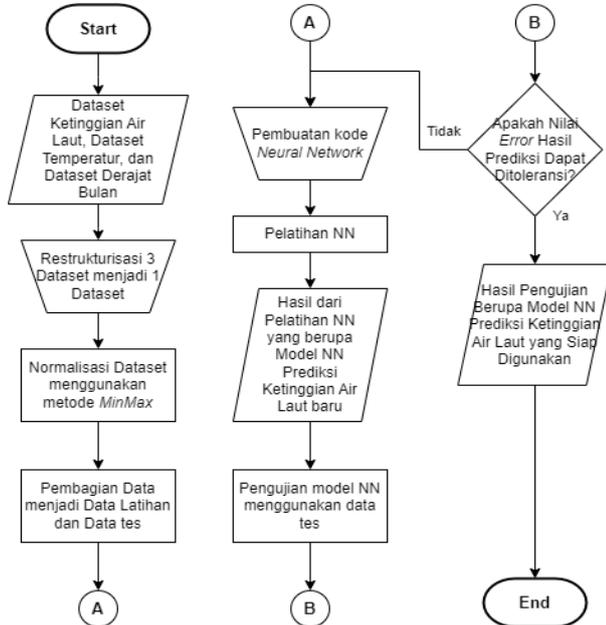
Untuk melatih NN agar mampu mengolah masukan sesuai dengan yang diinginkan, NN harus melalui proses pelatihan atau pembelajaran terlebih dahulu. Dalam proses pelatihan, NN akan diberikan data masukan dan target keluaran nyata dari data masukan yang diberikan. Hasil dari keluaran model NN serta target nyata kemudian akan dibandingkan dan dicari nilai *error*. Dari nilai *error* ini, NN akan memperbaiki nilai bobot pada setiap *neuron* untuk mendapatkan keluaran yang ditargetkan dari hasil masukan. Proses pelatihan ini menggunakan algoritma *backpropagation* dan dilakukan berkali-kali untuk mengoptimalkan nilai bobot dan mengecilkan nilai *error* dari keluaran NN seperti pada Gambar 1.

Salah satu jenis dari ANN adalah *Feedforward Neural Network* (FFNN). Sebuah NN dapat diklasifikasikan sebagai FFNN apabila semua *nodes* pada NN sepenuhnya terhubung ke *nodes* di lapisan setelahnya tetapi tidak terhubung ke *nodes* di lapisan yang sama atau informasi mengalir ke arah depan atau satu arah dari lapisan masukan ke lapisan keluaran tanpa adanya *feedback loop* atau koneksi mundur [6]. Aliran informasi dalam NN dimulai dari lapisan masukan yang kemudian akan diproses oleh lapisan tersembunyi sebelum hasilnya akan dikeluarkan melalui lapisan keluaran.

Terdapat jenis lain dari ANN, yaitu *Recurrent Neural Network* (RNN). RNN adalah sebuah NN yang umum



Gambar 2. Grafik fungsi ReLU.



Gambar 3. Diagram alir pembuatan dan pelatihan NN.

digunakan untuk mendeteksi pola dalam sebuah urutan data [7] Dengan kata lain, RNN merupakan NN yang berspesialisasi untuk bekerja pada data deret waktu atau data yang melibatkan urutan. Data deret waktu yang menjadi masukan RNN dapat berupa tulisan tangan, genom, teks, atau numerik rangkaian waktu. Salah satu perbedaan paling mencolok antara RNN dan FFNN adalah RNN memiliki *feedback loop*. RNN akan dijadikan sebagai metode pembandingan dari metode FFNN.

C. Activation Function (AF)

Di dalam ANN terdapat suatu fungsi yang bernama *Activation Function* (AF) atau fungsi aktivasi. Fungsi aktivasi merupakan sebuah fungsi yang digunakan dalam NN untuk mengkomputasi data dari hasil penjumlahan masukan, bobot, dan bias [8]. AF memiliki peran penting dalam pelatihan NN di mana AF memberikan nonlinieritas model yang diperlukan untuk dapat mempelajari representasi yang kompleks. Dalam penelitian ini, digunakan AF berjenis *Rectified Linear Unit* (ReLU).

ReLU merupakan fungsi *piecewise-linear* atau ‘sepotong-potong’ yang berarti fungsi ini terdiri dari ruas-ruas garis. Jenis fungsi *piecewise* ini memiliki ciri-ciri di mana fungsi-fungsi jenis ini ringan dalam penggunaan sumber daya pengkomputasian seperti pada Gambar 2 [9]. AF ReLU dikenal juga dengan nama *positive-part function* atau *ramp function*. Nama *rectified* berasal dari sebuah perangkat listrik bernama *rectifier* atau penyearah gelombang yang mengubah arus *alternating current* (AC) menjadi arus *direct current*



Gambar 4. Diagram alir peramalan ketinggian air laut.

(DC). AF ReLU memiliki fungsi yang sama dengan penyearah gelombang di mana AF ReLU membiarkan masukan positif lewat tanpa diubah sementara memotong masukan negatif. Berikut merupakan formula dari AF ReLU.

$$f(x) = \max(0, x) = \begin{cases} x_i, & \text{if } x_i \geq 0 \\ 0, & \text{if } x_i < 0 \end{cases} \quad (1)$$

D. Ketinggian Air Laut

Ketinggian air laut atau yang dikenal juga dengan Pasang-surut (Pasur) merupakan suatu gerakan vertikal (naik turunnya air laut secara teratur dan berulang-ulang) dari seluruh partikel massa air laut dari permukaan sampai bagian terdalam dari dasar laut. Gerakan pasang surut air laut disebabkan oleh pengaruh gravitasi (gaya tarik menarik) antara bumi, bulan, dan matahari [1]. Bulan dan matahari memiliki gelombang air laut tersendiri yang dipengaruhi oleh gaya gravitasi dari masing-masing benda langit. Namun dikarenakan posisi bulan yang lebih dekat dengan bumi, gelombang air laut yang dihasilkan oleh gaya gravitasi bulan lebih besar dibandingkan dengan gelombang air laut yang dihasilkan oleh gaya gravitasi matahari. Di saat matahari, bumi, dan bulan berada dalam satu garis, gelombang matahari dan gelombang bulan saling bertumpukan atau sefase sehingga menghasilkan gelombang pasang tertinggi dan surut terendah yang dinamakan *spring tide*. Kondisi *spring tide* terjadi saat bulan baru dan bulan purnama. Kondisi sebaliknya terjadi saat garis bulan-bumi tegak lurus dengan garis bumi-matahari di mana gelombang bulan dan gelombang matahari tidak sefase yang dinamakan *neap tide*. Dalam kondisi *neap tide*, air laut mengalami gelombang pasang terendah dan gelombang surut tertinggi. Kondisi *neap tide* terjadi saat fase bulan kuartal pertama dan kuartal ketiga.

Puncak gelombang disebut pasang tinggi dan lembah gelombang disebut surut/pasang rendah. Perbedaan vertikal antara pasang dan surut disebut rentang pasang surut atau tunggang pasang surut (*tidal range*) yang bisa mencapai beberapa meter hingga puluhan meter. Periode pasang surut

adalah waktu antara puncak atau lembah gelombang ke puncak atau lembah gelombang berikutnya. Periode pasang surut dapat bervariasi antara 12 jam 25 menit hingga 24 jam 50 menit.

Selain gravitasi dari benda-benda langit, ketinggian air laut juga dipengaruhi oleh perubahan lingkungan seperti pemanasan global. Korelasi antara pemanasan global dengan ketinggian air laut dapat dilihat dari perubahan volume air atau es di daratan seperti salju atau gletser yang dapat mengubah ketinggian air laut [10].

E. Python

Python adalah sebuah bahasa pemrograman yang kuat dan elegan yang mudah dipahami. Python memiliki sebagian besar fitur umum yang dimiliki oleh bahasa-bahasa pemrograman lain dan sudah banyak diaplikasikan di dunia nyata. Python juga didukung oleh *library* atau kumpulan kode-kode yang mudah digunakan, mudah dipasang, dan sangat berguna untuk menghemat waktu. Contoh dari *library* pada bahasa pemrograman adalah Numpy, Pandas, dan Tensorflow. Bersangkutan dengan penelitian ini, python akan digunakan sebagai bahasa pemrograman model NN baik dalam proses pelatihan maupun penggunaan.

III. PETUNJUK TAMBAHAN

A. Diagram Alir Pembuatan dan Pelatihan Neural Network

Diagram alir ini menjadi panduan bagi penulis dalam membuat dan melatih model NN prediksi ketinggian air laut. Proses pembuatan model NN dimulai dari pengakuisisian *dataset* rekaman ketinggian air laut, *dataset* rekaman temperatur, *dataset* rekaman kecepatan angin, dan *dataset* rekaman derajat bulan yang akan digunakan sebagai *dataset* pelatihan model NN. Data-data rekaman kemudian akan distrukturisasi di mana nilai temperatur, nilai kecepatan angin, dan nilai derajat fase bulan berperan sebagai masukan dari model NN serta nilai ketinggian air laut digunakan sebagai target keluaran. Setelah itu, *dataset* melalui proses normalisasi. *Dataset* yang telah dinormalisasi kemudian dipisah menjadi data latihan dan data tes dengan persentase data latihan lebih banyak dibandingkan dengan data tes.

Model NN dideklarasikan di dalam bahasa pemrograman Python. Model NN yang dideklarasikan berisi jumlah *nodes* masukkan, jumlah lapisan tersembunyi, jumlah *nodes* pada masing-masing lapisan tersembunyi, AF yang digunakan dalam lapisan tersembunyi, *learning rate* dan *epochs* maksimal pelatihan. Setelah semua parameter dideklarasikan, pelatihan NN dimulai menggunakan data latihan. Model hasil latihan ini merupakan model NN yang akan digunakan sebagai model prediksi ketinggian air laut. Untuk menguji *error* dari model yang telah dilatih, NN diberikan data tes dan dihitung perbedaan antara nilai target dengan nilai prediksi. Apabila nilai *error* dari model masih masuk nilai yang ditoleransi, maka NN dinyatakan siap digunakan. Apabila tidak, maka proses pelatihan akan dimulai dari awal kembali dengan perbedaan pada parameter. Untuk mengukur nilai *error* ini, digunakan standar MSE. Diagram alir dapat dilihat pada Gambar 3.

Persamaan dari MSE yang akan digunakan dalam menentukan nilai *error* dari model NN adalah sebagai berikut:

Tabel 4.

Dampak <i>Learning Rate</i> Terhadap MSE pada FFNN	
<i>Learning Rate</i>	<i>Mean Squared Error</i>
0,001	0,0389
0,005	0,0390
0,010	0,0391
0,050	0,0393
0,100	0,0394
0,500	0,0395
1,000	0,0395
5,000	0,0396

Tabel 5.

Dampak <i>Learning Rate</i> Terhadap MSE pada RNN	
<i>Learning Rate</i>	<i>Mean Squared Error</i>
0,001	0,0393
0,005	0,0394
0,010	0,0394
0,050	0,0395
0,100	0,0395
0,500	0,0395
1,000	0,0395
5,000	0,0395

$$MSE = \frac{1}{N} \sum_{i=1}^N (T_i - O_i)^2 \quad (2)$$

dengan T adalah nilai sebenarnya, O adalah nilai prediksi, dan N adalah jumlah data.

B. Diagram Alir Peramalan Ketinggian Air Laut

Gambar 4 merupakan proses peramalan ketinggian air laut. Diagram dimulai dengan sistem memberikan model NN nilai-nilai masukan. Nilai pertama merupakan nilai temperatur dalam satuan Fahrenheit antara nilai 64,00 derajat Fahrenheit dan 102,00 derajat Fahrenheit. Nilai kedua adalah nilai kecepatan angin dalam satuan mil per jam antara nilai 0,00 mil per jam dan 29,00 mil per jam. Nilai ketiga yang digunakan adalah nilai derajat fase bulan dengan satuan derajat antara nilai 0,24 derajat dan 179,16 derajat. Nilai-nilai masukan kemudian melalui proses normalisasi menggunakan metode *MinMax* untuk menyamakan skala nilai data masukan dengan data yang digunakan dalam proses pelatihan. Data yang telah dinormalisasi terus dijadikan masukan untuk model NN. Model NN akan mengeluarkan prediksi ketinggian air laut yang masih dalam nilai normalisasi. Model NN kemudian akan melakukan proses denormalisasi yang akan menghasilkan nilai prediksi ketinggian air laut dalam satuan meter antara nilai 0,10 meter dan 2,60 meter.

IV. PENGUJIAN DAN ANALISIS

A. Pengolahan Data

Terdapat beberapa proses yang perlu dilakukan terhadap *dataset* sebelum *dataset* dapat digunakan dalam pelatihan model NN di antaranya adalah proses normalisasi *dataset* seperti pada menggunakan metode *MinMax*. Langkah selanjutnya adalah pembagian *dataset* yang terdiri dari data derajat fase bulan, data kecepatan angin, data ketinggian air laut, dan data temperatur yang dapat dilihat pada lampiran seperti pada Tabel 1. *Dataset* ini memiliki periode antara Januari 2021 sampai Desember 2022. *Dataset* akan dibagi menjadi data latihan (*data training*) dan data tes (*data testing*).

Persentase pemisahan *dataset* menjadi data latihan dan data tes akan ditentukan melalui pengujian terhadap beberapa kombinasi. Pemisahan ini ditunjukkan untuk mencari jumlah

Tabel 6.

Dampak Jumlah Nodes Terhadap MSE pada FFNN

Jumlah Nodes	Mean Squared Error
1	0,0393
2	0,0392
3	0,0391
4	0,0392
5	0,0392
6	0,0391
7	0,0391
8	0,0389
9	0,0392
10	0,0390

Tabel 7.

Dampak Jumlah Nodes Terhadap MSE pada RNN

Jumlah Nodes	Mean Squared Error
1	0,03950
2	0,03950
3	0,03947
4	0,03945
5	0,03950
6	0,03936
7	0,03942
8	0,03940
9	0,03929
10	0,03927

Tabel 8.

Nilai MSE dari Pengujian Model NN

Jenis Model	Mean Squared Error
Feedforward Neural Network	0,0386
Recurrent Neural Network	0,0389

optimal data pada setiap jenis data untuk mengurangi nilai MSE yang dihasilkan oleh model NN [11]. Dalam pengujian ini, variabel kontrol yang digunakan adalah nilai *learning rates* sebesar 0,001 dan jumlah *nodes* pada *hidden layer* yaitu sebanyak 8 buah.

Pemisahan data *training* dan data *testing* dalam penelitian ini mengikuti hasil pengujian dari Tabel 3 dan Tabel 4 di mana kedua model NN menggunakan persentase pemisahan 60% dari *dataset* untuk data latihan dan 40% dari *dataset* untuk data tes.

Data Latihan digunakan untuk melatih model NN prediksi ketinggian air laut. Jumlah data pelatihan yang tidak memadai akan menyebabkan pelatihan yang tidak sempurna atau tidak selesai seperti yang tercerminkan pada nilai *mean squared error* pada pemisahan data latihan yang lebih kecil dari 60% *dataset* seperti pada Tabel 2 dan Tabel 3. Pada sisi lain, model NN dapat mengalami *overfitting* di mana NN terlalu terspesialisasi terhadap data latihan yang diberikan dan tidak mampu menghasilkan keluaran dari data masukan baru. Kondisi *overfitting* terjadi apabila model NN dilatih menggunakan data latihan yang terlalu banyak. Kondisi ini tercerminkan dalam nilai *mean squared error* dimana persentase data latihan lebih besar dibandingkan 60% *dataset* seperti pada Tabel 3 dan Tabel 4.

B. Pengujian Arsitektur

Pengujian arsitektur ini dilakukan dengan melakukan penyetalan terhadap beberapa bagian dari model NN seperti jumlah *nodes* pada lapisan tersembunyi dan *learning rate* dari pelatihan NN. Pengujian ini dilakukan untuk mencari kombinasi yang akan menghasilkan nilai MSE paling kecil.

1) Pengujian Terhadap Learning Rate

Learning rate adalah sebuah parameter yang menentukan

jumlah perubahan nilai bobot dan nilai bias pada model NN dalam proses pelatihan. Parameter *learning rate* mengendalikannya lama waktu pelatihan model NN. Pengujian ini dilakukan untuk mencari nilai *learning rate* paling optimal bagi kedua model NN yang menghasilkan nilai MSE terkecil [12]. Variabel kontrol yang digunakan dalam pengujian ini meliputi jumlah *nodes* pada *hidden layer* yaitu sebanyak 8 buah dan nilai persentase pembagian *dataset* mejadi 60% data latihan dan 40% data tes.

Nilai *Learning Rate* yang digunakan dalam pelatihan model FFNN dan model RNN berdasarkan Tabel 4 dan Tabel 5 adalah sebesar 0,001 dikarenakan menghasilkan nilai MSE terkecil pada dua model yaitu sebesar 0,0389 dan 0,0393. Dalam algoritma *backpropagation*, nilai *learning rate* digunakan sebagai faktor pengkali dari *gradient error*. Nilai *learning rate* yang kecil akan menghasilkan perubahan nilai yang lebih halus pada beban dan bias namun membutuhkan waktu pelatihan yang lebih lama. Sementara itu, penggunaan nilai *learning rate* yang tinggi akan menghasilkan perubahan nilai beban dan bias yang tidak stabil atau kacau namun mengurangi waktu pelatihan menjadi lebih singkat.

2) Pengujian Terhadap Jumlah Nodes

Nodes merepresentasikan sebuah unit komputasi yang menerima masukan, melakukan perhitungan, dan menghasilkan keluaran. *Nodes* merupakan salah satu dari elemen fundamental dari sebuah model NN. Setiap *nodes* memiliki parameter sendiri-sendiri yang terdiri dari bobot dan bias. Parameter-parameter ini menentukan seberapa kuat efek masukan terhadap komputasi *nodes* dan nilai keluaran yang dihasilkan. Dengan ini, jumlah *nodes* pada *hidden layer* secara langsung berkorelasi dengan kemampuan model NN untuk memproses masukan dan berpengaruh terhadap nilai MSE [13]. Variabel kontrol yang digunakan dalam pengujian ini meliputi nilai *learning rate* sebesar 0,001 dan nilai persentase pembagian *dataset* mejadi 60% data latihan dan 40% data tes.

Jumlah *nodes* yang digunakan untuk arsitektur model FFNN berdasarkan Tabel 7 adalah sebanyak 8 buah yang menghasilkan nilai MSE terkecil, yaitu sebesar 0,0389. Sementara untuk model RNN, jumlah *nodes* yang digunakan berdasarkan Tabel 8 adalah sebanyak 10 buah yang menghasilkan nilai MSE terkecil sebesar 0.03927. Tabel 7 dan Tabel 8 dapat terjadi karena *nodes* pada lapisan tersembunyi digunakan untuk memproses masukan dari lapisan maskan, maka jumlah *nodes* memiliki hubungan dengan kemampuan model NN untuk mempelajari hubungan yang kompleks antara masukan dan keluaran yang diinginkan. Dari Tabel 6 dan Tabel 7, dapat dilihat bahwa jumlah *nodes* yang lebih kecil mungkin tidak dapat mempelajari pemetaan masukan dan keluaran yang diinginkan. Di sisi lain, jumlah *nodes* yang lebih besar juga dapat menghasilkan nilai MSE yang lebih besar karena fenomena *overfitting* di mana model NN memperhitungkan *noise* atau fluktuasi acak yang secara langsung mempengaruhi keluaran dari model NN.

3) Pengujian Terhadap Model FFNN dan RNN

Pengujian ini dilakukan dengan membandingkan nilai keakurasian dari model FFNN dan RNN dan membandingkan nilai *error* dari kedua model yang telah dilatih. Dari Tabel 8 dapat dilihat bahwa nilai MSE dari pengujian model FFNN menghasilkan nilai sebesar 0,0386 yang lebih kecil diban-

dingkan nilai MSE dari model RNN, yaitu sebesar 0,0389.

V. KESIMPULAN

Pelatihan NN yang ditunjukkan untuk prediksi harus dilengkapi dengan *dataset* yang memadai. *Dataset* ini harus memetakan ciri-ciri unik dari obyek atau data yang akan diprediksi. Dalam penelitian ini, penggunaan periode Januari 2021 sampai Desember 2022 dilakukan dengan harapan bahwa model NN mampu mempelajari pola dari ketinggian air laut serta hubungannya dengan derajat fase bulan, kecepatan angin dan temperatur. Selain itu, *dataset* yang banyak juga mampu mengajari model NN mengenai anomali-anomali yang dapat terjadi dari obyek yang akan diprediksi. Namun jumlah data *training* yang terlalu banyak dapat menyebabkan *overfitting* di mana model NN tidak mampu menghasilkan data keluaran baru dari masukan baru.

Perencanaan desain dari NN harus memperhatikan tujuan atau untuk apa NN akan digunakan. Perencanaan ini meliputi struktur-struktur NN seperti pemilihan AF yang akan digunakan, jumlah *hidden layer*, jumlah *nodes* pada masing-masing *hidden layer*, dan jenis dari NN. Tingkat kerumitan tidak menjanjikan bahwa model NN layak digunakan pada segala permasalahan. Pada penelitian ini, model RNN dinilai lebih rumit dibandingkan dari model FFNN dikarenakan terdapatnya *feedback loop* namun berdasarkan Tabel 8, FFNN memiliki performa yang lebih bagus. Perbedaan performa dari model FFNN dan RNN dapat disebabkan oleh masukan yang digunakan dalam penelitian ini. Masukan yang digunakan merupakan kecepatan angin, derajat fase bulan, dan temperatur. RNN berspesialisasi dalam mencari pola dalam sebuah deretan data di mana data bergantung pada data sebelumnya namun dalam penelitian ini, masukan yang digunakan sama sekali tidak bergantung pada satu sama lain.

VI. DAFTAR PUSTAKA

- [1] T. Al Tanto, "Pengaruh Air Laut Pasang Dan Curah Hujan Tinggi Terhadap Banjir Daerah Bungus - Kota Padang," in *Seminar Sains Atmosfer*, Jun. 2014, pp. 465–474.
- [2] S. G. Meshram, M. A. Ghorbani, S. Shamshirband, V. Karimi, and C. Meshram, "River flow prediction using hybrid PSO-GSA algorithm based on feed-forward neural network," *Soft Comput.*, vol. 23, no. 20, pp. 10429–10438, 2019, doi: 10.1007/s00500-018-3598-7.
- [3] M. Herath, T. Jayatilake, Y. Hoshino, and U. Rathnayake, "Deep machine learning-based water level prediction model for colombo flood detention area," *Appl. Sci.*, vol. 13, pp. 1–18, Feb. 2023, doi: 10.3390/app13042194.
- [4] T. Tambouratzis, "A consensus-function artificial neural network for map-coloring," *IEEE Trans. Syst. Man, Cybern. Part B*, vol. 28, no. 5, pp. 721–728, 1998, doi: 10.1109/3477.718521.
- [5] A. Krogh, "What are artificial neural networks?," *Nat. Biotechnol.*, vol. 26, no. 2, pp. 195–197, 2008, doi: 10.1038/nbt1386.
- [6] W. F. Schmidt, M. A. Kraaijveld, and R. P. W. Duin, "Feedforward Neural Networks with Random Weights," in *Proceedings, 11th IAPR International Conference on Pattern Recognition. Vol.II. Conference B: Pattern Recognition Methodology and Systems*, 1992, pp. 1–4. doi: 10.1109/ICPR.1992.201708.
- [7] R. M. Schmidt, "Recurrent neural networks (rnns): A gentle introduction and overview," *Comput. Res. Repos.*, vol. abs/1912.0, 2019, doi: <https://doi.org/10.48550/arXiv.1912.05911>.
- [8] C. Nwankpa, W. Ijomah, A. Gachagan, and S. Marshall, "Activation functions: comparison of trends in practice and research for deep learning," *Comput. Res. Repos.*, 2018, doi: 10.48550/arXiv.1811.03378.
- [9] J. Lederer, "Activation functions in artificial neural networks: a systematic overview," *Comput. Res. Repos.*, vol. abs/2101.0, 2021, doi: 10.48550/arXiv.2101.09957.
- [10] United States Environmental Protection Agency, "Climate Change Indicators: Sea Level," United States Environmental Protection Agency, Washington, 2021.
- [11] Q. H. Nguyen *et al.*, "Influence of data splitting on performance of machine learning models in prediction of shear strength of soil," *Math. Probl. Eng.*, 2021, doi: 10.1155/2021/4832864.
- [12] V. C. Ebhota and V. M. Srivastava, "Performance analysis of learning rate parameter on prediction of signal power loss for network optimization and better generalization," *Wirel. Pers. Commun.*, vol. 118, no. 2, pp. 1111–1128, 2021, doi: 10.1007/s11277-020-08061-z.
- [13] Y. Dong and D. Li, "Efficient and effective algorithms for training single-hidden-layer neural networks," *Pattern Recognit. Lett.*, vol. 33, no. 5, pp. 554–558, 2012, doi: 10.1016/j.patrec.2011.12.002.