

**PREDIKSI KADAR AIR DALAM IKAN TUNUL UNTUK
MEMPERLAMBAT PEMBUSUKAN DENGAN METODE
ARTIFICIAL NEURAL NETWORK PADA UNIT
PENGOLAHAN IKAN (UPI) D'KRIWIL**

SKRIPSI



Oleh:

ANITA CEMPAKASARI

3333190102

**JURUSAN TEKNIK INDUSTRI
FAKULTAS TEKNIK
UNIVERSITAS SULTAN AGENG TIRTAYASA
CILEGON-BANTEN
2024**

**PREDIKSI KADAR AIR DALAM IKAN TUNUL UNTUK
MEMPERLAMBAT PEMBUSUKAN DENGAN METODE
ARTIFICIAL NEURAL NETWORK PADA UNIT
PENGOLAHAN IKAN (UPI) D'KRIWIL**

SKRIPSI



JURUSAN TEKNIK INDUSTRI

FAKULTAS TEKNIK

UNIVERSITAS SULTAN AGENG TIRTAYASA

CILEGON-BANTEN

2024

PERNYATAAN KEASLIAN SKRIPSI

Yang bertandatangan dibawah ini :

NAMA : Anita Cempakasari

NIM : 3333190102

JURUSAN : Teknik Industri

JUDUL : Prediksi Kadar Air Dalam Ikan Tunul Untuk Memperlambat
Pembusukan Dengan Metode *Artificial Neural Network* Pada Unit
Pengolahan Ikan (UPI) D'Kriwil

Dengan ini menyatakan bahwa penelitian dengan judul tersebut diatas adalah benar karya saya sendiri dengan arahan dari pembimbing I dan pembimbing II, dan tidak ada duplikasi dengan kerja orang lain kecuali yang telah disebutkan sumbernya.

Apabila dikemudian hari terbukti terdapat plagiat dalam penelitian ini, maka saya bersedia menerima sanksi sesuai peraturan perundang-undangan yang berlaku.

Cilegon, 22 Juli 2024



Anita Cempakasari

HALAMAN PENGESAHAN

Skripsi ini diajukan Oleh :

NAMA : Anita Cempakasari

NIM : 3333190102

JURUSAN : Teknik Industri

JUDUL : PREDIKSI KADAR AIR DALAM IKAN TUNUL UNTUK
MEMPERLAMBAT PEMBUSUKAN DENGAN METODE
ARTIFICIAL NEURAL NETWORK PADA UNIT PENGOLAHAN
IKAN (UPI) D'KRIWIL

Telah berhasil dipertahankan dihadapan Dewan penguji dan Diterima
sebagai bagian persyaratan yang diperlukan untuk memperoleh gelar
Sarjana Teknik pada Jurusan Teknik Industri, Fakultas Teknik, Universitas
Sultan Ageng Tirtayasa

Pada Hari : Rabu

Tanggal : 3 Januari 2024

DEWAN PENGUJI

Pembimbing 1 : Yusraini Muharni, S.T., M.T.

Pembimbing 2 : Dr. Eng. Ir. Bobby Kurniawan, S.T., M.T.

Penguji 1 : Dr. Lely Herlina, S.T., M.T.

Penguji 2 : Atia Sonda, S.Si., M.Si.



Mengetahui,

Ketua Jurusan Teknik Industri




Ade Irman Saeful Mutaqin S, ST., MT.
NIP. 198206152012121002

PRAKATA

Dengan menyebut nama Allah Yang Maha Pengasih lagi Maha Penyayang, puji syukur saya panjatkan kepada Allah swt. atas ridhanya saya dapat menyelesaikan penyusunan skripsi ini. Adapun judul skripsi yang saya ajukan adalah “Prediksi Kadar Air Dalam Ikan Tunul Untuk Memperlambat Pembusukan Dengan Metode *Artificial Neural Network* Pada Unit Pengolahan Ikan (UPI) D’Kriwil”. Skripsi ini saya ajukan untuk memenuhi syarat kelulusan mata kuliah Skripsi di Fakultas Teknik Universitas Sultan Ageng Tirtayasa. Tidak adapat disangkal bahwa butuh usaha yang keras dalam penyelesaian pengerjaan skripsi ini. Namun, karya ini tidak akan selesai tanpa orang-orang di sekeliling saya yang mendukung dan membantu. Terima kasih saya sampaikan kepada :

1. Bapak Ade Irman Saeful M. S., S.T., M.T. selaku Ketua Jurusan Teknik Industri Universitas Sultan Ageng Tirtayasa.
2. Ibu Yusraini Muharni, S.T., M.T. selaku pembimbing pertama, koordinator tugas akhir serta koordinator komunitas keilmuan sistem produksi.
3. Bapak Dr. Eng. Ir. Bobby Kurniawan, S.T., M.T. selaku pembimbing kedua dalam penyusunan skripsi.
4. Orang tua penulis, yang selalu menjadi motivasi terbesar serta yang selalu memberi dukungan berupa do’a dan semangat.
5. Kepada teman-teman asisten laboratorium sistem produksi yang selalu memberi dukungan ilmu dan masukan.

Penulis menyadari bahwa dalam penyusunan skripsi ini terdapat kesalahan dan kekurangan. Oleh karena itu, penulis mengharapkan kritik dan saran yang membangun untuk lebih baik kedepannya. Sebelumnya penulis mengucapkan mohon maaf apabila terdapat kata-kata yang kurang berkenan. Semoga skripsi ini dapat berguna bagi pembaca khususnya dan bagi para pembaca umumnya.

Cilegon, Juli 2024



Anita Cempakasari



ABSTRAK

UPI D’Kriwil merupakan salah satu unit usaha yang berada di Kota Cilegon yang fokus pada produksi olahan ikan yaitu ikan tunul. UPI ini mengolah bahan baku ikan tunul menjadi produk dimsum ikan. Produk hasil olahan ikan umumnya memiliki sifat *perisable* yaitu mudah rusak karena pembusukan, sehingga perlu diolah dengan sebelum dikonsumsi. Pembusukan ini disebabkan oleh proses oksidasi pada daging ikan oleh udara dan mikroorganisme yang ada pada daging ikan. Kondisi pembusukan bahan baku ikan yang relatif cepat juga dialami pada produksi dimsum di Unit Pengolahan Ikan (UPI) D’Kriwil. Kondisi tersebut mempengaruhi kualitas produk dimsum ikan yang menyebabkan banyak keluhan pelanggan karena klaim *expired* produk tidak sesuai. Berdasarkan permasalahan tersebut maka dilakukan penelitian dengan metode *artificial neural network* (ANN) untuk memprediksi kadar air pada produk dimsum ikan. Metode ANN cocok digunakan dalam menyelesaikan permasalahan prediksi dan klasifikasi data. Pada penelitian ini data diolah melalui beberapa langkah yaitu melakukan normalisasi data, menentukan arsitektur ANN, *training data* dengan *backpropagation* kemudian melakukan prediksi. Topografi arsitektur yang digunakan pada metode ANN yaitu 5-15-1. Hasil prediksi jumlah pengurangan kadar air dengan metode ANN senilai 0,148 kg hingga 0,756 kg dengan tingkat *MSE* (*Mean Square Error*) terkecil sebesar 0,0381 pada jaringan dengan 15 *hidden layer* (*epoch* pertama dan iterasi 1).

Kata kunci : Ikan Tunul, *Artificial Neural Network* (ANN), *Backpropagation*

ABSTRACT

UPI D’Kriwil is one of the business units located in the city of Cilegon that focuses on the production of processed fish, specifically the barracuda fish. This unit processes raw materials of barracuda fish into fish dimsum products. Processed fish products generally have perishable characteristics, making them prone to spoilage due to decay. Hence, they need to be processed before consumption. Spoilage occurs due to the oxidation process in the fish flesh caused by air and microorganisms present in the fish flesh. The rapid decay of raw fish materials is also experienced in the production of fish dimsum at the Fish Processing Unit (UPI) D’Kriwil. This condition affects the quality of the fish dimsum products, leading to numerous customer complaints about expired products not meeting expectations. To address this issue, research was conducted using the artificial neural network (ANN) method to predict the moisture content in fish dimsum products. ANN method is suitable for solving prediction and data classification problems. In this study, the data was processed through several steps, including data normalization, determining the ANN architecture, training data with backpropagation, and making predictions. The topology architecture used in the ANN method was 5-15-1. The prediction results showed a reduction in moisture content ranging from 0.148 kg to 0.756 kg using the ANN method, with the smallest MSE (Mean Square Error) of 0.0381 in the network with 15 hidden layers (first epoch and iteration 1).

Keyword : Barracuda Fish, Artificial Neural Network (ANN), Backpropagation

RINGKASAN

Anita Cempakasari. PREDIKSI KADAR AIR DALAM IKAN TUNUL UNTUK MEMPERLAMBAT PEMBUSUKAN DENGAN METODE ARTIFICIAL NEURAL NETWORK PADA UNIT PENGOLAHAN IKAN (UPI) D'KRIWIL. Dibimbing oleh Yusraini Muharni, ST., MT. dan Dr. Eng. Ir. Bobby Kurniawan, ST., MT.

Machine learning telah menjadi suatu instrumen yang dipakai untuk menyelesaikan suatu permasalahan dengan cara meniru cara manusia menyelesaikan masalah. Salah satu metode yang banyak digunakan saat ini adalah metode jaringan saraf (*neural network*). Permasalahan yang dapat diselesaikan dengan metode jaringan saraf atau bisa disebut juga *artificial neural network* yaitu prediksi dan klasifikasi data. Pada penelitian ini dilakukan implementasi penyelesaian masalah menggunakan metode ANN untuk memprediksi kadar air dalam ikan tunul untuk memperlambat perbusukan pada UPI D'Kriwil. Kondisi pembusukan bahan baku ikan yang relatif cepat juga dialami oleh Unit Pengolahan Ikan (UPI) D'Kriwil yang berpengaruh pada produk dimsum ikan. Sehingga terdapat banyak keluhan pelanggan karena klaim *expired* produk tidak sesuai. Oleh karena itu, penelitian ini dilakukan untuk menentukan besarnya kandungan air pada ikan yang baik untuk menjaga ketahanan produk dan memprediksi besarnya kandungan air untuk produksi selanjutnya dengan metode *artificial neural network*.

Penyelesaian permasalahan pada penelitian ini menggunakan metode *artificial neural network* (ANN) dengan *tools backpropagation* dalam memperbaiki error prediksi. Penelitian dirancang dengan metode penelitian kuantitatif. Data-data yang digunakan untuk melakukan prediksi seperti *operation process chart* (OPC), berat bahan baku ikan tunul periode bulan November-Desember 2022, waktu pembusukan ikan tunul, suhu lingkungan dan kelembaban lingkungan.

Tahap pertama penelitian yang dilakukan adalah menormalisasi data agar besar angka pada data berdistribusi normal. Selanjutnya menentukan arsitektur ANN yang terdiri dari *input* (5 data *input*), *hidden layer* (5, 10, 15 *hidden layer*)

dan *output* (target). Setelah menentukan arsitektur ANN, dilakukan *training data* menggunakan *tools backpropagation* pada pemrograman Matlab dan didapatkan hasil jaringan *layer* terbaik pada jaringan dengan 5 *hidden layer* (*epoch* ke-70 dan iterasi 2). Hasil *training data* terbaik menghasilkan nilai MSE terkecil sebesar 0,0381. Setelah jaringan terbaik dihasilkan, kemudian peramalan ditentukan menggunakan bobot yang dihasilkan dari *training data*. Hasil prediksi kadar air yang harus dikurangi pada bahan baku ikan tunul pada periode Januari 2023 untuk menjaga kualitas produk dimsum ikan tahan lama sebesar 0,494 kg, 0,503 kg, 0,5 kg, 0,499 kg, 0,497 kg, 0,5 kg, 0,493 kg, 0,4993 kg, 0,499 kg, 0,5 kg, 0,499 kg, 0,491 kg, 0,497 kg, 0,504kg, 0,497 kg, 0,5 kg, 0,5kg, 0,49 kg, 0,492 kg, 0,499 kg, 0,503 kg, 0,499 kg, 0,497 kg, 0,491 kg, 0,501 kg, 0,492 kg, 0,499kg, 0,495kg, 0,503 kg, 0,501 kg dan 0,501 kg.

Kata kunci: *Machine Learning, Artificial Neural Network (ANN), Backpropagation*

DAFTAR ISI

	Halaman
HALAMAN SAMPUL	i
HALAMAN JUDUL	ii
PERNYATAAN KEASLIAN SKRIPSI .Kesalahan! Bookmark tidak ditentukan.	
HALAMAN PENGESAHANKesalahan! Bookmark tidak ditentukan.	
PRAKATA	v
ABSTRAK	vii
ABSTRACT	viii
RINGKASAN	ix
DAFTAR ISI	xi
DAFTAR TABEL	xiv
DAFTAR GAMBAR	xv
DAFTAR ARTI LAMBANG, SINGKATAN DAN ISTILAH	xvi
DAFTAR LAMPIRAN	xviii
BAB I PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian	3
1.4 Batasan Masalah.....	3
1.5 Sistematika Penulisan.....	3
1.6 Penelitian Terdahulu	4
BAB II TINJAUAN PUSTAKA	
2.1 Ikan.....	10
2.1.1 Ikan Tunul	10
2.1.2 Pengolahan Ikan	11
2.1.3 Pembusukan Pada Ikan	11
2.1.3 Pengawetan Ikan dengan Pengeringan.....	12
2.2 <i>Artifical Neural Network</i>	12
2.2.1 Arsitektur <i>Artificial Neural Network</i>	13

2.2.2	<i>Training Data</i>	15
2.2.3	Algoritma <i>Backpropagation</i>	16
BAB III METODE PENELITIAN		
3.1	Rancangan Penelitian	19
3.2	Lokasi dan Waktu Penelitian.....	19
3.3	Cara Pengumpulan Data.....	19
3.4	Alur Pemecahan Masalah.....	20
3.5	Analisis Data	23
BAB IV PENGUMPULAN DAN PENGOLAHAN DATA		
4.1	Pengumpulan Data	28
4.1.1	<i>Operation Process Chart</i> (OPC) Produk Dimsum Ikan	28
4.1.2	Berat Bahan Baku Ikan Tunul.....	29
4.1.3	Waktu Pembusukan Ikan Tunul	31
4.1.4	Suhu Lingkungan	33
4.1.5	Kelembaban Lingkungan	35
4.2	Pengolahan Data.....	37
4.2.1	Normalisasi Data	38
4.2.2	Arsitektur Model <i>Artificial Neural Network</i> (ANN).....	40
4.2.3	<i>Artificial Neural Network</i> dengan Algoritma <i>Backpropagation</i> dengan Matlab	43
4.2.3.1	Hasil <i>Training Data</i> dengan 5 <i>Hidden Layer</i>	44
4.2.3.2	Hasil <i>Training Data</i> dengan 10 <i>Hidden Layer</i>	46
4.2.3.3	Hasil <i>Training Data</i> dengan 15 <i>Hidden Layer</i>	49
4.2.4	Prediksi Kadar Air Pada Ikan Tunul	52
BAB V ANALISA DAN PEMBAHASAN		
5.1	Analisa Hasil <i>Training Data</i> Menggunakan Metode <i>Artificial Neural Network Backpropagation</i>	56
5.2	Analisa Hasil Prediksi Kadar Air Pada Bahan Baku Ikan Tunul Periode Bulan Januari 2023.....	57
BAB VI KESIMPULAN DAN SARAN		
6.1	Kesimpulan	59

6.2	Saran.....	59
	DAFTAR PUSTAKA.....	60
	LAMPIRAN	



DAFTAR TABEL

	Halaman
Tabel 1. Penelitian Terdahulu.....	5
Tabel 2. Data Berat Bahan Baku Ikan Tunul Periode November-Desember 2022	29
Tabel 3. Data Waktu Pembusukan Dimsum Ikan Periode November-Desember 2022	31
Tabel 4. Data Suhu Lingkungan	34
Tabel 5. Kelembaban Udara Lingkungan Periode November-Desember 2022	36
Tabel 6. Hasil Normalisasi Data.....	38
Tabel 7. Bobot Pada <i>Training Data 5 Hidden Layer</i>	46
Tabel 8. Bobot Pada <i>Training Data 10 Hidden Layer</i>	49
Tabel 9. Bobot Pada <i>Training Data 15 Hidden Layer</i>	51
Tabel 10. Hasil Prediksi dan Denormalisasi Data	54

DAFTAR GAMBAR

	Halaman
Gambar 1. Arsitektur Jaringan <i>Layer</i> Tunggal	14
Gambar 2. Arsitektur Jaringan <i>Layer</i> Jamak.....	15
Gambar 3. <i>Flowchart</i> Penelitian Umum	21
Gambar 4. <i>Flowchart</i> Penyelesaian Masalah.....	24
Gambar 5. <i>Operation Process Chart</i> (OPC) Dimsum Ikan	28
Gambar 6. Arsitektur ANN dengan 5 <i>Hidden Layer</i>	41
Gambar 7. Arsitektur ANN dengan 10 <i>Hidden Layer</i>	42
Gambar 8. Arsitektur ANN dengan 15 <i>Hidden Layer</i>	43
Gambar 9. Hasil <i>Training</i> Data Dengan 5 <i>Hidden Layer</i>	44
Gambar 10. Grafik Performansi 5 <i>Hidden Layer</i>	45
Gambar 11. Grafik Uji Validasi Hasil <i>Training</i> 5 <i>Hidden layer</i>	45
Gambar 12. Hasil <i>Training</i> Data Dengan 10 <i>Hidden Layer</i>	47
Gambar 13. Grafik Performansi 10 <i>Hidden Layer</i>	48
Gambar 14. Grafik Uji Validasi Hasil <i>Training</i> 10 <i>Hidden Layer</i>	48
Gambar 15. Hasil <i>Training</i> Data Dengan 15 <i>Hidden Layer</i>	50
Gambar 16. Grafik Performansi 15 <i>Hidden Layer</i>	50
Gambar 17. Grafik Uji Validasi Hasil <i>Training</i> 15 <i>Hidden Layer</i>	51

DAFTAR ARTI LAMBANG, SINGKATAN DAN ISTILAH

Lambang/ Singkatan	Nama	Pemakaian Pertama Kali pada Halaman
UPI	Unit Pengolahan Ikan	1
ANN	<i>Artificial Neural Network</i>	2
OPC	<i>Operation Process Chart</i>	17
MSE	<i>Mean Squared Error</i>	27
Lambang		
X'	Hasil normalisasi data	17
X	Data asli/Hasil denormalisasi data	17
a	Nilai minimum	17
b	Nilai maksimum	17
n	Jumlah periode pada perhitungan	17
Z_{net_j}	Nilai net di neuron ke- j ($j = 1, 2, 3, \dots, n$)	26
x_i	Nilai <i>output</i> dari neuron <i>input</i> ke-1 ($i = 1, 2, 3, 4, 5$)	26
v_{ij}	Nilai bobot yang menghubungkan neuron ke- i ($j = 1, 2, 3, \dots, n$) dengan neuron ke- j ($k = 1, 2, 3, \dots, n$).	26
Z_j	nilai net di neuron ke- j ($j = 1, 2, 3, \dots, n$)	26
y_{net_k}	Nilai net di neuron ke- k pada <i>layer input</i>	26
δ_k	Nilai kesalahan pada neuron ke- k di <i>output layer</i>	26

ΔW_{kj}

Selisih bobot *hidden layer* pada
neuron ke-j dengan neuron ke-k

26



DAFTAR LAMPIRAN

Lampiran 1. Hasil Prediksi dengan 5 *Hidden Layer*

Lampiran 2. *Coding ANN Backpropagation* dengan 10 *Hidden Layer*

Lampiran 3. Hasil Prediksi dengan 10 *Hidden Layer*

Lampiran 4. *Coding ANN Backpropagation* dengan 15 *Hidden Layer*

Lampiran 5. Hasil Prediksi dengan 15 *Hidden Layer*



BAB I

PENDAHULUAN

1.1 Latar Belakang

Di abad ke-21 ini, *machine learning* telah menjadi sebuah teknik yang digunakan untuk menyelesaikan masalah dengan cara meniru cara manusia dalam memecahkan masalah tersebut. Salah satu metode yang banyak digunakan saat ini adalah metode jaringan saraf (*neural network*) yang diadaptasi dari peniruan proses belajar dengan mensimulasikan jaringan saraf. Metode *artificial neural network* (ANN) ini memiliki beberapa keunggulan jika dibandingkan dengan metode lainnya, yaitu mampu mempelajari suatu permasalahan berdasarkan data mentah yang kemudian dilakukan *training* terhadap data tersebut, metode ini mampu melakukan representasi sendiri terhadap permasalahan yang ada selama waktu *training*, dan memiliki toleransi terhadap kerusakan parsial pada jaringan sehingga jika kerusakan parsial terjadi pada jaringan maka sisa sistem jaringan yang ada masih dapat digunakan untuk menyelesaikan masalah (Sivanandam, Sumathi dan Deepa, 2006). Dalam beberapa topik permasalahan yang diselesaikan menggunakan metode ANN biasanya digunakan algoritma pembelajaran *backpropagation* untuk menyelesaikan permasalahan deret non linier. Algoritma *backpropagation* merupakan salah satu alat pada metode *artificial neural network* yang digunakan untuk mengoreksi *synapse weight* dari *output layer* ke *hidden layer*, kemudian *error* tersebut dipropagasi ke *layer* sebelumnya. *Error* yang dihasilkan ini digunakan untuk memodifikasi bobot-bobot sehingga adanya perubahan bobot yang diharapkan dapat mengurangi besarnya *error* sampai pada nilai yang ingin dicapai. Pada penggunaan algoritma *backpropagation* di dalam metode ANN banyak digunakan dalam permasalahan seperti *classification* dan prediksi (Azmi dan Yasin, 2021). Salah satu permasalahan yang dapat diselesaikan dengan metode ANN adalah memprediksi kandungan air pada bahan baku ikan tunul yang dibahas pada penelitian ini.

Produk hasil olahan ikan pada umumnya mempunyai sifat perisable (mudah rusak dikarenakan pembusukan) sehingga perlu diolah dengan baik dan dikonsumsi

secara langsung. Ikan akan mulai mengalami pembusukan sesaat setelah ditangkap. Pembusukan ini biasanya disebabkan oleh proses oksidasi pada lemah tubuh oleh udara dan mikroorganisme yang ada pada tubuh ikan baik karena ikan yang terkontaminasi saat setelah ditangkap maupun sebelum ditangkap. Proporsi 60% - 80% dalam tubuh ikan diisi oleh kandungan air yang mempunyai pH mendekati normal sehingga dengan keadaan tersebut pertumbuhan bakteri pembusukan berkembangbiak dengan baik (Ndahawali, 2016). Kandungan air merupakan jumlah air yang tersedia dalam makanan yang dapat mendukung adanya pertumbuhan mikroba. Dalam dua dekade terakhir, ada peningkatan kesadaran pada kalangan pengembang teknologi makanan dan ikan akan pentingnya jumlah kandungan air sebagai indikator utama potensi pembusukan mikroba dan penekanan yang muncul terhadap pengukuran dan kontrol kandungan air sebagai jaminan kualitas suatu makanan olahan ikan (Doe, 2020).

Kondisi pembusukan bahan baku ikan yang relatif cepat juga dialami oleh Unit Pengolahan Ikan (UPI) D'Kriwil. UPI D'Kriwil merupakan salah satu unit usaha yang berada di Kota Cilegon yang difokuskan pada produksi olahan ikan yaitu ikan tunul. UPI ini mengolah bahan ikan tunul menjadi produk dimsum ikan. Pada proses pembuatan produk, UPI D'Kriwil tidak menambahkan komponen kimiawi seperti pengawet buatan untuk menjaga kualitas bahan pangan tetap aman dikonsumsi sehingga pembusukan yang terjadi merupakan pembusukan alami yang terjadi karena adanya bakteri pembusukan. Pada periode produksi November-Desember 2022, pengelola UPI sering mendapatkan komplain terkait rusaknya kualitas produk karena produk tidak tahan lama seperti klaim produk yang diberikan oleh UPI. Pada tahap uji coba awal UPI menguji kualitas daya tahan produk olahan dihasilkan produk mengalami pembusukan paling cepat 3 hari setelah produksi, tetapi pada periode tersebut banyaknya komplain konsumen bahwa pembusukan terjadi hanya dalam 2 hari saja atau 50 jam setelah produksi. Oleh karena itu, penelitian ini dilakukan untuk menentukan besarnya kandungan air pada ikan yang baik untuk menjaga ketahanan produk dan memprediksi besarnya kandungan air untuk produksi selanjutnya dengan metode *artificial neural network*.

1.2 Rumusan Masalah

Adapun perumusan masalah yang digunakan untuk mengetahui hasil apa yang diinginkan. Berikut ini adalah perumusan masalah penelitian ini :

1. Bagaimana hasil prediksi kandungan air pada ikan tunul yang baik agar kualitas produk tetap baik?
2. Seberapa akurat *metode artificial neural network* dalam memprediksi kandungan air yang baik pada ikan tunul?
3. Berapa batasan kadar air yang harus dikurangi yang direkomendasikan agar kualitas produk tetap terjaga?

1.3 Tujuan Penelitian

Berdasarkan perumusan masalah, diketahui tujuan dilakukannya penelitian ini. Berikut ini adalah tujuan dilakukannya penelitian :

1. Memprediksi kandungan air pada ikan tunul yang baik agar kualitas produk tetap baik.
2. Menentukan akurasi dari hasil prediksi pada kadar air ikan tunul menggunakan metode *artificial neural network*.
3. Mengetahui batasan kadar air yang harus dikurangkan pada ikan tunul yang direkomendasikan agar kualitas produk tetap terjaga.

1.4 Batasan Masalah

Batasan masalah dibuat untuk memperjelas arah penelitian yang diharapkan dalam pembahasan penelitian ini. Berikut ini merupakan batasan masalah yang dibuat untuk penelitian ini :

1. Data yang digunakan pada penelitian ini merupakan data *gross weight* bahan baku ikan tunul sebelum diolah periode pada November-Desember 2022 sebanyak 61 data *gross weight* ikan tunul yang akan diolah oleh UPI D'Kriwil.
2. Model *artificial neural network* yang akan digunakan adalah model *backpropagation* dengan fungsi aktivasi fungsi *sigmoid biner*.
3. Hasil penelitian ini hanya berlaku pada objek penelitian ikan tunul.

1.5 Sistematika Penulisan

Berikut ini adalah rincian sistematika penulisan dalam penelitian.

BAB I PENDAHULUAN

Bab ini membahas mengenai latar belakang permasalahan pada penelitian, perumusan masalah, tujuan dilakukannya penelitian, batasan-batasan masalah, dan sistematikan dalam penulisan skripsi.

BAB II TINJAUAN PUSTAKA

Bab ini membahas mengenai teori-teori apa saja yang dapat menunjang penelitian yang diambil dari kutipan buku, jurnal dan penelitian skripsi terdahulu.

BAB III METODE PENELITIAN

Bab ini membahas mengenai metode apa saja yang digunakan dalam menyelesaikan masalah yang ada, waktu pengambilan data serta gambaran proses olah data dari awal hingga akhir.

BAB IV HASIL PENELITIAN

Bab ini menjabarkan proses pengolahan data mulai dari data mentah kemudian diolah menggunakan metode yang digunakan sehingga menghasilkan *output* yang sesuai.

BAB V ANALISA DAN PEMBAHASAN

Bab ini membahas mengenai hasil analisa data yang sudah diolah pada BAB 4, sehingga peneliti dapat mengidentifikasi permasalahan sekaligus menganalisa hasil dan langkah perbaikannya.

BAB VI KESIMPULAN DAN SARAN

Bab ini membahas simpulan dari hasil yang sudah didapatkan berdasarkan analisa dan pembahasan serta berisi saran dan masukan untuk penelitian selanjutnya baik penelitian dengan topik serupa maupun dengan metode serupa.

1.6 Penelitian Terdahulu

Berikut ini merupakan kumpulan jurnal terdahulu yang memiliki topik pembahasan yang dijadikan inspirasi untuk melakukan penelitian ini, yaitu sebagai berikut :

Tabel 1. Penelitian Terdahulu

No	Nama Penulis	Judul Jurnal	Masalah	Metode	Hasil	Kesimpulan
1	Hasdi Putra dan Nabilah Ulfa Walmi (2020)	Penerapan Prediksi Produksi Padi Menggunakan <i>Artificial Neural Network</i> Algoritma <i>Backpropagation</i>	Menentukan jumlah neuron dan <i>hidden layer</i> yang optimal sehingga akurasi prediksinya tinggi	<i>Artificial neural network</i> dengan algoritma <i>backpropagation</i>	Berdasarkan pengujian sistem terhadap model yang telah dirancang dengan parameter-parameter yang telah ditentukan, ditemukan bahwa parameter-parameter berikut menghasilkan nilai MAPE terkecil dan akurasi terbesar: epoch 200, momentum 0,5, dan learning rate 0,5. MAPE yang tercatat adalah 11,86%, sementara akurasi prediksi mencapai 88,14%, dengan nilai tertinggi mencapai 98,89%. Hasil ini menunjukkan kinerja yang sangat baik dengan akurasi yang tinggi	Telah berhasil dirancang dan diimplementasikan arsitektur Jaringan Saraf Tiruan (<i>Artificial Neural Network/ANN</i>) untuk meramalkan produksi padi di Sumatera Barat, Indonesia. Rancangan ANN ini menggunakan struktur multilayer dan telah diuji coba untuk memprediksi produksi padi pada periode berikutnya. Implementasi sistem ini berhasil menghasilkan prediksi dengan tingkat akurasi mencapai 88,14%.

Tabel 1. Penelitian Terdahulu (Lanjutan)

No	Nama Penulis	Judul Jurnal	Masalah	Metode	Hasil	Kesimpulan
2	Maharany Shandra Ayu Hapsary, Sawitri Subiyanto dan Hana Sagiastu Firdaus (2021)	Analisis Prediksi Perubahan Penggunaan Lahan Dengan Pendekatan <i>Artificial Neural Network</i> dan Regresi Logistik Di Kota Balikpapan	Mengetahui perubahan penggunaan lahan di Kota Balikpapan periode tahun 2009-2019, memprediksi penggunaan lahan dengan model <i>Artificial neural network</i> (ANN) dan Regresi Logistik, serta menentukan kesesuaian penggunaan lahan hasil prediksi tahun 2029 dengan peta Rencana Tata Ruang Wilayah (RTRW) Kota Balikpapan tahun 2012-2032.	<i>Artificial Neural Network</i> (ANN) dan regresi logistik	Hasil prediksi penggunaan lahan untuk tahun 2019 menggunakan metode ANN dan regresi logistik menunjukkan bahwa hutan mendominasi penggunaan lahan di Kota Balikpapan, dengan luas masing-masing sebesar 23.358,08 Ha dan 24.800,32 Ha. Secara keseluruhan, lahan tidak terbangun yang tidak digunakan untuk aktivitas perkotaan masih mendominasi penggunaan lahan di kota tersebut. Lahan kosong dan kebun campuran diproyeksikan akan mengalami peningkatan luas menurut hasil pemodelan baik menggunakan ANN maupun regresi logistik.	Dalam periode 2009 hingga 2019, perubahan penggunaan lahan di Kota Balikpapan yang diklasifikasikan secara terbimbing menunjukkan tren berikut: luas kebun campuran mengalami penurunan signifikan sebesar 3.499,69 Ha (6,85%), sementara luas mangrove meningkat sebesar 2.515,27 Ha (4,92%). Luas pertanian hortikultura juga mengalami peningkatan sebesar 2.510,26 Ha (4,91%), dan lahan terbangun bertambah sebesar 1.230,58 Ha (2,41%). Penambahan luas juga terlihat pada semak belukar sebesar 533,98 Ha (1,05%) dan tubuh air sebesar 360,80 Ha (0,71%). Di sisi lain, luas lahan terbuka mengalami penurunan sebesar 2.867,89 Ha (5,61%), sedangkan luas hutan berkurang sebesar 783,33 Ha (1,53%)

Tabel 1. Penelitian Terdahulu (Lanjutan)

No	Nama Penulis	Judul Jurnal	Masalah	Metode	Hasil	Kesimpulan
3	Nadia Annisa Maori	Perbandingan Metode ANN-PSO dan ANN-GA Untuk Peningkatan Akurasi Prediksi Harga Emas Antam	Dengan minat para investor yang cukup tinggi tersebut, maka suatu estimasi atau ramalan harga dimasa mendatang perlu diobservasi dengan alat prediksi yang efektif. Peramalan harga emas merupakan salah satu cara untuk memprediksi atau memperkirakan harga emas dimasa yang akan datang berdasarkan data di masa lalu yang dapat digunakan sebagai alat untuk berinvestasi. Peramalan dibutuhkan karena dunia bisnis berhadapan dengan ketidakpastian dimasa depan dengan menentukan model alat prediksi yang efektif yang akhirnya dapat meningkatkan jumlah investor dan para investor tidak ragu dalam melakukan investasi emas.	B	Berdasarkan hasil yang diperoleh, dapat disimpulkan bahwa kombinasi <i>Neural Network</i> dan PSO menghasilkan nilai RMSE terbaik, yakni 0.026. Hal ini menunjukkan bahwa PSO memiliki kemampuan untuk secara efektif mengoptimalkan bobot-bobot pada jaringan neural dalam melakukan prediksi.	Penyesuaian jumlah populasi dapat meningkatkan optimasi, namun memerlukan waktu komputasi tambahan.

Tabel 1. Penelitian Terdahulu (Lanjutan)

No	Nama Penulis	Judul Jurnal	Masalah	Metode	Hasil	Kesimpulan
4	Syukri dan Syamsuddin	Pengujian Algoritma Artificial Neural Network (ANN) Untuk Prediksi Kecepatan Angin	Sumber energi alternatif yang dapat diperbaharui yaitu salah satu angin. Angin yang bertiup pada suatu wilayah memiliki karakteristik kecepatan dan arah tertentu, yang nilainya selalu berubah-ubah setiap waktu sesuai dengan kondisi suhu, tekanan udara dan kelembaban setempat. Pemamfaatan energi angin dengan penggerakkan turbin angin, memerlukan pengetahuan tentang kondisi angin setempat agar kondisi angin dapat diketahui dengan meramalkan kecepatan angin berdasarkan data angin sebelumnya. Ada beberapa metode prediksi kecepatan angin yaitu didtribusi weibull, Rayleigh dan lainnya.	Artificial Neural network (ANN)	Dengan menggunakan data <i>input/output</i> dari satu bulan sampai lima tahun, hasil prediksi potensi angin menunjukkan bahwa pembelajaran dan pengujian terbaik dilakukan pada dua bulan tertentu (Januari dan Maret 2015). Metode ANN Backpropagation untuk memprediksi kecepatan angin menghasilkan MSE sebesar 0.00990 dan tingkat akurasi 99%, menunjukkan bahwa sistem pelatihan ANN Backpropagation efektif untuk tujuan prediksi kecepatan angin	Dengan menggunakan metode pembelajaran dan pengujian ANN backpropagation, diperoleh rata-rata kecepatan angin harian sebesar 3.99 m/s untuk lokasi yang dipilih. Model ini berhasil mencapai tingkat akurasi 99% dalam memprediksi kecepatan angin, terbukti dari pelatihan menggunakan data dari satu bulan sampai lima tahun, dengan nilai error terkecil dihasilkan dari penggunaan data dua bulan pada tahun 2015.

Tabel 1. Penelitian Terdahulu (Lanjutan)

No	Nama Penulis	Judul Jurnal	Masalah	Metode	Hasil	Kesimpulan
5	Yusraini Muharni (2021)	<i>The Application of Artificial Neural Network For Quality Prediction of Industrial Standard Water</i>	Nilai kekeruhan merupakan salah satu parameter yang mempengaruhi dalam menentukan dosis bahan kimia yang akan digunakan pada pengolahan air. Sehingga perlunya prediksi untuk nilai kekeruhan untuk membantu dan menjaga proses pengolahan air.	<i>Artificial Neural Network (ANN)</i>	Berdasarkan hasil <i>training data</i> dengan <i>epoch</i> maksimal 1000. Didapatkan <i>epoch</i> terbaik berada pada <i>epoch</i> ke-343 dengan nilai <i>error</i> MSE terkecil 0,0013. Adapun hasil visualisasi dari <i>training data</i> berupa grafik <i>best performance</i> yang menunjukkan tidak adanya <i>overfitting</i> , sehingga data input yang digunakan dapat menyelesaikan permasalahan prediksi pada penelitian ini.	Berdasarkan hasil prediksi menggunakan metode ANN untuk nilai kekeruhan pada pengolahan air dengan melibatkan pH, spektrum warna dan konduktivitas Listrik. ANN yang dihasilkan memiliki nilai terbaik dengan MSE sebesar 0,0013.

BAB II

TINJAUAN PUSTAKA

2.1 Ikan

Berdasarkan Pasal 1 UU Perikanan No. 45 tahun 2009, ikan didefinisikan sebagai organisme yang siklus hidupnya berada di lingkungan perairan, baik sebagian maupun seluruhnya. Ikan merupakan sumber makanan yang kaya protein, yang sangat penting bagi manusia karena mudah dicerna dan mengandung asam amino dengan pola serupa dengan asam amino yang ada dalam tubuh manusia. Bahan baku hasil perikanan termasuk dalam kategori bahan pangan yang sangat mudah mengalami kerusakan (*highly perishable*) karena memiliki tingkat kelembaban yang tinggi dan kandungan nutrisi yang menyediakan kondisi yang optimal bagi pertumbuhan mikroba pembusuk. Oleh karena itu, penanganan yang cermat dari proses penangkapan hingga pengolahan, baik di industri maupun di tingkat rumah tangga, sangatlah penting. Selain aspek mikrobiologis pada ikan, keberadaan enzim yang berasal dari tubuh ikan juga memainkan peran signifikan dalam proses penurunan kualitas ikan. Pengetahuan mengenai kondisi fisik dan kimia ikan menjadi dasar utama dalam teknik penanganan ikan segar. Namun, karena ikan memiliki sifat yang sangat mudah mengalami kerusakan (*highly perishable*) akibat kadar airnya yang tinggi (70-80%), penanganan yang hati-hati setelah penangkapan sangatlah krusial (Naiu dkk, 2018).

2.1.1 Ikan Tunul

Ikan Tunul (*Spyracnidae*) atau yang biasa disebut barakuda sering dijumpai di perairan dangkal di selat-selat, semenanjung, dan teluk-teluk di sepanjang pantai. Mereka tersebar luas di hampir semua lautan tropis dan subtropis, kecuali di Samudera Pasifik Timur. Barakuda biasanya ditemukan di perairan lepas pantai dan di sekitar karang, dermaga, bangkai kapal tenggelam, dan gosong pasir (tempat pengeringan ikan yang dilakukan secara digantung) dan padang lamun (daerah perairan dangkal yang ditumbuhi banyak rumput laut). Dibalik bentuknya yang menyeramkan karena giginya yang tajam, ternyata ikan tunul (*Spyracnidae*)

ini juga dapat diolah menjadi makanan yang enak dan bernilai jual tinggi. Ikan tunul (*Spyracnidae*) yang menyeramkan ini diolah menjadi sebuah hidangan yang lezat dan menggugah selera (Pratama, Suryanti dan Suryanto, 2018).

2.1.2 Pengolahan Ikan

Pengolahan tradisional melibatkan berbagai teknik untuk mengawetkan ikan, seperti pengeringan untuk mengurangi kadar air, penambahan garam, atau bahan kimia tertentu untuk menghasilkan perubahan yang menciptakan cita rasa yang diinginkan. Produk ikan olahan tradisional, atau *cured fish*, sering kali diproduksi secara sederhana, baik dalam skala industri rumah tangga. Jenis produk olahan tradisional ini meliputi ikan kering atau asin kering, ikan pindang, ikan asap, serta produk fermentasi seperti kecap, peda, terasi, dan sejenisnya (Naiu dkk, 2018).

Pengeringan ikan melibatkan dua proses utama: pertama, proses pemindahan panas untuk menguapkan cairan dari bahan dengan bantuan udara pengering; kedua, proses pemindahan massa di mana air atau uap air berpindah dari dalam bahan ke permukaan, dan selanjutnya ke udara pengering. Pengeringan ini digunakan untuk mengawetkan ikan dengan mengurangi kadar air dalam tubuh ikan seoptimal mungkin. Kandungan air dalam tubuh ikan mencapai 56-80%, dan penurunan kadar air ini akan mengganggu metabolisme bakteri dan menyebabkannya mati. Bakteri tidak aktif pada kadar air 40%, meskipun sebagian spora tetap bisa hidup. Spora ini dapat tumbuh dan aktif kembali jika kadar air meningkat. Oleh karena itu, sebelum pengeringan dilakukan, ikan umumnya digarami terlebih dahulu (Naiu dkk, 2018).

2.1.3 Pembusukan Pada Ikan

Kerusakan pada ikan dan produk olahannya terutama yang disebabkan oleh pertumbuhan mikorba memiliki ciri yang khas. Tanda-tanda kerusakan pada ikan dan produk olahannya, yaitu (Rorong dan Wilar, 2020) :

1. Adanya bau busuk yang disebabkan oleh gas monia, sulfida atau senyawa busuk lainnya. Perubahan bau busuk ini menjadi ciri pertama yang akan terjadi ketika ikan atau produk olahannya mengalami pembusukan tahap awal.
2. Terbentuknya lendir pada permukaan ikan dan produk olahannya.

3. Adanya perubahan warna pada ikan dan produk olahannya, yaitu perubahan warna menjadi pucat atau kusam.
4. Adanya perubahan tekstur pada ikan dan produk olahannya menjadi tidak kenyal lagi.

2.1.4 Pengawetan Ikan dengan Pengeringan

Cara pengeringan untuk mengawetkan bahan pangan telah dilakukan sejak lama. Kadar air dalam bahan pangan ataupun lebih tepatnya *water activity* sangat menentukan terhadap cepat atau lambatnya bahan menjadi rusak. Semakin rendah *water activity* maka semakin awet bahan tersebut. Berbagai cara telah digunakan untuk mengurangi kadar air dalam suatu bahan pangan. Salah satu cara umum yang digunakan dengan menggunakan sinar matahari. Pada masa kini, proses pengeringan dapat dilakukan dengan menggunakan alat pengering mekanis, dengan demikian baik suhu maupun kecepatan udara dapat dikendalikan dengan baik. Selain dilakukannya proses pengeringan, penguapan dan pengentalan dapat dilakukan untuk mengurangi kadar air dari bahan cair sehingga bahan mempunyai viskositas yang tinggi dengan *water activity* yang rendah (Effendi, 2015).

2.2 *Artificial Neural Network*

Sejarah perkembangan jaringan saraf tiruan dimulai sekitar tahun 1940-an, ketika para peneliti mulai mengaitkan cara kerja otak manusia dengan logika numerik yang dapat diadaptasi oleh komputer. Langkah-langkah awal dalam perkembangannya termasuk perancangan model formal pertama tentang neuron oleh ahli syaraf Warren McCulloch dan ahli logika Walter Pitts pada tahun 1943. Pada tahun 1949, Donald Hebb melakukan penelitian tentang proses belajar yang dilakukan oleh neuron, yang dikenal sebagai Hukum Hebb. Perkembangan ini menandai tahap-tahap awal dalam evolusi *artificial neural network*. Selama beberapa dekade terakhir, manusia telah berupaya mengembangkan sistem yang meniru kemampuan dan perilaku makhluk hidup. Salah satu hasil dari perkembangan ilmu teknologi yang sedang berkembang pesat adalah jaringan saraf tiruan (*artificial neural network*). Jaringan saraf tiruan ini didasarkan pada prinsip-prinsip organisasi otak manusia, di mana susunannya terdiri dari sel-sel neuron. Ketertarikan yang besar terhadap jaringan saraf tiruan ini dipicu oleh

keunggulannya, seperti kemampuan untuk melakukan komputasi secara paralel, kemampuan untuk memodelkan fungsi-fungsi non-linear, dan toleransi terhadap kesalahan (*fault tolerance*) (Kusumadewi, 2003).

Ketika merancang *artificial neural network*, selain memperhatikan struktur hubungan antara simpul *input* dan *output*, penting juga untuk menentukan metode pembelajarannya. Pembelajaran dalam *artificial neural network* mengacu pada proses penyesuaian bobot sinapsis berdasarkan sinyal masukan dan keluaran yang diinginkan. Umumnya, *artificial neural network* terdiri dari sejumlah neuron sebagai unit pemrosesan informasi dasar yang menjalankan fungsi atau tugasnya. (Siang, 2005). *Learning* terjadi ketika pembobotan dan bias disesuaikan. Salah satu metode yang umum digunakan dalam proses ini adalah *backpropagation*. Dalam metode ini, pembobotan disesuaikan untuk mengurangi kesalahan kuadrat antara *output model* dan *output* perkiraan, yang umumnya disebut sebagai nilai kuadrat galat atau *sum of square error* (Ripley, 2017)

Artificial neural network memiliki kelebihan diantaranya (Ripley, 2017) :

1. *Artificial neural network*, yang nonlinier secara alami, cocok digunakan untuk menangani sistem-sistem dengan tingkat kompleksitas yang tinggi.
2. *Artificial neural network* bersifat adaptif karena mampu belajar dari data yang diberikan dan menghasilkan solusi berdasarkan pengalaman yang diperoleh.
3. *Artificial neural network* memiliki kemampuan untuk melakukan generalisasi, yaitu mampu menerapkan pengetahuan yang diperoleh dari data pelatihan untuk situasi atau masalah yang serupa namun belum pernah dihadapi sebelumnya.

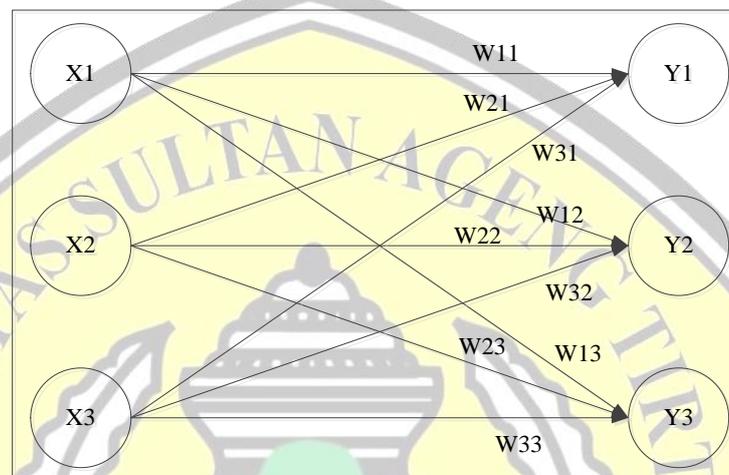
2.2.1 Arsitektur *Artificial Neural Network*

Artificial neural network memiliki beberapa jenis arsitektur untuk menggambarkan struktur jaringan yang digunakan dalam berbagai aplikasi. Arsitektur *artificial neural network*, antara lain :

1. Jaringan *layer* tunggal

Pada jenis jaringan *layer* tunggal, jaringan terdiri dari 1 *layer input*, 1 *layer output* dan 1 lapis bobot koneksi. Pada jaringan ini, sekumpulan

input neuron dihubungkan langsung dengan *output* dan sinyal mengalir searah dari *input* sampai *output*. Setiap simpul dihubungkan dengan simpul lainnya yang berada di atasnya dan di bawahnya, tetapi tidak dengan simpul yang berada pada lapisan yang sama. Model yang masuk kategori ini diantaranya ADALINE, Hopfield, Perceptron, LVQ dan lain-lain (Siang, 2005). Berikut ini merupakan arsitektur jaringan *layer tunggal* :

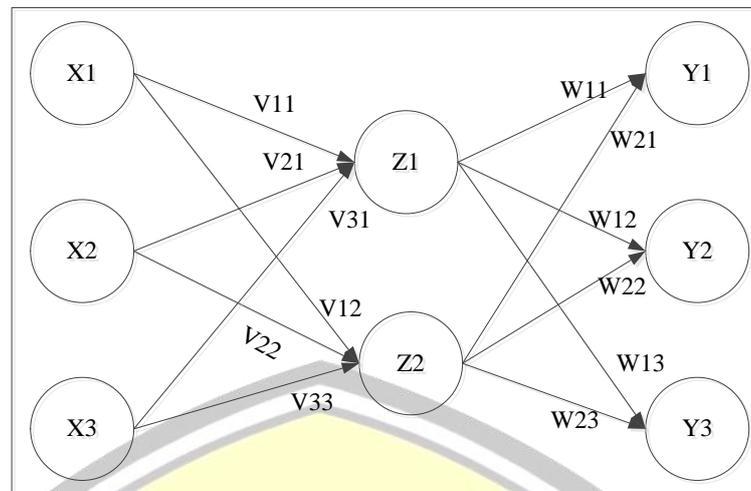


Gambar 1. Arsitektur Jaringan Layer Tunggal

(Sumber: Siang, 2005)

2. Jaringan *layer* jamak

Jaringan dengan lapisan jamak atau *multi-layer* memiliki tiga jenis lapisan yaitu *layer input*, *layer output* dan *hidden layer* (*layer* tersembunyi). Jaringan *multi-layer* dapat menyelesaikan permasalahan yang lebih kompleks dibandingkan dengan *single layer* karena *training* data yang dilakukan lebih kompleks dengan adanya *hidden layer*. Model yang termasuk dalam kategori jaringan *multi-layer* adalah MADALINE dan *backpropagation* (Siang, 2005). Berikut ini merupakan arsitektur jaringan *layer* jamak :



Gambar 2. Arsitektur Jaringan Layer Jamak

(Sumber: (Siang, 2005))

2.2.2 Training Data

Menentukan besarnya *training data* pada metode *Artificial Neural Network* (ANN) merupakan aspek penting dalam pembelajaran mesin. Penggunaan data yang tepat dapat mempengaruhi kinerja dalam kemampuan model untuk melakukan prediksi yang akurat (Santoso dkk, 2023). Berikut adalah beberapa pertimbangan untuk menentukan besarnya *training data* pada metode ANN (Aggarwal, 2019):

1. Jumlah fitur dan kompleksitas model. Jika penelitian memiliki banyak fitur (variabel) yang digunakan dalam *training data*, maka umumnya diperlukan lebih banyak data untuk melatih model agar dapat menangkap pola-pola yang tepat. Semakin kompleks model yang digunakan, semakin banyak data yang diperlukan.
2. Tingkat ketergantungan (*dependency*) dalam data. Jika data yang digunakan saling berkaitan satu sama lain, maka diperlukan lebih banyak data untuk memastikan bahwa variasi yang cukup besar dalam pola tersebut dapat ditangkap oleh model.
3. *Overfitting* dan *underfitting*. *Overfitting* terjadi jika model terlalu “terbias” pada *training data* dan tidak dapat digeneralisasi ke data yang baru. Di sisi lain, jika memiliki data yang terlalu banyak, risiko *overfitting* bisa berkurang.

4. Uji coba dan validasi. Pemisahan data menjadi set latihan, validasi, dan pengujian. *Training* data digunakan untuk melatih model, sedangkan data validasi digunakan untuk mengukur performa model saat ini.
5. Pedoman umum. Meskipun tidak ada aturan pasti, beberapa praktisi menggunakan pedoman umum seperti memiliki 70-80% data untuk *training*, 10-15% untuk validasi, dan sisanya untuk pengujian. Namun, ini dapat bervariasi tergantung dengan kasus penggunaan dan kompleksitas data.

Dalam melakukan training data, salah satu *output* yang dihasilkan adalah bobot bias yang dihasilkan dapat berbeda-beda berdasarkan fungsi aktivasi yang digunakan. Fungsi aktivasi bertugas untuk mengolah data yang masuk menjadi data keluaran yang diinginkan. Berikut adalah macam-macam fungsi aktivasi yang dapat digunakan (Pamungkas, Sumadi dan Alam, 2022):

1. Fungsi *sigmoid biner*, merupakan fungsi yang menghasilkan bobot bias yang menghasilkan *range* nilai 0 sampai 1 sehingga *output* berada pada interval 0 sampai 1.
2. Fungsi *sigmoid bipolar*, merupakan fungsi yang mirip dengan *sigmoid biner* namun *output* yang dihasilkan *range* angka -1 hingga 1.
3. Fungsi identitas/*linear*, mempunyai *output* yang sama persis dengan nilai *input*.

2.2.3 Algoritma *Backpropagation*

Backpropagation adalah teknik penurunan gradien yang digunakan untuk mengurangi kesalahan kuadrat output dalam jaringan *neural*. Proses pelatihan jaringan melibatkan tiga tahap utama: perambatan maju (*forward propagation*), perambatan balik (*backward propagation*), dan penyesuaian bobot dan bias. Arsitektur jaringan ini terdiri dari lapisan *input*, lapisan tersembunyi (*hidden layer*), dan lapisan *output* (Sutojo dkk, 2011). Sebelum melakukan pelatihan dan pengujian pada perhitungan prediksi menggunakan metode ANN, data yang akan digunakan harus melewati tahap transformasi. Tahap ini bertujuan untuk mengubah data ril menjadi format yang cocok untuk pelatihan ANN. Salah satu langkah penting dalam tahap ini adalah normalisasi data *input* dan target. Proses normalisasi

dilakukan untuk menyetarakan skala nilai *input* dan target sebelum data tersebut dimasukkan ke dalam ANN, digunakan fungsi sebagai berikut (Purnomo dkk, 2006):

$$X' = \frac{0,8(X-a)}{(b-a)} + 0,1 \dots \dots \dots (2.1)$$

Keterangan :

- X' = nilai hasil normalisasi data
 X = nilai asli dari data
 a = data minimum
 b = data maksimum

Setelah data real diubah melalui proses transformasi, langkah berikutnya adalah menerapkan 3 fase pada algoritma *backpropagation*, yang meliputi 9 tahap proses *backpropagation* dan satu tahap untuk mengembalikan data ke nilai semula (denormalisasi). Sembilan tahap dalam proses algoritma *backpropagation* mencakup (Purnomo dkk, 2006):

1. Penentuan bobot yang akan dimasukkan pada sistem manual, yaitu bobot nilai yang didapatkan dari hasil normalisasi data variabel.
2. Untuk tiap *input neuron* (X_i , $i=1,2,3,\dots,n$) menerima *input* J_i dan menyebarkan sinyal tersebut ke seluruh neuron kepada *hidden layer*.
3. Untuk setiap *input* lapisan neuron J_i akan mendapatkan sebaran lapisan *hidden layer*.
4. Menghitung *output hidden layer*.
5. Menghitung perubahan *output* unit pertama.
6. Menghitung faktor perubahan bobot masing-masing *output*, pada fase keenam disebut juga *forward propagation*.
7. Menghitung galat *error* hasil *output*.

$$MSE = \sum \frac{(Aktual-Forecast)^2}{n-1} \dots \dots \dots (2.2)$$

Keterangan :

MSE = *Mean Square Error*

N = jumlah periode yang digunakan dalam perhitungan

8. Melakukan proses *update* nilai bias dan bobot pada *output neuron*.

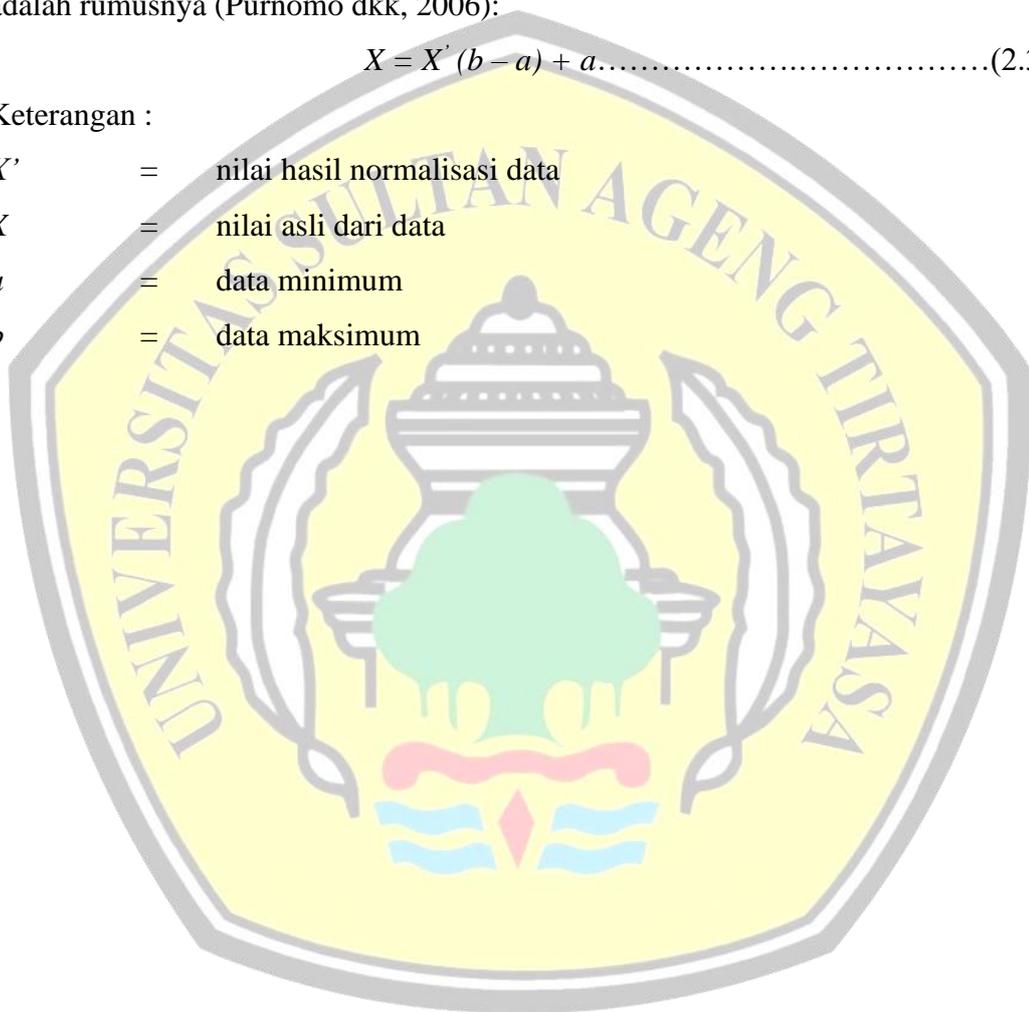
9. Menguji apakah kondisi berhenti sudah terpenuhi. Kondisi berhenti ini terpenuhi jika nilai kesalahan yang dihasilkan lebih kecil dari nilai kesalahan dari pola pelatihan sebelumnya.

Setelah dilakukannya 9 tahap *backpropagation*, dilakukan proses denormalisasi. Proses ini merupakan proses perubahan kembali angka dari desimal menjadi angka bilangan bulat agar didapatkan hasil berupa bilangan bulat. Berikut adalah rumusnya (Purnomo dkk, 2006):

$$X = X' (b - a) + a \dots \dots \dots (2.3)$$

Keterangan :

- X' = nilai hasil normalisasi data
 X = nilai asli dari data
 a = data minimum
 b = data maksimum



BAB III

METODE PENELITIAN

3.1 Rancangan Penelitian

Penelitian kali ini didasarkan oleh banyaknya komplain terhadap hasil produksi dimsum pada UPI D’Kriwil yaitu terjadi pembusukan lebih cepat dibandingkan klaim yang diberikan oleh UPI. Oleh karena itu, dilakukan penelitian ini untuk mengetahui besarnya kadar air yang dapat menjaga ketahanan produk dan menentukan akurasi dari prediksi yang dilakukan menggunakan metode *artificial neural network*.

Penelitian ini dilakukan menggunakan metode *artificial neural network* dengan alat *backpropagation* untuk menentukan bobot dan tingkat akurasi hasil prediksi kadar air pada bahan baku ikan tunul. Dari penelitian dengan metode ini diharapkan hasil batasan kadar air yang direkomendasi untuk menjaga ketahanan produk serta memprediksi kadar air untuk periode produksi selanjutnya.

3.2 Lokasi dan Waktu Penelitian

Penelitian ini dilakukan di UPI D’Kriwil yang berlokasi di Link. Wates dua kedung No.15, RT.003/RW.004, Gedong Dalem, Kec. Jombang, Kota Cilegon, Banten 42413. Waktu yang digunakan untuk melakukan penelitian ini adalah selama Bulan November-Desember 2022.

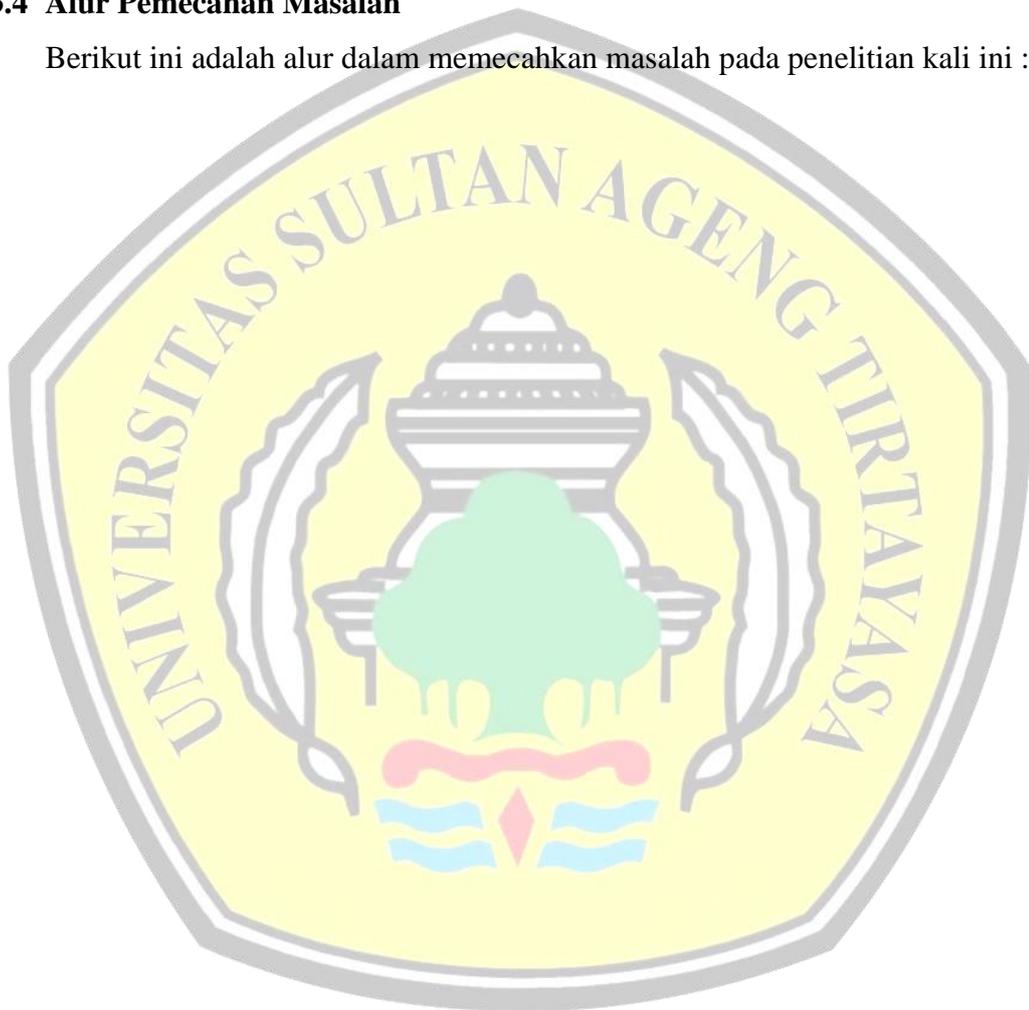
3.3 Cara Pengumpulan Data

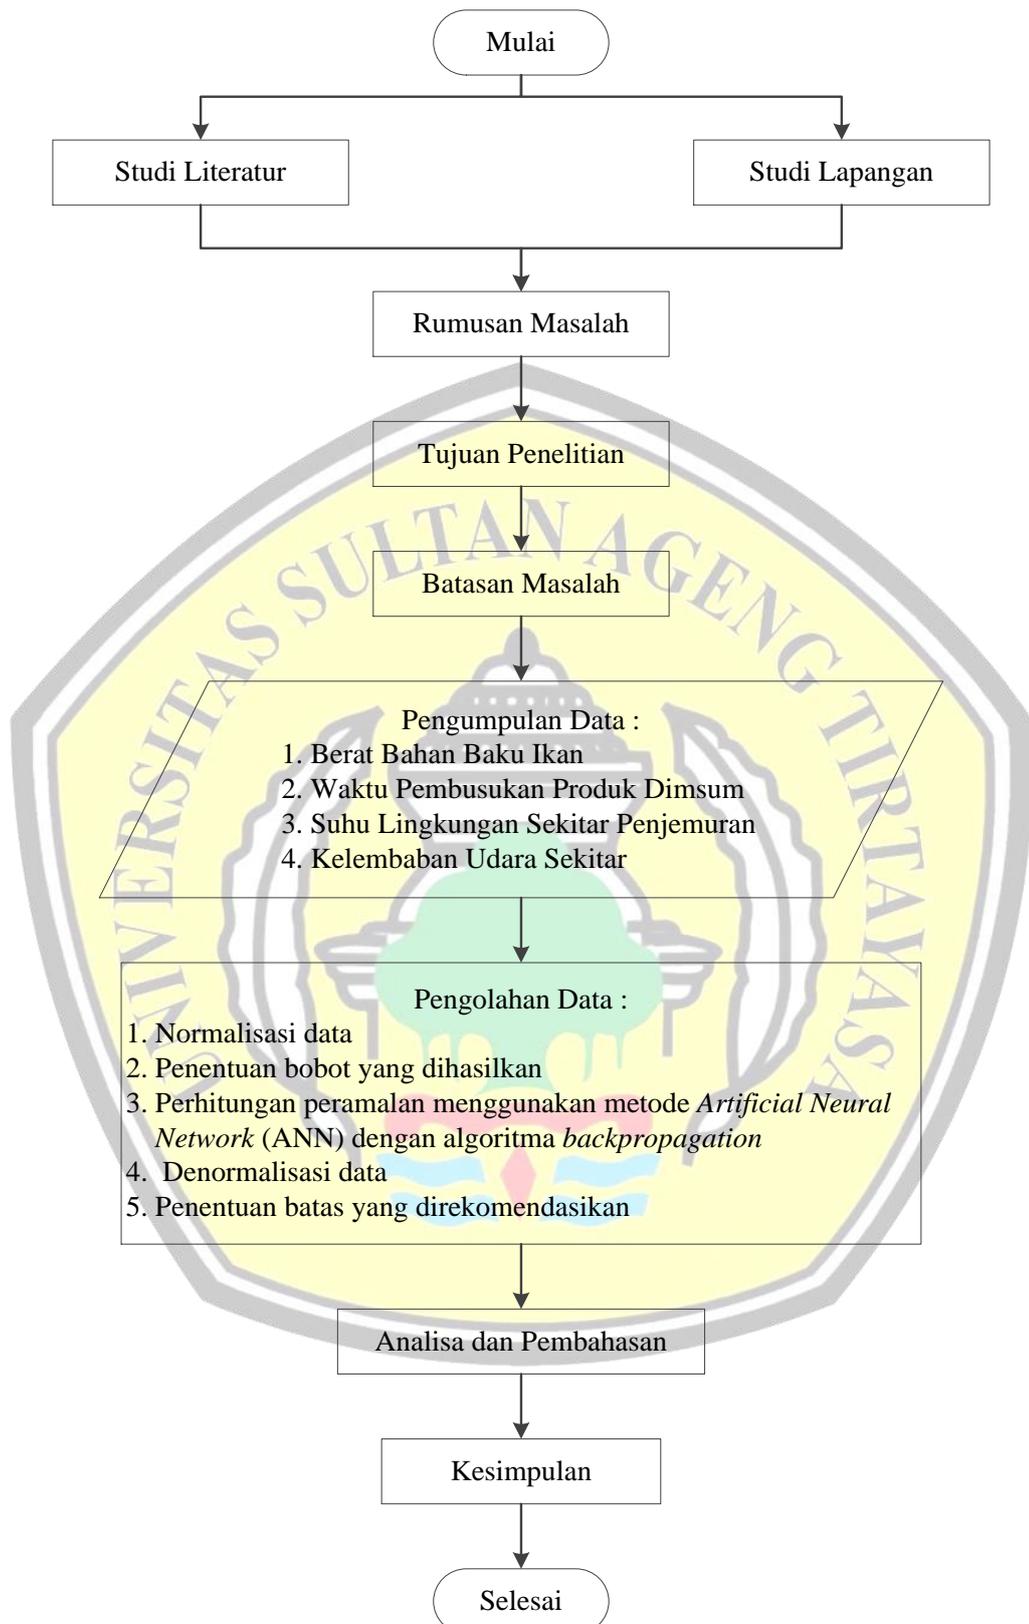
Data yang diperlukan pada penelitian ini didapatkan dari pengumpulan hasil penimbangan berat bahan baku ikan tunul yang dibeli. Kemudian dari pengukuran tersebut diambil sampel untuk diuji coba ketahanannya hingga mengalami pembusukan. Selain menguji coba dengan bahan baku asli, dilakukan pula uji coba dengan bahan baku ikan tunul dikeringkan terlebih dahulu dengan cara dijemur selama 2 jam di atap rumah produksi UMKM. Ikan diletakkan dalam nampan yang ditutup aluminium foil agar ikan tunul yang dijemur terjaga kebersihannya serta tetap mendapatkan panas sinar matahari yang berada di lingkungan sekitar. Ikan yang telah dijemur kemudian diuji coba ketahanannya hingga mengalami

pembusukan dengan memerhatikan tanda-tanda seperti adanya perubahan bau seperti bau ammonia dan bau busuk lainnya, adanya perubahan warna menjadi pucat, keluar lendir pada permukaan produk serta adanya perubahan tekstur pada produk (Rorong dan Wilar, 2020). Dari hasil uji coba tersebut hasil dianalisa untuk menentukan parameter kadar air yang baik dan memprediksi kadar air pada bahan baku untuk periode selanjutnya.

3.4 Alur Pemecahan Masalah

Berikut ini adalah alur dalam memecahkan masalah pada penelitian kali ini :





Gambar 3. Flowchart Penelitian Umum

Berikut ini adalah deskripsi setiap alur penelitian umum :

1. Mulai

Tahap permulaan pada penelitian ini.

2. Studi Literatur

Pada tahap studi literatur, dilakukan pencarian relevan mengenai metode *artificial neural network* (ANN), ikan dan bagaimana ikan mengalami pembusukan.

3. Studi Lapangan

Tahapan studi lapangan dilakukan untuk mengetahui permasalahan yang terjadi untuk dijadikan topik pembahasan penelitian. Pada penelitian ini, didapatkan hasil studi lapangan pada UPI D’Kriwil yaitu terdapat permasalahan mengenai kualitas produk berupa terlalu cepatnya pembusukan.

4. Rumusan Masalah

Pada tahap perumusan masalah dilakukan perumusan terhadap hal-hal yang menjadi sumber permasalahan sehingga hasil dari penelitian dapat mencapai tujuan yang diinginkan.

5. Tujuan Penelitian

Berdasarkan perumusan masalah, dilakukan penentuan tujuan yang diinginkan untuk menyelesaikan masalah yang terjadi.

6. Batasan Masalah

Penentuan batasan permasalahan merupakan salah satu hal yang penting agar topik pembahasan permasalahan tetap dalam lingkungannya. Salah satu batasan masalah pada penelitian ini yaitu data yang diperoleh merupakan data bahan baku UPI D’Kriwil (November-Desember 2022).

7. Pengumpulan Data

Pengumpulan data dilakukan untuk mengetahui berat bahan baku ikan tunul dan lamanya pembusukan pada produk olahan UPI D’Kriwil. Pengumpulan data dilakukan pada periode produksi pada bulan November-Desember 2022.

8. Pengolahan Data

Pada tahap pengolahan data ini, terdapat 5 tahap untuk mendapatkan *output* peramalan. Tahap pertama melakukan normalisasi data, kemudian menentukan bobot tiap *hidden layer*. Setelah mengetahui bobot tiap *hidden layer* maka didapatkan nilai peramalan dan kemudian data dikembalikan dengan denormalisasi data. Setelah mengetahui peramalan pada periode selanjutnya maka dapat dihasilkan batas yang direkomendasikan untuk kadar air agar kualitas produk semakin baik.

9. Analisa dan Pembahasan

Pada tahap ini, dilakukan analisa terhadap hasil simulasi olah data. Analisa yang dilakukan adalah analisa terhadap hasil perhitungan ANN sampai hasil peramalan.

10. Kesimpulan

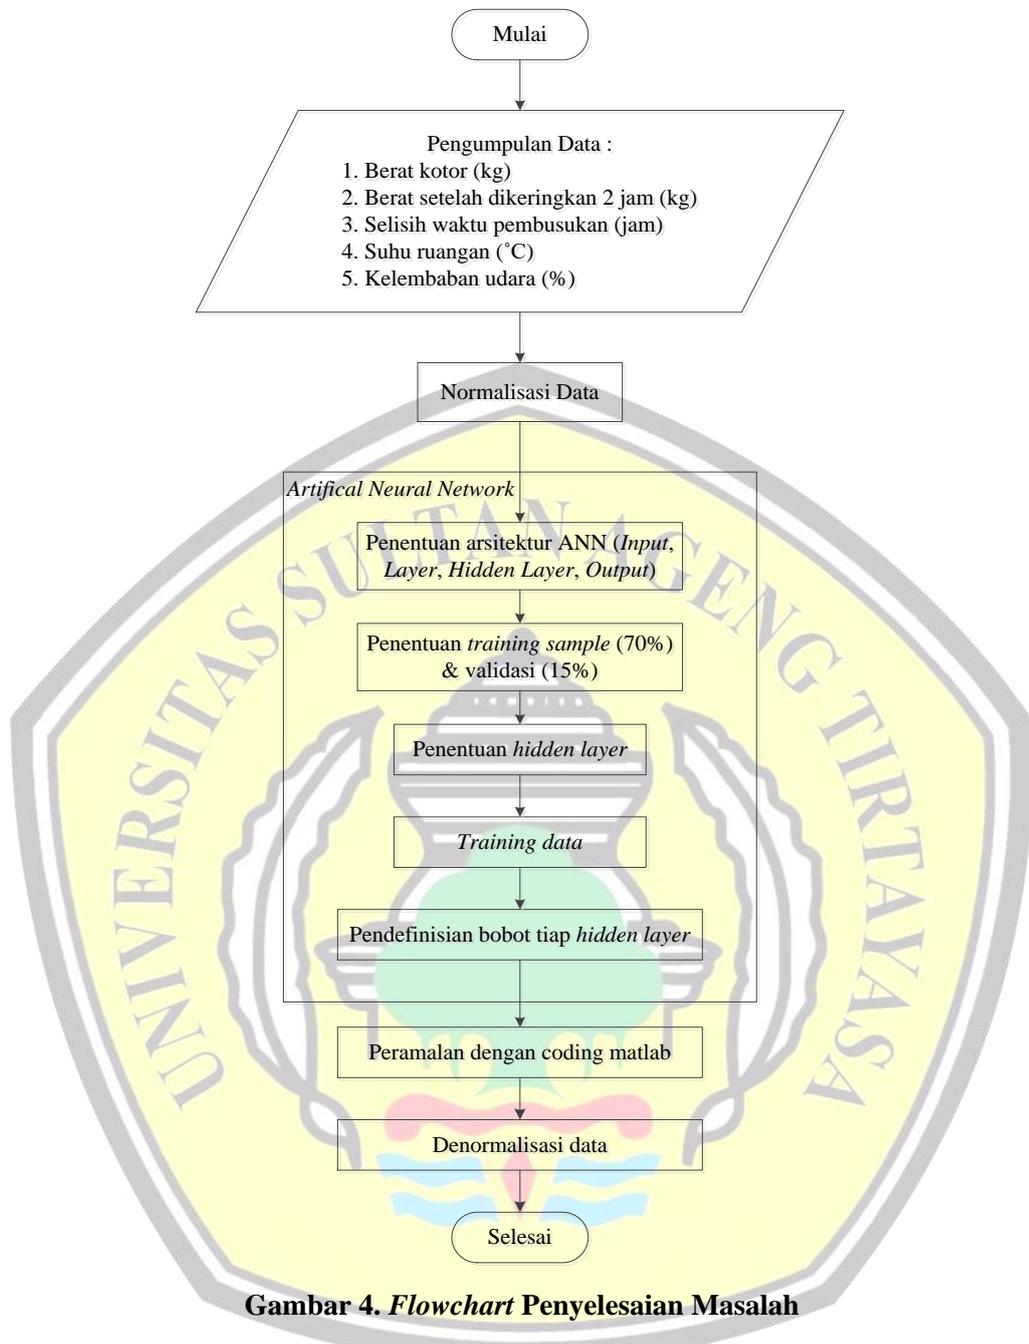
Dilakukan penyimpulan dari hasil analisa dan pembahasan untuk mengetahui hasil yang diperoleh sesuai tujuan yang ingin dicapai.

11. Selesai

Setelah melakukan kesimpulan penyelesaian dari permasalahan maka penelitian selesai dilaksanakan.

3.5 Analisis Data

Pada penelitian ini, dilakukan analisis data terhadap hasil perhitungan prediksi menggunakan metode *Artificial Neural Network* (ANN). Berikut ini adalah rincian alur pengolahan data dari metode ANN yang digunakan :



Gambar 4. Flowchart Penyelesaian Masalah

Berikut ini adalah deskripsi terhadap alur penyelesaian masalah pada penelitian ini :

1. Mulai

Tahap permulaan penyelesaian masalah pada penelitian ini.

2. Pengumpulan data

Pada tahap pengumpulan data, didapatkan 5 variabel yang akan menjadi variabel bebas pada penelitian ini. Variabel yang digunakan adalah berat

kotor (X1), berat setelah dikeringkan selama 2 jam (X2), selisih waktu pembusukan (X3), suhu ruangan (X4) dan kelembaban udara (X5).

3. Normalisasi data

Setelah didapatkan data variabel, kemudian dilakukan normalisasi data untuk standarisasi data karena data yang didapatkan merupakan data dengan satuan yang berbeda. Tahap *artificial neural network* (ANN)

Pada tahap perhitungan ANN, terdapat 5 langkah untuk mendapatkan hasil peramalan. Diantaranya :

a. Penentuan arsitektur ANN

Pada tahap ini, dilakukan pendefinisian terhadap *input* (5 variabel) dan *output* atau target (Y) dalam peramalan.

b. Penentuan *training sample* & validasi

Setelah diketahui arsitekturnya, kemudian dilakukan pemilihan jumlah sampel yang akan dilakukan *training* dan dilakukan pemilihan jumlah sampel untuk uji validasi setelah dilakukan *training*. Pada penelitian ini jumlah sampel yang digunakan untuk *training* adalah sebanyak 70% atau 43 data dan jumlah sampel yang digunakan untuk uji validasi adalah sebanyak 15% atau 9 data (Aggarwal, 2019).

c. Penentuan *hidden layer*

Pada tahap ini dilakukan penentuan banyaknya *hidden layer* yang diharapkan dalam *training data*. Pada penelitian ini, penentuan *hidden layer* yang digunakan berdasarkan kelipatan jumlah variabel yaitu kelipatan 5 (5, 10 dan 15 *hidden layer*) (Aggarwal, 2019).

d. *Training data*

Pada metode ANN, tahap inti pada metode adalah pada tahap *training data*. *Training data* dilakukan untuk mengestimasi data hasil simulasi dengan data yang ada sehingga dihasilkan perbandingan antara data simulasi dengan data penelitian. Perbandingan tersebut menghasilkan nilai *error* (MSE) yang menjadi parameter keberhasilan *training data* pada penelitian ini. Berikut merupakan rumus yang menjadi acuan

pemrograman untuk tahap *training data* (Santoso, Maimunah dan Sukmasetya, 2023):

$$Z_{netj} = v_{jo} + \sum_{i=1}^n x_i v_{ij} \dots \dots \dots (3.1)$$

$$Z_j = \frac{2}{1+e^{-z_{netj}}} - 1 \dots \dots \dots (3.2)$$

$$y_{netk} = W_{ko} + \sum_{j=1}^p Z_j W_{kj} \dots \dots \dots (3.3)$$

$$y_k = \frac{1}{1+e^{-y_{netk}}} \dots \dots \dots (3.4)$$

$$\delta_k = (t_k - y_k) y_k (1 - y_k) \dots \dots \dots (3.5)$$

$$\Delta W_{kj} = \alpha \delta_k z_j \dots \dots \dots (3.6)$$

Keterangan :

Z_{netj} = nilai net di neuron ke-j ($j = 1, 2, 3, \dots, n$)

x_i = nilai *output* dari neuron *input* ke-1 ($i = 1, 2, 3, 4, 5$)

v_{ij} = nilai bobot yang menghubungkan neuron ke-i ($j = 1, 2, 3, \dots, n$) dengan neuron ke-j ($k = 1, 2, 3, \dots, n$).

Z_j = nilai net di neuron ke-j ($j = 1, 2, 3, \dots, n$)

y_{netk} = nilai net di neuron ke-k pada *layer input*

δ_k = nilai kesalahan pada neuron ke-k di *output layer*

ΔW_{kj} = selisih bobot *hidden layer* pada neuron ke-j dengan neuron ke-k

e. Pendefinisian bobot tiap *hidden layer*

Setelah dilakukan *training data* serta dihasilkan nilai *error* (MSE) dan performansi data, kemudian didefinisikan bobot tiap *hidden layer* digunakan untuk mengetahui perbedaan setiap simulasi dengan *hidden layer* memiliki bobot yang berbeda pula. Berikut merupakan rumus yang digunakan untuk update *hidden layer* hasil *training data* terbaik (Santoso, Maimunah dan Sukmasetya, 2023):

$$W_{kj} (\text{baru}) = W_{kj} (\text{lama}) + \Delta W_{kj} \dots \dots \dots (3.7)$$

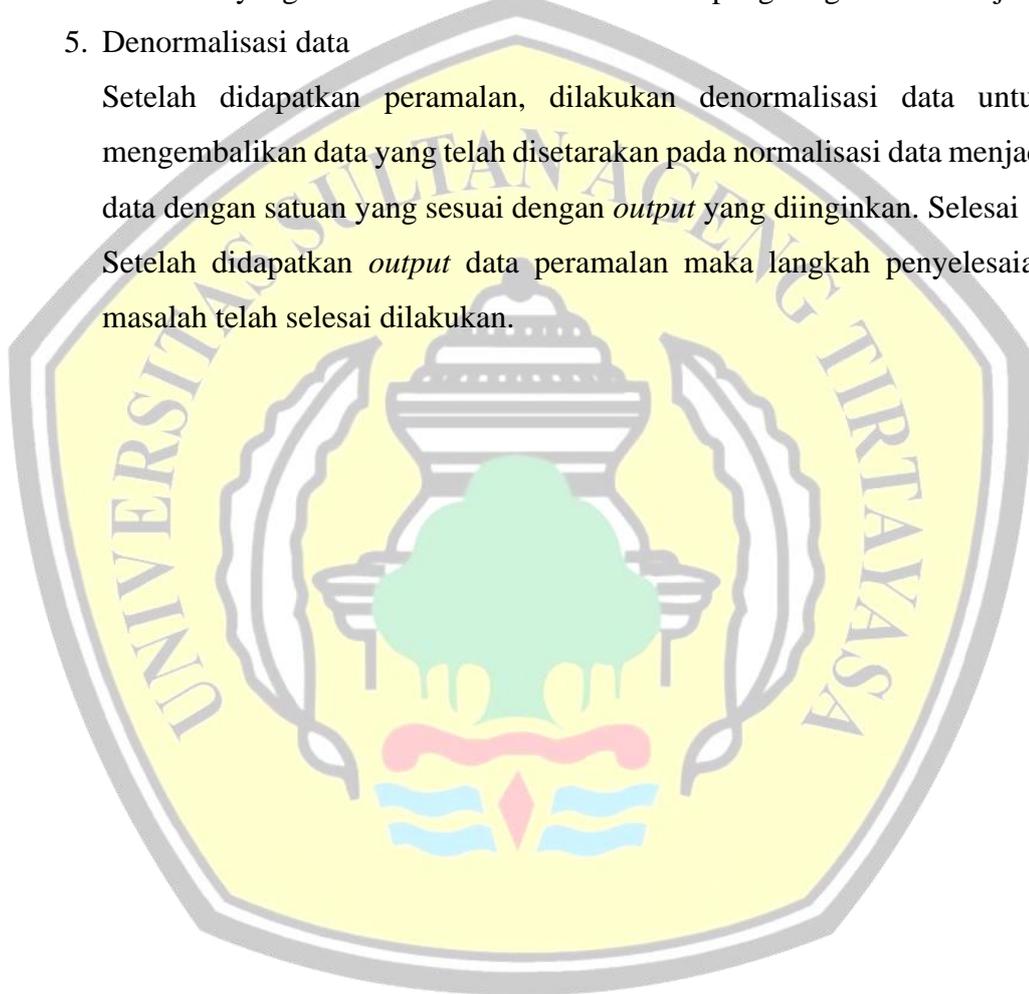
4. Peramalan dengan *coding* matlab

Berdasarkan hasil MSE, dilakukan perbandingan antara simulasi dengan *hidden layer* sebanyak 5, 10 dan 15. Hasil perbandingan tersebut dipilih

simulasi yang memiliki nilai MSE terkecil sehingga simulasi dianggap yang terbaik karena memiliki nilai *error* terkecil terhadap data penelitian. Hasil simulasi tersebut dilanjutkan dengan perhitungan peramalan terhadap kadar air pada ikan tunul dengan bobot yang telah didapatkan sebelumnya. Pada tahap peramalan, perhitungan dilakukan dengan membandingkan target yang diharapkan yaitu target selisih kadar air pada ikan tunul yang sebelum dan sesudah dilakukan pengeringan selama 2 jam.

5. Denormalisasi data

Setelah didapatkan peramalan, dilakukan denormalisasi data untuk mengembalikan data yang telah disetarakan pada normalisasi data menjadi data dengan satuan yang sesuai dengan *output* yang diinginkan. Selesai Setelah didapatkan *output* data peramalan maka langkah penyelesaian masalah telah selesai dilakukan.



BAB IV

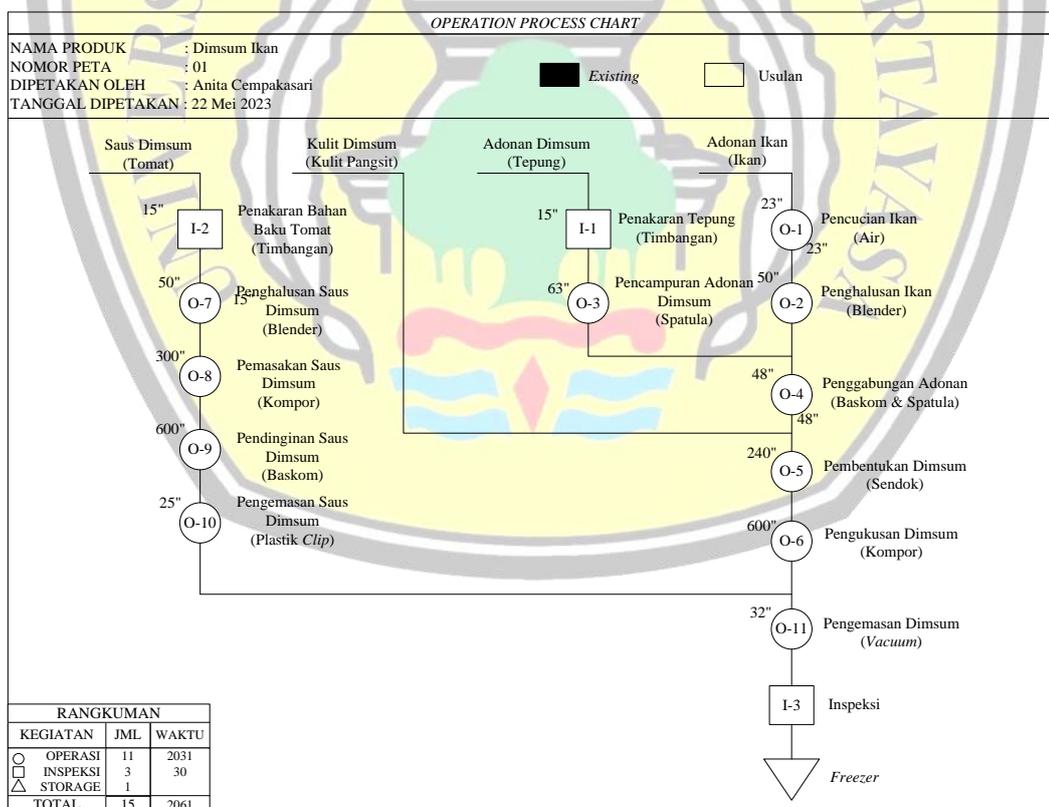
HASIL PENELITIAN

4.1 Pengumpulan Data

Pada penelitian ini, dilakukan pengumpulan data yang hasil datanya akan dilakukan pengolahan data dan analisa untuk mencapai tujuan penelitian. Terdapat 4 data yang dikumpulkan pada penelitian ini, yaitu *operation process chart* (OPC) produk, data berat bahan baku, data suhu lingkungan, dan data kelembaban lingkungan.

4.1.1 Operation Process Chart (OPC) Produk Dimsum Ikan

Sebelum dilakukan pengolahan data, dilakukan pengamatan terlebih dahulu terhadap proses produksi produk dimsum ikan. Berdasarkan pengamatan proses produksi dimsum ikan, berikut ini adalah OPC dari produk dimsum ikan :



Gambar 5. Operation Process Chart (OPC) Dimsum Ikan

Berdasarkan Gambar 5, diketahui bahwa total waktu yang dibutuhkan untuk memproduksi dimsum ikan adalah 2061 detik atau 34,35 menit dalam memproduksi 15 *pack* dimsum. Dalam proses produksi dimsum ikan terdapat 11 proses, 3 inspeksi dan 1 kali penyimpanan. Hasil pembuatan OPC menunjukkan bahwa waktu proses yang membutuhkan waktu lama adalah proses pengukusan dimsum dan pendinginan saus dimsum sebelum dimasukkan ke dalam *packaging* yaitu sebesar 600 detik atau 10 menit.

4.1.2 Berat Bahan Baku Ikan Tunul

Setelah mengetahui proses produksi pembuatan dimsum ikan, dilakukan pengumpulan data berat bahan baku ikan tunul untuk mengetahui prediksi yang akan dihitung. Berikut ini adalah hasil pengumpulan data berat bahan baku ikan tunul pada periode November-Desember 2022 :

Tabel 2. Data Berat Bahan Baku Ikan Tunul Periode November-Desember 2022

Tanggal	Berat Kotor (kg)	Berat Setelah Dikeringkan 2 jam (kg)	Jumlah Berat yang Berkurang Setelah Pengerangan (kg)
1-Nov-22	10,05	9,326	0,724
2-Nov-22	10,1	8,848	1,252
3-Nov-22	10	8,757	1,243
4-Nov-22	10,02	8,893	1,127
5-Nov-22	10,03	9,319	0,711
6-Nov-22	10,01	8,756	1,254
7-Nov-22	10,01	9,337	0,673
8-Nov-22	10,02	8,922	1,098
9-Nov-22	10,02	8,933	1,087
10-Nov-22	10,015	8,578	1,437
11-Nov-22	10,019	8,937	1,082
12-Nov-22	10	9,457	0,543
13-Nov-22	10	9,131	0,869
14-Nov-22	10,005	8,529	1,476
15-Nov-22	10	9,043	0,957
16-Nov-22	10	8,732	1,268
17-Nov-22	10	8,815	1,185
18-Nov-22	10,003	9,488	0,515
19-Nov-22	10,01	9,364	0,646
20-Nov-22	10	8,768	1,232
21-Nov-22	10	8,564	1,436

**Tabel 2. Data Berat Bahan Baku Ikan Tunul Periode November-Desember 2022
(Lanjutan)**

Tanggal	Berat Kotor (kg)	Berat Setelah Dikeringkan 2 jam (kg)	Jumlah Berat yang Berkurang Setelah Pengerinan (kg)
22-Nov-22	10	8,861	1,139
23-Nov-22	10	9,040	0,960
24-Nov-22	10	9,415	0,585
25-Nov-22	10	8,667	1,333
26-Nov-22	10,006	9,406	0,600
27-Nov-22	10,002	8,842	1,160
28-Nov-22	10,006	9,230	0,776
29-Nov-22	10,003	8,517	1,486
30-Nov-22	10,01	8,625	1,385
1-Dec-22	10,005	8,666	1,339
2-Dec-22	10	9,063	0,937
3-Dec-22	10,02	9,157	0,863
4-Dec-22	10	9,386	0,614
5-Dec-22	10	8,867	1,133
6-Dec-22	10,035	8,740	1,295
7-Dec-22	10,001	9,089	0,912
8-Dec-22	10	8,567	1,433
9-Dec-22	10	8,606	1,394
10-Dec-22	10	8,923	1,077
11-Dec-22	10	8,728	1,272
12-Dec-22	10,015	9,154	0,861
13-Dec-22	10,006	8,612	1,394
14-Dec-22	10,004	9,281	0,723
15-Dec-22	10,007	8,511	1,496
16-Dec-22	10	8,973	1,027
17-Dec-22	10,002	9,399	0,603
18-Dec-22	10,023	9,120	0,903
19-Dec-22	10	8,838	1,162
20-Dec-22	10	8,420	1,580
21-Dec-22	10	8,609	1,391
22-Dec-22	10	8,978	1,022
23-Dec-22	10,001	9,130	0,871
24-Dec-22	10,007	9,460	0,547
25-Dec-22	10,02	8,648	1,372
26-Dec-22	10	9,197	0,803
27-Dec-22	10	8,707	1,293
28-Dec-22	10,005	8,767	1,238

Tabel 2. Data Berat Bahan Baku Ikan Tunul Periode November-Desember 2022 (Lanjutan)

Tanggal	Berat Kotor (kg)	Berat Setelah Dikeringkan 2 jam (kg)	Jumlah Berat yang Berkurang Setelah Pengerinan (kg)
29-Dec-22	10,01	8,639	1,371
30-Dec-22	10,009	9,286	0,723
31-Dec-22	10,009	9,244	0,765

Berdasarkan hasil pengumpulan data bahan baku, diketahui bahwa setiap harinya dilakukan produksi terhadap 20 kg ikan tunul yang langsung diambil dari pemasok nelayan. Untuk menunjang penelitian ini, dilakukan percobaan terhadap bahan baku ikan yaitu 10 kg diolah berdasarkan proses produksi *existing* dan 10 kg diolah setelah dilakukan penjemuran selama 2 jam untuk mengurangi kadar air pada ikan tunul. Dapat dilihat pada Tabel 2 bahwa setelah dilakukan penjemuran, terjadi pengurangan berat pada bahan baku ikan sebesar 0,5-1,5 kg.

4.1.3 Waktu Pembeduan Ikan Tunul

Setelah dilakukan percobaan terhadap bahan baku ikan dengan 2 metode yaitu dengan berat asli dan dengan berat setelah dikeringkan, kemudian dilakukan percobaan terhadap lamanya pembeduan yang terjadi antara 2 jenis sampel tersebut. Berdasarkan hasil percobaan terhadap lamanya pembeduan, berikut ini adalah data lamanya pembeduan dimsum ikan yang didapatkan :

Tabel 3. Data Waktu Pembeduan Dimsum Ikan Periode November-Desember 2022

Tanggal	Waktu Pembeduan dengan Berat Kotor suhu ruangan (jam)	Waktu Pembeduan Setelah Dikurangi Kadar Air suhu ruangan (jam)	Selisih Waktu Pembeduan (jam)
1-Nov-22	50	68	18
2-Nov-22	50	78	28
3-Nov-22	50	78	28
4-Nov-22	50	76	26
5-Nov-22	50	72	22
6-Nov-22	50	78	28
7-Nov-22	50	68	18
8-Nov-22	50	76	26
9-Nov-22	50	76	26
10-Nov-22	50	84	34

**Tabel 3. Data Waktu Pembersihan Dimsum Ikan Periode November-Desember 2022
(Lanjutan)**

Tanggal	Waktu Pembersihan dengan Berat Kotor suhu ruangan (jam)	Waktu Pembersihan Setelah Dikurangi Kadar Air suhu ruangan (jam)	Selisih Waktu Pembersihan (jam)
11-Nov-22	50	76	26
12-Nov-22	50	65	15
13-Nov-22	50	73	23
14-Nov-22	50	84	34
15-Nov-22	50	75	25
16-Nov-22	50	78	28
17-Nov-22	50	76	26
18-Nov-22	50	65	15
19-Nov-22	50	68	18
20-Nov-22	50	78	28
21-Nov-22	50	84	34
22-Nov-22	50	78	28
23-Nov-22	50	75	25
24-Nov-22	50	65	15
25-Nov-22	50	80	30
26-Nov-22	50	68	18
27-Nov-22	50	78	28
28-Nov-22	50	72	22
29-Nov-22	50	84	34
30-Nov-22	50	80	30
1-Dec-22	50	80	30
2-Dec-22	50	75	25
3-Dec-22	50	73	23
4-Dec-22	50	72	22
5-Dec-22	50	76	26
6-Dec-22	50	78	28
7-Dec-22	50	75	25
8-Dec-22	50	84	34
9-Dec-22	50	80	30
10-Dec-22	50	76	26
11-Dec-22	50	80	30
12-Dec-22	50	73	23
13-Dec-22	50	80	30
14-Dec-22	50	72	22
15-Dec-22	50	84	34

Tabel 3. Data Waktu Pempusukan Dimsum Ikan Periode November-Desember 2022 (Lanjutan)

Tanggal	Waktu Pempusukan dengan Berat Kotor suhu ruangan (jam)	Waktu Pempusukan Setelah Dikurangi Kadar Air suhu ruangan (jam)	Selisih Waktu Pempusukan (jam)
16-Dec-22	50	76	26
17-Dec-22	50	68	18
18-Dec-22	50	75	25
19-Dec-22	50	76	26
20-Dec-22	50	86	36
21-Dec-22	50	80	30
22-Dec-22	50	76	26
23-Dec-22	50	73	23
24-Dec-22	50	65	15
25-Dec-22	50	80	30
26-Dec-22	50	73	23
27-Dec-22	50	78	28
28-Dec-22	50	78	28
29-Dec-22	50	80	30
30-Dec-22	50	72	22
31-Dec-22	50	72	22

Berdasarkan hasil pengumpulan data waktu pempusukan dimsum, diketahui bahwa adanya perubahan ketahanan dimsum dalam pempusukan. Pada dimsum dengan ikan yang tidak dikeringkan, waktu pempusukan cenderung stabil yaitu 50 jam dari pengemasan dilakukan. Sedangkan pada dimsum ikan yang dikeringkan, waktu pempusukan cenderung lebih lama yaitu 65-80 jam dari pengemasan dilakukan.

4.1.4 Suhu Lingkungan

Pada pengumpulan data uji coba, terdapat variabel pendukung dalam uji coba tersebut. Salah satunya adalah suhu lingkungan saat pengambilan data karena suhu merupakan hal yang cukup berpengaruh dalam proses perkembangan mikroba penyebab pempusukan. Berikut adalah data suhu lingkungan yang diperoleh dari database Badan Meteorologi, Klimatologi dan Geofisika (BMKG) :

Tabel 4. Data Suhu Lingkungan

Tanggal	Suhu Ruangan (°C)
1-Nov-22	28,2
2-Nov-22	27,3
3-Nov-22	27,6
4-Nov-22	28,7
5-Nov-22	26,4
6-Nov-22	27,8
7-Nov-22	27,5
8-Nov-22	26,7
9-Nov-22	26,4
10-Nov-22	27,4
11-Nov-22	26,9
12-Nov-22	27,3
13-Nov-22	26,1
14-Nov-22	27,7
15-Nov-22	27,5
16-Nov-22	27,9
17-Nov-22	25,6
18-Nov-22	28,1
19-Nov-22	28,1
20-Nov-22	27,9
21-Nov-22	27,2
22-Nov-22	27,2
23-Nov-22	28,5
24-Nov-22	27,8
25-Nov-22	27,4
26-Nov-22	28,4
27-Nov-22	28,1
28-Nov-22	27,3
29-Nov-22	29,2
30-Nov-22	29,3
1-Dec-22	28,9
2-Dec-22	27,8
3-Dec-22	27,4
4-Dec-22	28,2
5-Dec-22	27
6-Dec-22	28,1
7-Dec-22	28,1
8-Dec-22	28,4
9-Dec-22	25,9

(Sumber: BMKG, 2022)

Tabel 4. Data Suhu Lingkungan (Lanjutan)

<u>Tanggal</u>	<u>Suhu Ruangan (°C)</u>
10-Dec-22	29
11-Dec-22	26,6
12-Dec-22	27
13-Dec-22	27,2
14-Dec-22	28,2
15-Dec-22	29,3
16-Dec-22	27
17-Dec-22	29,2
18-Dec-22	28,9
19-Dec-22	28,7
20-Dec-22	27
21-Dec-22	26,8
22-Dec-22	28
23-Dec-22	27,4
24-Dec-22	28,2
25-Dec-22	26
26-Dec-22	26,2
27-Dec-22	24,5
28-Dec-22	24,3
29-Dec-22	26
30-Dec-22	25,6
31-Dec-22	26

(Sumber: BMKG, 2022)

Data pada Tabel 4 merupakan data suhu yang berasal dari *database* BMKG pada daerah Kecamatan Citangkil, Kota Cilegon dimana lokasi UPI D’Kriwil berada. Data suhu lingkungan yang digunakan merupakan data suhu harian rata-rata pada bulan November-Desember 2022. Pada data tersebut dapat dilihat bahwa setiap harinya terjadi perubahan suhu yang menyebabkan pengurangan kadar air pada ikan tunul tiap harinya berbeda pula.

4.1.5 Kelembaban Lingkungan

Selain data suhu lingkungan yang berpengaruh dalam pembusukan, ukuran kelembaban udara juga menjadi salah satu faktor yang berpengaruh dalam perkembangan mikroba pembusukan. Berikut adalah data kelembaban lingkungan yang diperoleh dari *database* Badan Meteorologi, Klimatologi dan Geofisika (BMKG) :

Tabel 5. Kelembaban Udara Lingkungan Periode November-Desember 2022

Tanggal	Kelembaban Udara (%)
1-Nov-22	76
2-Nov-22	80
3-Nov-22	84
4-Nov-22	75
5-Nov-22	88
6-Nov-22	80
7-Nov-22	82
8-Nov-22	85
9-Nov-22	83
10-Nov-22	82
11-Nov-22	84
12-Nov-22	82
13-Nov-22	89
14-Nov-22	81
15-Nov-22	79
16-Nov-22	80
17-Nov-22	88
18-Nov-22	74
19-Nov-22	76
20-Nov-22	77
21-Nov-22	77
22-Nov-22	79
23-Nov-22	75
24-Nov-22	78
25-Nov-22	78
26-Nov-22	77
27-Nov-22	74
28-Nov-22	81
29-Nov-22	70
30-Nov-22	65
1-Dec-22	72
2-Dec-22	74
3-Dec-22	82
4-Dec-22	76
5-Dec-22	81
6-Dec-22	78
7-Dec-22	78
8-Dec-22	78
9-Dec-22	86

(Sumber: BMKG, 2022)

**Tabel 5. Kelembaban Udara Lingkungan Periode November-Desember 2022
(Lanjutan)**

Tanggal	Kelembaban Udara (%)
10-Dec-22	72
11-Dec-22	82
12-Dec-22	82
13-Dec-22	80
14-Dec-22	76
15-Dec-22	65
16-Dec-22	84
17-Dec-22	72
18-Dec-22	73
19-Dec-22	75
20-Dec-22	81
21-Dec-22	86
22-Dec-22	78
23-Dec-22	78
24-Dec-22	76
25-Dec-22	90
26-Dec-22	90
27-Dec-22	88
28-Dec-22	91
29-Dec-22	83
30-Dec-22	91
31-Dec-22	85

(Sumber: BMKG, 2022)

Data pada Tabel 5 merupakan data kelembaban yang berasal dari *database* BMKG pada daerah Citangkil, Cilegon dimana lokasi UPI D’Kriwil berada. Data suhu lingkungan yang digunakan merupakan data kelembaban udara rata-rata pada bulan November-Desember 2022. Pada data tersebut dapat dilihat bahwa setiap harinya terjadi perubahan kelembaban udara sesuai dengan suhu lingkungan yang menyebabkan pengurangan kadar air pada ikan tunul tiap harinya berbeda pula.

4.2 Pengolahan Data

Pada penelitian prediksi kandungan air dalam bahan baku ikan tunul, dilakukan pengolahan data dengan tahapan yaitu melakukan normalisasi data, membuat arsitektur jaringan saraf dengan *hidden layer* yang berbeda, melakukan *training data* dan uji validasi hasil *training*, menentukan bobot tiap *hidden layer* dan melakukan prediksi terhadap hasil *training data* dengan MSE terkecil.

4.2.1 Normalisasi Data

Pada penentuan prediksi kadar air pada ikan tunul, dilakukan normalisasi data untuk menyetarakan nilai dari tiap variabel yang memiliki satuan dan nilai yang berbeda satu sama lain. Variabel yang dinormalisasikan datanya meliputi berat kotor (X_1), berat setelah dikeringkan selama 2 jam (X_2), selisih waktu pembusukan (X_3), suhu ruangan (X_4), kelembaban udara (X_5) dan jumlah berat yang berkurang setelah pengeringan (Y). Berikut ini adalah hasil normalisasi data yang dilakukan pada variabel penelitian :

Tabel 6. Hasil Normalisasi Data

Berat Kotor (kg) (X_1)	Berat Setelah Dikeringkan 2 jam (kg) (X_2)	Selisih Waktu Pembusukan (X_3)	Suhu Ruangan ($^{\circ}\text{C}$) (X_4)	Kelembaban Udara (%) (X_5)	Jumlah Berat yang Berkurang Setelah Pengeringan (kg) (Y)
0,5	0,78	0,214	0,724	0,438	0,257
0,9	0,42	0,595	0,580	0,562	0,654
0,1	0,35	0,595	0,628	0,685	0,647
0,26	0,45	0,519	0,804	0,408	0,560
0,34	0,77	0,367	0,436	0,808	0,248
0,18	0,35	0,595	0,660	0,562	0,655
0,18	0,79	0,214	0,612	0,623	0,218
0,26	0,48	0,519	0,484	0,715	0,538
0,26	0,48	0,519	0,436	0,654	0,530
0,22	0,22	0,824	0,596	0,623	0,792
0,252	0,49	0,519	0,516	0,685	0,526
0,1	0,88	0,100	0,580	0,623	0,121
0,1	0,63	0,405	0,388	0,838	0,366
0,14	0,18	0,824	0,644	0,592	0,822
0,1	0,57	0,481	0,612	0,531	0,432
0,1	0,33	0,595	0,676	0,562	0,665
0,1	0,40	0,519	0,308	0,808	0,604
0,124	0,90	0,100	0,708	0,377	0,100
0,18	0,81	0,214	0,708	0,438	0,199
0,1	0,36	0,595	0,676	0,469	0,639
0,1	0,21	0,824	0,564	0,469	0,792
0,1	0,43	0,595	0,564	0,531	0,569
0,1	0,56	0,481	0,772	0,408	0,435
0,1	0,85	0,100	0,660	0,500	0,152
0,1	0,29	0,671	0,596	0,500	0,714
0,148	0,84	0,214	0,756	0,469	0,164

Tabel 6. Hasil Normalisasi Data (Lanjutan)

Berat Kotor (kg) (X ₁)	Berat Setelah Dikeringkan 2 jam (kg) (X ₂)	Selisih Waktu Pembersukan (X ₃)	Suhu Ruangan (°C) (X ₄)	Kelembaban Udara (%) (X ₅)	Jumlah Berat yang Berkurang Setelah Pengeringan (kg) (Y)
0,116	0,42	0,595	0,708	0,377	0,584
0,148	0,71	0,367	0,580	0,592	0,296
0,124	0,17	0,824	0,884	0,254	0,830
0,18	0,25	0,671	0,900	0,100	0,754
0,14	0,28	0,671	0,836	0,315	0,719
0,1	0,58	0,481	0,660	0,377	0,417
0,26	0,65	0,405	0,596	0,623	0,362
0,1	0,82	0,367	0,724	0,438	0,174
0,1	0,43	0,519	0,532	0,592	0,564
0,38	0,34	0,595	0,708	0,500	0,686
0,108	0,60	0,481	0,708	0,500	0,398
0,1	0,21	0,824	0,756	0,500	0,790
0,1	0,24	0,671	0,356	0,746	0,760
0,1	0,48	0,519	0,852	0,315	0,522
0,1	0,33	0,671	0,468	0,623	0,669
0,22	0,65	0,405	0,532	0,623	0,360
0,148	0,24	0,671	0,564	0,562	0,761
0,132	0,74	0,367	0,724	0,438	0,256
0,156	0,17	0,824	0,900	0,100	0,837
0,1	0,51	0,519	0,532	0,685	0,485
0,116	0,83	0,214	0,884	0,315	0,166
0,284	0,62	0,481	0,836	0,346	0,392
0,1	0,41	0,519	0,804	0,408	0,586
0,1	0,10	0,900	0,532	0,592	0,900
0,1	0,24	0,671	0,500	0,746	0,758
0,1	0,52	0,519	0,692	0,500	0,481
0,108	0,63	0,405	0,596	0,500	0,368
0,156	0,88	0,100	0,724	0,438	0,124
0,26	0,27	0,671	0,372	0,869	0,744
0,1	0,68	0,405	0,404	0,869	0,317
0,1	0,32	0,595	0,132	0,808	0,684
0,14	0,36	0,595	0,100	0,900	0,644
0,18	0,26	0,671	0,372	0,654	0,743
0,172	0,75	0,367	0,308	0,900	0,256
0,172	0,72	0,367	0,372	0,715	0,288

Contoh Perhitungan:

$$\begin{aligned} X' &= \frac{0,8(X - \text{Min}(X))}{\text{Max}(X) - \text{Min}(X)} + 0,1 \\ &= \frac{0,8(10,05-10)}{10,1-10} + 0,1 \\ &= \frac{0,04}{0,1} + 0,1 = 0,5 \text{ (Berat kotor)} \end{aligned}$$

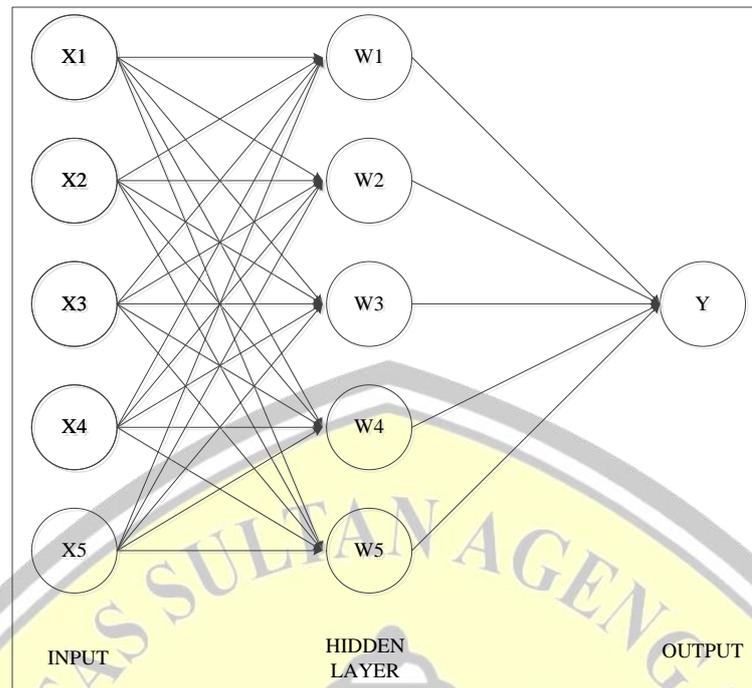
Berdasarkan tabel 6, dihasilkan nilai normalisasi dari tiap variabel. Nilai normalisasi yang dihasilkan pada variabel X_1, X_2, X_3, X_4, X_5 dan Y memiliki nilai terkecil 0,1 dan terbesar 0,9. Nilai maksimum dan minimum pada perhitungan didapatkan dari *raw data* Tabel 2. sampai Tabel 5.

4.2.2 Arsitektur Model *Artificial Neural Network* (ANN)

Pada penelitian dengan metode ANN ini, arsitektur digunakan untuk menggambarkan struktur jaringan yang diimplementasikan pada model pemrograman Matlab. Arsitektur yang digambarkan terdiri dari neuron (*input*) yang berjumlah 5 yang sesuai dengan variabel yang digunakan, *hidden layer* yang berjumlah sesuai kelipatan variabel yaitu 5, 10 dan 15 serta jumlah *output* yang diinginkan. Berikut ini adalah 3 model arsitektur yang digunakan dalam penelitian ini :

a. Model arsitektur 5 *hidden layer*

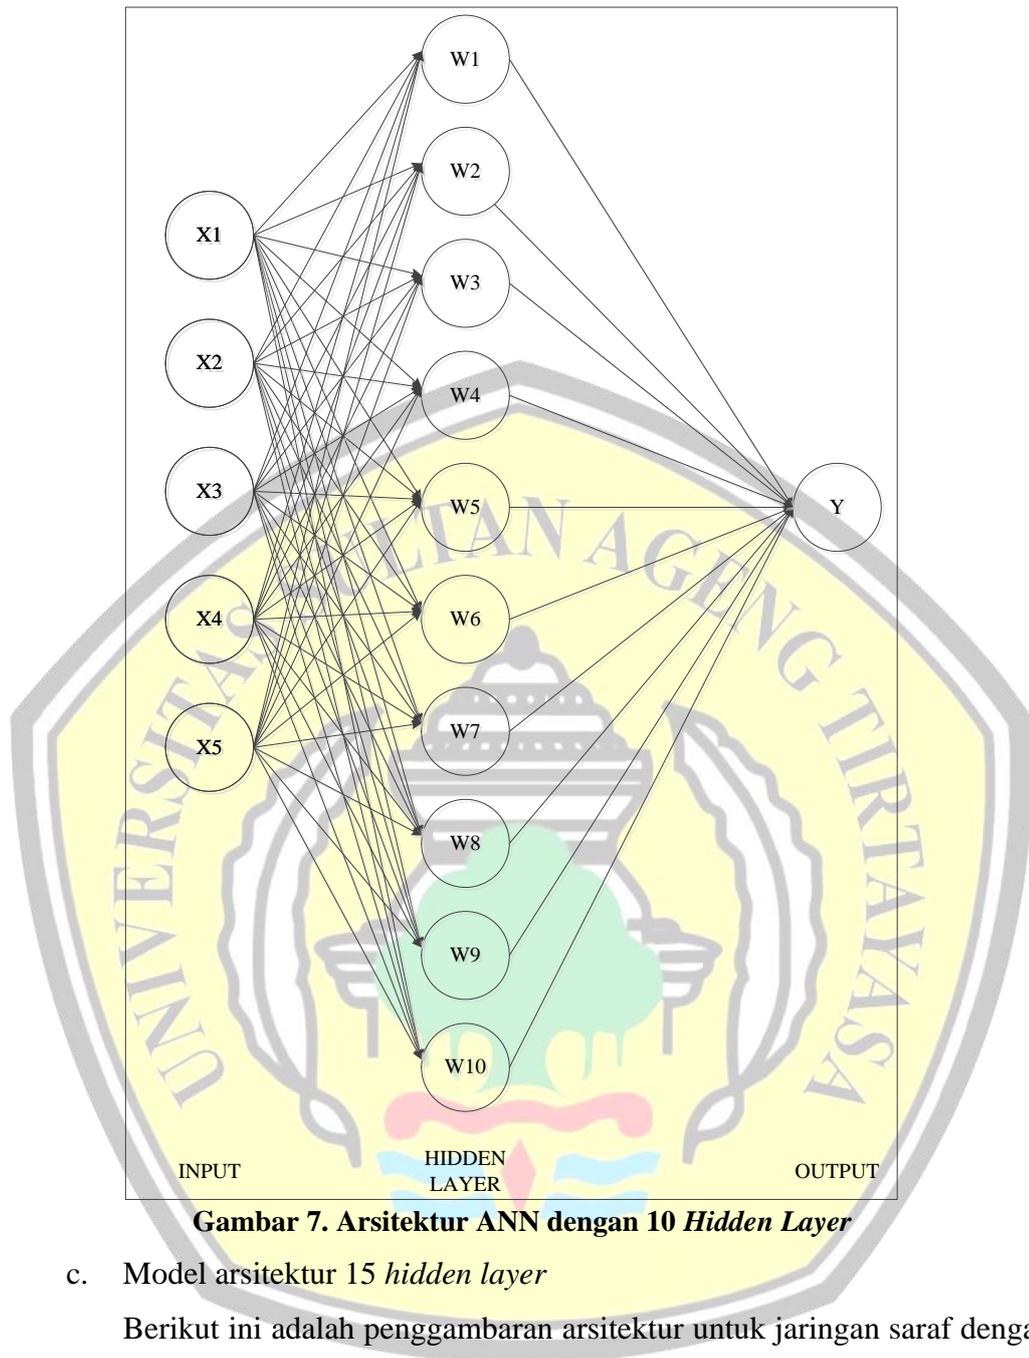
Berikut ini adalah penggambaran arsitektur untuk jaringan saraf dengan 5 *hidden layer*.



Gambar 6. Arsitektur ANN dengan 5 Hidden Layer

b. Model arsitektur 10 hidden layer

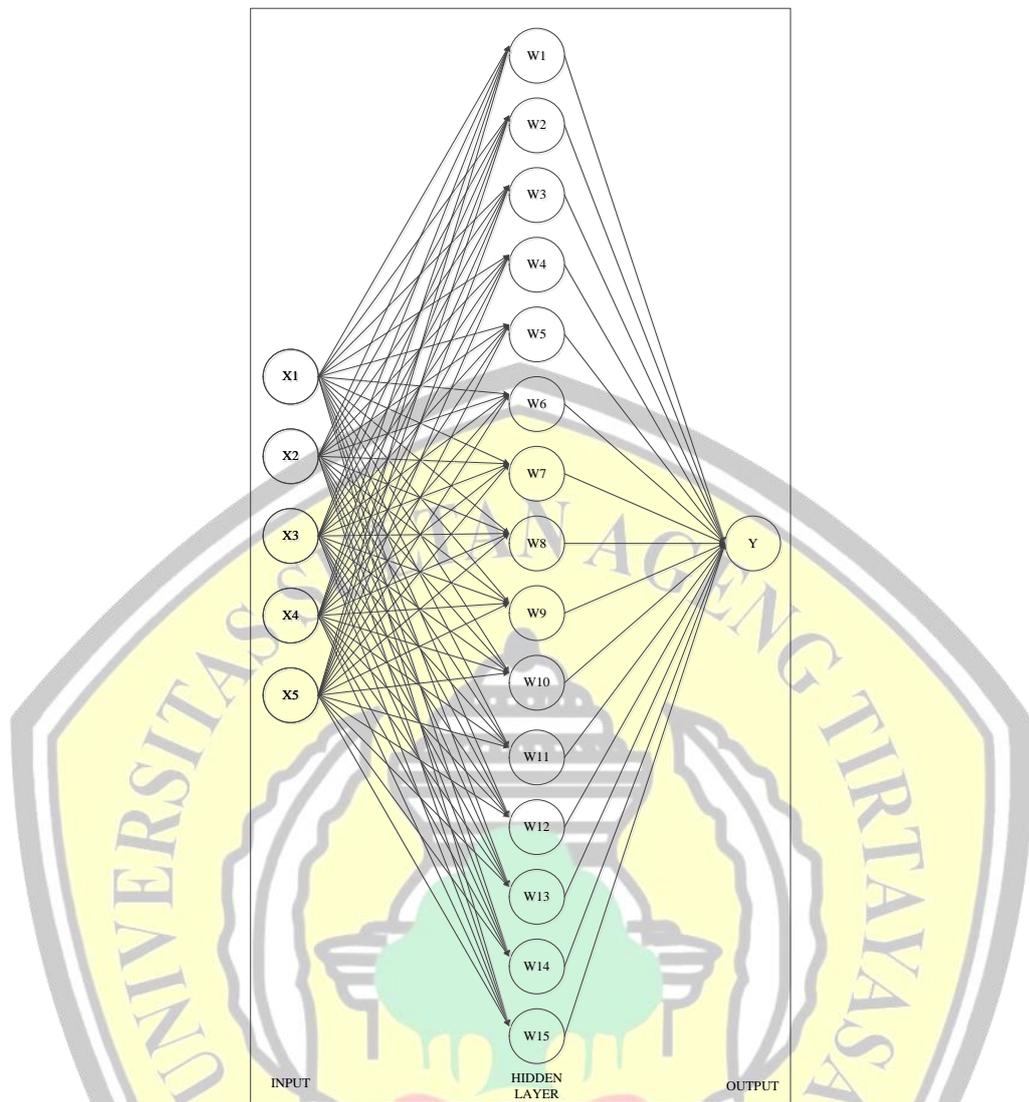
Berikut ini adalah penggambaran arsitektur untuk jaringan saraf dengan 10 hidden layer.



Gambar 7. Arsitektur ANN dengan 10 Hidden Layer

c. Model arsitektur 15 hidden layer

Berikut ini adalah penggambaran arsitektur untuk jaringan saraf dengan 15 hidden layer.



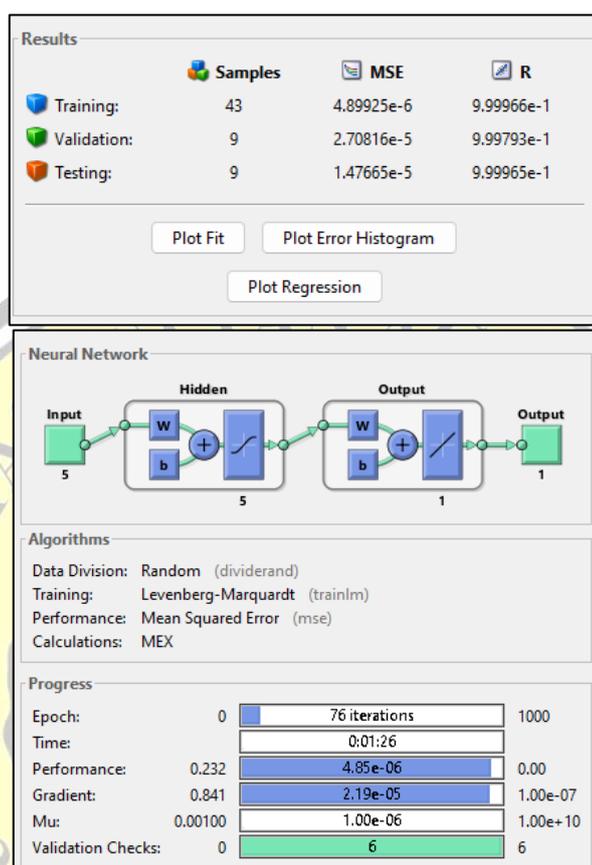
Gambar 8. Arsitektur ANN dengan 15 Hidden Layer

4.2.3 Artificial Neural Network dengan Algoritma Backpropagation dengan Matlab

Setelah dilakukan penggambaran arsitektur ANN maka sudah ditentukan variabel yang menjadi *input*, *layer*, *hidden layer* dan *output/target*. Kemudian dilakukan *training data* yang sudah dinormalisasi dengan *software* Matlab. Berikut ini adalah hasil dari *training data* menggunakan *software* Matlab dengan 3 macam *hidden layer* yang berbeda.

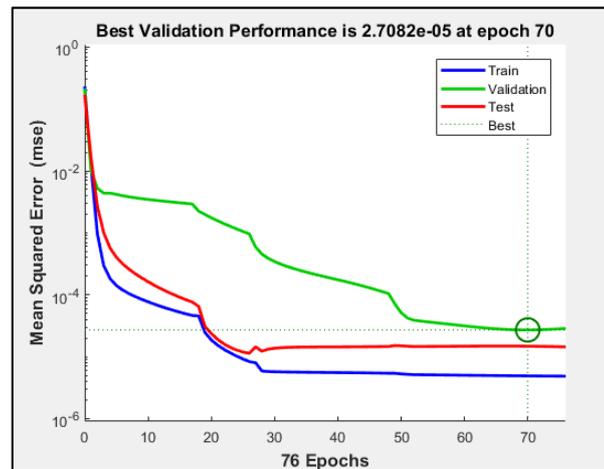
4.2.3.1 Hasil *Training Data* dengan 5 *Hidden Layer*

Pada proses *training data* ini, akan didapatkan *error* yang dihasilkan dari *training data* yang dibandingkan dengan data yang didapatkan, performansi hasil *training*, uji validasi data hasil *training* dan besaran bobot tiap *hidden layer*.



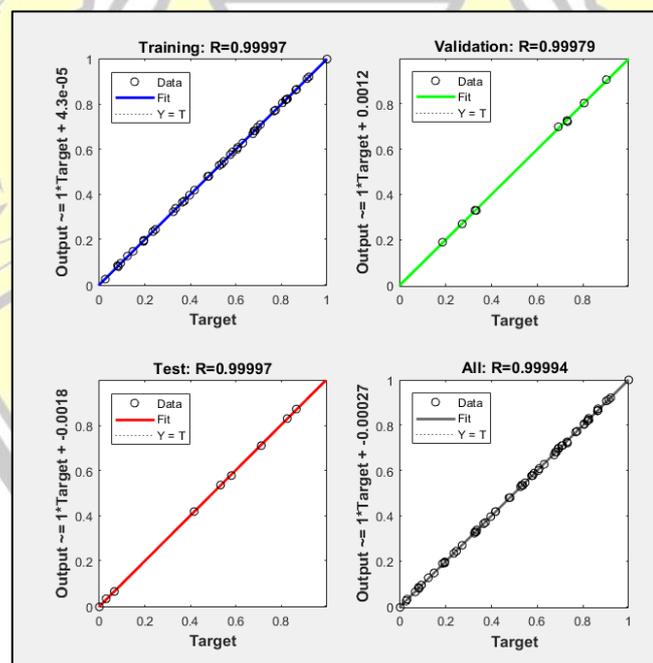
Gambar 9. Hasil *Training Data* dengan 5 *Hidden Layer*

Berdasarkan gambar 9., diketahui bahwasanya setelah dilakukan *training data* pada sampel sebanyak 70% atau 43 data. Adapun hasil uji validasi terhadap sample data 10% atau 6 data yang menghasilkan nilai koefisien korelasi *Pearson R* sebesar 0,99 dimana nilai tersebut mendekati sempurna atau angka 1.



Gambar 10. Grafik Performansi 5 Hidden Layer

Setelah mendapatkan nilai *error* MSE yang didapatkan pada *training data*, dapat dilihat pula grafik performansi hasil *training* yang menunjukkan bahwa performansi terbaik data berada pada *epoch* ke-70 dari 76 *epoch*. Pada grafik juga dapat dilihat bahwasanya tidak ada fenomena *overfitting* karena grafik training memiliki nilai yang jauh dibawah garis grafik validasi.



Gambar 11. Grafik Uji Validasi Hasil Training 5 Hidden Layer

Pada grafik gambar 11., seperti yang sudah dijelaskan sebelumnya bahwa hasil data *training* menunjukkan bahwa performansi terbaik berada mendekati garis *training data* yang asli. Berdasarkan hal tersebut, dapat dikaitkan bahwa jika

performansi terbaik data berada berdekatan dengan garis *training data* maka tingkat validasi mendekati nilai terbaik. Pada grafik gambar 9, ditunjukkan bahwa nilai R untuk uji validasi didapatkan 1 yang artinya hasil data *training* memiliki hasil yang sangat mendekati data aslinya sehingga dapat dinyatakan tidak ada fenomena *underfitting*.

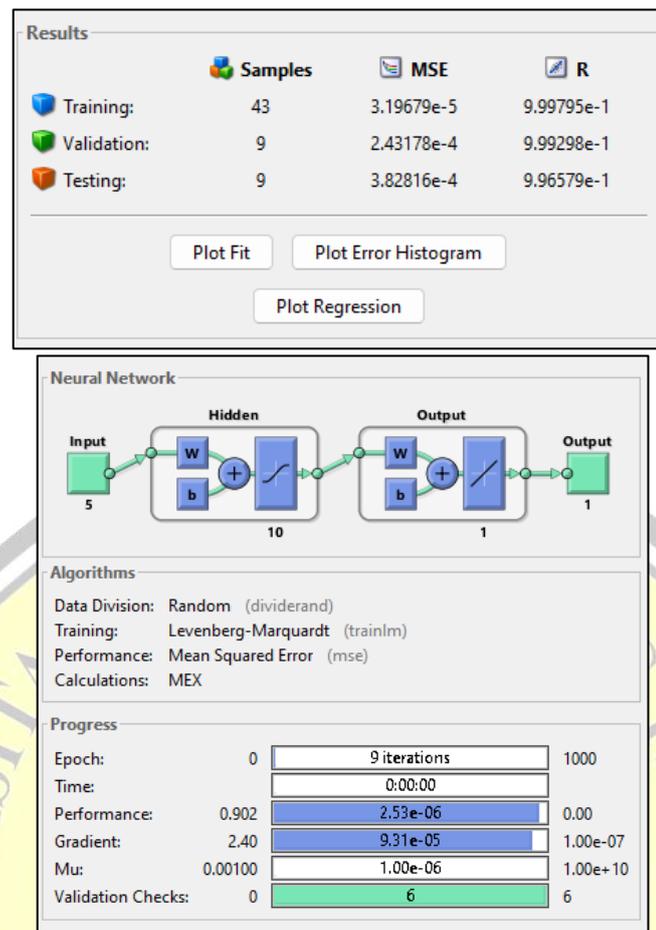
Tabel 7. Bobot Pada Training Data 5 Hidden Layer

<i>Layer</i>	<i>Hidden layer</i>	Bobot
1	1	0,534
	2	0,103
	3	0,027
	4	0,1
	5	0,036

Setelah didapatkan hasil *error* MSE dan validasi terhadap hasil *training data*, didapatkan pula bobot yang menjadi komponen hasil *training data* yang terdapat pada setiap *hidden layer*. Terdapat 5 bobot yang berbeda pada tiap *layer* dengan total 5 bobot yang menjadi variabel pengaruh dalam *training data*.

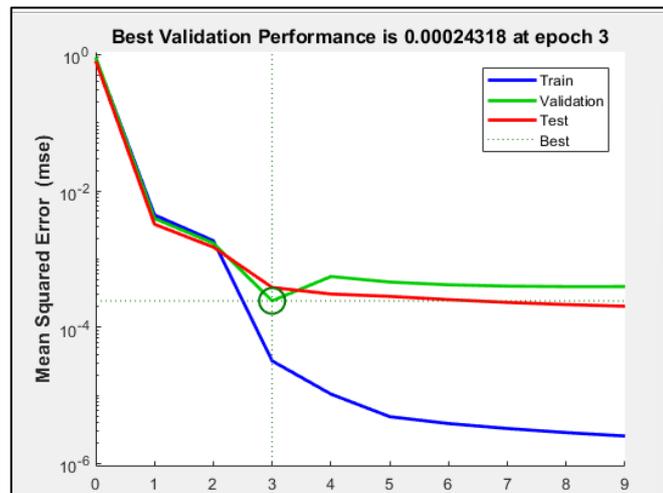
4.2.3.2 Hasil Training Data dengan 10 Hidden Layer

Pada proses *training data* ini, akan didapatkan *error* yang dihasilkan dari *training data* yang dibandingkan dengan data yang didapatkan, performansi hasil *training*, uji validasi data hasil *training* dan besaran bobot tiap *hidden layer*.



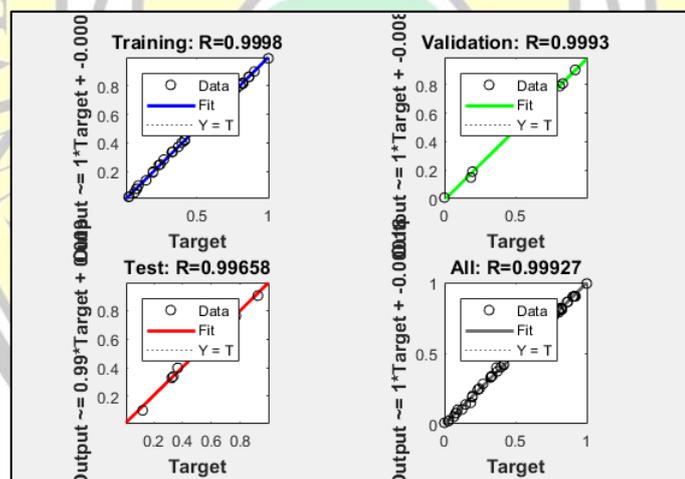
Gambar 12. Hasil Training Data dengan 10 Hidden layer

Berdasarkan gambar 12., diketahui bahwasanya setelah dilakukan *training data* pada sampel sebanyak 70% atau 43 data. Adapun hasil uji validasi terhadap sample data 10% atau 6 data yang menghasilkan nilai koefisien korelasi *Pearson R* sebesar 0,99 dimana nilai tersebut mendekati sempurna atau angka 1.



Gambar 13. Grafik Performansi 10 Hidden Layer

Setelah mendapatkan nilai *error* MSE yang didapatkan pada *training data*, dapat dilihat pula grafik performansi hasil *training* yang menunjukkan bahwa performansi terbaik data berada pada *epoch* ke-3 dari 9 *epoch*. Pada grafik juga dapat dilihat bahwasanya performansi data terbaik berada tidak jauh dari *training data*. Pada grafik juga dapat dilihat bahwasanya tidak ada fenomena *overfitting* karena grafik *training* memiliki nilai yang jauh dibawah garis grafik validasi.



Gambar 14. Grafik Uji Validasi Hasil Training 10 Hidden Layer

Pada grafik gambar 14. seperti yang sudah dijelaskan sebelumnya bahwa hasil data *training* menunjukkan bahwa performansi terbaik berada mendekati garis *training data* yang asli. Berdasarkan hal tersebut, dapat dikaitkan bahwa jika performansi terbaik data berada berdekatan dengan garis *training data* maka tingkat validasi mendekati nilai terbaik. Pada grafik gambar 12, ditunjukkan bahwa nilai R

untuk uji validasi didapatkan 0.99911 yang artinya hasil data *training* memiliki hasil yang mendekati data aslinya sehingga dapat dinyatakan tidak ada fenomena *underfitting*.

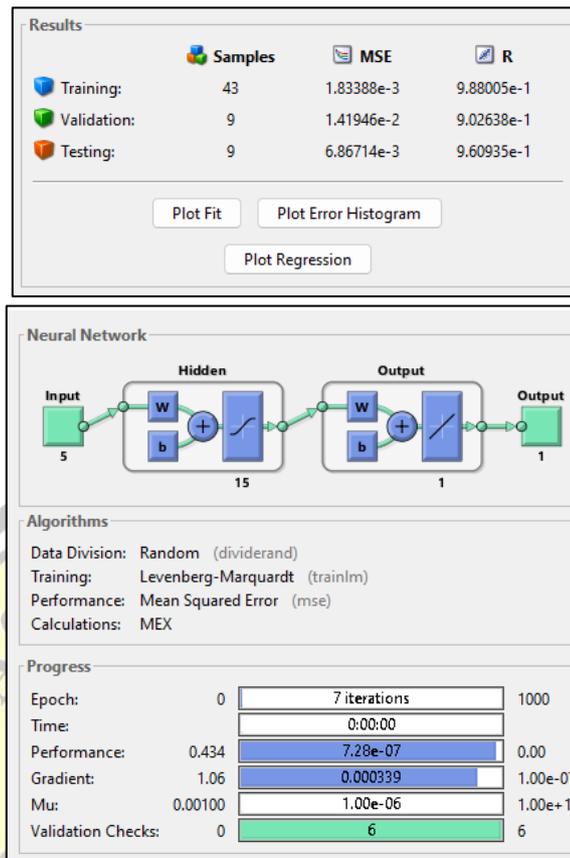
Tabel 8. Bobot Pada Training Data 10 Hidden Layer

<i>Layer</i>	<i>Hidden layer</i>	Bobot
1	1	0,398
	2	0,204
	3	0,229
	4	0,175
	5	0,262
	6	0,006
	7	0,399
	8	0,331
	9	0,447
	10	0,266

Setelah didapatkan hasil *error* MSE dan validasi terhadap hasil *training data*, didapatkan pula bobot yang menjadi komponen hasil *training data* yang terdapat pada setiap *hidden layer*. Terdapat 10 bobot yang berbeda pada tiap *layer* dengan total 10 bobot yang menjadi variabel pengaruh dalam *training data*.

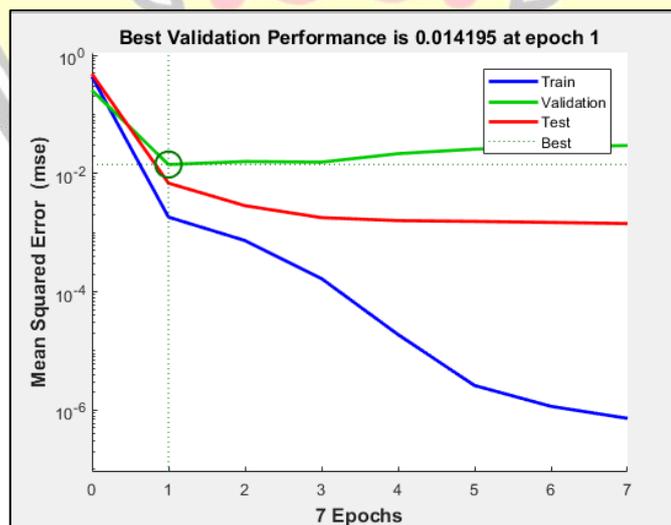
4.2.3.3 Hasil Training Data dengan 15 Hidden Layer

Pada proses *training data* ini, akan didapatkan *error* yang dihasilkan dari *training data* yang dibandingkan dengan data yang didapatkan, performansi hasil *training*, uji validasi data hasil *training* dan besaran bobot tiap *hidden layer*.



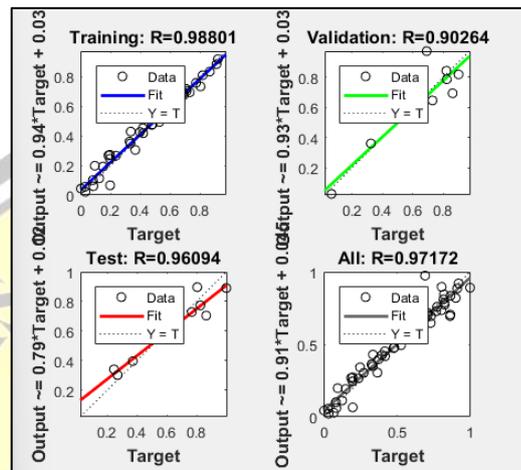
Gambar 15. Hasil Training Data dengan 15 Hidden Layer

Berdasarkan gambar 15., diketahui bahwasanya setelah dilakukan *training data* pada sampel sebanyak 70% atau 43 data. Adapun hasil uji validasi terhadap sample data 10% atau 6 data yang menghasilkan nilai koefisien korelasi *Pearson R* sebesar 0,99 dimana nilai tersebut mendekati sempurna atau angka 1.



Gambar 16. Grafik Performansi 15 Hidden Layer

Setelah mendapatkan nilai *error* MSE yang didapatkan pada *training data*, dapat dilihat pula grafik performansi hasil *training* yang menunjukkan bahwa performansi terbaik data berada pada *epoch* ke-1 dari 7 *epoch*. Pada grafik juga dapat dilihat bahwasanya performansi data terbaik berada jauh dari *training data*. Pada grafik juga dapat dilihat bahwasanya tidak ada fenomena *overfitting* karena grafik *training* memiliki nilai yang jauh dibawah garis grafik validasi.



Gambar 17. Grafik Uji Validasi Hasil Training 15 Hidden Layer

Pada grafik gambar 17., seperti yang sudah dijelaskan sebelumnya bahwa hasil data *training* menunjukkan bahwa performansi terbaik berada jauh diatas garis *training data* yang asli. Berdasarkan hal tersebut, dapat dikaitkan bahwa jika performansi terbaik data berada berdekatan dengan garis *training data* maka tingkat validasi mendekati nilai terbaik. Pada grafik gambar 15, ditunjukkan bahwa nilai R untuk uji validasi didapatkan 0,99981 yang artinya hasil data *training* memiliki hasil yang mendekati data aslinya sehingga dapat dinyatakan tidak ada fenomena *underfitting*.

Tabel 9. Bobot Pada Training Data 15 Hidden Layer

Layer	Hidden Layer	Bobot
1	1	0,157
	2	0,365
	3	0,504
	4	0,574
	5	0,051
	6	0,088
	7	0,453
	8	0,575

Tabel 9. Bobot Pada Training Data 15 Hidden Layer

Layer	Hidden Layer	Bobot
	9	0,504
	10	0,473
	11	0,624
1	12	0,049
	13	0,447
	14	0,3
	15	0,1

Setelah didapatkan hasil *error* MSE dan validasi terhadap hasil *training data*, didapatkan pula bobot yang menjadi komponen hasil *training data* yang terdapat pada setiap *hidden layer*. Terdapat 15 bobot yang berbeda pada *layer* yang menjadi variabel pengaruh dalam *training data*.

4.2.4 Prediksi Kadar Air Pada Ikan Tunul

Dengan menggunakan model *artificial neural network* terpilih yaitu model dengan *error* MSE terendah pada model dengan 5 *hidden layer*. Prediksi kadar air dihasilkan menggunakan aplikasi Matlab yang diselesaikan menggunakan coding *backpropagation* sebagai berikut:

```
%input data
filename_input = 'Input ANN (Normalisasi).xlsx';
input_data = xlsread(filename_input);
filename_output = 'Target After Normalisasi.xlsx';
output_data = xlsread(filename_output);

% Inisialisasi parameter jaringan
input_neurons = size(input_data, 2);
hidden_neurons = 15; % Jumlah neuron pada lapisan tersembunyi
output_neurons = 1;
learning_rate = 0.1;
epochs = 1000;

% Inisialisasi bobot dan bias secara acak
hidden_weights = rand(input_neurons, hidden_neurons);
hidden_bias = rand(1, hidden_neurons);
output_weights = rand(hidden_neurons, output_neurons);
output_bias = rand(1, output_neurons);

% Training jaringan menggunakan metode backpropagation
for epoch = 1:epochs

    % Forward propagation
    hidden_layer_input = input_data * hidden_weights +
repmat(hidden_bias, size(input_data, 1), 1);
```

```

hidden_layer_output = 1 ./ (1 + exp(-hidden_layer_input)); %
Fungsi aktivasi sigmoid biner

output_layer_input = hidden_layer_output * output_weights +
repmat(output_bias, size(input_data, 1), 1);
predicted_output = 1 ./ (1 + exp(-output_layer_input)); %
Fungsi aktivasi sigmoid biner

% Menghitung error
error = output_data - predicted_output;

% Backpropagation
d_predicted_output = error .* (predicted_output .* (1 -
predicted_output));
error_hidden_layer = d_predicted_output * output_weights';
d_hidden_layer = error_hidden_layer .* (hidden_layer_output .*
(1 - hidden_layer_output));

% Update bobot dan bias
output_weights = output_weights + hidden_layer_output' *
d_predicted_output * learning_rate;
output_bias = output_bias + sum(d_predicted_output) *
learning_rate;
hidden_weights = hidden_weights + input_data' * d_hidden_layer
* learning_rate;
hidden_bias = hidden_bias + sum(d_hidden_layer) *
learning_rate;
end

% Prediksi menggunakan jaringan yang telah dilatih
hidden_layer_input = input_data * hidden_weights +
repmat(hidden_bias, size(input_data, 1), 1);
hidden_layer_output = 1 ./ (1 + exp(-hidden_layer_input));

output_layer_input = hidden_layer_output * output_weights +
repmat(output_bias, size(input_data, 1), 1);
predicted_output = 1 ./ (1 + exp(-output_layer_input));

disp("Hasil Prediksi:");
disp(predicted_output);

%Menghitung nilai Error MSE hasil prediksi
MSE = sum((output_data - predicted_output).^2) /
numel(output_data);
disp("Nilai Error (MSE):");
disp(MSE);

```

Berdasarkan hasil *coding* pada *software* Matlab, didapatkan prediksi dengan MSE terkecil pada model ANN dengan jumlah 15 hidden *layer* dan pada iterasi 1. Maka hasil prediksi kadar air pada ikan tunul untuk periode Januari 2023 dapat dilihat pada Tabel 10.

Tabel 10. Hasil Prediksi dan Denormalisasi Data

Tanggal	Prediksi Jumlah Berat yang Berkurang Setelah Pengeringan (Y')	Denormalisasi (Kg)
1-Jan-23	0,218	0,228
2-Jan-23	0,663	0,617
3-Jan-23	0,652	0,607
4-Jan-23	0,551	0,519
5-Jan-23	0,263	0,268
6-Jan-23	0,658	0,612
7-Jan-23	0,197	0,211
8-Jan-23	0,538	0,508
9-Jan-23	0,530	0,501
10-Jan-23	0,812	0,747
11-Jan-23	0,528	0,499
12-Jan-23	0,134	0,156
13-Jan-23	0,354	0,347
14-Jan-23	0,823	0,756
15-Jan-23	0,432	0,415
16-Jan-23	0,663	0,617
17-Jan-23	0,588	0,551
18-Jan-23	0,126	0,148
19-Jan-23	0,186	0,201
20-Jan-23	0,643	0,599
21-Jan-23	0,808	0,743
22-Jan-23	0,592	0,554
23-Jan-23	0,431	0,415
24-Jan-23	0,143	0,163
25-Jan-23	0,722	0,668
26-Jan-23	0,172	0,188
27-Jan-23	0,602	0,563
28-Jan-23	0,288	0,289
29-Jan-23	0,823	0,756
30-Jan-23	0,743	0,686
31-Jan-23	0,724	0,670

Berdasarkan tabel 10, didapatkan hasil prediksi kadar air pada ikan tunul dalam bentuk prediksi jumlah air yang harus dikurangi pada saat bahan baku ikan tunul dilakukan proses penjemuran. Kemudian dilakukan terhadap MSE yang diperoleh dari hasil prediksi yang dibandingkan dengan aktual yang dapat dilihat pada variabel Y Tabel 2., sebagai berikut :

$$MSE = \frac{\sum (Aktual - Prediksi)^2}{n-1}$$

$$MSE = \frac{\sum (0,257-0,218)^2 + \dots + (0,288-0,724)^2}{31-1}$$

$$MSE = 0,000198$$

Prediksi yang dilakukan berdasarkan model ANN yang memiliki *error* MSE terendah yaitu model dengan 15 *hidden layer* sebesar 0,000198. Berdasarkan hasil prediksi pula, diketahui bahwasanya untuk mencapai kualitas yang baik sesuai dengan keinginan produsen kadar air pada ikan tunul harus dikurangi minimal sebesar 0,148 kg dan maksimal 0,756 kg.



BAB V

ANALISA DAN PEMBAHASAN

5.1 Analisa Hasil *Training Data* Menggunakan Metode *Artificial Neural Network Backpropagation*

Penelitian yang dilakukan pada UMKM D’Kriwil menggunakan hasil training data metode *Artificial Neural Network (ANN) Backpropagation* pada pemrograman Matlab. Metode ANN dengan *backpropagation* merupakan metode yang biasa digunakan dalam melakukan prediksi dan klasifikasi suatu data yang tidak memiliki pola. Digunakannya metode ANN *backpropagation* ini searah dengan tujuan utama penelitian yaitu untuk mengetahui prediksi kadar air pada bahan baku ikan tunul pada periode Bulan Januari 2023. Terdapat beberapa sebab penggunaan metode ANN dibandingkan dengan penggunaan metode lainnya dalam melakukan prediksi, diantaranya metode ini cocok digunakan untuk sistem-sistem data dengan kompleksitas permasalahan yang rumit, cenderung adaptif dalam mempelajari sebuah data sampai menghasilkan solusi, dan mampu melakukan generalisasi data (Ripley, 2017). Dalam melakukan prediksi terdapat tahapan inti dalam mendapatkan hasil peramalan. Salah satu tahapan inti adalah *training data*. *Training data* dilakukan untuk mengetahui pola data dan nilai keakuratan pada alternatif peramalan (Saluza dkk, 2023).

Tahapan *training data* dimulai dengan melakukan normalisasi data *input* sehingga besarnya nilai *input* memiliki rentang serupa. Kemudian dilakukan inisialisasi bobot dan bias tiap *hidden layer* yang sudah ditentukan saat pembuatan arsitektur ANN. Menurut Supriyanto, Sunardi dan Riadi (2022), penentuan jumlah *hidden layer* mempunyai pengaruh cukup besar dalam ekstraksi data *input* sehingga pola data terdefinisi. Salah satu cara penentuan jumlah *hidden layer* yang efektif adalah menggunakan jumlah kelipatan data input. Cara tersebut akan menghasilkan pola dengan waktu training cenderung lebih singkat karena jaringan mempelajari pola melalui jumlah *hidden layer* yang memiliki nilai kelipatan jumlah variabel. Oleh karena itu, pada penelitian ini digunakan jumlah *hidden layer* berdasarkan kelipatan jumlah variabel input yaitu 5, 10 dan 15. Dalam tahap inisiasi bobot dan

bias, dilakukan penentuan komposisi pembagian data untuk melalui *tahap training*, validasi dan *testing*. Menurut Aggarwal (2019), penentuan komposisi pembagian *sample data* tidak memiliki aturan yang mutlak. Umumnya penentuan komposisi pembagian *sample data* untuk *training sample* yang digunakan sebesar 70-90% dari jumlah data *input* dengan sisa persentase 30-10% dibagikan 1:1 untuk validasi dan *testing*. Maka, pada tahap ini digunakan komposisi *training data* sebesar 70, validasi data 15% dan *testing data* 15%.

Pada tahap *training data* menunjukkan bahwa jaringan saraf terbaik tercapai pada jaringan 15 *hidden layer* dengan *epoch* pertama iterasi 1 dan nilai tingkat *Mean Squared Error* (MSE) sebesar 0,000198. Dengan hasil tersebut dapat dianalisa bahwa jaringan saraf yang telah dilatih telah terkonvergensi dengan baik setelah mencapai *epoch* ke-7. Pada tahap ini, keberhasilan *training data* jaringan saraf dibuktikan pada perbandingan hasil peramalan dengan data aktual yang memiliki nilai MSE terendah. Menurut Leni dkk (2023), dalam penentuan validasi hasil prediksi dengan menggunakan machine learning ANN dengan pengambilan keputusan prediksi terbaik yang menghasilkan nilai MSE terkecil.

5.2 Analisa Hasil Prediksi Kadar Air Pada Bahan Baku Ikan Tunul Periode Bulan Januari 2023

Prediksi yang dilakukan pada UMKM D’Kriwil menggunakan hasil *testing data. Artificial Neural Network Backpropagation* pada pemrograman Matlab. Pada *training data* telah didapatkan jaringan terbaik dengan 15 *hidden layer* pada *epoch* pertama iterasi 1. Pada hasil *testing data* tersebut, didapatkan prediksi kadar air yang harus dikurangi pada bahan baku ikan tunul seperti pada Tabel 10. Hasil prediksi yang didapatkan kemudian dikembalikan menjadi nilai real dengan menggunakan denormalisasi data, sehingga didapatkan nilai prediksi dengan nilai maksimum sebagai batas maksimum kadar air pada ikan tunul sebesar 0,756 kg dan nilai minimum sebagai batas minimum sebesar 0,178 kg. Berdasarkan hasil prediksi menggunakan ANN *backpropagation*, dapat disimpulkan bahwasanya dilakukannya proses penjemuran bahan baku ikan tunul selama 2 jam merupakan upaya yang efektif dalam memperlambat tumbuhnya mikroorganisme yang

menyebabkan pembusukan pada bahan baku, sehingga produk dimsum ikan dapat layak konsumsi dalam jangka waktu yang lama.



BAB VI

KESIMPULAN DAN SARAN

6.1 Kesimpulan

Berdasarkan pengolahan data yang telah dilakukan dalam penelitian dengan metode *artificial neural network*, maka diperoleh kesimpulan sebagai berikut :

1. Hasil prediksi kadar air yang harus dikurangi pada bahan baku ikan tunul pada periode Januari 2023 untuk menjaga kualitas produk dimsum ikan tahan lama sebesar 0,494 kg, 0,503 kg, 0,5 kg, 0,499 kg, 0,497 kg, 0,5 kg, 0,493 kg, 0,4993 kg, 0,499 kg, 0,5 kg, 0,499 kg, 0,491 kg, 0,497 kg, 0,504kg, 0,497 kg, 0,5 kg, 0,5kg, 0,49 kg, 0,492 kg, 0,499 kg, 0,503 kg, 0,499 kg, 0,497 kg, 0,491 kg, 0,501 kg, 0,492 kg, 0,499kg, 0,495kg, 0,503 kg, 0,501 kg dan 0,501 kg.
2. Berdasarkan hasil *training data* menggunakan metode ANN dapat disimpulkan bahwa prediksi dengan jaringan yang memiliki 15 *hidden layer* menghasilkan nilai MSE terkecil, sehingga prediksi yang dihasilkan memiliki nilai *error* terkecil jika dibandingkan dengan aktual.
3. Berdasarkan prediksi yang dilakukan, disimpulkan bahwa batas maksimum pengurangan kadar air sebesar 0,756 kg dan batas minimum pengurangan kadar air sebesar 0,148 kg.

6.2 Saran

Saran yang dapat disampaikan untuk meningkatkan kualitas UMKM dan evaluasi untuk penelitian selanjutnya adalah sebagai berikut :

1. UMKM disarankan untuk menerapkan hasil dari prediksi pada proses penanganan bahan baku sehingga dapat mengevaluasi kesalahan yang ada pada proses yang sudah diterapkan.
2. Penelitian selanjutnya diharapkan mampu mengembangkan topik prediksi menggunakan metode 2 *machine learning* seperti *K-Nearest Neighbors* dan lainnya untuk menjadi pembanding hasil prediksi dari metode satu dengan yang lain.

DAFTAR PUSTAKA

- Aggarwal, C.C. 2019. *Neutral Networks and Deep Learning*. Edisi Pertama. Springer Cham.
- Doe, P.E. 2020. *Fish Drying and Smoking: Production and Quality*. Edisi Pertama. London. CRC Press.
- Effendi, S. 2015. *Teknologi Pengolahan dan Pengawetan Pangan*. Edisi 3. Jakarta. Alfabeta.
- Kusumadewi, S. 2003. *Artificial Intelligence : Teknik dan Aplikasinya*. Edisi Pertama. Yogyakarta. Graha Ilmu.
- Leni, D. *et al.* 2023. Perancangan Metode Machine Learning Berbasis Web Untuk Prediksi Sifat Mekanik Aluminium. *Jurnal Rekayasa Teknik Mesin*. Vol 4 No 2: 623–624.
- Naiu, A.S. *et al.* 2018. *Penanganan dan Pengolahan Hasil Perikanan*. Edisi Pertama. Edited by D.N. Fazrin. Gorontalo: CV. Athra Samudra.
- Ndahawali, D.H. 2016. Mikroorganisme Penyebab Kerusakan Pada Ikan dan Hasil Perikanan Lainnya. *Pojok Ilmiah*. Vol 3 No 2: 17–21.
- Pamungkas, I., Sumadi and Alam, S. 2022. Studi Komparasi Fungsi Aktivasi Sigmoid Biner, Sigmoid Bipolar dan Linear pada Jaringan Saraf Tiruan dalam Menentukan Warna RGB Menggunakan Matlab. *Serambi Engineering*. Vol 7 No 4.
- Pratama, F.R., Suryanti and Suryanto, A. 2018. Pemetaan Sebaran Echinodermata Pada Karakteristik Perairan Pulau Menjangan Kecil, Taman Nasional Karimunjawa (Mapping The Echinoderms Distribution In Coastal Characteristics Of Menjangan Kecil Island, Karimunjawa National Park). *Management of Aquatic Resources Journal (MAQUARES)*. Vol 6 No 4: 415–422.
- Purnomo, M.H. and Kurniawan, A. 2006. *Supervised Neural Networks dan Aplikasinya*. Edisi Pertama. Yogyakarta: Graha Ilmu.
- Ripley, B.D. 2017. Pattern Recognition and Neural Networks. *Cambridge University Press*. Vol 5 No 1: 1–5.

- Rorong, J.A. and Wilar, W.F. 2020. Keracunan Makanan Oleh Mikroba. *Techno Science Journal*. Vol 2 No 2: 47–60.
- Saluza, I. *et al.* 2023. Ensemble Backpropagation Neural Network Dalam Memprediksi Inflasi. *Jurnal JUPITER*. Vol 15 No 1: 734–735.
- Santoso, N.A. *et al.* 2023. Penerapan Neural Network Method dengan Struktur Backpropagation dalam Menentukan Prediksi Stock Barang. *Remik: Riset dan E-Jurnal Manajemen Informatika Komputer*. Vol 7 No 3.
- Santoso, W., Maimunah and Sukmasetya, P. (.Prediksi Volume Sampah di TPSA Banyuurip Menggunakan Metode Backpropagation Neural Network. *Jurnal Media Informatika Budidarma*. Vol 7 No 1: 464–472.
- Siang, J.J. 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Edisi Pertama. Yogyakarta: ANDI.
- Sivanandam, S.N., Sumathi, S. and Deepa, S.N. 2006. *Introduction To Neural Networks Using Matlab 6.0*. Edisi Pertama. New Delhi: Tata McGraw-Hill Publishing Company Limited.
- Supriyanto, Sunardi and Riadi, I. 2022. Pengaruh Nilai Hidden Layer Dan Learning Rate Terhadap Kecepatan Pelatihan Jaringan Syaraf Tiruan Backpropagation. *JIKO (Jurnal Informatika dan Komputer)*. Vol 6 No 1: 28–32.
- Sutojo, T., Mulyanto, E. and Suhartono, V. 2011. *Kecerdasan Buatan*. Edisi Pertama. Yogyakarta: Andi Offset.



LAMPIRAN

Lampiran 1. Hasil Prediksi dengan 5 Hidden Layer

<i>5 Hidden Layer</i>			
<i>Epoch maksimal 1000</i>			
Iterasi 1	Iterasi 2	Iterasi 3	Iterasi 4
Hasil Prediksi:	Hasil Prediksi:	Hasil Prediksi:	Hasil Prediksi:
0.2092	0.2136	0.2136	0.2146
0.6733	0.6628	0.6683	0.6703
0.6537	0.6471	0.6559	0.6563
0.5506	0.5497	0.5529	0.5527
0.2593	0.2651	0.2619	0.2618
0.6605	0.6556	0.6602	0.6612
0.1933	0.1916	0.1952	0.1967
0.541	0.5394	0.5403	0.5376
0.5362	0.537	0.532	0.5299
0.7995	0.7995	0.8044	0.8057
0.531	0.5298	0.5303	0.5279
0.147	0.1383	0.1412	0.148
0.3427	0.3455	0.3465	0.3418
0.8074	0.8109	0.8149	0.8132
0.4294	0.4315	0.4296	0.4277
0.6649	0.6607	0.666	0.6662
0.5897	0.5885	0.5883	0.5861
0.1451	0.1351	0.1355	0.1417
0.1877	0.185	0.1865	0.1884
0.6493	0.6468	0.6465	0.648
0.8026	0.8093	0.8038	0.8046
0.6042	0.6018	0.5966	0.6001
0.4274	0.4293	0.4301	0.4291
0.1538	0.1459	0.1487	0.153
0.7274	0.7271	0.7248	0.7268
0.1766	0.1722	0.1744	0.1773
0.6131	0.6114	0.6062	0.6098
0.2795	0.2828	0.2828	0.2807
0.8126	0.819	0.8149	0.8092
0.7471	0.7499	0.7419	0.7403
0.728	0.7267	0.7253	0.7259
0.4173	0.4213	0.415	0.4143
0.339	0.3446	0.3447	0.3403
0.2204	0.2194	0.2178	0.2206
0.556	0.5554	0.5547	0.553
0.6813	0.6752	0.6813	0.6822

0.4019	0.4035	0.404	0.403
0.7986	0.8008	0.8026	0.8011
0.749	0.7504	0.7521	0.7543
0.5171	0.5172	0.5183	0.519
0.7052	0.703	0.6996	0.7044
0.3384	0.3439	0.3419	0.3378
0.7485	0.7488	0.7503	0.7506
0.2569	0.2589	0.2586	0.2582
0.8173	0.8259	0.8163	0.8101
0.4952	0.4935	0.4942	0.4929
0.1773	0.1724	0.1742	0.1758
0.3988	0.4039	0.4018	0.4024
0.5666	0.5651	0.5699	0.5686
0.8381	0.8514	0.8517	0.8471
0.7455	0.7437	0.7511	0.7516
0.4887	0.488	0.4885	0.4885
0.3401	0.3445	0.3427	0.339
0.1484	0.1396	0.1414	0.1469
0.7415	0.7357	0.746	0.7486
0.311	0.3132	0.3143	0.3113
0.6857	0.6876	0.6804	0.6841
0.6623	0.6615	0.6553	0.6591
0.7434	0.7442	0.7425	0.7456
0.2627	0.266	0.2636	0.264
0.2787	0.2831	0.2786	0.2778
Nilai Error (MSE):	Nilai Error (MSE):	Nilai Error (MSE):	Nilai Error (MSE):
3.75E-04	2.91E-04	2.72E-04	3.39E-04

Lampiran 2. Coding ANN Backpropagation dengan 10 Hidden Layer

```

%input data
filename_input = 'Input ANN (Normalisasi).xlsx';
input_data = xlsread(filename_input);
filename_output = 'Target After Normalisasi.xlsx';
output_data = xlsread(filename_output);

% Inisialisasi parameter jaringan
input_neurons = size(input_data, 2);
hidden_neurons = 10; % Jumlah neuron pada lapisan tersembunyi
output_neurons = 1;
learning_rate = 0.1;
epochs = 1000;

% Inisialisasi bobot dan bias secara acak
hidden_weights = rand(input_neurons, hidden_neurons);
hidden_bias = rand(1, hidden_neurons);
output_weights = rand(hidden_neurons, output_neurons);
output_bias = rand(1, output_neurons);

% Training jaringan menggunakan metode backpropagation
for epoch = 1:epochs
    % Forward propagation
    hidden_layer_input = input_data * hidden_weights +
    repmat(hidden_bias, size(input_data, 1), 1);
    hidden_layer_output = 1 ./ (1 + exp(-hidden_layer_input)); %
    Fungsi aktivasi sigmoid biner

    output_layer_input = hidden_layer_output * output_weights +
    repmat(output_bias, size(input_data, 1), 1);
    predicted_output = 1 ./ (1 + exp(-output_layer_input)); %
    Fungsi aktivasi sigmoid biner

    % Menghitung error
    error = output_data - predicted_output;

    % Backpropagation
    d_predicted_output = error .* (predicted_output .* (1 -
    predicted_output));
    error_hidden_layer = d_predicted_output * output_weights';
    d_hidden_layer = error_hidden_layer .* (hidden_layer_output .*
    (1 - hidden_layer_output));

    % Update bobot dan bias
    output_weights = output_weights + hidden_layer_output' *
    d_predicted_output * learning_rate;
    output_bias = output_bias + sum(d_predicted_output) *
    learning_rate;
    hidden_weights = hidden_weights + input_data' * d_hidden_layer
    * learning_rate;
    hidden_bias = hidden_bias + sum(d_hidden_layer) *
    learning_rate;
    epoch=epoch+1;
end

```

```
% Prediksi menggunakan jaringan yang telah dilatih
hidden_layer_input = input_data * hidden_weights +
repmat(hidden_bias, size(input_data, 1), 1);
hidden_layer_output = 1 ./ (1 + exp(-hidden_layer_input));

output_layer_input = hidden_layer_output * output_weights +
repmat(output_bias, size(input_data, 1), 1);
predicted_output = 1 ./ (1 + exp(-output_layer_input));

disp("Hasil Prediksi:");
disp(predicted_output);

%Menghitung nilai Error MSE hasil prediksi
MSE = sum((output_data - predicted_output).^2) /
numel(output_data);
disp("Nilai Error (MSE):");
disp(MSE);
```



Lampiran 3. Hasil Prediksi dengan 10 *Hidden Layer*

10 <i>Hidden Layer</i>	
<i>Epoch</i> maksimum 1000	
Iterasi 1	Iterasi 2
Hasil Prediksi:	Hasil Prediksi:
0.2138	0.2181
0.6618	0.6622
0.6562	0.6478
0.5504	0.5469
0.2679	0.2704
0.6582	0.6534
0.1966	0.1955
0.539	0.536
0.5277	0.5296
0.8142	0.8168
0.5293	0.5266
0.135	0.133
0.3541	0.3513
0.8257	0.828
0.4304	0.4313
0.6642	0.6582
0.5838	0.5809
0.1272	0.126
0.1853	0.1861
0.642	0.6398
0.8102	0.8159
0.5914	0.5926
0.4309	0.4307
0.1429	0.1409
0.7223	0.723
0.1734	0.1726
0.6001	0.6015
0.2873	0.2891
0.8259	0.8276
0.7387	0.741
0.7249	0.7233
0.4124	0.4185
0.3496	0.35
0.2197	0.2233
0.5507	0.5489

0.6793	0.6754
0.4071	0.4067
0.8134	0.8142
0.7499	0.7514
0.515	0.5135
0.6961	0.6977
0.3456	0.3479
0.7497	0.7498
0.2618	0.2648
0.8257	0.8294
0.4957	0.492
0.1728	0.1718
0.4021	0.4059
0.5669	0.5614
0.8656	0.8725
0.7522	0.7496
0.4883	0.4864
0.3447	0.3479
0.1347	0.1328
0.7464	0.7452
0.3235	0.3205
0.6706	0.6754
0.6473	0.6507
0.7388	0.7424
0.2705	0.2715
0.2821	0.2868

Nilai <i>Error</i>	Nilai <i>Error</i>
(MSE):	(MSE):
2.38E-04	2.42E-04



Lampiran 4. Coding ANN Backpropagation dengan 15 Hidden Layer

```

%input data
filename_input = 'Input ANN (Normalisasi).xlsx';
input_data = xlsread(filename_input);
filename_output = 'Target After Normalisasi.xlsx';
output_data = xlsread(filename_output);

% Inisialisasi parameter jaringan
input_neurons = size(input_data, 2);
hidden_neurons = 15; % Jumlah neuron pada lapisan tersembunyi
output_neurons = 1;
learning_rate = 0.1;
epochs = 1000;

% Inisialisasi bobot dan bias secara acak
hidden_weights = rand(input_neurons, hidden_neurons);
hidden_bias = rand(1, hidden_neurons);
output_weights = rand(hidden_neurons, output_neurons);
output_bias = rand(1, output_neurons);

% Training jaringan menggunakan metode backpropagation
for epoch = 1:epochs
    % Forward propagation
    hidden_layer_input = input_data * hidden_weights +
    repmat(hidden_bias, size(input_data, 1), 1);
    hidden_layer_output = 1 ./ (1 + exp(-hidden_layer_input)); %
    Fungsi aktivasi sigmoid biner

    output_layer_input = hidden_layer_output * output_weights +
    repmat(output_bias, size(input_data, 1), 1);
    predicted_output = 1 ./ (1 + exp(-output_layer_input)); %
    Fungsi aktivasi sigmoid biner

    % Menghitung error
    error = output_data - predicted_output;

    % Backpropagation
    d_predicted_output = error .* (predicted_output .* (1 -
    predicted_output));
    error_hidden_layer = d_predicted_output * output_weights';
    d_hidden_layer = error_hidden_layer .* (hidden_layer_output .*
    (1 - hidden_layer_output));

    % Update bobot dan bias
    output_weights = output_weights + hidden_layer_output' *
    d_predicted_output * learning_rate;
    output_bias = output_bias + sum(d_predicted_output) *
    learning_rate;
    hidden_weights = hidden_weights + input_data' * d_hidden_layer
    * learning_rate;

```

```
hidden_bias = hidden_bias + sum(d_hidden_layer) *  
learning_rate;  
end  
  
% Prediksi menggunakan jaringan yang telah dilatih  
hidden_layer_input = input_data * hidden_weights +  
repmat(hidden_bias, size(input_data, 1), 1);  
hidden_layer_output = 1 ./ (1 + exp(-hidden_layer_input));  
  
output_layer_input = hidden_layer_output * output_weights +  
repmat(output_bias, size(input_data, 1), 1);  
predicted_output = 1 ./ (1 + exp(-output_layer_input));  
  
disp("Hasil Prediksi:");  
disp(predicted_output);  
  
%Menghitung nilai Error MSE hasil prediksi  
MSE = sum((output_data - predicted_output).^2) /  
numel(output_data);  
disp("Nilai Error (MSE):");  
disp(MSE);
```



Lampiran 5. Hasil Prediksi dengan 15 Hidden Layer

<i>15 Hidden Layer</i>	
<i>Epoch maksimum 1000</i>	
Iterasi 1	Iterasi 2
Hasil Prediksi:	Hasil Prediksi:
0.2178	0.2133
0.6631	0.6683
0.6519	0.6554
0.5511	0.5517
0.2631	0.2667
0.6575	0.6587
0.1974	0.195
0.538	0.5407
0.5304	0.5301
0.8121	0.8124
0.528	0.531
0.1341	0.1348
0.3539	0.3514
0.8226	0.8224
0.4315	0.4304
0.6629	0.6636
0.5878	0.5834
0.1258	0.1281
0.1863	0.1849
0.6429	0.6426
0.8077	0.8092
0.5916	0.5935
0.4313	0.4309
0.143	0.1427
0.7221	0.7225
0.1719	0.1728
0.6016	0.602
0.2875	0.2861
0.8232	0.8217
0.7429	0.7382
0.7244	0.7242
0.4168	0.4133
0.3481	0.3491
0.2156	0.2199
0.5544	0.5509
0.6812	0.6807

0.4047	0.4071
0.808	0.8099
0.7497	0.7497
0.517	0.5154
0.6945	0.6977
0.3464	0.3451
0.7505	0.7491
0.2606	0.2613
0.8253	0.8224
0.4933	0.4958
0.1712	0.1722
0.3992	0.4043
0.5692	0.5663
0.8639	0.8618
0.7495	0.7507
0.4873	0.4888
0.3487	0.3438
0.1339	0.1349
0.7455	0.747
0.32	0.3207
0.6758	0.6721
0.6502	0.6494
0.7413	0.7402
0.2684	0.2683
0.2842	0.2812

Nilai <i>Error</i> (MSE):	Nilai <i>Error</i> (MSE):
1.98E-04	2.51E-04

