



TUGAS AKHIR - TF 181801

**PERANCANGAN INTEGRASI SISTEM DENGAN
PREDIKTOR UNTUK IDENTIFIKASI TERJADINYA IUU
FISHING DAN TRANSHIPMENT BERBASIS DATA
AUTOMATIC IDENTIFICATION SYSTEM (AIS)
MENGGUNAKAN NEURAL NETWORKS**

**MUHAMMAD MUKHLIS JAMALI
NRP. 02311640000065**

Dosen Pembimbing:
Prof. Dr. Ir. Aulia Siti Aisjah, M. T.
Dr. Ir. A. A. Masroeri, M. Eng.

**Departemen Teknik Fisika
Fakultas Teknologi Industri Dan Rekayasa Sistem
Institut Teknologi Sepuluh Nopember
Surabaya
2020**



TUGAS AKHIR - TF 181801

**PERANCANGAN INTEGRASI SISTEM DENGAN
PREDIKTOR UNTUK IDENTIFIKASI TERJADINYA
IUU FISHING DAN TRANSHIPMENT BERBASIS DATA
AUTOMATIC IDENTIFICATION SYSTEM (AIS)
MENGGUNAKAN NEURAL NETWORKS**

MUHAMMAD MUKHLIS JAMALI
NRP. 02311640000065

Dosen Pembimbing:
Prof. Dr. Ir. Aulia Siti Aisjah, M. T.
Dr. Ir. A. A. Masroeri, M. Eng.

Departemen Teknik Fisika
Fakultas Teknologi Industri Dan Rekayasa Sistem
Institut Teknologi Sepuluh Nopember
Surabaya
2020

Halaman ini sengaja dikosongkan



FINAL PROJECT - TF 181801

***DESIGN OF SYSTEM INTEGRATION WITH
PREDICTOR FOR IDENTIFICATION OF IUU
FISHING AND TRANSHIPMENT BASED ON
AUTOMATIC IDENTIFICATION SYSTEM (AIS)
DATA USING NEURAL NETWORKS***

MUHAMMAD MUKHLIS JAMALI
NRP. 02311640000065

Supervisors:
Prof. Dr. Ir. Aulia Siti Aisjah, M. T.
Dr. Ir. A. A. Masroeri, M. Eng.

*Department of Engineering Physics
Faculty of Industrial Technology and System Engineering
Institut Teknologi Sepuluh Nopember
Surabaya
2020*

Halaman ini sengaja dikosongkan

PERNYATAAN BEBAS PLAGIASI

Saya yang bertanda tangan di bawah ini.

Nama : Muhammad Mukhlis Jamali
NRP : 02311640000065
Departemen / Prodi : Teknik Fisika / S1 Teknik Fisika
Fakultas : Fakultas Teknologi Industri & Rekayasa Sistem (FT-IRS)
Perguruan Tinggi : Institut Teknologi Sepuluh Nopember

Dengan ini menyatakan bahwa Tugas Akhir dengan judul "PERANCANGAN INTEGRASI SISTEM DENGAN PREDIKTOR UNTUK IDENTIFIKASI TERjadinya IUU FISHING DAN TRANSHIPMENT BERBASIS DATA AUTOMATIC IDENTIFICATION SYSTEM (AIS) MENGGUNAKAN NEURAL NETWORKS" adalah benar karya saya sendiri dan bukan plagiat dari karya orang lain. Apabila di kemudian hari terbukti terdapat plagiat pada Tugas Akhir ini, maka saya bersedia menerima sanksi sesuai ketentuan yang berlaku.

Demikian surat pernyataan ini saya buat dengan sebenarnya-benarnya.

Surabaya, 30 Juli 2020

Yang membuat pernyataan,



Muhammad Mukhlis Jamali

NRP. 02311640000065

Halaman ini sengaja dikosongkan

LEMBAR PENGESAHAN
TUGAS AKHIR

**PERANCANGAN INTEGRASI SISTEM DENGAN PREDIKTOR
UNTUK IDENTIFIKASI TERJADINYA IUU FISHING DAN
TRANSHIPMENT BERBASIS DATA *AUTOMATIC IDENTIFICATION
SYSTEM (AIS)* MENGGUNAKAN NEURAL NETWORKS**

oleh:

Muhammad Mukhlis Jamali

NRP. 02311640000065

Surabaya, 30 Juli 2020

Menyetujui,
Pembimbing I

Prof. Dr Ir. Aulia Siti Aisjah, M. T.

NIP. 1966011619890321001

Menyetujui,
Pembimbing II

Dr. Ir. A.A Masroeri, M. Eng.

NIP. 195808071984031001

Mengetahui,

Kepala Departemen
TEKNIK FISIKA FTI-ITS



Dwi Mulyanto, S.T., M.T.

NIP. 197111131995121002

Halaman ini sengaja dikosongkan

LEMBAR PENGESAHAN

PERANCANGAN INTEGRASI SISTEM DENGAN PREDIKTOR UNTUK IDENTIFIKASI TERJADINYA IUU FISHING DAN *TRANSHIPMENT BERBASIS DATA AUTOMATIC IDENTIFICATION SYSTEM (AIS) MENGGUNAKAN NEURAL NETWORKS*

TUGAS AKHIR

Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Teknik
pada

Progam Studi S-1 Departemen Teknik Fisika
Fakultas Teknologi Industri & Rekayasa Sistem (FT-IRS)
Institut Teknologi Sepuluh Nopember

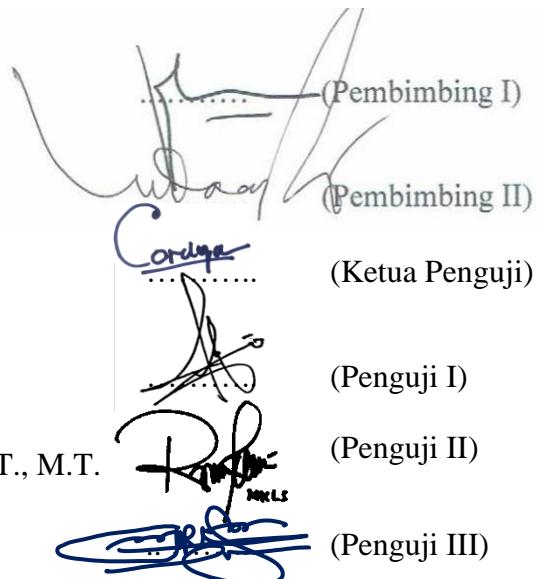
oleh:

MUHAMMAD MUKHLIS JAMALI

NRP. 02311640000065

Disetujui oleh Tim Penguji Tugas Akhir:

- 1 Prof. Dr. Ir. Aulia Siti Aisjah, M.T.
- 2 Dr. Ir. A.A. Masroeri, M.Eng.
- 3 Hendra Cordova, S.T., M.T.
- 4 Prof. Dr. Ir. Sekartedjo, M.Sc.
- 5 Dr.rer.nat. Ruri Agung Wahyuono, S.T., M.T.
- 6 Dr. Ir. Syamsul Arifin, M.T.



(Pembimbing I)

(Pembimbing II)

(Ketua Penguji)

(Penguji I)

(Penguji II)

(Penguji III)

SURABAYA

2020

Halaman ini sengaja dikosongkan

**PERANCANGAN INTEGRASI SISTEM DENGAN
PREDIKTOR UNTUK IDENTIFIKASI TERJADINYA IUU
FISHING DAN TRANSHIPMENT BERBASIS DATA
AUTOMATIC IDENTIFICATION SYSTEM (AIS)
MENGGUNAKAN NEURAL NETWORKS**

Nama : Muhammad Mukhlis Jamali
NRP : 02311640000065
Departemen : Teknik Fisika FTIRS - ITS
Dosen Pembimbing : Prof. Dr. Ir. Aulia Siti Aisjah, M. T.
Dr. Ir. A. A. Masroeri, M. Eng.

ABSTRAK

Eksplorasi sumber kekayaan alam maritim di Indonesia masih banyak terjadi. Upaya pengawasan terhadap praktik *illegal fishing* dan *transhipment* masih kurang optimal karena keterbatasan kemampuan instrumen pengawasan. Terjadinya hilangnya / *losses* data *Automatic Identification System* (AIS) berdampak pada kelemahan di dalam sistem monitoring gerakan kapal. Kelemahan sistem pada penelitian sebelumnya, dengan tanpa memperhatikan adanya *losses* data sehingga secara *real* identifikasi terhadap *illegal fishing* dan *transhipment*, menjadi kurang akurat dan valid. Penelitian tugas akhir ini melakukan perancangan integrasi sistem dengan prediktor untuk identifikasi terjadinya praktik *illegal fishing* dan *transhipment* berbasis data AIS dengan adanya data AIS yang hilang. Prediktor dirancang menggunakan *recurrent neural networks* (RNN) dan integrasi sistem dirancang menggunakan *artificial neural networks* (ANN). Prediktor dan integrasi sistem disimulasikan, diuji dan divalidasi menggunakan data kapal *real* yang melakukan praktik *illegal fishing* dan *transhipment* dari pusat data *marinetraffic.com* dan NASDEC-ITS. Hasil validasi menunjukkan bahwa hasil prediksi dari prediktor bisa digunakan sebagai masukan integrasi sistem identifikasi dan akurasi pada identifikasi *illegal fishing* dan *transhipment* sebesar 99.64%.

Kata Kunci: *Artificial Neural Networks (ANN), Automatic Identification System (AIS), illegal transhipment, IUU fishing, prediktor data hilang, Recurrent Neural Networks (RNN), sistem identifikasi*

***DESIGN OF SYSTEM INTEGRATION WITH PREDICTOR FOR
IDENTIFICATION OF IUU FISHING AND TRANSHIPMENT
BASED ON AUTOMATIC IDENTIFICATION SYSTEM (AIS)
USING NEURAL NETWORKS***

<i>Name</i>	: Muhammad Mukhlis Jamali
<i>NRP</i>	: 02311640000065
<i>Department</i>	: Engineering Physics FTIRS – ITS
<i>Supervisors</i>	: Prof. Dr. Ir. Aulia Siti Aisjah, M. T. Dr. Ir. A. A. Masroeri, M. Eng.

ABSTRACT

Exploitation of maritime natural resources in Indonesia is still widespread. Efforts to monitor illegal fishing and transhipment practices are still less than optimal due to the limited ability of monitoring instruments. The loss of data Automatic Identification System (AIS) has an impact on weakness in the ship's motion monitoring system. The weakness of the system in the previous research, without regard to data losses so that in real identification of illegal fishing and transhipment, it becomes less accurate and valid. This research designs system integration with predictors to identify the occurrence of illegal fishing and transhipment in the presence of missing AIS data. Predictors are designed using recurrent neural networks (RNN) and system integration is designed using artificial neural networks (ANN). Predictors and system integration are simulated, tested and validated using data of real ship that committed illegal fishing and transhipment from the marinetraffic.com and NASDEC-ITS data centers. The validation results show that the predictor results from the predictor can be used as input for system integration and the accuracy of the identification of illegal fishing and transhipment is 99.64%.

Keywords: *Artificial Neural Networks (ANN), Automatic Identification System (AIS), identification systems, illegal transhipment, IUU fishing, missing data predictors, Recurrent Neural Networks (RNN)*

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Puji dan syukur penulis panjatkan kehadirat Allah SWT atas rahmat dan karunia-Nya, penulis dapat menyelesaikan Usulan Penelitian yang berjudul “**Perancangan Integrasi Sistem dengan Prediktor untuk Identifikasi Terjadinya IUU Fishing dan Transhipment Berbasis Data Automatic Identification System (AIS) Menggunakan Neural Networks**”.

Penulis menyadari bahwa dalam proses penelitian ini tidak terlepas dari bantuan dan bimbingan dari berbagai pihak. Pada kesempatan ini penulis menyampaikan terima kasih yang sebesar-besarnya kepada:

1. Allah SWT yang telah memberikan rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan penelitian Tugas Akhir dan Laporan Tugas Akhir ini.
2. Keluarga, terutama kedua orang tua yang selalu memberikan dukungan dan semangat kepada penulis.
3. Dr. Suyanto, S.T., M.T. selaku Kepala Departemen Teknik Fisika yang telah memfasilitasi penelitian ini.
4. Prof. Dr. Ir. Aulia Siti Aisjah, M.T. selaku Dosen pembimbing 1 yang telah banyak membantu, memberikan ilmu, saran, masukan serta bimbingannya dalam penyusunan laporan ini.
5. Dr. Ir. A.A. Masroeri, M.Eng. selaku Dosen pembimbing 2 yang senantiasa membimbing dan memberikan masukan dalam penyusunan laporan ini.
6. Rekan satu topik bimbingan, Deaz Indra Setiawan dan Ferry Bastian yang sudah memberikan semangat dan membantu dalam melakukan penelitian.
7. Teman satu kos, Dije dan NP yang telah menemani dalam proses penggerjaan penelitian ini.

Penulis sangat menyadari bahwa dalam laporan Tugas Akhir ini masih terdapat kekurangan. Kritik dan saran yang membangun sangat dibutuhkan dalam menyempurnakan laporan Tugas Akhir ini.

Surabaya, 30 Juli 2020

Penulis

DAFTAR ISI

PERNYATAAN BEBAS PLAGIASI	v
LEMBAR PENGESAHAN	vii
LEMBAR PENGESAHAN	ix
ABSTRAK	xi
ABSTRACT	xiii
KATA PENGANTAR	xv
DAFTAR ISI.....	xvii
DAFTAR GAMBAR	xxi
DAFTAR TABEL.....	xxv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan.....	5
1.4 Batasan Masalah.....	5
1.5 Sistematika Laporan	6
BAB II DASAR TEORI	7
2.1 Teknologi AIS	7
2.2 <i>Artificial Neural Networks (ANN)</i>	10
2.3 <i>K-Fold Cross Validation</i>	15
2.4 <i>Recurrent Neural Networks (RNN)</i>	17
2.5 <i>Mean Absolute Percentage Error (MAPE)</i>	19
2.6 <i>IUU Fishing</i>	20
2.7 <i>IUU Transhipment</i>	22
2.8 <i>Collision Regulations (COLREGs)</i>	23

BAB III METODOLOGI PENELITIAN	25
3.1 Analisa Sistem Pada Penelitian Sebelumnya.....	26
3.2 Identifikasi Masalah.....	27
3.3 Studi Literatur	28
3.4 Pengumpulan Data AIS Kapal <i>Illegal Fishing</i> dan <i>Transhipment</i>	28
3.5 Perancangan Prediktor untuk Prediksi Data AIS Kapal <i>Illegal Fishing</i> dan <i>Transhipment</i> yang Hilang.....	29
3.6 Pengujian dan Validasi Prediktor	35
3.7 Analisa Hasil Prediksi.....	36
3.8 Perancangan Integrasi Sistem untuk Identifikasi dengan <i>Artificial Neural Networks</i> (<i>ANN Selection & ANN Decision</i>)	37
3.9 Analisa Hasil Perancangan Integrasi Sistem untuk Identifikasi dengan <i>Artificial Neural Networks</i> (<i>ANN Selection & ANN Decision</i>).....	62
3.10 Validasi Integrasi Sistem untuk Identifikasi	63
3.11 Penyusunan Laporan dan Pengambilan Kesimpulan.....	64
BAB IV HASIL DAN PEMBAHASAN.....	65
4.1 Hasil Pengujian Prediksi Data AIS <i>Longitude</i> dan <i>Latitude</i> yang Hilang pada Kapal <i>Illegal Fishing</i> dan <i>Transhipment</i>	65
4.2 Model Arsitektur Jaringan RNN <i>Predictor</i> untuk Prediksi Data AIS <i>Longitude</i> dan <i>Latitude</i> yang Hilang	67
4.3 Hasil Pengujian Prediksi Data AIS <i>Heading</i> yang Hilang pada Kapal <i>Illegal Fishing</i> dan <i>Transhipment</i>	68
4.4 Model Arsitektur Jaringan RNN <i>Predictor</i> untuk Prediksi Data AIS <i>Heading</i> yang Hilang	71
4.5 Hasil Pengujian Prediksi Data AIS <i>Speed</i> yang Hilang pada Kapal <i>Illegal Fishing</i> dan <i>Transhipment</i> menggunakan Metode Perbandingan Senilai	72

4.6	Hasil Validasi Subsistem Prediktor Data AIS yang Hilang pada Kapal <i>Illegal Transhipment</i> dan <i>Illegal Fishing</i>	73
4.7	Hasil Perancangan Subsistem ANN <i>Selection</i>	105
4.8	Hasil Perancangan Subsistem ANN <i>Decision Transhipment</i>	117
4.9	Hasil Perancangan Subsistem ANN <i>Decision Fishing</i>	126
4.10	Analisis Akurasi Integrasi Sistem untuk Identifikasi	137
4.11	Hasil Validasi Integrasi Sistem untuk Identifikasi	138
BAB V KESIMPULAN DAN SARAN.....		151
5.1	Kesimpulan.....	151
5.2	Saran	152
DAFTAR PUSTAKA		153
LAMPIRAN		159
BIODATA PENULIS		173

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

Gambar 2. 1 Prinsip Kerja <i>Automatic Identification System</i> (AIS) (U.S. Coast Guard Navigation Center, 2010)	8
Gambar 2. 2 Arsitektur JST pada Pelatihan Trayektori IUU <i>Fishing</i> (Maulida, 2018)	13
Gambar 2. 3 Fungsi Aktivasi ReLu	14
Gambar 2. 4 Fungsi Aktivasi Sigmoid	15
Gambar 2. 5 Model Representasi Skematis Prosedur <i>K-Fold Cross Validation</i> dengan K=3	16
Gambar 2. 6 Proses RNN	17
Gambar 2. 7 Diagram unit LSTM (Goodfellow, Bengio, & Courville, 2016)....	18
Gambar 2. 8 Fleksibilitas Arsitektur RNN (Karpathy, 2015).....	19
Gambar 2. 9 Ilustrasi Operasi Alat Tangkap Cantrang (KKP, 2019).....	21
Gambar 2. 10 Illustrasi <i>Transhipment</i>	22
Gambar 2. 11 COLREG (a) <i>Head on</i> , (b) <i>Crossing</i> , (c) <i>Overtake</i> (www.fishweb.com/boating/rules/crossing.gif)	23
Gambar 3. 1 Diagram alir penelitian	26
Gambar 3. 2 Diagram blok sistem pengambilan keputusan (Fatmawati, 2018)	27
Gambar 3. 3 Diagram alir perancangan model RNN <i>predictor</i>	29
Gambar 3. 4 Diagram blok pelatihan <i>neural networks</i>	33
Gambar 3. 5 Diagram blok integrasi sistem untuk identifikasi dengan masukan dari hasil prediksi prediktor	37
Gambar 3. 6 Desain subsistem ANN <i>selection</i>	38
Gambar 3. 7 Diagram alir perancangan subsistem ANN <i>selection</i>	39
Gambar 3. 8 Representasi skematis prosedur <i>k-fold cross validation</i> pada ANN <i>selection</i>	44
Gambar 3. 9 Desain subsistem ANN <i>decision</i>	45
Gambar 3. 10 Diagram alir perancangan ANN <i>decision transhipment</i>	46
Gambar 3. 11 Representasi skematis prosedur <i>k-fold cross validation</i> pada ANN <i>decision transhipment</i>	53

Gambar 3. 12	Diagram alir perancangan ANN <i>decision fishing</i>	55
Gambar 3. 13	Representasi skematis prosedur <i>k-fold cross validation</i> pada ANN <i>decision fishing</i>	61
Gambar 4. 1	Model RNN untuk prediksi data AIS <i>longitude</i> dan <i>latitude</i> yang hilang	68
Gambar 4. 2	Model RNN untuk prediksi data AIS <i>heading</i> yang hilang	71
Gambar 4. 3	Pergerakan Kapal Lurongyuanyu 105 dan posisi Kapal Eagle Seville	74
Gambar 4. 4	Pergerakan Kapal Lurongyuanyu 105 dengan adanya data yang hilang dan posisi Kapal Eagle Seville	76
Gambar 4. 5	Hasil prediksi pergerakan Kapal Lurongyuanyu 105 dengan adanya data yang hilang dan posisi Kapal Eagle Seville	78
Gambar 4. 6	Grafik perbandingan hasil prediksi data AIS <i>heading</i> terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam	79
Gambar 4. 7	Grafik perbandingan hasil prediksi data AIS <i>speed</i> terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam	81
Gambar 4. 8	Pergerakan Kapal Lurongyuanyu 105 dengan adanya data yang hilang secara berselang dan posisi Kapal Eagle Seville	83
Gambar 4. 9	Hasil prediksi pergerakan Kapal Lurongyuanyu 105 dengan adanya data yang hilang secara berselang dan posisi Kapal Eagle Seville	85
Gambar 4. 10	Grafik perbandingan hasil prediksi data ke-5 sampai dengan data ke-8 AIS <i>heading</i> terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam	86
Gambar 4. 11	Grafik perbandingan hasil prediksi data ke-13 sampai dengan data ke-16 AIS <i>heading</i> terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam	87
Gambar 4. 12	Grafik perbandingan hasil prediksi data ke-5 sampai dengan data ke-8 AIS <i>speed</i> terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam	88

Gambar 4. 13	Grafik perbandingan hasil prediksi data ke-13 sampai dengan data ke-16 AIS <i>speed</i> terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam	89
Gambar 4. 14	Pergerakan Kapal Ikan di Selat Singapura	91
Gambar 4. 15	Pergerakan Kapal Ikan di Selat Singapura dengan adanya data yang hilang	92
Gambar 4. 16	Hasil prediksi pergerakan Kapal Ikan di Selat Singapura dengan adanya data yang hilang	94
Gambar 4. 17	Grafik perbandingan hasil prediksi data AIS <i>heading</i> terhadap data AIS aktual Kapal Ikan di Selat Singapura	96
Gambar 4. 18	Grafik perbandingan hasil prediksi data AIS <i>speed</i> terhadap data AIS aktual Kapal Ikan di Selat Singapura	97
Gambar 4. 19	Pergerakan Kapal Ikan di Selat Singapura dengan adanya data yang hilang secara berselang	99
Gambar 4. 20	Hasil prediksi pergerakan Kapal Ikan di Selat Singapura dengan adanya data yang hilang secara berselang	101
Gambar 4. 21	Grafik perbandingan hasil prediksi data ke-5 sampai dengan data ke-8 AIS <i>heading</i> terhadap data AIS aktual Kapal Ikan di Selat Singapura	102
Gambar 4. 22	Grafik perbandingan hasil prediksi data ke-13 sampai dengan data ke-16 AIS <i>heading</i> terhadap data AIS aktual Kapal Ikan di Selat Singapura	103
Gambar 4. 23	Model arsitektur jaringan ANN <i>selection</i>	107
Gambar 4. 24	Sortir dua kapal diduga <i>transhipment</i> pola ke-1	109
Gambar 4. 25	Gambar dua kapal diduga <i>transhipment</i> pola ke-2	111
Gambar 4. 26	Sortir dua kapal diduga <i>transhipment</i> pola ke-3	112
Gambar 4. 27	Sortir dua kapal diduga <i>illegal fishing</i> pola ke-1	114
Gambar 4. 28	Sortir dua kapal diduga <i>illegal fishing</i> pola ke-2	116
Gambar 4. 29	Model arsitektur jaringan ANN <i>decision transhipment</i>	120
Gambar 4. 30	Pola gerak kapal <i>illegal transhipment</i> ke-1	121
Gambar 4. 31	Pola gerak kapal <i>illegal transhipment</i> ke-2	123
Gambar 4. 32	Pola gerak kapal <i>illegal transhipment</i> ke-3	125
Gambar 4. 33	Model arsitektur jaringan ANN <i>decision fishing</i>	129

Gambar 4. 34	Pola gerak kapal 1 <i>illegal fishing</i> ke-1	130
Gambar 4. 35	Pola gerak kapal 2 <i>illegal fishing</i> ke-1	132
Gambar 4. 36	Pola gerak kapal 1 <i>illegal fishing</i> ke-2	134
Gambar 4. 37	Pola gerak kapal 2 <i>illegal fishing</i> ke-2	136
Gambar 4. 38	Pergerakan kapal Nordic Bahari dan pelabuhan Sorong Papua (https://marinetraffic.com)	140
Gambar 4. 39	Grafik kecepatan kapal Nordic Bahari (https://marinetraffic.com)	140
Gambar 4. 40	Pergerakan Kapal Lurongyuanyu 105 dan Kapal Eagle Seville di perairan Batam (https://marinetraffic.com)	143
Gambar 4. 41	Grafik kecepatan Kapal Lurongyuanyu 105	144
Gambar 4. 42	Pergerakan kapal Ikan B di Selat Singapura	147
Gambar 4. 43	Pola pergerakan Kapal Ikan berdasarkan data <i>real AIS</i>	149

DAFTAR TABEL

Tabel 2. 1	Skala penentuan nilai akurasi suatu prediktor	20
Tabel 3. 1	Data Masukan RNN <i>Predictor</i> untuk Prediksi Data AIS <i>Longitude</i> dan <i>Latitude</i> yang Hilang	30
Tabel 3. 2	Data Masukan RNN <i>Predictor</i> untuk Prediksi Data AIS <i>Heading</i> yang Hilang	31
Tabel 3. 3	Variabel Masukan pada Subsistem ANN <i>Selection</i>	40
Tabel 3. 4	Variabel Masukan pada Subsistem ANN <i>Decision Transhipment</i> .	47
Tabel 3. 5	Variabel Masukan pada Subsistem ANN <i>Decision Fishing</i>	56
Tabel 4. 1	Hasil Pengujian Kombinasi Parameter <i>Learning Rate</i> untuk Prediksi Data AIS <i>Longitude</i> dan <i>Latitude</i> yang Hilang.....	66
Tabel 4. 2	Hasil Pengujian Kombinasi Parameter <i>Unit Neurons</i> pada LSTM <i>Layers</i> untuk Prediksi Data AIS <i>Longitude</i> dan <i>Latitude</i> yang Hilang.....	67
Tabel 4. 3	MAPE Dari Model RNN untuk Prediksi Data AIS <i>Longitude</i> dan <i>Latitude</i> yang Hilang.....	68
Tabel 4. 4	Hasil Pengujian Kombinasi Parameter <i>Learning Rate</i> untuk Prediksi Data AIS <i>Heading</i> yang Hilang	70
Tabel 4. 5	Hasil Pengujian Kombinasi Parameter <i>Unit Neurons</i> pada LSTM <i>Layers</i> untuk Prediksi Data AIS <i>Heading</i> yang Hilang	70
Tabel 4. 6	MAPE Dari Model RNN untuk Prediksi Data AIS <i>Heading</i> yang Hilang	72
Tabel 4. 7	RMSE Dari Hasil Prediksi Data AIS <i>Speed</i> yang Hilang Menggunakan Metode Perbandingan Senilai.....	72
Tabel 4. 8	Data <i>Real AIS</i> Kapal Lurongyuanyu 105 di Perairan Batam	73
Tabel 4. 9	Data <i>Real AIS</i> Kapal Lurongyuanyu 105 di Perairan Batam yang Diasumsikan Terdapat Data yang Hilang	75
Tabel 4. 10	Hasil Prediksi Data <i>Real AIS</i> Kapal Lurongyuanyu 105 di Perairan Batam yang Diasumsikan Terdapat Data yang Hilang	76

Tabel 4.11	Perbandingan Hasil Validasi I Prediksi Data AIS <i>Longitude</i> dan <i>Latitude</i> Terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam	77
Tabel 4.12	Perbandingan Hasil Validasi I Prediksi Data AIS <i>Heading</i> Terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam	79
Tabel 4.13	Perbandingan Hasil Validasi I Prediksi Data AIS <i>Speed</i> Terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam	80
Tabel 4.14	Data <i>Real AIS</i> Kapal Lurongyuanyu 105 di Perairan Batam yang Diasumsikan Terdapat Data yang Hilang Secara Berselang	81
Tabel 4.15	Hasil Prediksi Data <i>Real AIS</i> Kapal Lurongyuanyu 105 di Perairan Batam yang Diasumsikan Terdapat Data yang Hilang Secara Berselang	83
Tabel 4.16	Perbandingan Hasil Validasi II Prediksi Data AIS <i>Longitude</i> dan <i>Latitude</i> Terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam	84
Tabel 4.17	Perbandingan Hasil Validasi II Prediksi Data AIS <i>Heading</i> Terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam	86
Tabel 4.18	Perbandingan Hasil Validasi II Prediksi Data AIS <i>Speed</i> Terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam	88
Tabel 4.19	Data <i>Real AIS</i> Kapal Ikan di Selat Singapura	90
Tabel 4.20	Data <i>Real AIS</i> Kapal Ikan di Selat Singapura yang Diasumsikan Terdapat Data yang Hilang.....	91
Tabel 4.21	Hasil Prediksi Data <i>Real AIS</i> Kapal Ikan di Selat Singapura yang Diasumsikan Terdapat Data yang Hilang.....	93
Tabel 4.22	Perbandingan Hasil Validasi I Prediksi Data AIS <i>Longitude</i> dan <i>Latitude</i> Terhadap Data AIS Aktual Kapal Ikan di Selat Singapura.....	94
Tabel 4.23	Perbandingan Hasil Validasi I Prediksi Data AIS <i>Heading</i> Terhadap Data AIS Aktual Kapal Ikan di Selat Singapura	95
Tabel 4.24	Perbandingan Hasil Validasi I Prediksi Data AIS <i>Speed</i> Terhadap Data AIS Aktual Kapal Ikan di Selat Singapura	96
Tabel 4.25	Data <i>Real AIS</i> Kapal Ikan di Selat Singapura yang Diasumsikan Terdapat Data yang Hilang Secara Berselang	98

Tabel 4. 26	Hasil Prediksi Data <i>Real AIS</i> Kapal Ikan di Selat Singapura yang Diasumsikan Terdapat Data yang Hilang Secara Berselang	99
Tabel 4. 27	Perbandingan Hasil Validasi II Prediksi Data AIS <i>Longitude</i> dan <i>Latitude</i> Terhadap Data AIS Aktual Kapal Ikan di Selat Singapura	100
Tabel 4. 28	Perbandingan Hasil Validasi II Prediksi Data AIS <i>Heading</i> Terhadap Data AIS Aktual Kapal Ikan di Selat Singapura.....	102
Tabel 4. 29	Perbandingan Hasil Validasi II Prediksi Data AIS <i>Speed</i> Terhadap Data AIS Aktual Kapal Ikan di Selat Singapura.....	104
Tabel 4. 30	Hasil Pengimplementasian <i>K-Fold Cross Validation</i> pada Perancangan ANN <i>Selection</i>	105
Tabel 4. 31	Data Masukan <i>Selection Pola Transhipment</i> ke-1	109
Tabel 4. 32	Hasil Perbandingan Keluaran Subsistem <i>Selection Pola Kapal Transhipment</i> ke-1	110
Tabel 4. 33	Data Masukan <i>Selection Pola Transhipment</i> ke-2.....	111
Tabel 4. 34	Hasil Perbandingan Keluaran Subsistem <i>Selection Pola Kapal Transhipment</i> ke-2	112
Tabel 4. 35	Data Masukan <i>Selection Pola Transhipment</i> ke-3.....	113
Tabel 4. 36	Hasil Perbandingan Keluaran Subsistem <i>Selection Pola Kapal Transhipment</i> ke-3	113
Tabel 4. 37	Data Masukan <i>Selection Pola Illegal Fishing</i> ke-1	115
Tabel 4. 38	Hasil Perbandingan Keluaran Subsistem <i>Selection Pola Kapal Illegal Fishing</i> ke-1	115
Tabel 4. 39	Data Masukan <i>Selection Pola Illegal Fishing</i> ke-2	116
Tabel 4. 40	Hasil Perbandingan Keluaran Subsistem <i>Selection Pola Kapal Illegal Fishing</i> ke-2	117
Tabel 4. 41	Hasil Pengimplementasian <i>K-Fold Cross Validation</i> pada Perancangan ANN <i>Decision Transhipment</i>	118
Tabel 4. 42	Data Masukan <i>Decision Pola Transhipment</i> ke-1	122
Tabel 4. 43	Hasil Perbandingan Keluaran Subsistem <i>Decision Transhipment Pola Kapal Transhipment</i> ke-1	122
Tabel 4. 44	Data Masukan <i>Decision Pola Transhipment</i> ke-2	123

Tabel 4. 45	Hasil Perbandingan Keluaran Subsistem <i>Decision Transhipment</i> Pola Kapal <i>Transhipment</i> ke-2	124
Tabel 4. 46	Data Masukan <i>Decision</i> Pola <i>Transhipment</i> ke-3.....	125
Tabel 4. 47	Hasil Perbandingan Keluaran Subsistem <i>Decision Transhipment</i> Pola Kapal <i>Transhipment</i> ke-3	126
Tabel 4. 48	Hasil Pengimplementasian K-Fold Cross Validation pada Perancangan ANN <i>Decision Fishing</i>	127
Tabel 4. 49	Data Masukan <i>Decision Fishing</i> Kapal 1 Pola ke-1	131
Tabel 4. 50	Hasil Perbandingan Keluaran Subsistem <i>Decision Fishing</i> Kapal 1 Pola <i>Fishing</i> ke-1	131
Tabel 4. 51	Data Masukan <i>Decision Fishing</i> Kapal 2 Pola ke-1	133
Tabel 4. 52	Hasil Perbandingan Keluaran Subsistem <i>Decision Fishing</i> Kapal 2 Pola <i>Fishing</i> ke-1	133
Tabel 4. 53	Data Masukan <i>Decision Fishing</i> Kapal 1 Pola ke-2	135
Tabel 4. 54	Hasil Perbandingan Keluaran Subsistem <i>Decision Fishing</i> Kapal 1 Pola <i>Fishing</i> ke-2	135
Tabel 4. 55	Data Masukan <i>Decision Fishing</i> Kapal 2 Pola ke-2	136
Tabel 4. 56	Hasil Perbandingan Keluaran Subsistem <i>Decision Fishing</i> Kapal 2 Pola <i>Fishing</i> ke-2	137
Tabel 4. 57	Perbandingan Hasil Akurasi yang Didapat dengan <i>Fuzzy Logic</i> dan ANN	138
Tabel 4. 58	Data <i>Real AIS</i> Kapal <i>Transhipment</i> pada Pelabuhan Sorong, Papua	139
Tabel 4. 59	Data Masukan Subsistem ANN <i>Selection</i> pada Validasi 1.....	141
Tabel 4. 60	Data Masukan Subsistem ANN <i>Decision Transhipment</i> pada Validasi ke-1	141
Tabel 4. 61	Data <i>Real AIS</i> Kapal Lurongyuanyu 105 di Perairan Batam	142
Tabel 4. 62	Data Masukan Subsistem ANN <i>Selection</i> pada Validasi 2.....	144
Tabel 4. 63	Data Masukan Subsistem ANN <i>Decision Transhipment</i> pada Validasi ke- 2	145
Tabel 4. 64	Data <i>Real AIS</i> Kapal Ikan B di Selat Singapura	146
Tabel 4. 65	Data Masukan Subsistem ANN <i>Selection</i> pada Validasi 3.....	147

Tabel 4. 66	Data Masukan Subsistem ANN <i>Decision Fishing</i> pada Validasi 3 148
Tabel 4. 67	Data Masukan Subsistem ANN <i>Selection</i> pada Validasi 4 149
Tabel 4. 68	Data Masukan Subsistem ANN <i>Decision Fishing</i> pada Validasi 4 150

Halaman ini sengaja dikosongkan

BAB I

PENDAHULUAN

1.1 Latar Belakang

Indonesia memiliki potensi geografis dengan total wilayah perairan laut sebesar 77% dari seluruh luas Indonesia. Potensi geografis inilah yang menjadikan Indonesia sebagai negara maritim. Sayangnya, di laut Indonesia masih banyak terjadi eksploitasi sumber hayati. Praktek *illegal, unreported, and unregulated* (IUU) *fishing* dan *transhipment* menjadi ancaman sekaligus tantangan yang muncul di tengah potensi perikanan yang dimiliki Indonesia.

Menurut *International Plan of Action* (IPOA) - IUU *fishing*, yang pertama, *illegal fishing* adalah kegiatan menangkap ikan yang bertentangan dengan peraturan nasional yang berlaku atau kewajiban internasional. Kedua *unreported fishing* adalah suatu kegiatan penangkapan ikan yang tidak pernah dilaporkan atau dilaporkan secara tidak benar kepada instansi yang berwenang, tidak sesuai dengan peraturan perundang-undangan nasional. Ketiga *unregulated fishing* adalah kegiatan penangkapan ikan yang dilakukan pada suatu area yang menjadi kewenangan organisasi pengelolaan perikanan regional dengan cara yang tidak sesuai dengan ketentuan pelestarian dan pengelolaan dari organisasi tersebut. Dalam pengertian yang lebih sederhana dan bersifat operasional, IUU *Fishing* dapat diartikan sebagai kegiatan perikanan yang melanggar hukum (Gustina, 2014). Praktek *illegal fishing* yang terjadi di Indonesia, yaitu sejak Januari hingga April 2019 terdapat 38 kapal pelaku *illegal fishing* di Laut Natuna, dengan rincian 15 Kapal Ikan Asing (KIA) Vietnam, 13 KIA Malaysia, dan 10 Kapal Ikan Indonesia (KII) (KKP, 2019). Praktek *illegal fishing* pada tahun 2017 salah satunya dilakukan KMN Kurnia Lestari dengan muatan 10 Ton ikan yang ditangkap di perairan Tanjung Selatan Kabupaten Tanah Laut (Rahman, 2017). Modus IUU *Fishing* yang kerap dilakukan di wilayah perairan Indonesia salah satunya adalah penggunaan jenis alat tangkap yang dilarang (BPK, 2016). Salah satu alat tangkap ikan yang banyak digunakan oleh nelayan di Indonesia adalah cantrang. Penggunaan cantrang di Indonesia dilarang menurut Peraturan Menteri Kelautan dan Perikanan RI Nomor

2/PERMEN-KP/2015. Penggunaan cantrang dilarang karena dapat menyebabkan kerusakan pada biota yang ada di laut Indonesia dan meresahkan nelayan kecil (Ambari, 2018).

Transhipment merupakan salah satu modus pencurian ikan. Modus *transhipment* artinya pemindahan muatan ikan yang terjadi di tengah lautan lepas dari satu kapal ke kapal asing. Modusnya, kapal itu menjual ikannya di laut lepas tanpa melaporkan hasil tangkapannya, baru pada tangkapan terakhir atau saat periode perizinan hampir berakhir, biasanya hasil tangkapan dilaporkan ke pejabat yang berwenang di Indonesia. Hal-hal seperti ini menjadi angka rugi yang tersamarkan (Tsamenyi & et.al, 2010). Menteri Kelautan dan Perikanan telah mengeluarkan aturan pelarangan bongkar muat atau *transhipment* diatur dalam Permen KP No. 57/2014 sejak 12 November 2014. Peraturan Menteri tentang larangan *transhipment* tujuannya untuk mencegah kapal bisa mengirim langsung ikan keluar negeri. Larangan ini agar kapal-kapal harus bersandar dahulu di pelabuhan Indonesia sebelum melakukan ekspor, di pelabuhan para kapal harus membayar Penerima Negara Bukan Pajak (PNBP) hingga retribusi lainnya (Almuzzamil, 2015). Kapal pengangkut ikan berukuran 2285 *Gross Tonage* (GT) milik Thailand MV Silver Sea 2 ditangkap oleh KRI Teuku Umar di perairan Sabang, Aceh 12 Agustus 2015. Kapal tersebut melakukan *transhipment* atau alih muatan ikan *illegal* di laut Arafura dengan kapal Pusaka Benjina Resources, dan tidak mengaktifkan Sistem Pemantauan Kapal Perikanan (VMS). Perilaku tersebut dinyatakan bersalah oleh Ketua Majelis Hakim Pengadilan Negeri Sabang pada tanggal 19 Oktober 2017, karena melanggar Peraturan KKP Nomor 57 Tahun 2014 dan UU Nomor 45 Tahun 2009 tentang perikanan.

Pemantauan saat ini terhadap aktifitas *illegal fishing* dan *transhipment* di Indonesia dilakukan melalui VTS di Kantor Pusat Kementerian Kelautan Jakarta atau dari pelabuhan terdekat. Pemantauan ini berdasarkan informasi data *Automatic Identification System* (AIS) dan radar *long range camera* yang mampu memantau hingga 40-60 kilometer, serta kamera pemantau (CCTV) sejauh 4 kilometer (Aisjah & A.A Masroeri, 2013). Kawasan laut Indonesia sangat luas, namun jumlah armada pantau belum memenuhi standar kecukupan, untuk itu perlu didukung oleh

teknologi yang mampu mengidentifikasi pelayaran yang masuk dalam kategori IUU *Fishing* dan *Transhipment*.

Adanya teknologi AIS (*Automatic Identification Sistem*) sejak tahun 1980an, sebagai suatu sistem komunikasi yang berfungsi untuk anti tabrakan, *vessel traffic services* dan *search and rescue*, dan dapat juga digunakan untuk memonitor pelayaran sudah sangat membantu dalam pemantauan aktivitas pelayaran di laut. *International Maritime Organization* (IMO) membuat peraturan mewajibkan setiap kapal untuk memasang peralatan AIS pada tahun 2000. AIS sebagai sistem informasi elektronik diharuskan dipasang di kapal berkapasitas di atas 300 GT sebagai alat pengaman kelautan (Aisjah, Arifin, Masroeri, & Saiko, 2011).

Penelitian mengenai teknologi AIS dengan integrasi sistem untuk identifikasi kapal yang terindikasi melakukan IUU *fishing* dan *transhipment* telah dirancang sebelumnya. Data statis dan dinamis pada AIS yang telah terpasang pada kapal, digunakan untuk membuat trayektori gerakan sebuah kapal dan identifikasi gerakan kapal yang dikategorikan sebagai *illegal fishing* dan *transhipment*. Penelitian mengenai sistem integrasi identifikasi kapal IUU *fishing* dan *transhipment* telah dirancang dengan berbagai metode. Sarah Maulida telah menggunakan jaringan saraf tiruan untuk merancang sistem integrasi identifikasi kapal IUU *fishing* dan *transhipment*, di mana akurasi keluaran sistem teridentifikasi melakukan IUU *fishing* dan *transhipment* masing-masing sebesar 80,53% dan 75,01% (Maulida, 2018). Selain itu, Novia Nurul Fatmawati juga telah merancang sistem integrasi identifikasi kapal IUU *fishing* dan *transhipment* menggunakan logika fuzzy, di mana akurasi keluaran sistem teridentifikasi melakukan IUU *fishing* dan *transhipment* sebesar 97,7% (Fatmawati, 2018). Kemudian, Chairani Farahdiba juga telah merancang sistem integrasi identifikasi kapal IUU *fishing* dan *transhipment* menggunakan *Adaptive Neuro-Fuzzy Inference System* (ANFIS), di mana akurasi keluaran sistem teridentifikasi melakukan IUU *fishing* dan *transhipment* masing-masing sebesar 89,3% dan 87,4% (Farahdiba, 2018). Tetapi, pada penelitian sebelumnya masih terdapat kelemahan karena saat kondisi *real* terjadinya tindakan *illegal fishing* dan *transhipment*, pada AIS terdapat *missing data* atau data yang hilang yang berdampak pada kurang akurat dan *valid* hasil dari

identifikasi gerakan kapal yang dikategorikan sebagai *illegal fishing* dan *transhipment* nantinya.

Oleh karena itu, tugas akhir ini dilakukan untuk merancang integrasi sistem dengan penambahan prediktor untuk identifikasi IUU *fishing* dan *transhipment* berbasis data AIS dengan adanya data yang hilang pada AIS menggunakan *neural networks*. Penggunaan *neural networks* pada perancangan integrasi sistem untuk identifikasi pada penelitian ini dikarenakan *neural networks* mampu menghasilkan hasil identifikasi yang lebih *general* dibandingkan metode sistem pakar lain seperti logika fuzzy yang mana pada logika fuzzy hanya mampu mengidentifikasi berdasarkan aturan yang sudah ditetapkan sehingga tidak mampu untuk mengidentifikasi sesuatu yang berada di luar aturan yang telah ditetapkan pada logika fuzzy tersebut. Berbeda dengan *neural networks*, pada *neural networks* mampu menghasilkan identifikasi yang bersifat *general* (Lorenz, Ferraudo, & Suesdek, 2015) dikarenakan *neural networks* selalu mampu mempelajari hal-hal baru selama ada data baru dan dilakukan terus pelatihan sehingga *neural networks* mampu mengidentifikasi sesuatu tanpa dibatasi oleh aturan seperti pada logika fuzzy. Data AIS kapal *illegal fishing* dan *transhipment* sebelum data hilang akan dijadikan informasi masukan untuk prediksi data AIS yang hilang pada kapal *illegal fishing* dan *transhipment*. Keluaran hasil dari prediksi akan dijadikan informasi masukan perancangan integrasi sistem untuk identifikasi terjadinya *illegal fishing* dan *transhipment*.

1.2 Rumusan Masalah

Dari latar belakang yang telah dibahas sebelumnya, maka dapat dirumuskan permasalahan di antaranya:

- a) Bagaimana merancang integrasi sistem dengan prediktor untuk identifikasi terjadinya IUU *fishing* dan *transhipment* dengan adanya data AIS yang hilang menggunakan *neural networks*?
- b) Bagaimana merancang prediktor dengan akurasi tinggi untuk prediksi data AIS yang hilang pada kapal pelaku *illegal fishing* dan *transhipment*?
- c) Apakah hasil keluaran dari prediktor dapat digunakan sebagai masukan untuk integrasi sistem identifikasi kapal *illegal fishing* dan *transhipment*?

- d) Bagaimana membangun model pada integrasi sistem dengan *neural networks* yang mampu mengidentifikasi kapal-kapal yang diduga melakukan *illegal fishing* dan *transhipment* dengan akurasi tinggi?

1.3 Tujuan

Berdasarkan rumusan masalah yang telah disebutkan di atas sehingga tujuan dari tugas akhir ini yaitu:

- a) Dapat merancang integrasi sistem dengan prediktor untuk identifikasi terjadinya IUU *fishing* dan *transhipment* dengan adanya data AIS yang hilang menggunakan *neural networks*.
- b) Dapat merancang prediktor dengan akurasi tinggi untuk prediksi data AIS yang hilang pada kapal pelaku *illegal fishing* dan *transhipment*.
- c) Mengetahui apakah hasil keluaran dari prediktor dapat digunakan sebagai masukan untuk integrasi sistem identifikasi kapal *illegal fishing* dan *transhipment*.
- d) Mampu membangun model pada integrasi sistem dengan *neural networks* yang mampu mengidentifikasi kapal-kapal yang diduga melakukan *illegal fishing* dan *transhipment* dengan akurasi tinggi.

1.4 Batasan Masalah

Batasan masalah yang digunakan pada tugas akhir ini di antaranya:

- a) Data diperoleh dari pusat data *marinetraffic.com* dan *National Ship Design & Engineering Center* (NASDEC)-ITS.
- b) Prediktor untuk prediksi data AIS yang hilang pada kapal pelaku IUU *fishing* dan *transhipment* dirancang menggunakan *recurrent neural networks* (RNN) dan metode perbandingan senilai.
- c) Prediksi dilakukan dengan mempelajari pola dan tingkah laku historis data AIS kapal pelaku IUU *fishing* dan *transhipment*.
- d) Integrasi sistem untuk identifikasi kapal pelaku IUU *fishing* dan *transhipment* dirancang menggunakan *artificial neural networks* (ANN).
- e) Identifikasi IUU *fishing* hanya untuk identifikasi kapal yang memakai alat tangkap ikan cantrang.

- f) Asumsi bahwa pada kapal telah terpasang peralatan AIS dan terdapat data yang hilang pada data AIS.
- g) Variabel yang digunakan sebagai variabel masukan dalam integrasi sistem dengan prediktor untuk identifikasi adalah data statis dan dinamis yang diperoleh dari AIS.
- h) Perancangan model RNN untuk prediktor dan model ANN untuk identifikasi ditulis dalam bahasa pemrograman Python menggunakan Keras *library* dengan TensorFlow *backend* dan Scikit-Learn *library*.

1.5 Sistematika Laporan

Dalam laporan tugas akhir ini terdiri dari beberapa bab, sebagai berikut :

- a) BAB I Pendahuluan : Bab ini menjelaskan tentang latar belakang penelitian, rumusan masalah, tujuan, batasan masalah, dan sistematika laporan.
- b) BAB II Dasar Teori : Bab ini menjelaskan tentang teori-teori penunjang yang digunakan dalam penelitian ini.
- c) BAB III Metodologi Penelitian : Bab ini menjelaskan secara detail mengenai langkah-langkah yang dilakukan dalam perancangan prediktor dan integrasi sistem untuk identifikasi kapal pelaku IUU *Transhipment* dan IUU *Fishing*.
- d) BAB IV Hasil Dan Pembahasan : Pada bab ini menjelaskan hasil dan pembahasan dari perancangan prediktor dan integrasi sistem untuk identifikasi kapal pelaku IUU *Transhipment* dan IUU *Fishing*.
- e) BAB V Kesimpulan dan Saran : Dalam bab ini berisi kesimpulan dan saran dalam penelitian ini.
- f) Lampiran : Berisi program yang digunakan dalam perancangan, data-data perancangan dan pengujian secara lengkap yang telah dilakukan.

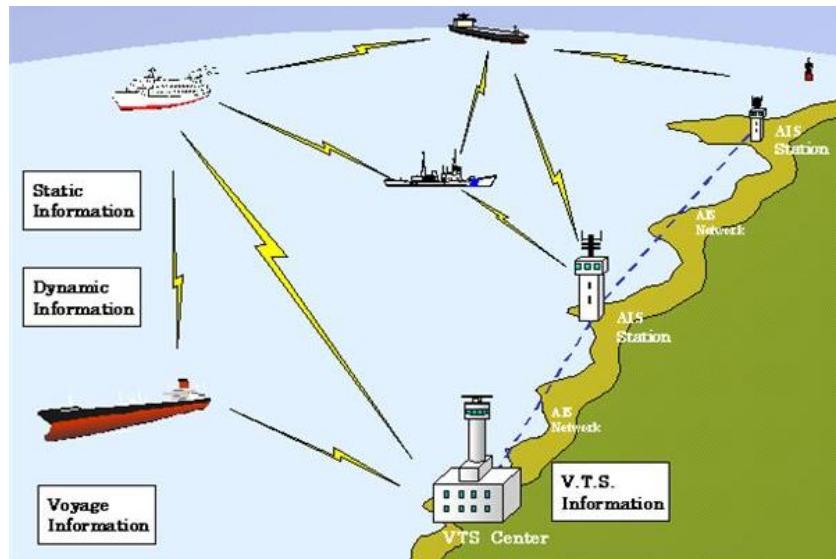
BAB II

DASAR TEORI

2.1 Teknologi AIS

Secara sederhana, *Automatic Identification System* (AIS) adalah sebuah teknologi untuk membuat kapal-kapal terlihat satu sama lain. Sistem AIS mentransmisikan data status pelayaran kapal dan menukar data tersebut dengan kapal terdekat lainnya dan stasiun darat. Data AIS dikirim setiap beberapa detik melalui dua saluran *Very High Frequency* (VHF) laut digital khusus dalam ruang geografis yang terbatas. Interval transmisi bervariasi berdasarkan kecepatan dan laju perubahan arah. Kapal yang lebih cepat dan berputar lebih sering diperbarui datanya. Transponder AIS berkerja secara kontinu dalam mengirimkan datanya. Kapal yang tertambat dan berlabuh mengirimkan datanya lebih jarang (Huang, Nieh, & Kuo, 2019). Data yang dikirimkan oleh AIS terdiri dari beberapa klasifikasi data, yaitu data statik, data dinamik, data terkait pelayaran, dan pesan keamanan singkat. Data statik dimasukkan ke dalam AIS pada instalasi dan perlu diubah hanya jika jenis kapal berubah oleh perubahan besar atau jika nama atau tanda panggilannya berubah. Sebagian besar data dinamis akan secara otomatis diperbarui melalui sensor kapal yang terhubung dengan AIS, dan data terkait pelayaran dimasukkan secara manual selama setiap pelayaran (Harati-Mokhtar, Wall, Brook, & Wang, 2007). Data-data AIS tersebut termasuk identifikasi, posisi, kegiatan atau keadaan kapal, dan kecepatan, dengan kapal terdekat yang lainnya dan stasiun VTS melalui gelombang radio (Saputra & Istardi, 2016).

International Maritime Organization (IMO) *International Convention for the Safety of Life at Sea* (SOLAS) mewajibkan penggunaan AIS pada pelayaran kapal internasional dengan *Gross Tonnage* (GT) lebih dari sama dengan 300 GT pada pelayaran internasional dan diatas 500GT pada pelayaran non-internasional dan seluruh kapal penumpang (*passenger ship*) diwajibkan menggunakan peralatan AIS (IMO, 1998).



Gambar 2.1 Prinsip kerja *Automatic Identification System* (AIS) (U.S. Coast Guard Navigation Center, 2010)

Sistem AIS mampu menangani lebih dari 2000 data setiap menit dan diperbarui setiap dua detik. AIS diklasifikasikan menjadi 7 tipe yaitu *Class A*, *Class B*, *Base Station*, *Aids to Navigation* (AtoN), *Search and Rescue Transponder* (SART) dan *Specialist AIS Transponder* (IMO, 1998). Sebagian besar kapal besar dilengkapi AIS kelas A sebagai *transceiver* (untuk mengirim dan menerima) dengan daya transmisi 12,5 W dan kemampuan untuk menyimpan slot pengiriman melalui 2 penerima dalam operasi kontinu. AIS kelas A mampu memberikan informasi setiap 2 hingga 10 detik selama pada kondisi berlayar, dan setiap 3 menit selama kondisi lego jangkar. Untuk kapal kecil dan sejenisnya menggunakan AIS kelas B dengan daya transmisi yang lebih kecil (2 W) dan tidak secanggih AIS kelas A untuk mentrasmisikan informasi. Laju siaran informasi AIS kelas B setiap 30 detik atau 3 menit tergantung pada kecepatan kapal (Longépé, Ardianto, & Hajduch, 2017). Informasi yang diberikan oleh AIS A di antaranya adalah:

1. *MMSI number*
2. *Navigation Status*
3. *Rate of turn*
4. *Speed over ground*
5. *Position accuracy*
6. *Longitude and Latitude*

7. *Course over ground*
8. *True heading*
9. *Time stamps*

Informasi tambahan yang diberikan oleh AIS kelas A setiap 6 menit di antaranya:

1. *MMSI number*
2. *IMO Number*
3. *Radio call sign*
4. *Name of ship*
5. *Dimension of ship*
6. *Refenrence point location*
7. *Type of possition fixing devices*
8. *Draught of ship*
9. *Destination*
10. *Estimated time of Arrival at destination*

AIS kelas B sama seperti kelas A di atas kecuali untuk beberapa hal, yaitu:

1. Informasi yang dikirim lebih jarang dari kelas A
2. Tidak mentransmisikan nomor IMO atau *call sign*
3. Tidak mentransmisikan ETA atau destinasi
4. Tidak mentransmisikan navigational status
5. Hanya digunakan untuk menerima, tidak mentransmisikan *text safety messages*
6. Hanya digunakan untuk menerima, tidak mentransmisikan, *application identifiers (binary messages)*
7. Tidak mentransmisikan informasi *rate of turn*
8. Tidak mentransmisikan *maximum present static draught*

Pada penelitian Tugas Akhir ini data dinamis AIS yaitu *longitude*, *latitude*, *heading*, dan *speed* akan digunakan sebagai data masukan dalam perancangan prediktor dan integrasi sistem untuk identifikasi terjadinya *illegal fishing* dan *transhipment*.

2.2 Artificial Neural Networks (ANN)

Artificial neural networks (ANN) atau jaringan saraf tiruan adalah sebuah model komputasi yang mempunyai karakteristik menyerupai jaringan saraf manusia yang didasarkan atas asumsi sebagai berikut (Hermawan, 2006):

1. Pemrosesan informasi terjadi pada elemen sederhana yang disebut neuron.
2. Isyarat mengalir di antara sel saraf/neuron melalui satu sambungan penghubung.
3. Setiap sambungan penghubung memiliki bobot yang bersesuaian.
4. Setiap sel saraf akan menerapkan fungsi aktivasi terhadap isyarat hasil penjumlahan berbobot yang masuk kepadanya untuk menentukan isyarat keluarannya.

Struktur dasar jaringan saraf tiruan adalah jaringan diarahkan dari node pemrosesan independen yang digabung menggunakan koneksi berbobot (Graves, 2012). Node mewakili neuron dan koneksi mewakili sinapsis di antara mereka. Aktivasi jaringan dilakukan dengan memberikan input, yang kemudian merambat dari node input dan melalui seluruh jaringan. Perbedaan penting dalam ANN adalah antara siklik dan asiklik. Jaringan siklik biasanya disebut sebagai umpan balik, rekursif, atau *recurrent NN* (NN berulang) dan digunakan untuk perancangan prediktor dalam penelitian ini. Jaringan asiklik disebut NN *feedforward*, seperti jaringan *multilayer perceptron*, dikembangkan dan diteliti oleh Rumelhart et al. (Rumelhart, Hinton, & Williams, 1987), Werbos (Werbos, 1988), dan Bishop (Bishop, 1995).

ANN tediri oleh lapisan-lapisan (*layers*). Setiap lapisan neuron terhubung dengan neuron lapisan sebelumnya dan berikutnya. Neuron di lapisan yang sama tidak berkomunikasi. Lapisan antara lapisan masukan (*input layer*) dan lapisan keluaran (*output layer*) dianggap sebagai lapisan tersembunyi (*hidden layers*). Setiap masukan neuron terdiri dari jumlah bobot dari keluaran yang berasal dari neuron yang terhubung pada lapisan sebelumnya, ditambah konstanta bias. Keluaran neuron ke lapisan berikutnya adalah nilai masukannya diumpulkan ke fungsi aktivasi. Fungsi aktivasi dapat berupa fungsi linier, tetapi lebih umum sigmoid, *Rectified Linear Unit* (ReLU), atau fungsi nonlinear lainnya.

ANN adalah *universal approximators* yang biasanya menggunakan *supervised learning* untuk melatih parameter mereka (bobot dan bias) untuk tugas yang diberikan melalui proses optimisasi (Goodfellow, Bengio, & Courville, 2016). Proses optimisasi mencoba untuk meminimalkan *loss* pada set poin data yang disebut set pelatihan. ANN menggunakan berbagai *loss functions*, termasuk *mean* atau *absolute squared error*, *categorical cross entropy*, dan *cosine proximity*. Dalam banyak kasus *loss functions* yang digunakan disesuaikan untuk mengakomodasi masalah yang diberikan. Kelebihan ANN di antaranya (Makarynskyy, 2004):

- Dapat digunakan untuk peramalan sistem *nonlinier*
- Mempermudah pemetaan keluaran sistem tanpa mengetahui proses yang terjadi (*black-box*)
- Memiliki kemampuan untuk mempelajari suatu proses berdasarkan data yang diberikan *training* (Sutojo, 2010)
- Mampu merepresentasikan informasi yang diterima selama proses *training* (Sutojo, 2010)

Baik tidaknya suatu model ANN ditentukan oleh (Sutojo, 2010) :

- Arsitektur jaringan, yaitu sebuah arsitektur yang menentukan pola antar *neuron*
- Metode pembelajaran, yaitu metode yang digunakan untuk menentukan dan mengubah bobot
- Fungsi aktivasi
- Pemilihan masukan (Papslinka-Swerpel, 2006)

2.2.1 Arsitektur Jaringan

Arsitektur jaringan adalah hubungan antar neuron. Neuron – neuron tersebut terkumpul dalam lapisan – lapisan yang disebut lapisan *neuron*. Lapisan – lapisan tersebut adalah (Sutojo, 2010) :

1. Lapisan masukan (*Input layer*)

Merupakan unit masukan yang bertugas menerima pola masukan yang menggambarkan suatu permasalahan.

2. Lapisan tersembunyi (*Hidden layers*)

Merupakan unit tersembunyi di mana keluarannya tidak dapat diamati secara langsung. Lapisan tersembunyi berada di antara lapisan masukan dan lapisan keluaran.

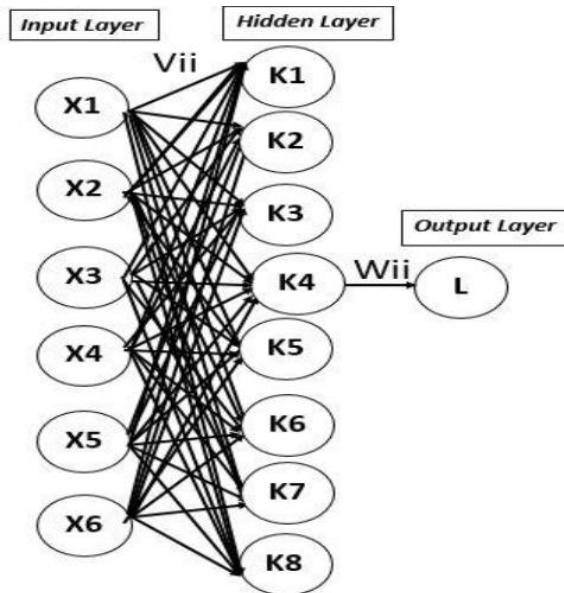
3. Lapisan keluaran (*Output layer*)

Unit keluaran yang merupakan solusi jaringan saraf tiruan.

2.2.2 Algoritma Pembelajaran

Proses pembelajaran jaringan saraf tiruan terdiri dari *forward*, *backward*, dan *update* bobot. Semakin banyak *training* yang terjadi maka akan semakin kecil eror yang dihasilkan pada keluaran (Sutojo, 2010). Sehingga semakin kecil pula eror suatu sistem. Salah satu algoritma pembelajaran atau pelatihan pada jaringan saraf tiruan yang sering digunakan adalah algoritma Levenberg-Marquardt.

Algoritma Levenberg-Marquardt merupakan salah satu jenis dari algoritma pelatihan JST *Backpropagation* dengan dua jenis perhitungan, yaitu perhitungan maju dan perhitungan mundur. Langkah dasar algoritma Levenberg-Marquardt adalah penentuan matriks Hessian untuk mencari bobot-bobot dan bias koneksi yang digunakan. Matriks Hessian merupakan turunan kedua dari fungsi kinerja terhadap masing-masing komponen bobot dan bias. Matriks Hessian diubah dengan pendekatan secara iteratif pada masing-masing *epoch* selama algoritma pelatihan berjalan dengan tujuan untuk memudahkan komputasi. *Epoch* pada jaringan saraf tiruan merupakan sebuah proses pengulangan untuk melakukan pembaharuan bobot dengan menggunakan seluruh data pelatihan. Gambar 2.2 menunjukkan arsitektur untuk pelatihan trayektori IUU *Fishing* dengan *backpropagation Levenberg-Marquardt*.



Gambar 2. 2 Arsitektur JST pada pelatihan trayektori IUU *fishng* (Maulida, 2018)

2.2.3 Fungsi Aktivasi

Fungsi aktivasi digunakan untuk menentukan keluaran suatu neuron. Mengaktifkan jaringan saraf tiruan berarti mengaktifkan neuron pada jaringan saraf tiruan tersebut. Fungsi aktivasi dalam mengaktifkan jaringan saraf tiruan yang digunakan dalam perancangan integrasi sistem untuk identifikasi pada penelitian ini adalah fungsi aktivasi *Rectified Linear Unit* (ReLU) dan sigmoid.

Fungsi aktivasi ReLu merupakan fungsi aktivasi yang paling banyak digunakan saat ini, terutama diimplementasikan dalam lapisan tersembunyi (*hidden layers*). Fungsi ReLu didapat dengan persamaan (2.1). *Output* y adalah nol ketika *input* x kurang dari nol dan *output* y sama dengan x ketika *input* x di atas atau sama dengan nol. Ini melibatkan operasi matematika yang lebih sederhana dibandingkan dengan sigmoid. Yang membuatnya lebih cepat dalam perhitungan.

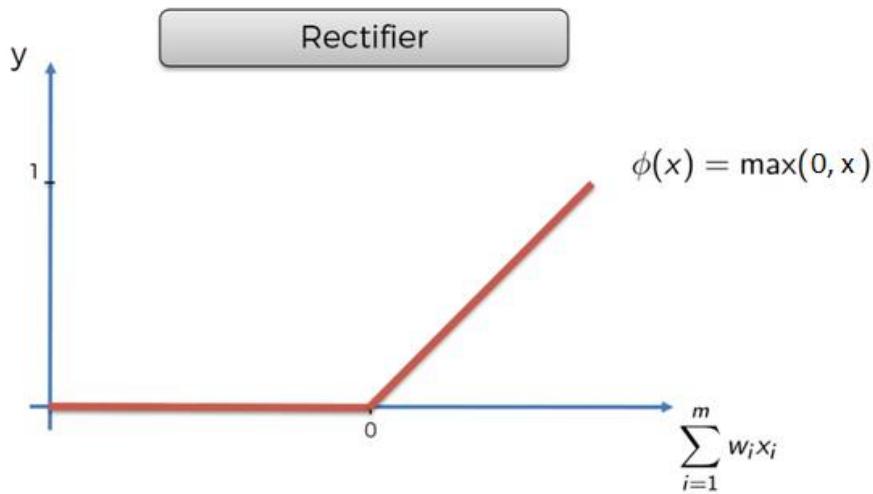
$$y = f(x) = \max(0, x) \quad (2.1)$$

Dengan :

x = masukan

y = keluaran

Gambar 2.3 merupakan fungsi aktivasi ReLu di mana sumbu x merupakan masukan dan sumbu y merupakan keluaran.



Gambar 2.3 Fungsi aktivasi ReLu

Fungsi aktivasi sigmoid memiliki *range* dari 0 sampai 1 yang didapat dengan persamaan (2.2). Fungsi aktivasi sigmoid merupakan fungsi non-linear. Pada fungsi aktivasi sigmoid perubahan kecil dalam nilai x juga akan membawa perubahan besar dalam nilai y . Biasanya digunakan pada *output layer* dalam klasifikasi biner di mana hasilnya dapat diprediksi dengan mudah menjadi 1 jika nilainya lebih besar dari 0,5 dan sebaliknya menjadi 0 jika nilainya lebih kecil dari 0,5.

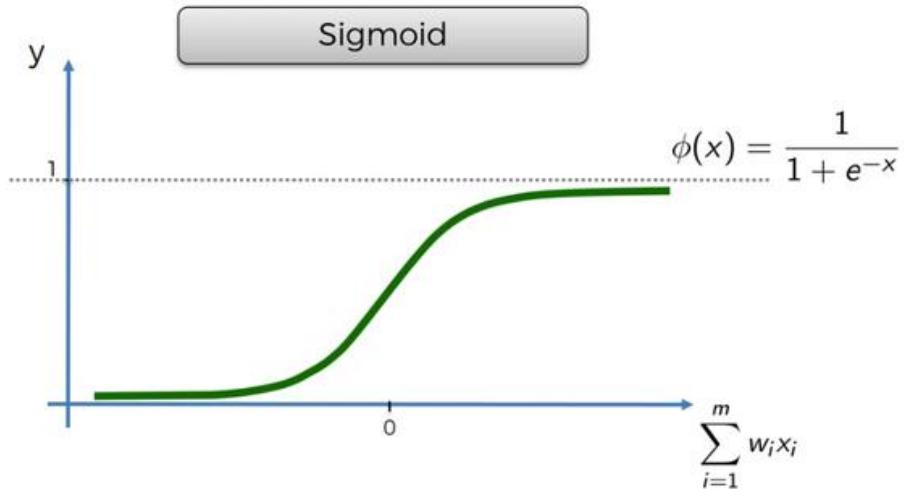
$$y = f(x) = \frac{1}{1 + e^{-\sigma x}} \quad (2.2)$$

Dengan :

x = masukan

y = keluaran

Gambar 2.4 merupakan fungsi aktivasi sigmoid di mana sumbu x merupakan masukan dan sumbu y merupakan keluaran.



Gambar 2. 4 Fungsi aktivasi sigmoid

2.3 K-Fold Cross Validation

Cross-validation atau validasi silang adalah sebuah teknik validasi model untuk menilai bagaimana hasil statistik analisis akan menggeneralisasi kumpulan data independen. Teknik ini utamanya digunakan untuk melakukan prediksi model dan memperkirakan seberapa akurat sebuah model prediktif ketika dijalankan dalam praktiknya. Salah satu teknik dari validasi silang adalah *k-fold cross validation*, yang mana memecah data menjadi k bagian set data dengan ukuran yang sama. *K-fold cross validation* digunakan untuk menghilangkan bias pada data. Pelatihan dan pengujian dilakukan sebanyak k kali. Pada percobaan pertama, subset S_1 diperlakukan sebagai data pengujian dan subset lainnya diperlakukan sebagai data pelatihan, pada percobaan kedua subset S_1, S_3, \dots, S_k menjadi data pelatihan dan S_2 menjadi data pengujian, dan seterusnya (Bramer, 2007).

Pada Gambar 2. 5 merupakan penggunaan *3-fold cross validation*. Di mana setiap data akan di eksekusi sebanyak 3 kali dan setiap subset data akan mempunyai kesempatan sebagai data pengujian atau data pelatihan. Model pengujian seperti berikut dengan diasumsikan nama setiap pembagian data yaitu D_1, D_2 , dan D_3 :

1. Percobaan pertama data D_1 sebagai data pengujian sedangkan D_2 dan D_3 sebagai data pelatihan.
2. Percobaan pertama data D_2 sebagai data pengujian sedangkan D_1 dan D_3 sebagai data pelatihan.

3. Percobaan pertama data D3 sebagai data pengujian sedangkan D1 dan D2 sebagai data pelatihan.



Gambar 2.5 Model representasi skematis prosedur *k-fold cross validation* dengan $k=3$

Untuk pengukuran performa klasifikasi yaitu dengan cara membandingkan seluruh data uji yang diklasifikasi benar dengan banyaknya data uji. Persamaan (2.3) adalah persamaan yang digunakan untuk mengukur kinerja klasifikasi.

$$\text{akurasi} = \frac{\sum \text{klasifikasi benar}}{\sum \text{data uji}} \times 100\% \quad (2.3)$$

Selain itu, standar deviasi (*standar deviation*) juga akan dihitung, standar deviasi adalah ukuran penyebaran data yang menunjukkan jarak rata-rata dari nilai tengah ke suatu titik nilai. Semakin besar standar deviasi yang dihasilkan, maka penyebaran dari nilai tengahnya juga besar, begitu pula sebaliknya. Tujuan dihitung standar deviasi dalam penelitian ini yaitu untuk melihat jarak antara rata-rata akurasi dengan akurasi setiap percobaan. Persamaan (2.4) adalah persamaan yang digunakan untuk menghitung standar deviasi (Brown, 1982).

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (2.4)$$

dengan:

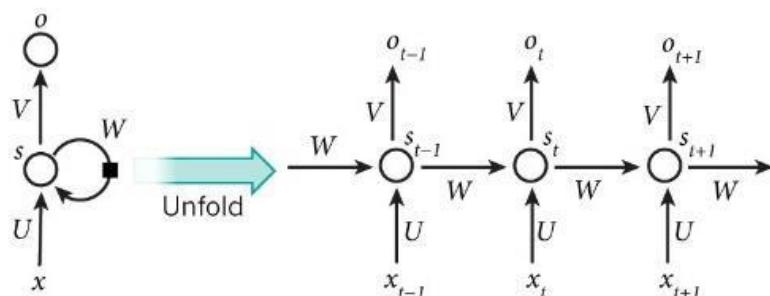
σ = standar deviasi

x = percobaan ke-i

μ	= mean
N	= banyaknya percobaan
i	= indeks setiap percobaan

2.4 Recurrent Neural Networks (RNN)

Recurrent Neural Network (RNN) atau jaringan saraf berulang, pertama dikembangkan oleh Jeff Elman pada tahun 1990 (Elman, 1990). RNN merupakan variasi dari ANN, perbedaan utama yang terdapat pada model ini adalah sinyal dapat mengalir secara *forward* dan *backward* secara berulang. Untuk bisa melakukan hal tersebut, maka ditambahkan sebuah layer baru yang disebut dengan *context layer*. Selain melewati input antar *layer*, output dari setiap *layer* juga menuju ke *context layer* untuk digunakan sebagai inputan pada *time step* berikutnya. RNN menyimpan informasi di *context layer*, yang membuatnya dapat mempelajari urutan data dan menghasilkan output atau urutan lain. Jika ditarik kesimpulan maka bisa dikatakan bahwa RNN memiliki memori yang berisikan hasil rekaman informasi yang dihasilkan sebelumnya, sehingga RNN sangat cocok digunakan untuk prediksi *time series*.

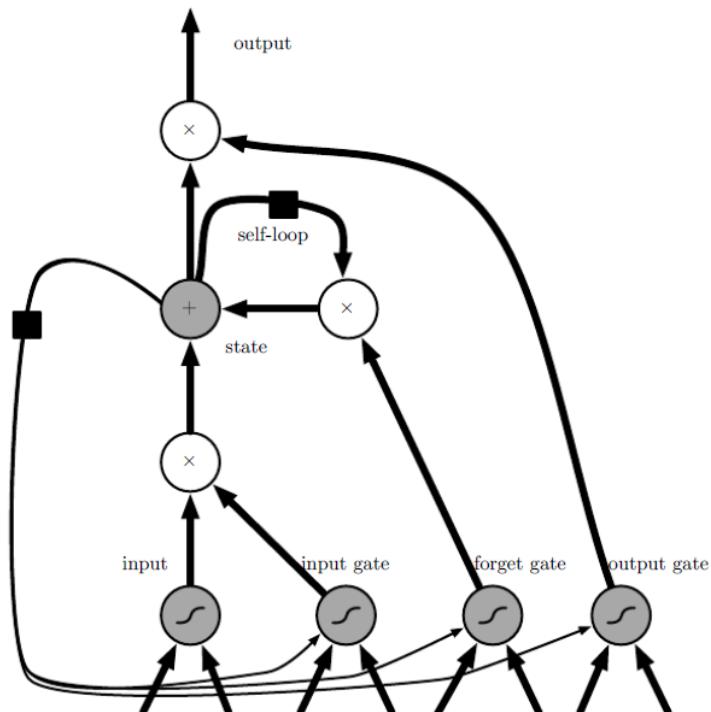


Gambar 2.6 Proses RNN

Gambar 2.6 menunjukkan RNN pada posisi yang tidak dibuka ke *full network*. Dengan membuka gulungan RNN maka sederhananya kita menuliskan seluruh jaringan dengan urutan (*sequence*) secara lengkap. Berikut ialah keterangan simbol yang ada pada Gambar 2.6 :

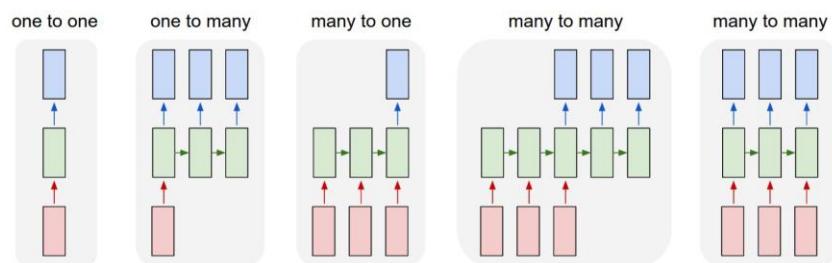
1. x_t ialah input pada setiap *time step*.
2. s_t adalah *hidden state* pada setiap *time step* t
3. o_t adalah output untuk setiap *step* t

Banyak jenis lapisan ANN telah dikembangkan dan digunakan untuk memproses gambar, teks, suara, dan jenis informasi lainnya. Karena penelitian ini berkaitan dengan RNN, jenis lapisan penting adalah lapisan berulang yang disebut *Long Short-Term Memory* (LSTM). Seperti Goodfellow et al. (Goodfellow, Bengio, & Courville, 2016) jelaskan, unit-unit ini memiliki struktur yang agak lebih kompleks daripada neuron sederhana. Selain dari "perulangan" beberapa output mereka kembali ke diri mereka sendiri sebagai input pada langkah waktu berikutnya, yang umum untuk semua unit berulang di RNN, LSTM memiliki satu set gerbang yang mengontrol keadaan internal mereka. LSTM mengontrol berapa banyak input saat ini akan diambil menggunakan gerbang input. Mereka mengatur berapa banyak dari keadaan sebelumnya akan dilingkarkan kembali ke keadaan saat ini menggunakan gerbang lupa dan berapa banyak keadaan internal akan menjadi output menggunakan gerbang keluaran. Semua gerbang ini dipengaruhi oleh keadaan internal unit LSTM, yang terdiri dari parameter yang dapat dilatih. Diagram unit LSTM ditunjukkan pada Gambar 2.7.



Gambar 2.7 Diagram unit LSTM (Goodfellow, Bengio, & Courville, 2016)

RNN dapat mengambil input berurutan seperti *times series* pada harga saham, kalimat atau dokumen, serangkaian bingkai gambar dari video, atau rekaman suara, dan mereka juga dapat mengambil input ukuran tetap berapa pun panjangnya. Dengan cara yang sama, output mereka mungkin berupa prediksi tunggal berdasarkan seluruh seri input, serangkaian prediksi panjang tetap, atau output panjang tidak tetap. Gambar 2.8 menunjukkan tentang fleksibilitas arsitektur RNN. Persegi panjang merah mewakili input RNN dan persegi panjang biru mewakili output.



Gambar 2.8 Fleksibilitas arsitektur RNN (Karpathy, 2015)

Seperti yang dijelaskan Karpathy (Karpathy, 2015), RNN dapat menggunakan arsitektur satu-ke-banyak untuk penulisan gambar di mana input adalah gambar tunggal dan outputnya berupa kalimat dengan panjang variabel. Ini bisa berupa arsitektur banyak ke satu, seperti analisis sentimen suatu kalimat.

2.5 Mean Absolute Percentage Error (MAPE)

Dalam membuat pemodelan suatu sistem/subsistem prediktor dilakukan evaluasi untuk mengetahui kinerja dari sistem/subsistem prediktor yang digunakan. Evaluasi pada subsistem prediktor pada penelitian ini dilakukan menggunakan *Mean Absolute Percentage Error* (MAPE).

Mean Absolute Percentage Error (MAPE) dihitung dengan menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu. Lalu, merata-rata kesalahan persentase absolut tersebut. pendekatan yang dilakukan ini berfungsi saat ukuran atau besar variabel prediksi itu penting dalam mengevaluasi ketepatan prediksi. MAPE mengindikasi seberapa besar kesalahan dalam prediksi yang dibandingkan dengan nilai nyata. Rumus dari MAPE ditunjukkan pada Persamaan (2.5).

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{x-x'}{x} \right| \quad (2.5)$$

dengan:

x = data aktual

x' = data hasil prediksi

n = jumlah data

Nilai MAPE di atas merepresentasikan nilai prediksi. Apabila nilai MAPE semakin kecil menunjukkan bahwa hasil prediksi semakin baik dan akurat. Skala dalam menentukan apakah suatu prediktor bernilai akurat atau tidak berdasarkan MAPE telah dikembangkan oleh Lewis (Lewis, 1982) (Klimberg, Sillup, Boyle, & Tavva, 2010). Pada Tabel 2.1 merupakan klasifikasi akurasi suatu prediktor yang telah dikembangkan oleh Lewis.

Tabel 2.1 Skala Penentuan Nilai Akurasi Suatu Prediktor

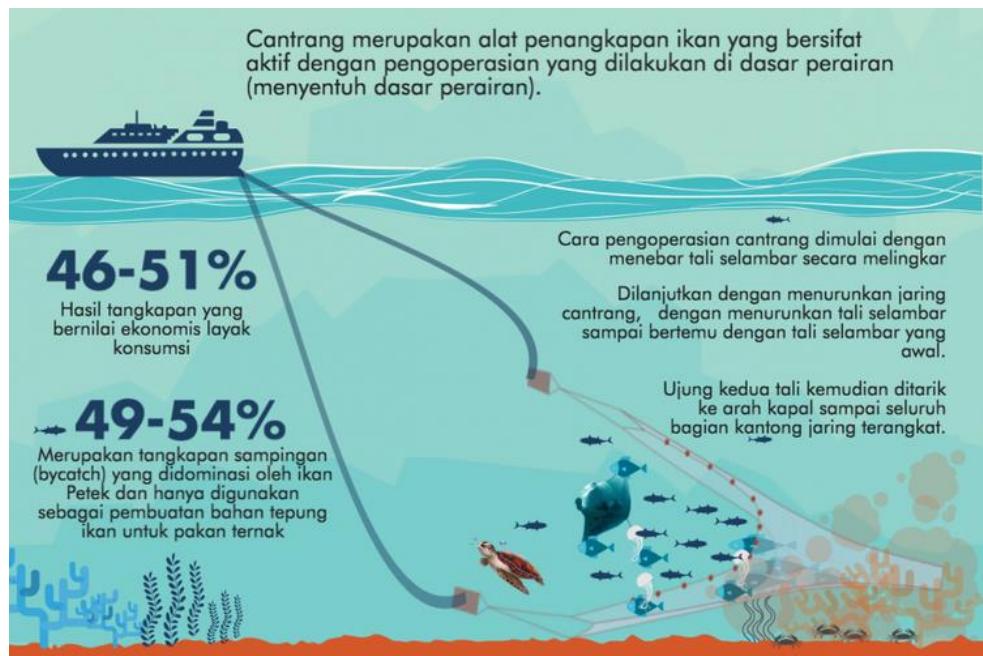
MAPE	Nilai Akurasi
$\leq 10\%$	<i>Highly accurate</i>
11%-20%	<i>Good forecast</i>
21%-50%	<i>Reasonable forecast</i>
$\geq 51\%$	<i>Inaccurate forecast</i>

2.6 IUU *Fishing*

IUU Fishing menurut *International Plan of Action* (IPOA) adalah kegiatan menangkap ikan yang bertentangan dengan peraturan nasional yang berlaku atau kewajiban internasional, kegiatan penangkapan ikan yang tidak pernah dilaporkan atau dilaporkan secara tidak benar kepada intansi yang berwenang, dan kegiatan penangkapan ikan dengan cara tidak sesuai dengan ketentuan pelestarian dan pengelolaan pada suatu area organisasi pengelolaan perikanan regional. Dalam pengertian yang lebih sederhana dan bersifat operasional, *IUU Fishing* dapat diartikan sebagai kegiatan perikanan yang melanggar hukum (Gustina, 2014).

Kasus *IUU fishing* masih banyak terjadi di wilayah laut Indonesia, diperkirakan pencurian ikan oleh nelayan dan kapal asing jumlahnya sebesar 1 juta

ton/tahun (Rp 30 triliun/tahun). Kasus IUU *fishing* yang sering terjadi di Indonesia dilakukan oleh nelayan dan kapal asing yang memakai alat tangkap ikan terlarang yaitu cantrang.



Gambar 2.9 Ilustrasi operasi alat tangkap cantrang (KKP, 2019)

Cantrang merupakan alat penangkapan ikan bersifat aktif dengan pengoperasian dilakukan di dasar perairan (menyentuh dasar perairan). Cara pengoperasian cantrang dimulai dengan menebar tali selambar secara melingkar, dilanjutkan dengan menurunkan jaring cantrang, dengan menurunkan tali selambar sampai bertemu dengan tali selambar yang awal, proses ini dinamakan *casting*, di mana pada proses ini kecepatan kapal berada di bawah 1 knot. Ujung kedua tali jaring kemudian ditarik ke arah kapal, pada proses ini jaring ditarik secara vertikal dan dilakukan dengan kecepatan kapal 1 sampai dengan 2 knot, proses ini dinamakan *towing*. Kemudian jaring ditarik sampai seluruh bagian kantong jaring terangkat ke atas kapal, dilakukan dengan posisi kapal bertahan atau mendekati 0 knot, proses ini dinamakan *hauling* (Badan Standardisasi Nasional, 2006) (Ambari, 2018).

Penggunaan cantrang dalam penangkapan ikan dinilai *illegal* karena merusak biota bawah laut dan menyebabkan kerugian yang besar. Daerah yang menjadi titik rawan terjadinya IUU *fishing* adalah Laut Arafuru, Laut Natuna, Sebelah Utara

Sulawesi Utara (Samudra Pasifik), Selat Makassar, Barat Sumatera (Samudera Hindia) (Gustina, 2014).

2.7 IUU *Transhipment*

Transhipment merupakan salah satu modus pencurian ikan. Modus *transhipment* artinya pemindahan muatan ikan yang terjadi di tengah lautan lepas dari satu kapal ke kapal lain atau kapal asing. Modusnya, kapal itu menjual ikannya di laut lepas tanpa melaporkan hasil tangkapannya, baru pada tangkapan terakhir atau saat periode perizinan hampir berakhir, biasanya hasil tangkapan dilaporkan ke pejabat yang berwenang di Indonesia. Hal-hal seperti ini menjadi angka rugi yang tersamarkan (Tsamenyi & et.al, 2010). Menteri Kelautan dan Perikanan telah mengeluarkan aturan pelarangan bongkar muat atau *transhipment* diatur dalam Permen KP No. 57/2014 sejak 12 November 2014. Peraturan Menteri tentang larangan *transhipment* tujuannya untuk mencegah kapal bisa mengirim langsung ikan keluar negeri. Larangan ini agar kapal-kapal harus bersandar dahulu di pelabuhan Indonesia sebelum melakukan ekspor, di pelabuhan para kapal harus membayar Penerima Negara Bukan Pajak (PNBP) hingga retribusi lainnya (Almuzzamil, 2015).



Gambar 2. 10 Ilustrasi *transhipment*

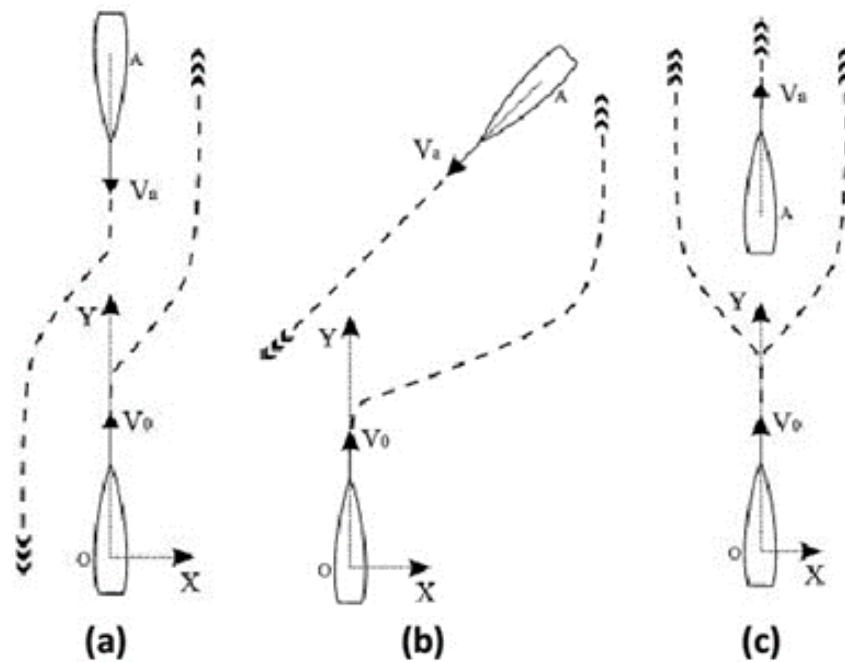
Pola pelaku *transhipment* biasanya ditandai dengan adanya dua kapal di tengah laut dengan jarak yang berdekatan dan kedua kapal memiliki *heading*

tertentu. Sangat kecil sekali kemungkinan dua kapal berdekatan di tengah laut tanpa melakukan *transhipment*.

2.8 Collision Regulations (COLREGs)

COLREGs merupakan akronim dari *Collision Regulations* atau yang secara lengkapnya *International Regulations for Preventing Collisions at Sea* yaitu peraturan internasional untuk pencegahan tabrakan antar kapal. COLREGs diterbitkan oleh *International Maritime Organization* (IMO) pada tahun 1972.

Peraturan COLREGs mengenai tabrakan dibahas pada bagian *Steering and Sailing*. Pada bagian ini, terdapat tiga jenis teknik *manuver* dalam menghindari tabrakan antar kapal, yaitu *head-on*, *overtake*, dan *crossing*. Dalam pembahasan mengenai *anti-collision ship* (anti-tabrakan kapal), terdapat istilah yang sering digunakan yakni *own vessel* dan *target vessel*. *Own vessel* merupakan kapal yang dapat dikendalikan sedangkan *target vessel* merupakan kapal yang menjadi sasaran ketika terjadi tabrakan. Pada Gambar 2. 11 merupakan ilustrasi pengaplikasian peraturan COLREGs dan regulasinya untuk *anti-collision ship*.



Gambar 2. 11 COLREGs (a) *head on*, (b) *crossing*, (c) *overtake*
[\(www.fishweb.com/boating/rules/crossing.gif\)](http://www.fishweb.com/boating/rules/crossing.gif)

Pola *head on*, *overtake* dan *crossing* tersebut dijadikan acuan sebuah kapal melakukan IUU *Transhipment* dan *Fishing*.

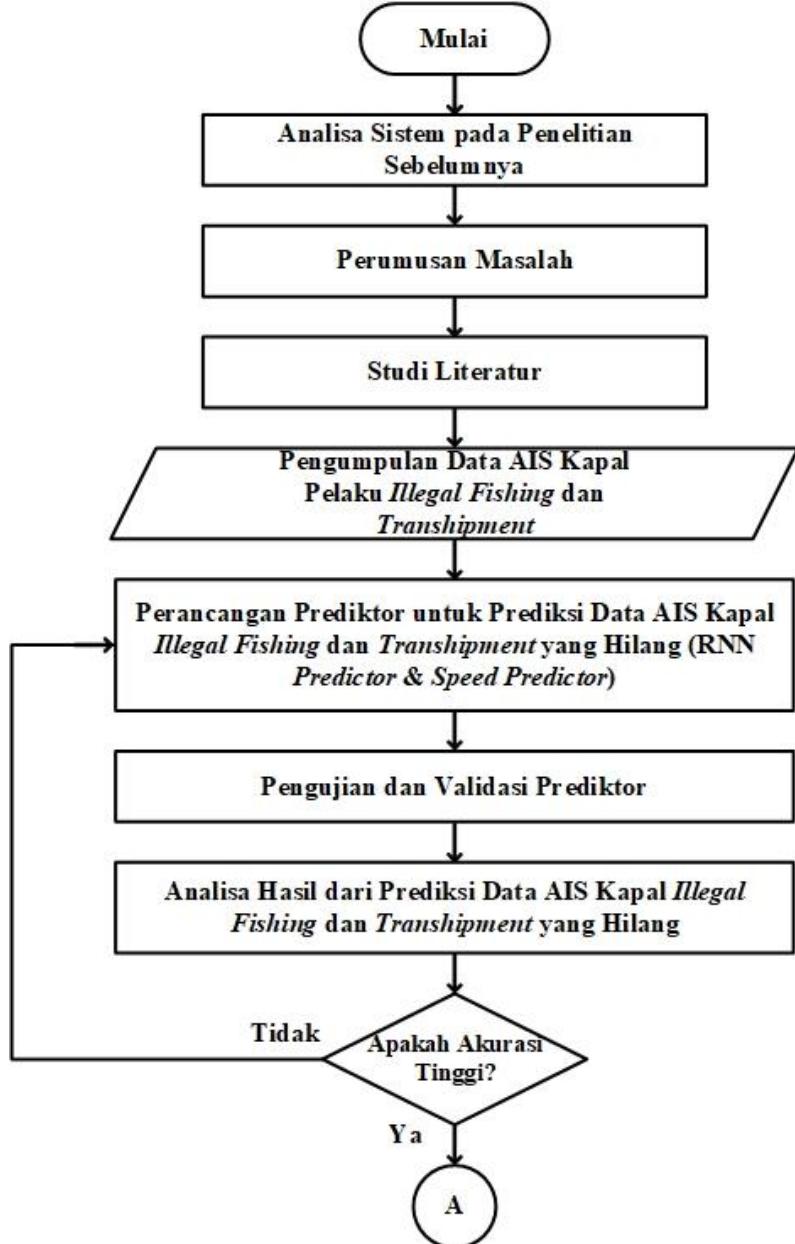
- *Head on :* $174^\circ < |\text{heading kapal 1} - \text{heading kapal 2}| < 186^\circ$
- *Crossing:* $6^\circ < |\text{heading kapal 1} - \text{heading kapal 2}| < 174^\circ$
- *Overtake:* $-6^\circ < \text{heading kapal 1} - \text{heading kapal 2} < 6^\circ$

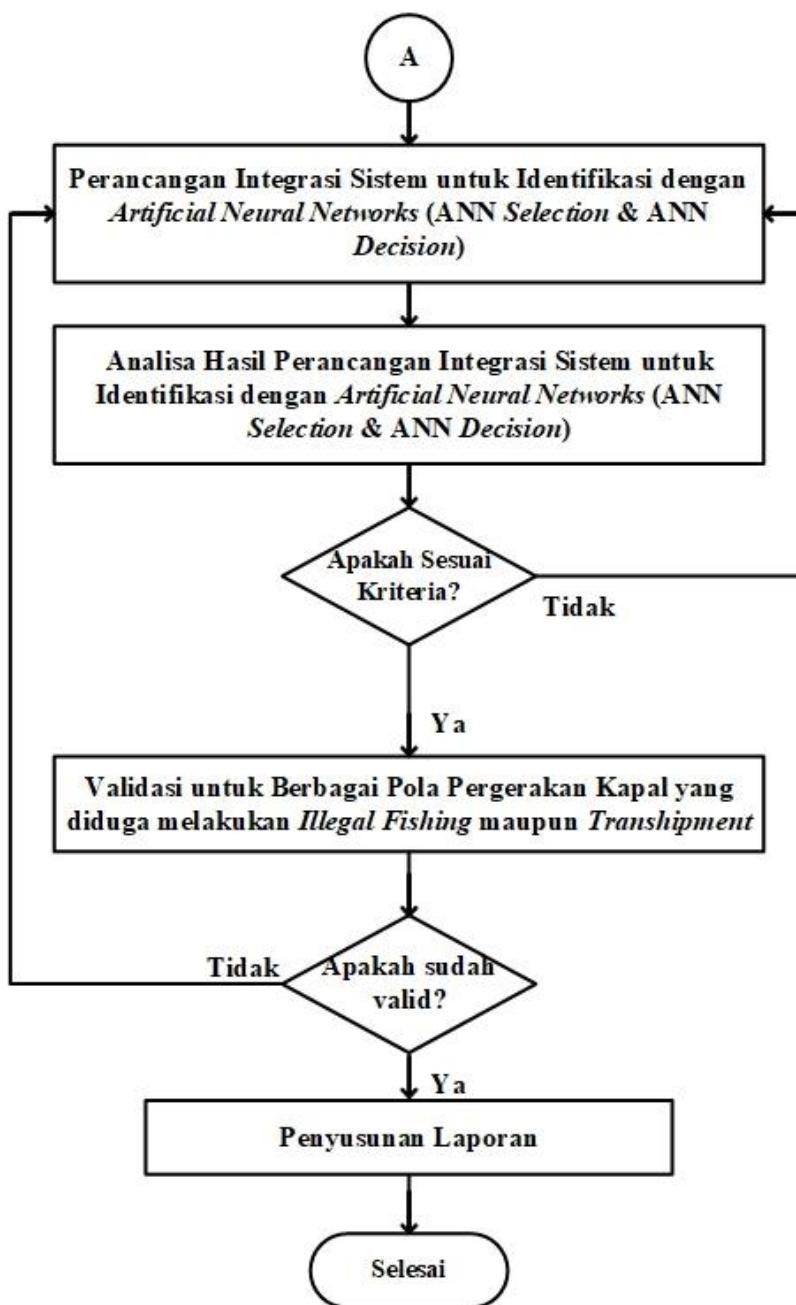
Sangat kecil kemungkinan dua kapal di tengah laut dengan jarak yang berdekatan dan memiliki *heading* kapal seperti Gambar 2. 11, karena beresiko terjadi tabrakan antar kapal. Teknologi AIS yang dipasang membantu dua buah kapal tersebut dapat menghindari tabrakan dari jarak yang jauh. Dengan kata lain, apabila kasus tersebut terjadi maka dapat dikatakan dua kapal ini berdekatan untuk melakukan *transhipment* (Masroeri, 2018).

BAB III

METODOLOGI PENELITIAN

Bab ini berisi tahapan-tahapan yang dilakukan dalam penggerjaan tugas akhir, yang ditunjukkan pada Gambar 3.1 diagram alir berikut.





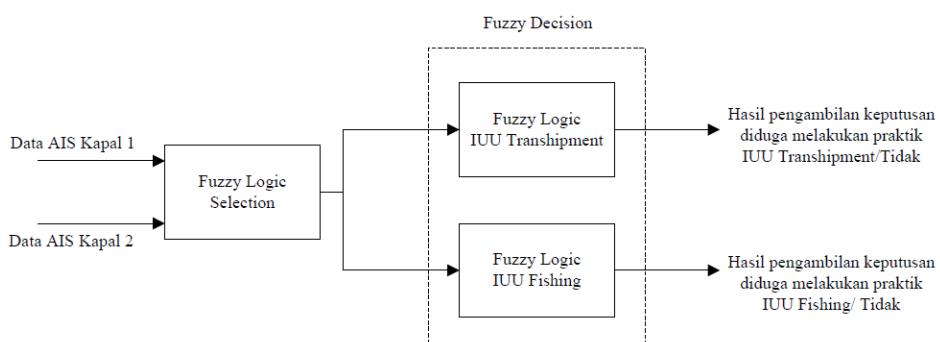
Gambar 3. 1 Diagram alir penelitian

3.1 Analisa Sistem Pada Penelitian Sebelumnya

Pada penelitian sebelumnya telah dirancang integrasi sistem pengambilan keputusan berbasis data *Automatic Identification System* (AIS) untuk identifikasi terjadinya IUU *Fishing* dan *Transhipment* menggunakan Logika Fuzzy. Rancangan sistem pengambilan keputusan dibagi menjadi dua subsistem, yang pertama adalah *fuzzy selection* yang digunakan untuk mensortir kapal-kapal yang diduga

melakukan IUU *Fishing* atau *Transhipment*. Masukan dari *fuzzy selection* ini merupakan data AIS dari 2 kapal, berupa jarak antara 2 kapal dan selisih *heading* 2 kapal. Keluaran dari *fuzzy selection* berupa keputusan apakah kapal diduga melakukan IUU *Fishing* atau *Transhipment* dan keluaran ini juga digunakan sebagai masukan untuk subsistem yang kedua, yaitu *fuzzy decision*. *Fuzzy decision* digunakan untuk mengolah lebih lanjut keluaran dari *fuzzy selection*. Sistem *fuzzy decision* merupakan integrasi dari 2 sistem, yaitu sistem fuzzy untuk identifikasi terjadinya IUU *Fishing* dan sistem fuzzy untuk identifikasi terjadinya IUU *Transhipment*. Variabel masukan yang digunakan pada *fuzzy decision* IUU *Transhipment* adalah selisih *heading*, jarak antara 2 kapal, rata-rata kecepatan dari masing-masing kapal, dan selisih kecepatan kedua kapal. Parameter *fuzzy decision* IUU *Fishing* adalah kecepatan kapal pada saat *casting*, kecepatan kapal pada saat *towing*, kecepatan kapal saat *hauling*, laju perubahan posisi lintang dan bujur kapal. Keluaran dari keduanya adalah hasil pengambilan keputusan dinyatakan diduga melakukan IUU *Transhipment* atau IUU *Fishing* atau tidak melakukan kedua praktik ilegal tersebut.

Desain integrasi sistem pengambilan keputusan berbasis data AIS untuk identifikasi terjadinya IUU *Fishing* dan *Transhipment* menggunakan Logika Fuzzy pada penelitian sebelumnya dapat dilihat pada Gambar 3.2.



Gambar 3. 2 Diagram blok sistem pengambilan keputusan (Fatmawati, 2018)

3.2 Identifikasi Masalah

Penelitian tentang integrasi sistem pengambilan keputusan *Illegal Transhipment* dan *Illegal Fishing* yang telah dirancang sebelumnya masih terdapat

kelemahan karena saat kondisi *real* terjadinya tindakan *illegal fishing* dan *transhipment*, pada AIS terdapat data yang *losses* atau hilang yang berdampak pada kurang akurat dan *valid* hasil dari identifikasi gerakan kapal yang dikategorikan sebagai *illegal fishing* dan *transhipment* nantinya. Oleh karena itu, perlu dilakukan pengembangan berupa penambahan suatu subsistem prediktor menggunakan *recurrent neural networks* (RNN) untuk memprediksikan tiga variabel data dinamis AIS yang hilang (*longitude*, *latitude*, dan *heading*) dan metode perbandingan senilai yang berguna untuk memprediksi satu variabel data dinamis AIS yang hilang (*speed*) ketika pada AIS terdapat data yang hilang. RNN memiliki memori yang berisikan hasil rekaman informasi yang dihasilkan sebelumnya, sehingga RNN sangat cocok digunakan untuk prediksi *time series* seperti data AIS. Selain itu, metode perbandingan senilai bisa diterapkan untuk mengetahui data *speed* kapal yang hilang dengan mengetahui data historisnya.

3.3 Studi Literatur

Studi literatur dimaksud untuk membangun pemahaman awal hingga detail mengenai topik tugas akhir, yakni *Automatic Identification System (AIS)*, *artificial neural networks* (ANN), *recurrent neural networks* (RNN), kriteria *Ilegal transhipment*, dan *illegal fishing* desain sistem pengambilan keputusan berbasis data AIS untuk mendeteksi terjadinya *illegal transhipment* atau *illegal fishing*. Serta menemukan validasi data untuk kriteria *illegal transhipment* dan *illegal fishing*. Referensi yang digunakan berasal dari jurnal, *website*, dan buku pendukung yang membahas penelitian tentang topik terkait.

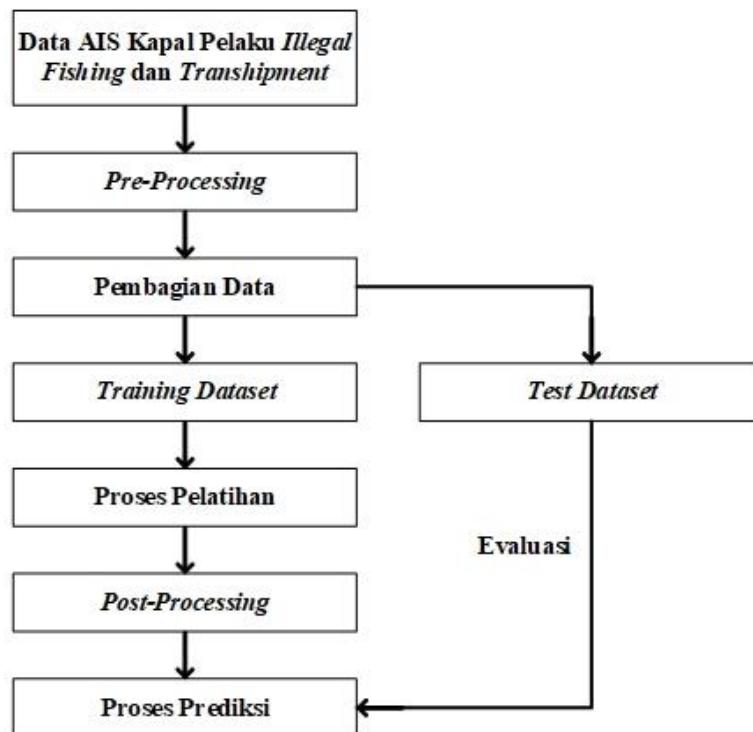
3.4 Pengumpulan Data AIS Kapal *Illegal Fishing* dan *Transhipment*

Data AIS yang digunakan adalah data dinamis kapal dan sebagian memakai data statis, serta data validasi untuk kriteria IUU *Transhipment* dan *Fishing* didapatkan dari NASDEC dan *website* marinetraffic.com. Data yang digunakan untuk prediksi (pada prediktor) adalah informasi kapal, posisi *longitude* dan *latitude*, posisi *heading* kapal, dan kecepatan kapal. Data yang digunakan untuk identifikasi IUU *Transhipment* di antaranya adalah informasi kapal, posisi *longitude* dan *latitude*, kecepatan, *yaw* merupakan posisi *heading* kapal, dan selisih

kecepatan kedua kapal. Data yang didapatkan untuk identifikasi IUU *Fishing* antara lain, kecepatan kapal ketika melakukan *casting*, kecepatan kapal ketika melakukan *towing*, kecepatan kapal ketika melakukan *hauling*, laju perubahan posisi kapal (*longitude* dan *latitude*).

3.5 Perancangan Prediktor untuk Prediksi Data AIS Kapal *Illegal Fishing* dan *Transhipment* yang Hilang

Perancangan prediktor untuk prediksi data AIS kapal pelaku *illegal fishing* dan *transhipment* yang hilang terbagi menjadi dua. Pertama, perancangan model untuk prediksi data AIS *longitude*, *latitude*, dan *heading* kapal pelaku *illegal fishing* dan *transhipment* yang hilang menggunakan *recurrent neural networks* (RNN). Kedua, perancangan prediktor untuk prediksi data AIS *speed* kapal pelaku *illegal fishing* dan *transhipment* yang hilang menggunakan metode perbandingan senilai dengan membandingkan nilai jarak dan kecepatan.



Gambar 3. 3 Diagram alir perancangan model RNN *predictor*

3.5.1 Perancangan Model RNN untuk Prediksi Data AIS *Longitude, Latitude* dan *Heading* Kapal *Illegal Fishing* dan *Transhipment* yang Hilang (RNN Predictor)

Proses perancangan model untuk prediksi data AIS *longitude, latitude*, dan *heading* yang hilang terdiri dari beberapa tahap seperti ditunjukkan oleh Gambar 3.3.

- **Data AIS Kapal Pelaku *Illegal Fishing* dan *Transhipment* yang Digunakan sebagai Masukan RNN Predictor**

Untuk melakukan prediksi data AIS *longitude, latitude*, dan *heading* kapal pelaku *illegal fishing* dan *transhipment* yang hilang, langkah pertama yaitu mengambil data AIS sesuai dengan variabel yang dibutuhkan untuk melakukan prediksi.

Data AIS yang digunakan sebagai masukan adalah data *real* kapal yang diduga melakukan praktik *illegal transhipment* dan *illegal fishing*. Data *real* kapal tersebut didapatkan dari website marinetraffic.com dan NASDEC ITS. Untuk data *real* kapal *illegal transhipment* yang digunakan adalah data *real* Kapal Lurongyuanyu 105 di perairan Batam yang dikirimkan oleh AIS (marinetraffic.com), sedangkan untuk data *real* kapal *illegal fishing* yang digunakan adalah data *real* Kapal Ikan B di Selat Singapura yang juga dikirimkan oleh AIS (marinetraffic.com).

Data AIS yang digunakan sebagai variabel masukan untuk prediksi *longitude* dan *latitude* yang hilang hanyalah data AIS *longitude* dan *latitude* dari kedua kapal tersebut. Data kedua kapal tersebut digabungkan menjadi sebuah tabel seperti yang ditunjukkan oleh Tabel 3.1.

Tabel 3.1 Data Masukan RNN Predictor untuk Prediksi Data AIS *Longitude* dan *Latitude* yang Hilang

No	Long	Lat	Long1	Lat1
1	104.068	1.2491	103.78357	1.18565
2	104.069	1.2484	103.7805	1.18559
3	104.07	1.2483	103.77229	1.18592
4	104.07	1.2484	103.76632	1.18667
5	104.07	1.2485	103.76031	1.18727

Tabel 3. 1 (Lanjutan)

No	Long	Lat	Long1	Lat1
6	104.071	1.2486	103.75921	1.18732
7	104.071	1.2487	103.75821	1.18749
8	104.072	1.2488	103.74554	1.18925
9	104.072	1.2489	103.74566	1.18925
10	104.073	1.249	103.75596	1.18288
11	104.073	1.2491	103.75857	1.18214
12	104.073	1.2491	103.76138	1.18225
13	104.073	1.2492	103.7645	1.18272
14	104.074	1.2492	103.76722	1.18322
15	104.074	1.2493	103.77823	1.18428
16	104.074	1.2493	103.7811	1.18478
17	104.074	1.2494	103.78396	1.18568
18	104.074	1.2494	103.78951	1.18774
19	104.074	1.2494	103.79233	1.18834
20	104.074	1.2495	103.79813	1.18921

Keterangan:

Long = Data AIS *Longitude* Kapal *illegal transhipment* (°)

Lat = Data AIS *Latitude* Kapal *illegal transhipment* (°)

Long1 = Data AIS *Longitude* Kapal *illegal fishing* (°)

Lat1 = Data AIS *Latitude* Kapal *illegal fishing* (°)

Data AIS yang digunakan sebagai variabel masukan untuk prediksi data AIS *heading* yang hilang hanyalah data AIS *heading* dari kedua kapal tersebut. Data kedua kapal tersebut digabungkan menjadi sebuah tabel seperti yang ditunjukkan oleh Tabel 3.2.

Tabel 3. 2 Data Masukan RNN *Predictor* untuk Prediksi Data AIS *Heading* yang Hilang

No	Ψ	Ψ_1
1	145	266
2	103	267
3	96	275
4	90	277
5	89	278
6	89	282
7	88	292
8	87	258

Tabel 3.2 (Lanjutan)

No	Ψ	Ψ_1
9	88	141
10	88	110
11	88	91
12	88	83
13	88	79
14	87	83
15	87	83
16	87	75
17	86	70
18	86	78
19	85	83
20	84	82

Keterangan:

Ψ = Data AIS Heading Kapal *illegal transhipment* ($^{\circ}$)

Ψ_1 = Data AIS Heading Kapal *illegal fishing* ($^{\circ}$)

- **Pre-Processing**

Kemudian data masukan dilakukan *pre-processing* dengan melakukan normalisasi sehingga data dari seluruh variabel memiliki *range* yang sama yaitu 0 hingga 1. Fungsi dari normalisasi adalah untuk mempercepat konvergensi saat melakukan pelatihan (*training*) dan pengujian (*test*). Normalisasi dilakukan dengan menggunakan persamaan (3.1).

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3.1)$$

dengan:

x' = data yang sudah dinormalisasi

x = data yang belum dinormalisasi

$\min(x)$ = nilai minimum dari keseluruhan data

$\max(x)$ = nilai maksimum dari keseluruhan data

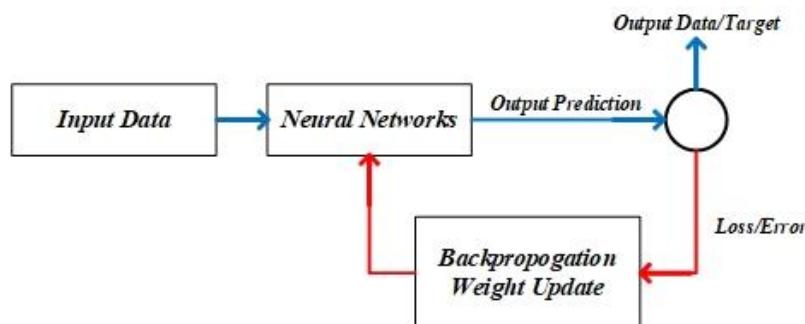
- **Pembagian Data**

Setelah itu, dilakukan pembagian data yaitu 50% untuk pelatihan (*training*) dan 50% untuk pengujian (*test*). Di mana masing-masing data untuk pelatihan

(*training*) berjumlah 10 data (50%) dan data untuk pengujian (*test*) berjumlah 10 data (50%).

- **Proses Pelatihan**

Proses pelatihan terdiri dari 2 bagian utama yaitu *forward pass* dan *backward pass*. Gambar 3.4 merupakan tahapan dari proses pelatihan, panah biru adalah *forward pass* dan panah merah adalah *backward pass*. Pada saat *forward pass*, *input* akan di-*propagate* menuju *output layer* dan hasil dari *output* tersebut akan dibandingkan dengan data target yang benar dengan menggunakan fungsi *loss function*.



Gambar 3. 4 Diagram blok pelatihan *neural networks*

Pada proses pelatihan ini, parameter-parameter RNN dimasukkan ke dalam subsistem. Adapun parameter-parameter tersebut adalah jumlah pola *input* (*time step*), jumlah LSTM *layers*, dan jumlah *unit neuron* pada LSTM *layers* dan nilai *learning rate*. Adapun pada perancangan model RNN *predictor* ini jumlah pola *input* (*time step*) yang digunakan adalah 2 *time step*, jumlah *layer* untuk *input layer* adalah 1, jumlah LSTM *layers* adalah 1, dan jumlah *layer* pada *output layer* adalah 1.

- **Post-Processing**

Setelah dilakukan proses pelatihan, langkah selanjutnya adalah melakukan *post-processing*. *Post-processing* dilakukan dengan melakukan denormalisasi untuk mengubah data hasil *pre-processing* yang bernilai 0 sampai 1 kembali menjadi nilai data aslinya. Denormalisasi dilakukan dengan menggunakan persamaan (3.2).

$$x = x'(\max(x) - \min(x)) + \min(x) \quad (3.2)$$

dengan:

- x' = data yang sudah dinormalisasi
- x = data yang belum dinormalisasi
- $\min(x)$ = nilai minimum dari keseluruhan data
- $\max(x)$ = nilai maksimum dari keseluruhan data

- **Proses Prediksi**

Setelah itu, model dari rancangan subsistem dari proses pelatihan inilah yang digunakan pada proses prediksi untuk pengujian dengan masukan dari *test dataset*.

3.5.2 Perancangan Prediktor untuk Prediksi Data AIS Speed Kapal Illegal Fishing dan Transhipment yang Hilang (*Speed Predictor*)

Perancangan prediktor untuk prediksi data AIS *speed* yang hilang menggunakan metode perbandingan senilai dengan membandingkan nilai jarak pada waktu sebelum data hilang dan pada waktu data hilang terhadap kecepatan pada waktu sebelum data hilang dan pada waktu data hilang. Nilai jarak didapat dengan persamaan (3.6) yaitu dari hasil konversi nilai *longitude* dan *latitude* hasil prediksi menggunakan RNN *predictor*. Dengan mengetahui jarak perpindahan antara posisi kapal sebelum data hilang dan pada waktu data hilang, serta membandingkannya terhadap kecepatan sebelum data hilang maka kecepatan pada waktu data hilang bisa didapatkan. Pada metode ini, interval waktu tiap data AIS diasumsikan konstan. Persamaan metode perbandingan senilai yang digunakan untuk perancangan adalah persamaan (3.7).

$$a = \sin^2 \left(\frac{\text{Lat}_2 \left(\frac{\pi}{180} \right) - \text{Lat}_1 \left(\frac{\pi}{180} \right)}{2} \right) \quad (3.3)$$

$$b = \cos \left(\text{Lat}_2 \left(\frac{\pi}{180} \right) \right) \cos \left(\text{Lat}_1 \left(\frac{\pi}{180} \right) \right) \sin^2 \left(\frac{\text{Long}_2 \left(\frac{\pi}{180} \right) - \text{Long}_1 \left(\frac{\pi}{180} \right)}{2} \right) \quad (3.4)$$

$$h = a + b \quad (3.5)$$

$$d = 2r \sin^{-1}(\sqrt{h}) \quad (3.6)$$

$$\frac{d_{t-1}}{d_t} = \frac{v_{t-1}}{v_t} \quad (3.7)$$

dengan:

d = jarak perpindahan kapal (meter)

r = radius bumi = 6.371.000 (meter)

Lat ₁	= posisi <i>latitude</i> kapal pada waktu sebelum data hilang (°)
Lat ₂	= posisi <i>latitude</i> kapal pada waktu data hilang (°)
Long ₁	= posisi <i>longitude</i> kapal pada waktu sebelum data hilang (°)
Long ₂	= posisi <i>longitude</i> kapal pada waktu data hilang (°)
v_{t-1}	= kecepatan pada waktu sebelum data hilang (knot)
v_t	= kecepatan pada waktu data hilang (knot)
d_{t-1}	= jarak perpindahan kapal pada waktu sebelum data hilang (meter)
d_t	= jarak perpindahan kapal pada waktu data hilang (meter)

3.6 Pengujian dan Validasi Prediktor

Pengujian dan validasi prediktor untuk prediksi data AIS kapal pelaku *illegal fishing* dan *transhipment* yang hilang terbagi menjadi dua. Pertama, pengujian dan validasi model RNN *predictor*. Kedua, pengujian dan validasi *speed predictor*.

3.6.1 Pengujian dan Validasi Model RNN untuk Prediksi Data AIS *Longitude*, *Latitude* dan *Heading* Kapal *Illegal Fishing* dan *Transhipment* yang Hilang (RNN Predictor)

Pengujian model untuk prediksi data AIS *longitude*, *latitude*, dan *heading* yang hilang akan dilakukan setelah model RNN *predictor* selesai dirancang. Pengujian prediksi data AIS *longitude*, *latitude*, dan *heading* yang hilang dilakukan dengan melakukan prediksi menggunakan masukan dari *test dataset* yang mana merupakan data *real* AIS kapal pelaku *illegal fishing* dan *transhipment*. Pada pengujian jumlah data *real* yang digunakan 10 data AIS kapal pelaku *illegal fishing* dan 10 data AIS kapal pelaku *illegal transhipment*. Di mana masing-masing data tersebut merupakan lanjutan *series* dari 10 data sebelumnya pada proses pelatihan. Hasil dari pengujian ini nantinya akan dievaluasi untuk mengukur performansi dari prediktor. Pengujian akan terus dilakukan hingga didapat performansi paling optimal dengan mendapatkan kombinasi parameter terbaik.

Setelah pengujian selesai, dengan mendapatkan kombinasi parameter terbaik, maka dilakukanlah validasi dengan melakukan prediksi kapal pelaku *illegal fishing* dan *transhipment* yang diasumsikan terdapat beberapa data AIS yang hilang dalam *interval* waktu tertentu. Hasil validasi dievaluasi untuk mengetahui performa akurasi dari prediktor.

3.6.2 Pengujian dan Validasi Prediktor untuk Prediksi Data AIS Speed Kapal

Illegal Fishing dan Transhipment yang Hilang (Speed Predictor)

Pengujian prediktor untuk prediksi data AIS *speed* yang hilang dilakukan dengan melakukan prediksi menggunakan data *real* kapal yang diduga melakukan praktik *illegal transhipment* dan *illegal fishing*. Data *real* kapal tersebut didapatkan dari website marinetraffic.com dan NASDEC ITS. Untuk data *real* kapal *illegal transhipment* yang digunakan adalah data *real* Kapal Lurongyuanyu 105 di perairan Batam yang dikirimkan oleh AIS (marinetraffic.com), sedangkan untuk data *real* kapal *illegal fishing* yang digunakan adalah data *real* Kapal Ikan B di Selat Singapura yang juga dikirimkan oleh AIS (marinetraffic.com).

Setelah pengujian selesai, maka dilakukanlah validasi dengan melakukan prediksi kapal pelaku *illegal fishing* dan *transhipment* yang diasumsikan terdapat beberapa data AIS yang hilang dalam *interval* waktu tertentu. Hasil validasi dievaluasi untuk mengetahui performa akurasi dari prediktor.

3.7 Analisa Hasil Prediksi

Analisa hasil prediksi dilakukan setelah melakukan validasi pada prediktor yang telah dirancang. RNN *predictor* dapat dikatakan telah berhasil atau dapat bekerja dengan baik apabila hasil akurasi tinggi atau nilai MAPE $\leq 10\%$, sedangkan untuk *speed predictor* dapat dikatakan telah berhasil atau dapat bekerja dengan baik apabila nilai prediksinya mendekati nilai aktual yang diukur dengan *root mean square error* (RMSE), semakin kecil nilai RMSE yang didapat maka semakin tinggi akurasi dari *speed predictor*. Persamaan yang digunakan untuk menghitung RMSE pada *speed predictor* adalah persamaan (3.8).

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (x' - x)^2}{n}} \quad (3.8)$$

dengan:

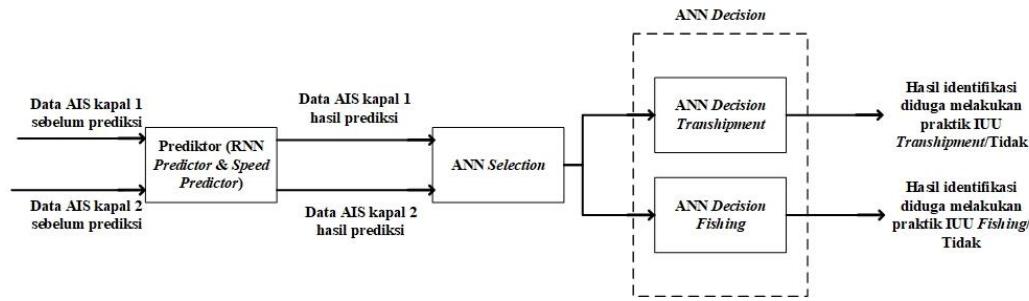
x = data aktual

x' = data hasil prediksi

n = jumlah data

3.8 Perancangan Integrasi Sistem untuk Identifikasi dengan *Artificial Neural Networks* (ANN Selection & ANN Decision)

Pada Gambar 3.5 merupakan rancangan masukan dan keluaran dari integrasi sistem untuk identifikasi yang dirancang menggunakan *artificial neural networks* dengan masukan dari keluaran prediktor (RNN Predictor dan GLBB Predictor).



Gambar 3. 5 Diagram blok integrasi sistem untuk identifikasi dengan masukan dari hasil prediksi prediktor

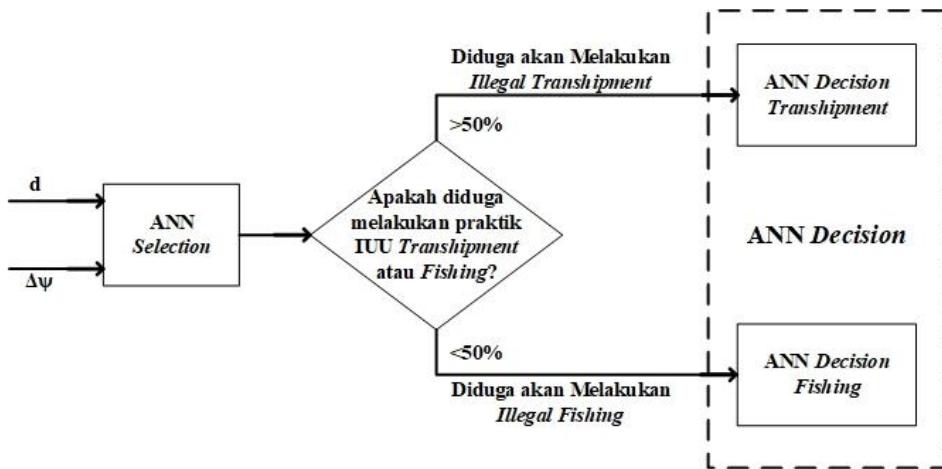
Integrasi sistem untuk identifikasi yang dirancang menggunakan *artificial neural networks* dibagi menjadi dua subsistem, yang pertama adalah ANN *selection* dan yang kedua adalah ANN *decision*. Masukan dari ANN *selection* merupakan keluaran hasil prediksi dari prediktor yaitu data AIS dari dua kapal, berupa variabel jarak antara dua kapal dan selisih *heading* dua kapal. ANN *selection* digunakan untuk mensortir kapal-kapal yang diduga melakukan IUU *Transhipment* atau IUU *Fishing*. Keluaran ANN *selection* digunakan sebagai masukan dari ANN *decision* yang mana termasuk IUU *Transhipment* atau IUU *Fishing*.

ANN *decision* terbagi menjadi dua subsistem yaitu ANN *decision transhipment* dan ANN *decision fishing*. Variabel masukan yang digunakan pada ANN *decision transhipment* adalah selisih *heading*, jarak antara 2 kapal, dan selisih kecepatan kedua kapal. Sedangkan variabel masukan pada ANN *decision fishing* adalah kecepatan kapal pada saat *casting*, kecepatan kapal pada saat *towing*, kecepatan kapal saat *hauling*, laju perubahan posisi lintang dan bujur kapal. Keluaran dari keduanya adalah hasil pengambilan keputusan dinyatakan diduga melakukan IUU *Transhipment* atau IUU *Fishing* atau tidak melakukan kedua praktik illegal tersebut.

3.8.1 Perancangan Subsistem *Selection* untuk Mensortir Kapal-Kapal Pelaku

Illegal Fishing atau Transhipment (ANN Selection)

ANN *selection* digunakan untuk mensortir kapal-kapal yang diduga melakukan IUU *Transhipment* atau IUU *Fishing*. Gambar 3.6 ini menunjukkan desain dari subsistem ANN *selection*.



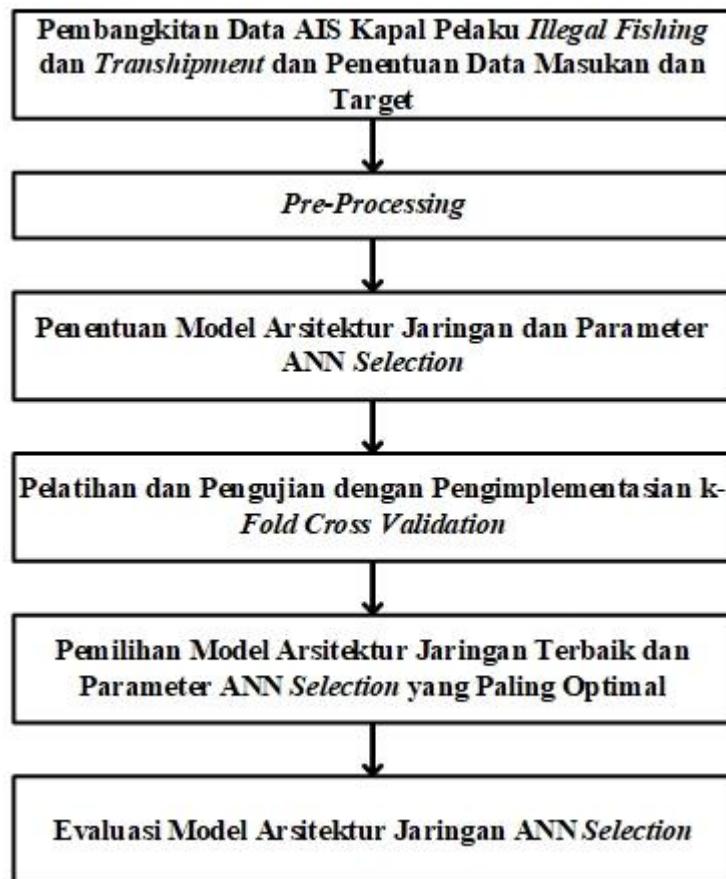
Gambar 3. 6 Desain subsistem ANN *selection*

Pada Gambar 3.6 desain subsistem mempunyai variabel masukan dan hasil keluaran dari subsistem ANN *selection*. Terdapat 2 variabel masukan pada subsistem ANN *selection*, yaitu jarak kedua kapal (d) dan selisih *heading* dua kapal ($\Delta\Psi$). Proses perancangan subsistem ANN *selection* terdiri dari beberapa tahap seperti ditunjukkan oleh Gambar 3.7.

- **Pembangkitan Data AIS Kapal Pelaku *Illegal Fishing* dan *Illegal Transhipment* dan Penentuan Data Masukan dan Target**

Pembangkitan data AIS kapal pelaku *illegal fishing* dan *illegal transhipment* dan penentuan data masukan dan target didasarkan pada informasi dari pakar di bidang kelautan (Masroeri, 2018). Data masukan variabel jarak untuk *range* 500-800 meter merupakan jarak waspada kapal, sedangkan di atas 800 meter merupakan jarak aman kapal. Nilai tersebut berdasarkan penelitian yang telah dilakukan sebelumnya mengenai anti tabrakan kapal (Nuryahya & Masroeri, 2003). Variabel jarak didapatkan dengan perhitungan posisi *latitude* (lintang) dan *longitude* (bujur) antara dua kapal. Data masukan variabel selisih *heading* antara dua kapal didapatkan dari perhitungan nilai *heading* kapal 1 dan kapal 2. Variabel tersebut digunakan untuk mengetahui arah kapal, apakah mendekati atau menjauhi. Batas

nilai yang digunakan pada sudut *heading* ini berdasarkan *collision regulation* (COLREGS) yang terdapat pada IMO.



Gambar 3.7 Diagram alir perancangan subsistem ANN *selection*

Target atau variabel keluaran dari subsistem ANN *selection* berupa keputusan kapal mana yang diduga terindikasi melakukan IUU *Transhipment* atau IUU *Fishing*. Nilai keluaran yang menunjukkan lebih dari 50% ($>50\%$), yang mana akan diubah menjadi nilai akhir 1 (*True*), maka diduga terindikasi melakukan IUU *Transhipment*. Nilai keluaran yang menunjukkan kurang dari 50% ($<50\%$), yang mana akan diubah menjadi nilai akhir 0 (*False*), maka diduga terindikasi melakukan IUU *Fishing*. Variabel yang digunakan dalam pembangkitan data untuk data masukan ANN *selection* ditunjukkan pada Tabel 3.3.

Seperti yang ditunjukkan oleh Gambar 3.6, pada subsitem ANN *selection* terdapat dua variabel untuk data masukan yaitu jarak kedua kapal dan selisih heading kedua kapal, dengan satu keluaran.

Tabel 3.3 Variabel Masukan pada Subsistem ANN Selection

No	Variabel	Satuan	Kategori	Rentang Nilai
1	Jarak kedua kapal (d)	Meter	Near	500 s.d. 680
			Far	681 s.d. 800
2	Selisih <i>heading</i> kedua kapal ($\Delta\Psi$)	Degree	OT	-6 s.d. 6
			C	6 s.d. 174
			HO	174 s.d. 186

Keterangan:

OT = *Overtake*

C = *Crossing*

HO = *Head On*

Pada Tabel 3.3, variabel masukan jarak kapal dibagi menjadi 2 kategori. Kategori tersebut terdiri dari *Near* (dekat) dan *Far* (jauh). Masing-masing kategori memiliki rentang nilai yang berbeda. Nilai tersebut berdasarkan penelitian sebelumnya mengenai tabrakan kapal. Rentang jarak 500-800 meter merupakan jarak waspada kapal, dengan ukuran kapal yang memiliki Lpp 50-250 meter. Variabel masukan jarak kapal diperoleh dari perhitungan dengan menggunakan formula Haversine yang ditunjukkan oleh persamaan (3.11).

$$a = \sin^2\left(\frac{\text{Lat}_2\left(\frac{\pi}{180}\right) - \text{Lat}_1\left(\frac{\pi}{180}\right)}{2}\right) \quad (3.8)$$

$$b = \cos\left(\text{Lat}_2\left(\frac{\pi}{180}\right)\right) \cos\left(\text{Lat}_1\left(\frac{\pi}{180}\right)\right) \sin^2\left(\frac{\text{Long}_2\left(\frac{\pi}{180}\right) - \text{Long}_1\left(\frac{\pi}{180}\right)}{2}\right) \quad (3.9)$$

$$h = a + b \quad (3.10)$$

$$d = 2r \sin^{-1}(\sqrt{h}) \quad (3.11)$$

dengan:

d = jarak kedua kapal (meter)

r	= radius bumi = 6.371.000 (meter)
Lat ₁	= posisi <i>latitude</i> kapal 1 (°)
Lat ₂	= posisi <i>latitude</i> kapal 2 (°)
Long ₁	= posisi <i>longitude</i> kapal 1 (°)
Long ₂	= posisi <i>longitude</i> kapal 2 (°)

Pada Tabel 3.3, variabel masukan *heading* kapal dibagi menjadi 3 kategori yaitu OT (*overtake*), C (*crossing*), dan HO (*head on*). Ketiganya memiliki rentang nilai *overtake* (-6 s.d. 6 derajat), *crossing* (6 s.d. 174 derajat), dan *head on* (174 s.d. 186 derajat). Rentang nilai tersebut berdasarkan dengan aturan COLREGS yang terdapat pada IMO. Variabel masukan selisih *heading* antara kedua kapal dihitung menggunakan persamaan (3.12).

$$\Delta\Psi = \Psi_1 - \Psi_2 \quad (3.12)$$

dengan:

$\Delta\Psi$	= selisih <i>heading</i> kedua kapal (°)
Ψ_1	= <i>heading</i> kapal 1 (°)
Ψ_2	= <i>heading</i> kapal 2 (°)

Target atau variabel keluaran dari subsistem ANN *selection* berupa keputusan kapal mana yang diduga terindikasi melakukan IUU *Transhipment* atau IUU *Fishing*. Nilai keluaran yang menunjukkan lebih dari 50% (>50%), yang mana akan diubah menjadi nilai akhir 1 (*True*), maka diduga terindikasi melakukan IUU *Transhipment*. Nilai keluaran yang menunjukkan kurang dari 50% (<50%), yang mana akan diubah menjadi nilai akhir 0 (*False*), maka diduga terindikasi melakukan IUU *Fishing*.

Pada pembangkitan dan penentuan data masukan dan target pada subsistem ANN *selection* untuk identifikasi ini, mengikuti basis aturan dari penelitian sebelumnya (Fatmawati, 2018). Di mana basis aturan tersebut merupakan basis aturan dengan dua variabel dan kategori dengan rentang nilai tertentu. Berdasarkan variabel dan parameter tersebut diketahui pola pergerakan kapal yang diduga melakukan IUU *Transhipment* atau IUU *Fishing*. Jumlah basis aturan dibuat berdasarkan atas kemungkinan terjadinya praktik *illegal* tersebut. Basis aturan ini

berjumlah 6 aturan *if-then*. Berikut ini merupakan basis aturan yang akan jadi acuan dalam penentuan data masukan dan target pada subsistem ANN *selection*:

1. If (dJarak2Kapal is Near) and (SelisihHeading is OT) then (IUUT/IUUF? is Allegedly_IUUT)
2. If (dJarak2Kapal is Near) and (SelisihHeading is C) then (IUUT/IUUF? is Allegedly_IUUT)
3. If (dJarak2Kapal is Near) and (SelisihHeading is HO) then (IUUT/IUUF? is Allegedly_IUUT)
4. If (dJarak2Kapal is Far) and (SelisihHeading is OT) then (IUUT/IUUF? is Allegedly_IUUF)
5. If (dJarak2Kapal is Far) and (SelisihHeading is C) then (IUUT/IUUF? is Allegedly_IUUF)
6. If (dJarak2Kapal is Far) and (SelisihHeading is HO) then (IUUT/IUUF? is Allegedly_IUUF)

- ***Pre-Processing***

Kemudian data masukan dilakukan *pre-processing* dengan melakukan standardisasi sehingga data dari seluruh variabel masukan terdistribusi normal yang memiliki nilai *mean* sama dengan 0 dan nilai standar deviasi sama dengan 1. Standardisasi dilakukan dengan menggunakan persamaan (3.15).

$$\mu = \frac{1}{N} \sum_{i=1}^N (x_i) \quad (3.13)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (3.14)$$

$$x' = \frac{x - \mu}{\sigma} \quad (3.15)$$

dengan:

x' = data yang sudah distandardisasi

x = data yang belum distandardisasi

μ = rata-rata data yang belum distandardisasi

σ = standard deviasi data yang belum distandardisasi

N = jumlah data

- **Penentuan Model Arsitektur Jaringan dan Parameter ANN Selection**

Berdasarkan pada aspek yang dibahas pada bagian pembangkitan data dan penentuan data masukan dan target, model ANN harus mempertimbangkan dimensi *input layer* yang terdiri dari dua *neurons*, yang sesuai dengan jumlah variabel masukan pada subsistem ANN *selection* yaitu dua variabel masukan. Parameter lainnya yang diperlukan untuk membuat *neural networks*, di antaranya adalah fungsi aktivasi (*activation function*) dan pengoptimal (*optimizer*), jumlah lapisan tersembunyi (*hidden layers*) dan jumlah *neurons* masing-masing (*neurons* pada *hidden layer*), nilai laju pembelajaran (*learning rate*), dan jumlah *epochs*, yang didefinisikan sebagai berikut:

- Jumlah hidden layers: 1
- Jumlah neurons pada hidden layer: 5, 10, 15, 20, 25
- Fungsi aktivasi: *rectified linear unit* (ReLU) pada *input layer* dan *hidden layer*, sigmoid pada *output layer*
- Optimizer: *adaptative moment estimation* (Adam)
- Nilai learning rate: 0.0001, 0.0005, 0.001, 0.005, 0.01
- Jumlah epochs: 100

Pada perancangan ANN *selection*, parameter yang divariasikan hanyalah jumlah *neurons* pada *hidden layer* dan nilai *learning rate*.

Pada fungsi aktivasi digunakan *rectified linear unit* (ReLU) pada *input layer* dan *hidden layer*, sedangkan pada *output layer* digunakan fungsi aktivasi sigmoid.

Penggunaan fungsi aktivasi ReLu pada *input layer* dan *hidden layer* dikarenakan fungsi aktivasi ReLu mampu belajar lebih cepat dibanding fungsi aktivasi yang lain itu disebabkan fungsi aktivasi ReLu tidak mengaktifkan semua *neurons* secara bersamaan, yang mana membuat lebih efisien dan mudah dalam komputasi. Penggunaan fungsi aktivasi sigmoid pada *output layer* dikarenakan keluaran dari ANN *selection* merupakan probabilitas yang bernilai di antara 0%-50% dan 51%-100%, yang mana ini sangat cocok menggunakan fungsi aktivasi sigmoid di mana fungsi aktivasi sigmoid akan merubah nilai keluaran dari ANN *selection* yang bernilai 0%-50% menjadi 0 dan nilai keluaran yang bernilai 51%-

100% menjadi 1, yang mana jika nilai 0 maka diduga terindikasi melakukan IUU *Fishing* dan jika nilai 1 maka diduga terindikasi melakukan IUU *Transhipment*.

Pada *optimizer* digunakan fungsi optimasi Adam, yang mana merupakan salah satu fungsi optimasi yang tersedia pada Keras *library*. Adam (Kingma & Ba, 2015) adalah suatu algoritma untuk optimisasi berbasis gradien orde pertama dari fungsi objektif stokastik. Ini adalah metode yang sederhana dan mudah yang membutuhkan memori komputasi rendah dan cocok untuk masalah optimisasi *nonconvex* dalam pembelajaran mesin.

- **Pelatihan dan Pengujian dengan Pengimplementasian K-Fold Cross Validation**

K-fold cross-validation (Picard & Cook, 1984) digunakan dalam 4515 pengamatan yang terkandung dalam dataset, yang dibagi menjadi lima set dengan ukuran yang kira-kira sama seperti ditunjukkan pada Gambar 3.8.

ANN 1	<i>Testing set</i>	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>
ANN 2	<i>Training set</i>	<i>Testing set</i>	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>
ANN 3	<i>Training set</i>	<i>Training set</i>	<i>Testing set</i>	<i>Training set</i>	<i>Training set</i>
ANN 4	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>	<i>Testing set</i>	<i>Training set</i>
ANN 5	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>	<i>Testing set</i>

Gambar 3.8 Representasi skematis prosedur *k-fold cross validation* pada ANN selection

Dalam pendekatan ini, empat set (80% pengamatan atau sebanyak 3612 pengamatan) digunakan untuk melatih *neural network*, dan set yang tersisa (20% dari pengamatan atau sebanyak 903 pengamatan) disimpan untuk menguji kinerja model. Proses ini dilakukan lima kali karena lima kombinasi yang berbeda digunakan untuk membagi lima set menjadi empat set untuk mengembangkan

model (*train*) dan set lainnya untuk melakukan tes yang sesuai (*test*). Pendekatan ini memungkinkan kapasitas prediksi umum ANN untuk diprediksi, yang mana menguntungkan.

- **Pemilihan Model Arsitektur Jaringan Terbaik dan Parameter ANN Selection yang Paling Optimal**

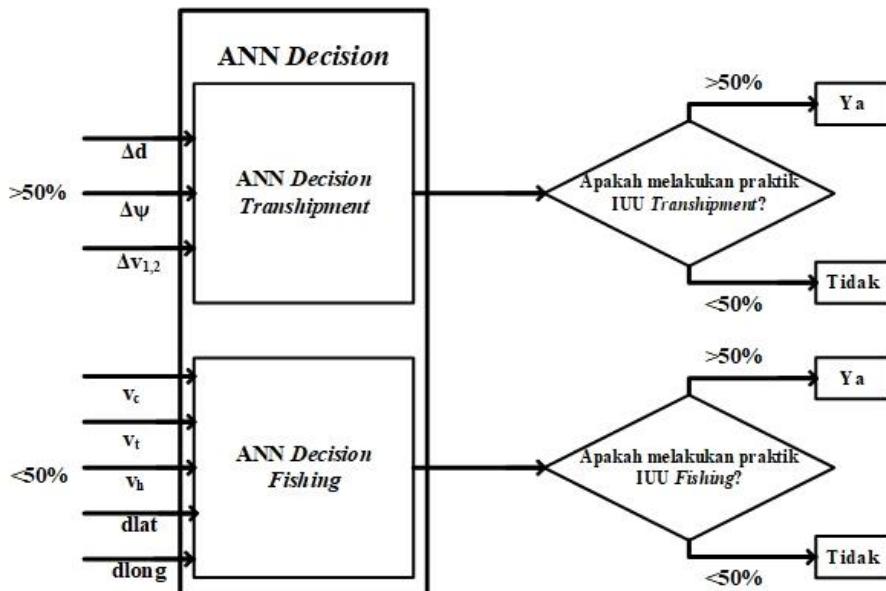
Selama implementasi proses *k-fold cross validation*, akan dihasilkan 25 model *neural networks*, sebagai hasil dari kombinasi lima *neurons* pada *hidden layer* untuk lima nilai *learning rate*. Dari 25 *neural networks* tersebut, model terbaik dengan parameter paling optimal akan dipilih berdasarkan model yang menghasilkan rata-rata akurasi paling tinggi dan standard deviasi rendah.

- **Evaluasi Model Arsitektur Jaringan ANN Selection**

Evaluasi model arsitektur jaringan ANN *selection* dilakukan dengan membandingkan hasil keluaran identifikasi dari ANN *selection* terhadap hasil dari keluaran subsistem *selection* dari rancangan penelitian sebelumnya (Fatmawati, 2018).

3.8.2 Perancangan Subsistem *Decision* untuk Pengambilan Keputusan Akhir Kapal-Kapal Pelaku *Illegal Fishing* atau *Transhipment* (ANN *Decision*)

ANN *decision* adalah subsistem yang berfungsi untuk mengolah lebih lanjut keluaran dari subsistem ANN *selection*.

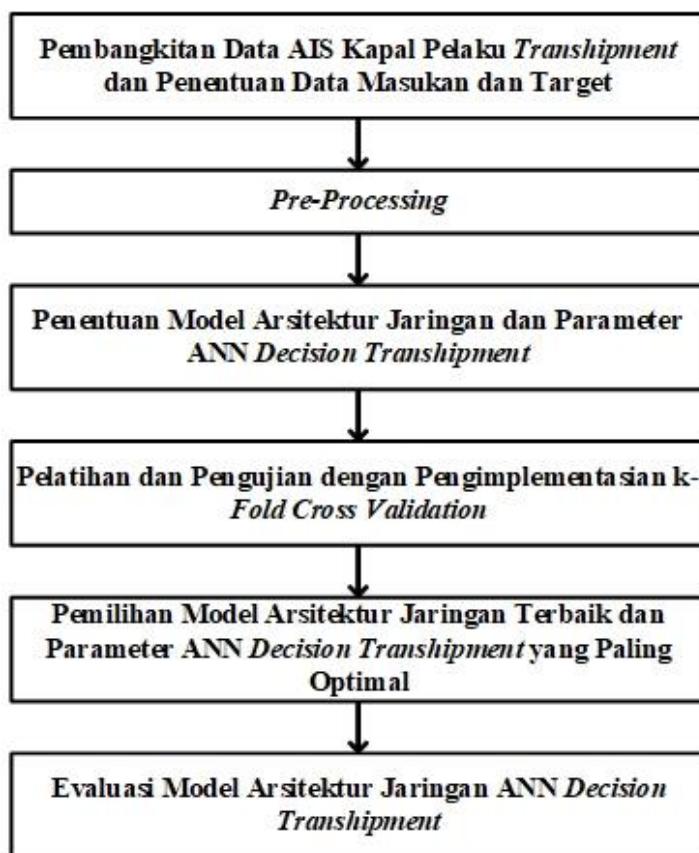


Gambar 3.9 Desain subsistem ANN *decision*

Gambar 3. 9 menunjukkan ANN *decision* merupakan integrasi dari 2 subsistem, yaitu ANN *decision transhipment* untuk identifikasi terjadinya IUU *Transhipment* dan ANN *decision fishing* untuk identifikasi terjadinya IUU *Fishing*.

3.8.2.1 Perancangan ANN Decision Transhipment

ANN *decision transhipment* merupakan salah satu sub sistem yang diintegrasikan di dalam ANN *decision*, untuk mengidentifikasi terjadinya *illegal transhipment*. ANN *decision transhipment* terdapat 3 variabel masukan yaitu jarak antara dua kapal (Δd), selisih heading dua kapal ($\Delta \Psi$), dan selisih kecepatan dua kapal ($\Delta v_{1,2}$) serta satu keluaran. Proses perancangan ANN *decision transhipment* terdiri dari beberapa tahap seperti ditunjukkan oleh Gambar 3. 10.



Gambar 3. 10 Diagram alir perancangan ANN *decision transhipment*

- Pembangkitan Data AIS Kapal Pelaku *Illegal Transhipment* dan Penentuan Data Masukan dan Target**

Pembangkitan data AIS kapal pelaku *illegal transhipment* dan penentuan data masukan dan target didasarkan pada informasi dari pakar di bidang kelautan

(Masroeri, 2018). ANN *decision transhipment* memiliki data variabel masukan tambahan dan rentang nilai parameter sesuai dengan pola gerak kapal yang terindikasi melakukan *transhipment*. Parameter tersebut memudahkan untuk pengambilan keputusan, kapal-kapal tersebut terindikasi melakukan praktik *illegal transhipment* atau tidak. Variabel yang digunakan dalam pembangkitan data untuk data masukan ANN *decision transhipment* ditunjukkan pada Tabel 3. 4.

Tabel 3. 4 Variabel Masukan pada Subsistem ANN *Decision Transhipment*

No	Variabel	Satuan	Kategori	Rentang Nilai
1	Jarak kedua kapal (d)	Meter	<i>Near</i>	0 s.d. 30
			<i>Medium</i>	31 s.d. 50
			<i>Far</i>	50 s.d. 80
2	Selisih <i>heading</i> kedua kapal ($\Delta\Psi$)	<i>Degree</i>	OT	-6 s.d. 6
			C	6 s.d. 174
			HO	174 s.d. 186
3	Selisih kecepatan kedua kapal ($\Delta v_{1,2}$)	Knot	<i>Small</i>	0 s.d. 0.8
			<i>Big</i>	0.9 s.d. 10

Keterangan:

OT = *Overtake*

C = *Crossing*

HO = *Head On*

Seperti yang ditunjukkan oleh Gambar 3. 9, pada ANN *decision transhipment* terdapat tiga variabel masukan yaitu jarak antara dua kapal (Δd), selisih heading dua kapal ($\Delta\Psi$), dan selisih kecepatan dua kapal ($\Delta v_{1,2}$) serta satu keluaran.

Pada Tabel 3. 4, variabel masukan jarak kapal dibagi menjadi 3 kategori. Kategori tersebut terdiri dari *Near*, *Medium* dan *Far*. Masing-masing kategori memiliki rentang nilai yang berbeda. Rentang nilai tersebut didapatkan berdasarkan penelitian sebelumnya yang membahas anti tabrakan pada kapal, dan jika kedua kapal berdekatan dengan jarak sangat dekat maka dapat dicurigai melakukan *transhipment*. Nilai perubahan jarak dari kedua kapal dapat dihitung menggunakan formula Haversine yang ditunjukkan oleh persamaan (3.19).

$$a = \sin^2\left(\frac{\text{Lat}_2\left(\frac{\pi}{180}\right) - \text{Lat}_1\left(\frac{\pi}{180}\right)}{2}\right) \quad (3.16)$$

$$b = \cos\left(\text{Lat}_2\left(\frac{\pi}{180}\right)\right) \cos\left(\text{Lat}_1\left(\frac{\pi}{180}\right)\right) \sin^2\left(\frac{\text{Long}_2\left(\frac{\pi}{180}\right) - \text{Long}_1\left(\frac{\pi}{180}\right)}{2}\right) \quad (3.17)$$

$$h = a + b \quad (3.18)$$

$$d = 2r \sin^{-1}(\sqrt{h}) \quad (3.19)$$

dengan:

d = jarak kedua kapal (meter)

r = radius bumi = 6.371.000 (meter)

Lat_1 = posisi *latitude* kapal 1 ($^\circ$)

Lat_2 = posisi *latitude* kapal 2 ($^\circ$)

Long_1 = posisi *longitude* kapal 1 ($^\circ$)

Long_2 = posisi *longitude* kapal 2 ($^\circ$)

Pada Tabel 3.6, variabel masukan *heading* kapal dibagi menjadi 3 kategori yaitu OT (*overtake*), C (*crossing*), dan HO (*head on*). Ketiganya memiliki rentang nilai *overtake* (-6 s.d. 6 derajat), *crossing* (6 s.d. 174 derajat), dan *head on* (174 s.d. 186 derajat). Rentang nilai tersebut berdasarkan dengan aturan COLREGS yang terdapat pada IMO. Variabel masukan selisih *heading* antara kedua kapal dihitung menggunakan persamaan (3.20).

$$\Delta\Psi = \Psi_1 - \Psi_2 \quad (3.20)$$

dengan:

$\Delta\Psi$ = selisih *heading* kedua kapal ($^\circ$)

Ψ_1 = *heading* kapal 1 ($^\circ$)

Ψ_2 = *heading* kapal 2 ($^\circ$)

Selain itu pada Tabel 3.6, variabel masukan selisih kecepatan kedua kapal di sini adalah perbedaan kecepatan kapal 1 dan kecepatan kapal 2 dalam besaran vektor. Kategori pada parameter ini dibagi menjadi 2 untuk mengelompokan setiap nilai dari masukan tersebut. Kategori tersebut yaitu, *small* dengan rentang nilai (0 s.d. 0.8 knot) dan *big* dengan rentang nilai (0.9 s.d. 10 knot). Rentang nilai tersebut didapatkan berdasarkan kecepatan maksimum operasional kapal adalah 10 knot, dan apabila selisih kecepatan kurang dari 0.8 knot dapat dicurigai melakukan

praktik *illegal transhipment*. Variabel masukan tersebut dapat dihitung menggunakan persamaan (3.21).

$$\Delta v_{1,2} = v_1 - v_2 \quad (3.21)$$

dengan:

$\Delta v_{1,2}$ = selisih kecepatan kedua kapal (knot)

v_1 = kecepatan kapal 1 (knot)

v_2 = kecepatan kapal 2 (knot)

Target atau variabel keluaran dari subsistem ANN *decision transhipment* berupa keputusan kapal mana yang terindikasi melakukan IUU *Transhipment* atau tidak terindikasi melakukan IUU *Transhipment*. Nilai keluaran yang menunjukkan lebih dari 50% ($>50\%$), yang mana akan diubah menjadi nilai akhir 1 (*True*), maka terindikasi melakukan IUU *Transhipment*. Nilai keluaran yang menunjukkan kurang dari 50% ($<50\%$), yang mana akan diubah menjadi nilai akhir 0 (*False*), maka tidak terindikasi melakukan IUU *Transhipment*.

Pada pembangkitan dan penentuan data masukan dan target pada subsistem ANN *decision transhipment* untuk identifikasi ini, mengikuti basis aturan dari penelitian sebelumnya (Fatmawati, 2018). Di mana basis aturan tersebut merupakan basis aturan dengan tiga variabel dan kategori dengan rentang nilai tertentu. Berdasarkan variabel dan parameter tersebut diketahui pola pergerakan kapal yang diduga melakukan IUU *Transhipment*. Jumlah basis aturan dibuat berdasarkan asas kemungkinan terjadinya praktik *illegal* tersebut. Basis aturan ini berjumlah 18 aturan *if-then*. Berikut ini merupakan basis aturan yang akan jadi acuan dalam penentuan data masukan dan target pada subsistem ANN *decision transhipment*:

1. If (Jarak__2__Kapal is Near) and (Selisih__Heading is OT) and (Selisih__VK1VK2 is Small) then (Identification__Result is Allegedly__Transhipment)
2. If (Jarak__2__Kapal is Near) and (Selisih__Heading is OT) and (Selisih__VK1VK2 is Big) then (Identification__Result is Not__Allegedly__Transhipment)

3. If (Jarak_2_Kapal is Near) and (Selisih_Heading is C) and (Selisih_VK1VK2 is Small) then (Identification_Result is Allegedly_Transhipment)
4. If (Jarak_2_Kapal is Near) and (Selisih_Heading is C) and (Selisih_VK1VK2 is Big) then (Identification_Result is Not_Allegedly_Transhipment)
5. If (Jarak_2_Kapal is Near) and (Selisih_Heading is HO) and (Selisih_VK1VK2 is Small) then (Identification_Result is Allegedly_Transhipment)
6. If (Jarak_2_Kapal is Near) and (Selisih_Heading is HO) and (Selisih_VK1VK2 is Big) then (Identification_Result is Not_Allegedly_Transhipment)
7. If (Jarak_2_Kapal is Medium) and (Selisih_Heading is OT) and (Selisih_VK1VK2 is Small) then (Identification_Result is Allegedly_Transhipment)
8. If (Jarak_2_Kapal is Medium) and (Selisih_Heading is OT) and (Selisih_VK1VK2 is Big) then (Identification_Result is Not_Allegedly_Transhipment)
9. If (Jarak_2_Kapal is Medium) and (Selisih_Heading is C) and (Selisih_VK1VK2 is Small) then (Identification_Result is Allegedly_Transhipment)
10. If (Jarak_2_Kapal is Medium) and (Selisih_Heading is C) and (Selisih_VK1VK2 is Big) then (Identification_Result is Not_Allegedly_Transhipment)
11. If (Jarak_2_Kapal is Medium) and (Selisih_Heading is HO) and (Selisih_VK1VK2 is Small) then (Identification_Result is Allegedly_Transhipment)
12. If (Jarak_2_Kapal is Medium) and (Selisih_Heading is HO) and (Selisih_VK1VK2 is Big) then (Identification_Result is Not_Allegedly_Transhipment)

13. If (Jarak_2_Kapal is Far) and (Selisih_Heading is OT) and (Selisih_VK1VK2 is Small) then (Identification_Result is Not_Allegedly_Transhipment)
14. If (Jarak_2_Kapal is Far) and (Selisih_Heading is OT) and (Selisih_VK1VK2 is Big) then (Identification_Result is Not_Allegedly_Transhipment)
15. If (Jarak_2_Kapal is Far) and (Selisih_Heading is C) and (Selisih_VK1VK2 is Small) then (Identification_Result is Not_Allegedly_Transhipment)
16. If (Jarak_2_Kapal is Far) and (Selisih_Heading is C) and (Selisih_VK1VK2 is Big) then (Identification_Result is Not_Allegedly_Transhipment)
17. If (Jarak_2_Kapal is Far) and (Selisih_Heading is HO) and (Selisih_VK1VK2 is Small) then (Identification_Result is Not_Allegedly_Transhipment)
18. If (Jarak_2_Kapal is Far) and (Selisih_Heading is HO) and (Selisih_VK1VK2 is Big) then (Identification_Result is Not_Allegedly_Transhipment)

- ***Pre-Processing***

Kemudian data masukan dilakukan *pre-processing* dengan melakukan standardisasi sehingga data dari seluruh variabel masukan terdistribusi normal yang memiliki nilai *mean* sama dengan 0 dan nilai standar deviasi sama dengan 1. Standardisasi dilakukan dengan menggunakan persamaan (3.24).

$$\mu = \frac{1}{N} \sum_{i=1}^N (x_i) \quad (3.22)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (3.23)$$

$$x' = \frac{x - \mu}{\sigma} \quad (3.24)$$

dengan:

x' = data yang sudah distandardisasi

x = data yang belum distandardisasi

μ = rata-rata data yang belum distandardisasi

σ = standard deviasi data yang belum distandardisasi

N = jumlah data

- **Penentuan Model Arsitektur Jaringan dan Parameter ANN *Decision Transhipment***

Berdasarkan pada aspek yang dibahas pada bagian pembangkitan data dan penentuan data masukan dan target, model ANN harus mempertimbangkan dimensi *input layer* yang terdiri dari tiga *neurons*, yang sesuai dengan jumlah variabel masukan pada subsistem ANN *decision transhipment* yaitu tiga variabel masukan. Parameter lainnya yang diperlukan untuk membuat *neural networks*, di antaranya adalah fungsi aktivasi (*activation function*) dan pengoptimal (*optimizer*), jumlah lapisan tersembunyi (*hidden layers*) dan jumlah *neurons* masing-masing (*neurons* pada *hidden layer*), nilai laju pembelajaran (*learning rate*), dan jumlah *epochs*, yang didefinisikan sebagai berikut:

- Jumlah hidden layers: 1
- Jumlah neurons pada hidden layer: 5, 10, 15, 20, 25
- Fungsi aktivasi: *rectified linear unit* (ReLU) pada *input layer* dan *hidden layer*, sigmoid pada *output layer*
- Optimizer: *adaptative moment estimation* (Adam)
- Nilai learning rate: 0.0001, 0.0005, 0.001, 0.005, 0.01
- Jumlah epochs: 100

Pada perancangan ANN *decision transhipment*, parameter yang divariasikan hanyalah jumlah *neurons* pada *hidden layer* dan nilai *learning rate*.

Pada fungsi aktivasi digunakan *rectified linear unit* (ReLU) pada *input layer* dan *hidden layer*, sedangkan pada *output layer* digunakan fungsi aktivasi sigmoid. Penggunaan fungsi aktivasi ReLu pada *input layer* dan *hidden layer* dikarenakan fungsi aktivasi ReLu mampu belajar lebih cepat dibanding fungsi aktivasi yang lain itu disebabkan fungsi aktivasi ReLu tidak mengaktifkan semua *neurons* secara bersamaan, yang mana membuat lebih efisien dan mudah dalam komputasi. Penggunaan fungsi aktivasi sigmoid pada *output layer* dikarenakan keluaran dari ANN *decision transhipment* merupakan probabilitas yang bernilai di antara 0%-50% dan 51%-100%, yang mana ini sangat cocok menggunakan fungsi aktivasi

sigmoid di mana fungsi aktivasi sigmoid akan merubah nilai keluaran dari *decision transhipment* yang bernilai 0%-50% menjadi 0 dan nilai keluaran yang bernilai 51%-100% menjadi 1, yang mana jika nilai 0 maka tidak terindikasi melakukan IUU *Transhipmen* dan jika nilai 1 maka terindikasi melakukan IUU *Transhipment*.

Pada *optimizer* digunakan fungsi optimasi Adam, yang mana merupakan salah satu fungsi optimasi yang tersedia pada Keras *library*. Adam (Kingma & Ba, 2015) adalah suatu algoritma untuk optimisasi berbasis gradien orde pertama dari fungsi objektif stokastik. Ini adalah metode yang sederhana dan mudah yang membutuhkan memori komputasi rendah dan cocok untuk masalah optimisasi *nonconvex* dalam pembelajaran mesin.

- **Pelatihan dan Pengujian dengan Pengimplementasian K-Fold Cross Validation**

K-fold cross-validation (Picard & Cook, 1984) digunakan dalam 4500 pengamatan yang terkandung dalam dataset, yang dibagi menjadi lima set dengan ukuran yang kira-kira sama seperti ditunjukkan pada Gambar 3.11.

ANN 1	<i>Testing set</i>	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>
ANN 2	<i>Training set</i>	<i>Testing set</i>	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>
ANN 3	<i>Training set</i>	<i>Training set</i>	<i>Testing set</i>	<i>Training set</i>	<i>Training set</i>
ANN 4	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>	<i>Testing set</i>	<i>Training set</i>
ANN 5	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>	<i>Testing set</i>

Gambar 3. 11 Representasi skematis prosedur *k-fold cross validation* pada ANN *decision transhipment*

Dalam pendekatan ini, empat set (80% pengamatan atau sebanyak 3600 pengamatan) digunakan untuk melatih *neural network*, dan set yang tersisa (20% dari pengamatan atau sebanyak 900 pengamatan) disimpan untuk menguji kinerja

model. Proses ini dilakukan lima kali karena lima kombinasi yang berbeda digunakan untuk membagi lima set menjadi empat set untuk mengembangkan model (*train*) dan set lainnya untuk melakukan tes yang sesuai (*test*). Pendekatan ini memungkinkan kapasitas prediksi umum ANN untuk diprediksi, yang mana menguntungkan.

- **Pemilihan Model Arsitektur Jaringan Terbaik dan Parameter ANN *Decision Transhipment* yang Paling Optimal**

Selama implementasi proses *k-fold cross validation*, akan dihasilkan 25 model *neural networks*, sebagai hasil dari kombinasi lima *neurons* pada *hidden layer* untuk lima nilai *learning rate*. Dari 25 *neural networks* tersebut, model terbaik dengan parameter paling optimal akan dipilih berdasarkan model yang menghasilkan rata-rata akurasi paling tinggi dan standard deviasi rendah.

- **Evaluasi Model Arsitektur Jaringan ANN *Decision Transhipment***

Evaluasi model arsitektur jaringan ANN *decision transhipment* dilakukan dengan membandingkan hasil keluaran identifikasi dari ANN *decision transhipment* terhadap hasil dari keluaran subsistem *decision transhipment* dari rancangan penelitian sebelumnya (Fatmawati, 2018).

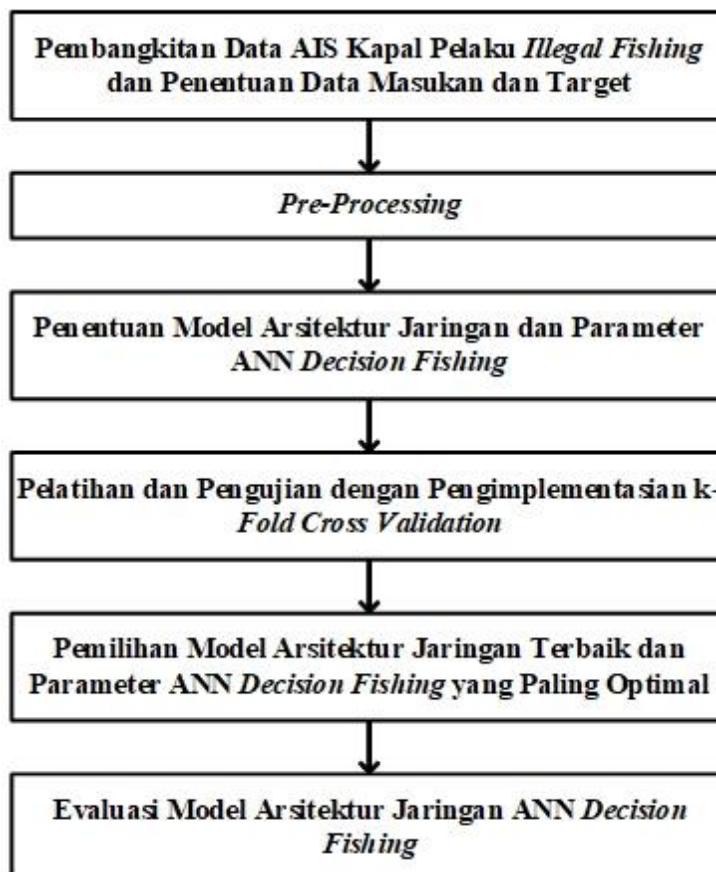
3.8.2.2 Perancangan ANN *Decision Fishing*

ANN *decision fishing* merupakan salah satu sub sistem yang diintegrasikan di dalam ANN *decision*, untuk mengidentifikasi terjadinya *illegal fishing*. Kapal cantrang yang biasanya banyak digunakan oleh nelayan di Indonesia adalah berukuran 30 GT. Pada kapal cantrang saat menangkap ikan terdapat 3 proses yaitu, *casting* atau *setting*, *towing*, dan *hauling*. *Casting* atau *setting* adalah saat kapal menebar jaring selambar biasanya sejauh \pm 1000 meter dengan kecepatan dibawah 1 knot. Kecepatan rendah seperti itu memudahkan kapal membentuk pola melingkar, karena penebaran jaring kapal cantrang cenderung melingkar seperti kerucut atau disebut “*cone*”. Kecepatan pada waktu dilakukan proses tersebut sangat mempengaruhi jumlah tangkapan ikan. *Towing* adalah proses menarik jaring secara vertikal setelah proses tebar jaring selesai dilakukan, dengan kecepatan 1 s.d 2 knot. *Hauling* adalah proses saat jaring yang sudah menangkap ikan ditarik ke

atas kapal, dilakukan dengan posisi kapal bertahan atau mendekati 0 knot (Badan Standardisasi Nasional, 2006).

ANN *decision fishing* terdapat 5 variabel masukan yaitu kecepatan kapal saat melakukan *casting* (V_c), kecepatan kapal saat melakukan *towing* (V_t), kecepatan kapal saat melakukan *hauling* (V_h), laju perubahan posisi *latitude* (dlat) dan *longitude* (dlong). Laju perubahan posisi pada kapal cantrang biasanya adalah 0.025 *nautical mile* atau setara dengan ± 45 meter. Terdapat perbedaan dengan kapal yang menggunakan alat tangkap *trawl* memiliki laju perubahan posisi yang cenderung besar yaitu ± 0.1 *nautical mile* atau setara dengan 185.4 meter. Hal tersebut dikarenakan jaring yang digunakan cantrang lebih kecil secara ukuran lebar dibandingkan dengan jaring *trawl* (Sasmita, 2013).

Proses perancangan ANN *decision fishing* terdiri dari beberapa tahap seperti ditunjukkan oleh Gambar 3. 12.



Gambar 3. 12 Diagram alir perancangan ANN *decision fishing*

- **Pembangkitan Data AIS Kapal Pelaku *Illegal Fishing* dan Penentuan Data Masukan dan Target**

Pembangkitan data AIS kapal pelaku *illegal fishing* dan penentuan data masukan dan target didasarkan pada informasi dari penelitian sebelumnya (Fatmawati, 2018) dengan sedikit perubahan agar lebih efisien untuk kategori variabelnya. ANN *decision fishing* memiliki data variabel masukan tambahan dan rentang nilai parameter sesuai dengan pola gerak kapal yang terindikasi melakukan *illegal fishing*. Parameter tersebut memudahkan untuk pengambilan keputusan, kapal-kapal tersebut terindikasi melakukan praktik *illegal fishing* atau tidak. Variabel yang digunakan dalam pembangkitan data untuk data masukan ANN *decision fishing* ditunjukkan pada Tabel 3. 5.

Tabel 3. 5 Variabel Masukan pada Subsistem ANN *Decision Fishing*

No	Variabel	Satuan	Kategori	Rentang Nilai
1	Kecepatan saat <i>casting</i> (Vc)	Knot	<i>Low</i>	0 s.d. 0.1
			<i>Medium</i>	0.2 s.d. 0.9
			<i>High</i>	1 s.d. 2
2	Kecepatan saat <i>towing</i> (Vt)	Knot	<i>Low</i>	0 s.d. 0.9
			<i>High</i>	1 s.d. 2
3	Kecepatan saat <i>hauling</i> (Vh)	Knot	<i>Low</i>	0 s.d. 0.1
			<i>High</i>	0.2 s.d. 0.4
4	Laju perubahan posisi <i>latitude</i> (dlat)	<i>Nautical Mile</i>	<i>Low</i>	0 s.d. 0.0009
			<i>Medium</i>	0.001 s.d. 0.05
			<i>High</i>	0.06 s.d. 0.1
5	Laju perubahan posisi <i>longitude</i> (dlong)	<i>Nautical Mile</i>	<i>Low</i>	0 s.d. 0.0009
			<i>Medium</i>	0.001 s.d. 0.05
			<i>High</i>	0.06 s.d. 0.1

Seperti yang ditunjukkan oleh Gambar 3. 9, pada ANN *decision fishing* terdapat lima variabel masukan yaitu kecepatan kapal saat melakukan *casting* (Vc), kecepatan kapal saat melakukan *towing* (Vt), kecepatan kapal saat melakukan *hauling* (Vh), laju perubahan posisi *latitude* (dlat) dan *longitude* (dlong) dan satu keluaran.

Pada Tabel 3. 5, variabel masukan kecepatan kapal saat melakukan *casting* dibagi menjadi 3 kategori. Kategori tersebut terdiri dari *Low*, *Medium* dan *High*. Masing-masing kategori memiliki rentang nilai yang berbeda. Rentang nilai tersebut didapatkan berdasarkan penelitian sebelumnya (Fatmawati, 2018), tetapi dimodifikasi lagi rentangnya pada penelitian ini agar lebih efisien dan sesuai dengan kegiatan pengoperasian kapal cantrang saat melakukan penangkapan ikan. Kapal cantrang yang digunakan umumnya memiliki muatan 30 GT. Pemilihan rentang nilai kategori pada kecepatan saat *casting* ini dikarenakan kecepatan kapal pada saat melakukan *casting*, dengan menebar jaring selambar biasanya sejauh ± 1000 meter, adalah dibawah 1 knot tetapi tidak terlalu mendekati 0 knot, yang mana itu berada di rentang kategori *Medium*. Kecepatan rendah seperti itu memudahkan kapal membentuk pola melingkar, karena penebaran jaring kapal cantrang cenderung melingkar seperti kerucut atau disebut “*cone*”. Kecepatan pada waktu dilakukan proses tersebut sangat mempengaruhi jumlah tangkapan ikan.

Pada Tabel 3.5, variabel masukan kecepatan kapal saat melakukan *towing* dibagi menjadi 2 kategori yaitu *Low* dan *High*. Keduanya memiliki rentang nilai yang berbeda. Rentang nilai tersebut didapatkan berdasarkan spesifikasi dan pengoperasian kapal cantrang saat melakukan penangkapan ikan. Kapal cantrang yang digunakan umumnya memiliki muatan 30 GT. Pemilihan rentang nilai kategori pada kecepatan saat *towing* ini dikarenakan kecepatan kapal pada saat melakukan *towing*, dengan menarik jaring secara vertikal setelah proses tebar jaring selesai dilakukan, adalah 1 s.d 2 knot, yang mana itu berada di rentang kategori *High*.

Pada Tabel 3.5, variabel masukan kecepatan kapal saat melakukan *hauling* dibagi menjadi 2 kategori yaitu *Low* dan *High*. Keduanya memiliki rentang nilai yang berbeda. Rentang nilai tersebut didapatkan berdasarkan spesifikasi dan pengoperasian kapal cantrang saat melakukan penangkapan ikan. Kapal cantrang yang digunakan umumnya memiliki muatan 30 GT. Pemilihan rentang nilai kategori pada kecepatan saat *hauling* ini dikarenakan kecepatan kapal pada saat melakukan *hauling*, saat jaring yang sudah menangkap ikan ditarik ke atas kapal, dilakukan dengan posisi kapal bertahan atau mendekati 0 knot (Badan Standardisasi Nasional, 2006), yang mana itu berada di rentang kategori *Low*.

Pada Tabel 3.5, variabel masukan laju perubahan posisi lintang (*latitude*) dan bujur (*longitude*) dibagi menjadi 3 kategori yaitu *Low*, *Medium*, dan *High*. Rentang nilai tersebut didapatkan berdasarkan spesifikasi dan pengoperasian kapal cantrang saat melakukan penangkapan ikan. Kapal cantrang yang digunakan umumnya memiliki muatan 30 GT. Kapal cantrang biasanya melakukan penebaran jaring selama 20 s.d 25 menit dengan jaring selambar \pm 1000 meter, oleh karena itu laju perubahan posisi kapal cantrang biasanya adalah 0.025 *nautical mile* atau setara \pm 45 meter. Terdapat perbedaan dengan kapal yang menggunakan alat tangkap *trawl* memiliki laju perubahan posisi yang cenderung besar yaitu \pm 0.1 *nautical mile* atau setara dengan 185.4 meter. Hal tersebut dikarenakan jaring yang digunakan cantrang lebih kecil secara ukuran lebar dibandingkan dengan jaring *trawl* (Sasmita, 2013). Variabel masukan laju perubahan posisi *latitude* dan *longitude* masing-masing dihitung menggunakan persamaan (3.25) dan (3.26).

$$dlat = \sum_{i=1}^n (lat_{i+1} - lat_i) \frac{60}{n} \quad (3.25)$$

$$dlong = \sum_{i=1}^n (long_{i+1} - long_i) \frac{60}{n} \quad (3.26)$$

dengan:

dlat = laju perubahan posisi *latitude* (*nautical mile*)

dlong = laju perubahan posisi *longitude* (*nautical mile*)

lat = *latitude* ke-i ($^{\circ}$)

long = *longitude* ke-i ($^{\circ}$)

N = banyaknya percobaan

i = indeks setiap percobaan

Target atau variabel keluaran dari subsistem ANN *decision fishing* berupa keputusan kapal mana yang terindikasi melakukan IUU *Fishing* atau tidak terindikasi melakukan IUU *Fishing*. Nilai keluaran yang menunjukkan lebih dari 50% ($>50\%$), yang mana akan diubah menjadi nilai akhir 1 (*True*), maka terindikasi melakukan IUU *Fishing*. Nilai keluaran yang menunjukkan kurang dari 50% ($<50\%$), yang mana akan diubah menjadi nilai akhir 0 (*False*), maka tidak terindikasi melakukan IUU *Fishing*.

Pada pembangkitan dan penentuan data masukan dan target pada subsistem ANN *decision fishing* untuk identifikasi ini, mengikuti basis aturan dengan lima variabel dan kategori dengan rentang nilai tertentu. Berdasarkan variabel dan parameter tersebut diketahui pola pergerakan kapal yang diduga melakukan IUU IUU *Fishing*. Jumlah basis aturan dibuat berdasarkan atas kemungkinan terjadinya praktik *illegal* tersebut. Basis aturan ini berjumlah 108 aturan *if-then*, tetapi dikarenakan jumlah observasi data yang dihasilkan sangat banyak dari 108 basis aturan ini, maka hanya digunakan 5 basis aturan yang sangat mewakili kejadian yang mengindikasikan terjadi IUU *Fishing* dan yang mewakili kejadian tidak mengindikasikan terjadi IUU *Fishing*. Berikut ini merupakan 5 basis aturan yang akan jadi acuan dalam penentuan data masukan dan target pada subsistem ANN *decision fishing*:

1. If (Vc is Med) and (Vt is High) and (Vh is Low) and (dlat is Med) and (dlon is Med) then (Identification__Result is Allegedly_IUU)
2. If (Vc is High) and (Vt is Low) and (Vh is High) and (dlat is High) and (dlon is High) then (Identification__Result is Not_Allegedly_IUU)
3. If (Vc is Low) and (Vt is Low) and (Vh is High) and (dlat is Low) and (dlon is Low) then (Identification__Result is Not_Allegedly_IUU)
4. If (Vc is High) and (Vt is High) and (Vh is High) and (dlat is High) and (dlon is High) then (Identification__Result is Not_Allegedly_IUU)
5. If (Vc is Low) and (Vt is Low) and (Vh is Low) and (dlat is Low) and (dlon is Low) then (Identification__Result is Not_Allegedly_IUU)

- ***Pre-Processing***

Kemudian data masukan dilakukan *pre-processing* dengan melakukan standardisasi sehingga data dari seluruh variabel masukan terdistribusi normal yang memiliki nilai *mean* sama dengan 0 dan nilai standar deviasi sama dengan 1. Standardisasi dilakukan dengan menggunakan persamaan (3.29).

$$\mu = \frac{1}{N} \sum_{i=1}^N (x_i) \quad (3.27)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (3.28)$$

$$x' = \frac{x - \mu}{\sigma} \quad (3.29)$$

dengan:

- x' = data yang sudah distandardisasi
- x = data yang belum distandardisasi
- μ = rata-rata data yang belum distandardisasi
- σ = standard deviasi data yang belum distandardisasi
- N = jumlah data

- **Penentuan Model Arsitektur Jaringan dan Parameter ANN *Decision Fishing***

Berdasarkan pada aspek yang dibahas pada bagian pembangkitan data dan penentuan data masukan dan target, model ANN harus mempertimbangkan dimensi *input layer* yang terdiri dari lima *neurons*, yang sesuai dengan jumlah variabel masukan pada subsistem ANN *decision fishing* yaitu lima variabel masukan. Parameter lainnya yang diperlukan untuk membuat *neural networks*, di antaranya adalah fungsi aktivasi (*activation function*) dan pengoptimal (*optimizer*), jumlah lapisan tersembunyi (*hidden layers*) dan jumlah *neurons* masing-masing (*neurons* pada *hidden layer*), nilai laju pembelajaran (*learning rate*), dan jumlah *epochs*, yang didefinisikan sebagai berikut:

- Jumlah hidden layers: 1
- Jumlah neurons pada hidden layer: 5, 10, 15, 20, 25
- Fungsi aktivasi: *rectified linear unit* (ReLU) pada *input layer* dan *hidden layer*, sigmoid pada *output layer*
- Optimizer: *adaptative moment estimation* (Adam)
- Nilai learning rate: 0.0001, 0.0005, 0.001, 0.005, 0.01
- Jumlah epochs: 100

Pada perancangan ANN *decision fishing*, parameter yang divariasikan hanyalah jumlah *neurons* pada *hidden layer* dan nilai *learning rate*.

Pada fungsi aktivasi digunakan *rectified linear unit* (ReLU) pada *input layer* dan *hidden layer*, sedangkan pada *output layer* digunakan fungsi aktivasi sigmoid. Penggunaan fungsi aktivasi ReLU pada *input layer* dan *hidden layer* dikarenakan fungsi aktivasi ReLU mampu belajar lebih cepat dibanding fungsi aktivasi yang lain itu disebabkan fungsi aktivasi ReLU tidak mengaktifkan semua *neurons* secara

bersamaan, yang mana membuat lebih efisien dan mudah dalam komputasi. Penggunaan fungsi aktivasi sigmoid pada *output layer* dikarenakan keluaran dari ANN *decision fishing* merupakan probabilitas yang bernilai di antara 0%-50% dan 51%-100%, yang mana ini sangat cocok menggunakan fungsi aktivasi sigmoid di mana fungsi aktivasi sigmoid akan merubah nilai keluaran dari *decision transhipment* yang bernilai 0%-50% menjadi 0 dan nilai keluaran yang bernilai 51%-100% menjadi 1, yang mana jika nilai 0 maka tidak terindikasi melakukan IUU *Fishing* dan jika nilai 1 maka terindikasi melakukan IUU *Fishing*.

Pada *optimizer* digunakan fungsi optimasi Adam, yang mana merupakan salah satu fungsi optimasi yang tersedia pada Keras *library*. Adam (Kingma & Ba, 2015) adalah suatu algoritma untuk optimisasi berbasis gradien orde pertama dari fungsi objektif stokastik. Ini adalah metode yang sederhana dan mudah yang membutuhkan memori komputasi rendah dan cocok untuk masalah optimisasi *nonconvex* dalam pembelajaran mesin.

- **Pelatihan dan Pengujian dengan Pengimplementasian K-Fold Cross Validation**

K-fold cross-validation (Picard & Cook, 1984) digunakan dalam 4745 pengamatan yang terkandung dalam dataset, yang dibagi menjadi lima set dengan ukuran yang kira-kira sama seperti ditunjukkan pada Gambar 3.13.

ANN 1	<i>Testing set</i>	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>
ANN 2	<i>Training set</i>	<i>Testing set</i>	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>
ANN 3	<i>Training set</i>	<i>Training set</i>	<i>Testing set</i>	<i>Training set</i>	<i>Training set</i>
ANN 4	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>	<i>Testing set</i>	<i>Training set</i>
ANN 5	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>	<i>Training set</i>	<i>Testing set</i>

Gambar 3. 13 Representasi skematis prosedur *k-fold cross validation* pada ANN *decision fishing*

Dalam pendekatan ini, empat set (80% pengamatan atau sebanyak 3796 pengamatan) digunakan untuk melatih *neural network*, dan set yang tersisa (20% dari pengamatan atau sebanyak 949 pengamatan) disimpan untuk menguji kinerja model. Proses ini dilakukan lima kali karena lima kombinasi yang berbeda digunakan untuk membagi lima set menjadi empat set untuk mengembangkan model (*train*) dan set lainnya untuk melakukan tes yang sesuai (*test*). Pendekatan ini memungkinkan kapasitas prediksi umum ANN untuk diprediksi, yang mana menguntungkan.

- **Pemilihan Model Arsitektur Jaringan Terbaik dan Parameter ANN *Decision Fishing* yang Paling Optimal**

Selama implementasi proses *k-fold cross validation*, akan dihasilkan 25 model *neural networks*, sebagai hasil dari kombinasi lima *neurons* pada *hidden layer* untuk lima nilai *learning rate*. Dari 25 *neural networks* tersebut, model terbaik dengan parameter paling optimal akan dipilih berdasarkan model yang menghasilkan rata-rata akurasi paling tinggi dan standard deviasi rendah.

- **Evaluasi Model Arsitektur Jaringan ANN *Decision Fishing***

Evaluasi model arsitektur jaringan ANN *decision fishing* dilakukan dengan membandingkan hasil keluaran identifikasi dari ANN *decision fishing* terhadap hasil dari keluaran subsistem *decision fishing* dari rancangan penelitian sebelumnya (Fatmawati, 2018).

3.9 Analisa Hasil Perancangan Integrasi Sistem untuk Identifikasi dengan Artificial Neural Networks (ANN Selection & ANN Decision)

Analisa dilakukan dengan menguji integrasi sistem yang telah dirancang, dengan berbagai variasi pola gerak kapal yang telah dibangkitkan. Pembangkitan data posisi 2 kapal untuk uji pola pergerakan kapal *illegal transhipment* dilakukan dengan memvariasikan variabel untuk uji coba sistem yang diperoleh dari pembangkitan data *heading*, kecepatan dan posisi kapal dengan berbagai trayektori yang mengacu pada standar data AIS dua kapal yang melakukan *transhipment*. Pengujian dilakukan untuk melihat apakah sistem yang dirancang telah sesuai dengan target yang diinginkan. Pembangkitan data posisi kapal untuk uji pola pergerakan kapal *illegal fishing* dilakukan dengan memvariasikan variabel untuk

uji coba sistem diperoleh dari pembangkitan data kecepatan kapal saat melakukan *casting*, kecepatan kapal saat melakukan *towing*, kecepatan kapal saat melakukan *hauling*, laju perubahan posisi lintang (*latitude*) dan bujur (*longitude*). Data tersebut kemudian diketahui pola pergerakan kapal *illegal fishing* yang menggunakan alat tangkap cantrang. Pengujian dilakukan untuk melihat apakah sistem yang dirancang telah sesuai dengan target yang diinginkan.

3.10 Validasi Integrasi Sistem untuk Identifikasi

Validasi dilakukan untuk menguji apakah sistem yang telah dirancang dapat dikatakan valid atau sesuai. Pada keputusan akhir ANN *decision* terdapat 2 subsistem yaitu, ANN *decision transhipment* untuk identifikasi terjadinya *illegal transhipment* dan ANN *decision fishing* untuk identifikasi terjadinya *illegal fishing*. Masing-masing sistem mempunyai keluaran apabila trayektori kapal melebihi 50% maka dapat dikatakan terindikasi melakukan *illegal transhipment* atau *illegal fishing*. Apabila kedua sistem menunjukkan kurang dari 50% maka dapat dikatakan tidak terindikasi *illegal transhipment* atau *illegal fishing*.

Validasi untuk terjadinya *illegal transhipment* dilakukan dengan menggunakan masukan sistem berupa data kecepatan kapal pada pelabuhan dan perubahan posisi kapal pada penelitian sebelumnya. Data *real AIS* kapal tersebut didapatkan dari website marinetraffic.com, sebanyak 30 data kapal Nordic Bahari. Pendekatan ini dilakukan dengan asumsi bahwa pelabuhan adalah sebuah kapal diam ditengah laut yang sedang menunggu kapal lain untuk melakukan transhipment. Data validasi tersebut merupakan kapal yang sedang bersandar di pelabuhan Sorong, Papua pada tanggal 16 April 2016 pukul 11.00 WIB sampai tanggal 16 April 2016 pukul 11.15 WIB. Data validasi kedua merupakan data AIS kapal Eagle Seville dan Lurongyuanyu 105 di Perairan Batam pada tanggal 02 Mei 2016 pukul 11.30 WIB sampai tanggal 02 Mei 2016 pukul 11.45 WIB.

Validasi untuk terjadinya *illegal fishing* dilakukan dengan menggunakan masukan sistem berupa data kecepatan kapal di selat Singapura kapal ikan A pada 21 Agustus 2017 pukul 02.40 WIB sampai tanggal 21 Agustus 2017 pukul 05.15 WIB. Data validasi kedua merupakan data AIS kapal ikan B pada tanggal 21 September 2017 pukul 06.43 WIB sampai tanggal 21 September 2017 pukul 10.45

WIB. Data *real AIS* kapal tersebut didapatkan dari NASDEC, sebanyak ratusan data namun disortir ketika terindikasi melakukan *illegal fishing*. Pendekatan ini dilakukan karena kapal memiliki pola gerak atau trayektori sama persis dengan cantrang, yaitu melakukan gerakan melingkar. Data validasi tersebut merupakan data *real AIS* dari kapal yang tertangkap sedang melakukan *illegal transhipment* dan *illegal fishing* dapat dilihat pada Bab IV.

3.11 Penyusunan Laporan dan Pengambilan Kesimpulan

Setelah dilakukan validasi, kemudian dilakukan penyusunan laporan dan pengambilan kesimpulan.

BAB IV

HASIL DAN PEMBAHASAN

Dalam bab ini akan dijelaskan mengenai hasil dan pembahasan terkait prediksi data AIS kapal pelaku *illegal fishing* dan *illegal transhipment* yang hilang dan validasinya beserta penjabaran pembahasan mengenai penentuan parameter yang optimal untuk model RNN pada rancangan subsistem RNN *predictor*. Pada bab ini juga akan dijelaskan mengenai hasil dan pembahasan terkait perancangan dan validasi integrasi sistem untuk identifikasi kapal pelaku *illegal fishing* dan *illegal transhipment*.

4.1 Hasil Pengujian Prediksi Data AIS *Longitude* dan *Latitude* yang Hilang pada Kapal *Illegal Fishing* dan *Transhipment*

Pada proses pengujian prediksi data AIS *longitude* dan *latitude* yang hilang pada kapal *illegal fishing* dan *transhipment*, dilakukan observasi terhadap kombinasi parameter untuk mendapatkan kombinasi parameter terbaik, meliputi jumlah LSTM *layers*, jumlah *unit neuron* pada LSTM *layers* dan nilai *learning rate*. Berikut adalah variasi nilai parameter yang diuji.

- Jumlah LSTM layers: 1
- Nilai learning rate: 0.001, 0.005, 0.01, 0.05, 0.1
- Jumlah unit neuron pada LSTM layers: 5, 10, 15, 20, 25

Untuk masing-masing parameter yang dikombinasikan dilakukan percobaan sebanyak 5 kali, hasil yang diambil adalah rata-rata dari 5 kali percobaan tersebut. Hal ini dilakukan karena bobot awal diinisialisasi secara acak, sehingga hasil yang didapatkan tidak akan sama setiap kali percobaan, bisa saja kebetulan baik, atau kebetulan buruk. Agar sistem yang dibangun tidak mengalami kondisi *overfitting*, maka *error* yang diperhitungkan adalah *error* pada proses pengujian. Parameter yang menghasilkan *error* pengujian terkecil dianggap sebagai parameter terbaik. Berikut ini adalah parameter-parameter awal yang digunakan:

- Jumlah LSTM layers: 1
- Jumlah unit neuron pada LSTM layers: 5

4.1.1 Hasil Pengujian *Learning Rate* pada LSTM Layers untuk Prediksi Data AIS *Longitude* dan *Latitude* yang Hilang

Learning rate adalah sebuah parameter yang mempengaruhi kecepatan jaringan saraf tiruan dalam mencari solusi minimum. Nilai *learning rate* yang terlalu kecil akan mengakibatkan laju perubahan pada bobot dalam mencari solusi menjadi pelan sedangkan nilai *learning rate* yang terlalu besar akan mengakibatkan laju perubahan bobot dalam langkah mencari solusi menjadi sangat besar dan sulit menemukan solusi. Bahkan jika terlalu besar maka sistem akan berosilasi dan tidak bias mencapai kondisi konvergen. Tidak ada aturan pasti berapa nilai *learning rate* yang cocok dalam suatu prediksi data *time series*. Nilai *learning rate* yang cocok umumnya didapatkan melalui percobaan (*trials and error*).

Nilai *learning rate* yang digunakan dalam skenario pengujian ini adalah 0.001, 0.005, 0.01, 0.05 dan 0.1. Tabel 4.1 merupakan hasil pengujian dengan menggunakan beberapa nilai *learning rate*.

Tabel 4. 1 Hasil Pengujian Kombinasi Parameter *Learning Rate* untuk Prediksi Data AIS *Longitude* dan *Latitude* yang Hilang

LSTM Layers	LSTM Unit Neurons	Learning Rate	MAPE (Average)
1	5	0.001	0.056%
1	5	0.005	0.055%
1	5	0.01	0.058%
1	5	0.05	0.059%
1	5	0.1	0.062%

Berdasarkan Tabel 4.1, diketahui bahwa penggunaan nilai *learning rate* sebesar 0.005 menghasilkan MAPE terkecil yaitu 0.055%.

4.1.2 Hasil Pengujian *Unit Neuron* pada LSTM Layers untuk Prediksi Data AIS *Longitude* dan *Latitude* yang Hilang

Jumlah *unit neuron* LSTM layers mempengaruhi penghitungan pada fungsi aktivasi suatu *neuron* pada *output layer* dari sistem yang dibangun yang pada akhirnya menentukan nilai *output* yang dihasilkan oleh RNN.

Tidak ada aturan pasti berapa jumlah *unit neuron LSTM layers* yang cocok dalam suatu prediksi data *time series*. Jumlah *unit neuron* yang besar pada LSTM *layers* tidak dapat merepresentasikan bahwa hasil yang didapat akan semakin baik. Hal ini bergantung pada kasus yang dialami. Sehingga biasanya jumlah *unit neuron* yang digunakan didapat melalui percobaan (*trials and error*).

Parameter jumlah *unit neuron* yang digunakan adalah 5, 10, 15, 20 dan 25 *units neurons*. Tabel 4.2 merupakan hasil pengujian dengan beberapa parameter tersebut.

Tabel 4.2 Hasil Pengujian Kombinasi Parameter *Unit Neurons* pada LSTM *Layers* untuk Prediksi Data AIS *Longitude* dan *Latitude* yang Hilang

LSTM Layers	LSTM Unit Neurons	Learning Rate	MAPE (Average)
1	5	0.005	0.055%
1	10	0.005	0.056%
1	15	0.005	0.057%
1	20	0.005	0.058%
1	25	0.005	0.056%

Berdasarkan Tabel 4.2 diketahui bahwa penggunaan jumlah *unit neuron* sebanyak 5 buah menghasilkan MAPE terkecil yaitu 0.055%.

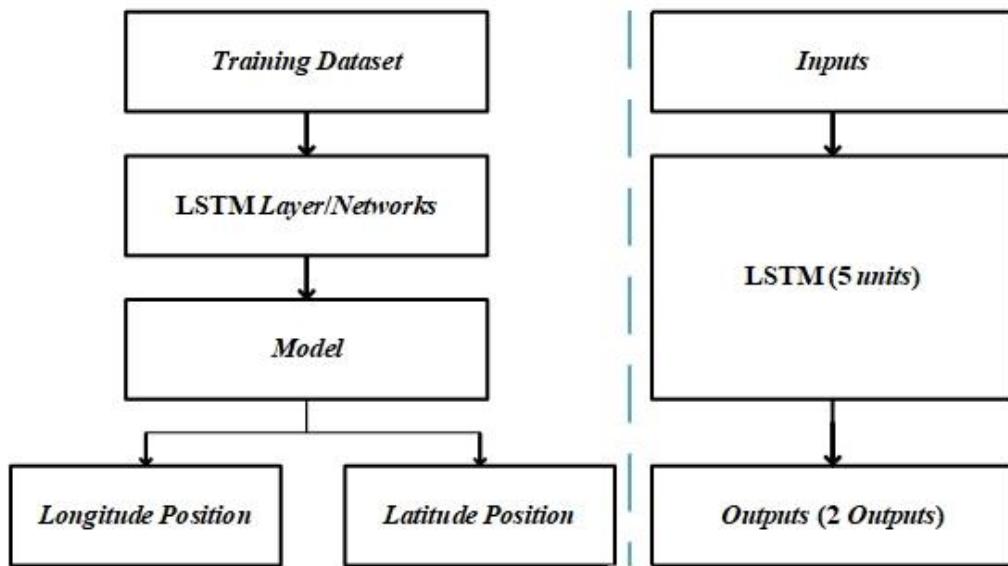
4.2 Model Arsitektur Jaringan RNN *Predictor* untuk Prediksi Data AIS *Longitude* dan *Latitude* yang Hilang

Berdasarkan pengujian yang telah dilakukan, diperoleh parameter yang optimal yang dapat digunakan untuk memprediksi data AIS *longitude* dan *latitude* yang hilang. Parameter-parameter tersebut adalah:

- Jumlah LSTM layers: 1
- Jumlah unit neuron pada LSTM layers: 5
- Nilai learning rate: 0.005

Selain menggunakan parameter di atas, jaringan dilatih dan diuji menggunakan *batch* ukuran 2, selain itu *input layer* dan *output layer* adalah lapisan

padat/*dense layer* (terhubung sepenuhnya). *Loss function* yang digunakan adalah *Mean Squared Error*, *optimizer* yang digunakan adalah *Adaptive Moment Estimation* (Adam), dan model dilatih sebanyak 100 *epochs*. Dari hasil pelatihan dan pengujian ini, maka didapatkan model terbaik untuk prediksi data AIS *longitude* dan *latitude* yang hilang seperti ditunjukkan oleh Gambar 4.1.



Gambar 4.1 Model RNN untuk prediksi data AIS *longitude* dan *latitude* yang hilang

Tabel 4.3 merupakan performa dari model RNN untuk prediksi data AIS *longitude* dan *latitude* yang hilang.

Tabel 4.3 MAPE Dari Model RNN untuk Prediksi Data AIS *Longitude* dan *Latitude* yang Hilang

Time Step (Pola Input)	MAPE <i>Longitude</i> dan <i>Latitude</i>
2	0.055%

4.3 Hasil Pengujian Prediksi Data AIS *Heading* yang Hilang pada Kapal *Illegal Fishing* dan *Transhipment*

Pada proses pengujian prediksi data AIS *heading* yang hilang pada kapal *illegal fishing* dan *transhipment*, dilakukan observasi terhadap kombinasi parameter untuk mendapatkan kombinasi parameter terbaik, meliputi jumlah

LSTM *layers*, jumlah *unit neuron* pada LSTM *layers* dan nilai *learning rate*. Berikut adalah variasi nilai parameter yang diuji.

- Jumlah LSTM layers: 1
- Nilai learning rate: 0.001, 0.005, 0.01, 0.05, 0.1
- Jumlah unit neuron pada LSTM layers: 5, 10, 15, 20, 25

Untuk masing-masing parameter yang dikombinasikan dilakukan percobaan sebanyak 5 kali, hasil yang diambil adalah rata-rata dari 5 kali percobaan tersebut. Hal ini dilakukan karena bobot awal diinisialisasi secara acak, sehingga hasil yang didapatkan tidak akan sama setiap kali percobaan, bisa saja kebetulan baik, atau kebetulan buruk. Agar sistem yang dibangun tidak mengalami kondisi *overfitting*, maka *error* yang diperhitungkan adalah *error* pada proses pengujian. Parameter yang menghasilkan *error* pengujian terkecil dianggap sebagai parameter terbaik. Berikut ini adalah parameter-parameter awal yang digunakan:

- Jumlah unit neuron pada LSTM layers: 15
- Nilai learning rate: 0.001

4.3.1 Hasil Pengujian *Learning Rate* pada LSTM Layers untuk Prediksi Data AIS Heading yang Hilang

Learning rate adalah sebuah parameter yang mempengaruhi kecepatan jaringan saraf tiruan dalam mencari solusi minimum. Nilai *learning rate* yang terlalu kecil akan mengakibatkan laju perubahan pada bobot dalam mencari solusi menjadi pelan sedangkan nilai *learning rate* yang terlalu besar akan mengakibatkan laju perubahan bobot dalam langkah mencari solusi menjadi sangat besar dan sulit menemukan solusi. Bahkan jika terlalu besar maka sistem akan berosilasi dan tidak bias mencapai kondisi konvergen. Tidak ada aturan pasti berapa nilai *learning rate* yang cocok dalam suatu prediksi data *time series*. Nilai *learning rate* yang cocok umumnya didapatkan melalui percobaan (*trials and error*).

Nilai *learning rate* yang digunakan dalam skenario pengujian ini adalah 0.001, 0.005, 0.01, 0.05 dan 0.1. Tabel 4.4 merupakan hasil pengujian dengan menggunakan beberapa nilai *learning rate*.

Tabel 4.4 Hasil Pengujian Kombinasi Parameter *Learning Rate* untuk Prediksi Data AIS *Heading* yang Hilang

LSTM Layers	LSTM Unit Neurons	Learning Rate	MAPE (Average)
1	5	0.001	44.14 %
1	5	0.005	30.03 %
1	5	0.01	30.68 %
1	5	0.05	37.66 %
1	5	0.1	12.92 %

Berdasarkan Tabel 4.4 diketahui bahwa penggunaan nilai *learning rate* sebesar 0.1 menghasilkan MAPE terkecil yaitu 12.92 %.

4.3.2 Hasil Pengujian *Unit Neuron* pada LSTM *Layers* untuk Prediksi Data AIS *Heading* yang Hilang

Jumlah *unit neuron* LSTM *layers* mempengaruhi penghitungan pada fungsi aktivasi suatu *neuron* pada *output layer* dari sistem yang dibangun yang pada akhirnya menentukan nilai *output* yang dihasilkan oleh RNN.

Tidak ada aturan pasti berapa jumlah *unit neuron* LSTM *layers* yang cocok dalam suatu prediksi data *time series*. Jumlah *unit neuron* yang besar pada LSTM *layers* tidak dapat merepresentasikan bahwa hasil yang didapat akan semakin baik. Hal ini bergantung pada kasus yang dialami. Sehingga biasanya jumlah *unit neuron* yang digunakan didapat melalui percobaan (*trials and error*).

Tabel 4.5 Hasil Pengujian Kombinasi Parameter *Unit Neurons* pada LSTM *Layers* untuk Prediksi Data AIS *Heading* yang Hilang

LSTM Layers	LSTM Unit Neurons	Learning Rate	MAPE (Average)
1	5	0.1	12.92 %
1	10	0.1	8.01 %
1	15	0.1	12.12 %
1	20	0.1	12.54 %
1	25	0.1	30.42 %

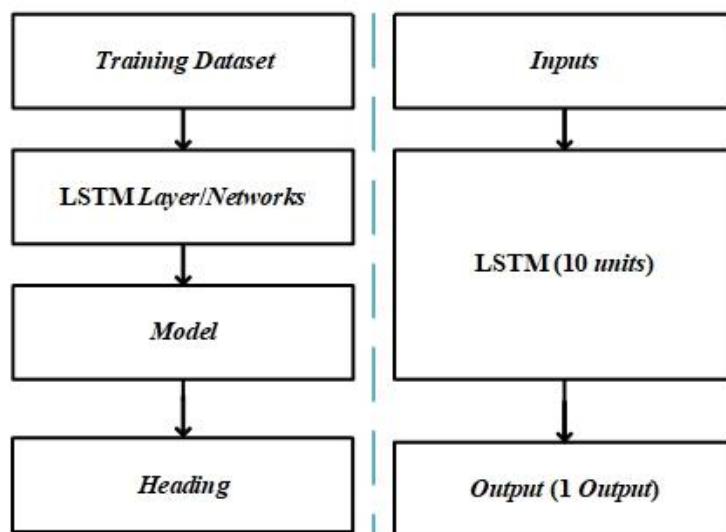
Parameter jumlah *unit neuron* yang digunakan adalah 5, 10, 15, 20 dan 25 *units neurons*. Tabel 4.5 merupakan hasil pengujian dengan beberapa parameter tersebut. Berdasarkan Tabel 4.5 diketahui bahwa penggunaan jumlah *unit neuron* sebanyak 10 buah menghasilkan MAPE terkecil yaitu 8.01 %.

4.4 Model Arsitektur Jaringan RNN *Predictor* untuk Prediksi Data AIS *Heading* yang Hilang

Berdasarkan pengujian yang telah dilakukan, diperoleh parameter yang optimal yang dapat digunakan untuk memprediksi data AIS *heading* yang hilang. Parameter-parameter tersebut adalah:

- Jumlah LSTM layers: 1
- Jumlah unit neuron pada LSTM layers: 10
- Nilai learning rate: 0.1

Selain menggunakan parameter di atas, jaringan dilatih dan diuji menggunakan *batch* ukuran 2, selain itu *input layer* dan *output layer* adalah lapisan padat / *dense layer* (terhubung sepenuhnya). *Loss function* yang digunakan adalah *Mean Squared Error*, *optimizer* yang digunakan adalah *Adaptive Moment Estimation* (Adam), dan model dilatih sebanyak 100 *epochs*. Dari hasil pelatihan dan pengujian ini, maka didapatkan model terbaik untuk prediksi data AIS *heading* yang hilang seperti ditunjukkan oleh Gambar 4.2.



Gambar 4.2 Model RNN untuk prediksi data AIS *heading* yang hilang

Tabel 4.6 merupakan performa dari model RNN untuk prediksi data AIS *heading* yang hilang.

Tabel 4.6 MAPE Dari Model RNN untuk Prediksi Data AIS *Heading* yang Hilang

Time Step (Pola Input)	MAPE Heading
2	8.01 %

4.5 Hasil Pengujian Prediksi Data AIS Speed yang Hilang pada Kapal *Illegal Fishing* dan *Transhipment* menggunakan Metode Perbandingan Senilai

Pada proses pengujian prediksi data AIS *speed* yang hilang pada kapal *illegal fishing* dan *transhipment*, dilakukan dengan menggunakan metode perbandingan senilai dengan membandingkan nilai jarak pada waktu sebelum data hilang dan pada waktu data hilang terhadap kecepatan pada waktu sebelum data hilang dan pada waktu data hilang. Nilai jarak didapat dengan persamaan (3.6) yaitu dari hasil konversi nilai *longitude* dan *latitude* hasil prediksi menggunakan RNN *predictor*. Dengan mengetahui jarak perpindahan antara posisi kapal sebelum data hilang dan pada waktu data hilang, serta membandingkannya terhadap kecepatan sebelum data hilang maka kecepatan pada waktu data hilang bisa didapatkan. Pada metode ini, interval waktu tiap data AIS diasumsikan konstan. Persamaan metode perbandingan senilai yang digunakan untuk perancangan adalah persamaan (3.7). Didapat nilai *error RMSE* rata-rata untuk prediksi seperti ditunjukkan pada Tabel 4.7.

Tabel 4.7 RMSE Dari Hasil Prediksi Data AIS *Speed* yang Hilang Menggunakan Metode Perbandingan Senilai

RMSE Speed
0.83 knot

Pada pengujian ini menghasilkan *error RMSE* sebesar 0.83 knot untuk prediksi data AIS *speed* kapal pelaku *illegal transhipment* dan *illegal fishing* yang hilang, di mana semakin kecil nilai RMSE yang didapat maka semakin tinggi

akurasi dari *speed predictor*. Nilai *error* ini masih bisa ditoleransi untuk prediksi data AIS *speed* kapal pelaku *illegal transhipment* dan *illegal fishing* yang hilang.

4.6 Hasil Validasi Subsistem Prediktor Data AIS yang Hilang pada Kapal *Illegal Transhipment* dan *Illegal Fishing*

Validasi subsistem dilakukan untuk mengetahui rancangan subsistem RNN *predictor* berhasil melakukan prediksi data AIS yang hilang. Validasi dilakukan menggunakan data *real* kapal yang diduga melakukan praktik *illegal transhipment* dan *fishing* yang diasumsikan terdapat beberapa data AIS yang hilang dalam *interval* waktu tertentu. Data *real* kapal tersebut didapatkan dari *website* marinetraffic.com dan NASDEC ITS.

4.6.1 Hasil Validasi Subsistem Prediktor Menggunakan Data *Real* AIS Kapal *Illegal Transhipment* (*Lurongyuanyu 105* dan *Eagle Seville*) di Perairan Batam (Validasi Prediktor *Transhipment I*)

Validasi *transhipment* pertama ini dilakukan dengan data salah satu kapal yang sedang melakukan *transhipment* di Perairan Batam pada tanggal 02 Mei 2016 pukul 11.30 WIB sampai tanggal 02 Mei 2016 pukul 11.45 WIB. Data posisi (*longitude & latitude*), *heading*, dan kecepatan (*speed*) pada kapal berdasarkan informasi dari AIS yang terpasang pada Kapal Lurongyuanyu 105 dapat dilihat pada Tabel 4.8.

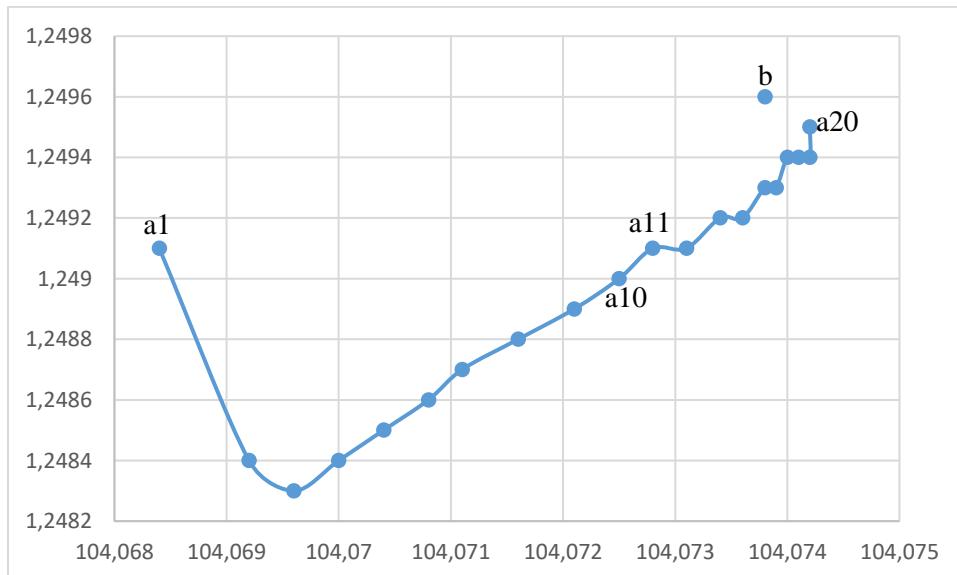
Tabel 4.8 Data *Real* AIS Kapal Lurongyuanyu 105 di Perairan Batam

No	<i>Longitude</i> (°)	<i>Latitude</i> (°)	<i>Heading</i> (°)	<i>Speed</i> (knot)
1	104.0684	1.2491	145	2.4
2	104.0692	1.2484	103	2.4
3	104.0696	1.2483	96	2.5
4	104.07	1.2484	90	2.6
5	104.0704	1.2485	89	2.7
6	104.0708	1.2486	89	2.8
7	104.0711	1.2487	88	2.8
8	104.0716	1.2488	87	2.9
9	104.0721	1.2489	88	2.9
10	104.0725	1.2490	88	2.8
11	104.0728	1.2491	88	2.7

Tabel 4.8 (Lanjutan)

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (knot)
12	104.0731	1.2491	88	2.6
13	104.0734	1.2492	88	2.5
14	104.0736	1.2492	87	2
15	104.0738	1.2493	87	1.4
16	104.0739	1.2493	87	0.9
17	104.0740	1.2494	86	0.5
18	104.0741	1.2494	86	0.3
19	104.0742	1.2494	85	0.1
20	104.0742	1.2495	84	0

Data posisi *real* AIS Kapal Lurongyuanyu 105 di Perairan Batam pada Tabel 4.8 jika diplot ke dalam trayektori (titik a1 s.d. titik a20) maka akan terlihat seperti pada Gambar 4.3. Untuk mengilustrasikan terjadinya *transhipment*, maka data AIS posisi kapal lainnya yaitu kapal Eagle Seville juga diplot (titik b). Kapal Eagle Seville berada pada koordinat 104.0738° dan 1.2496° (*longitude & latitude*) dengan posisi diam (0 knot).

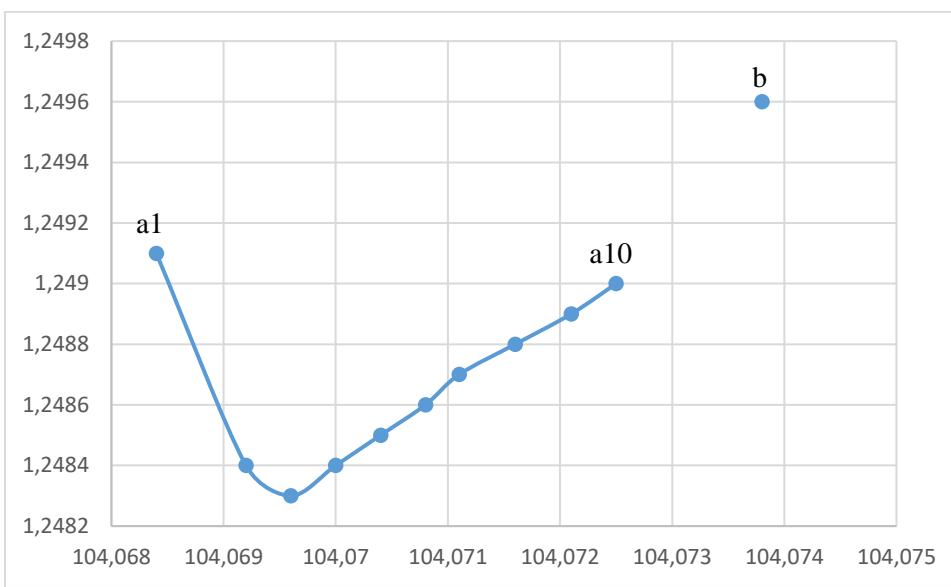
**Gambar 4.3** Pergerakan Kapal Lurongyuanyu 105 dan posisi Kapal Eagle Seville

Kemudian dilakukan prediksi terhadap data AIS Kapal Lurongyuanyu 105 tersebut dengan mengasumsikan terdapat data yang hilang. Data yang diasumsikan hilang adalah data ke-11 sampai data ke-20 seperti ditunjukkan oleh Tabel 4.9.

Tabel 4.9 Data *Real* AIS Kapal Lurongyuanyu 105 di Perairan Batam yang Diasumsikan Terdapat Data yang Hilang

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (knot)
1	104.0684	1.2491	145	2.4
2	104.0692	1.2484	103	2.4
3	104.0696	1.2483	96	2.5
4	104.07	1.2484	90	2.6
5	104.0704	1.2485	89	2.7
6	104.0708	1.2486	89	2.8
7	104.0711	1.2487	88	2.8
8	104.0716	1.2488	87	2.9
9	104.0721	1.2489	88	2.9
10	104.0725	1.2490	88	2.8
11				
12				
13				
14				
15				
16				
17				
18				
19				
20				

Data posisi AIS Kapal Lurongyuanyu 105 di Perairan Batam yang diasumsikan terdapat data yang hilang pada Tabel 4.9 jika diplot ke dalam trayektori (titik a1 s.d. titik a10) maka akan terlihat seperti pada Gambar 4.4. Data AIS posisi kapal lainnya yaitu kapal Eagle Seville juga diplot (titik b). Kapal Eagle Seville berada pada koordinat 104.0738° dan 1.2496° (*longitude & latitude*) dengan posisi diam (0 knot).



Gambar 4.4 Pergerakan Kapal Lurongyuanyu 105 dengan adanya data yang hilang dan posisi Kapal Eagle Seville

Untuk melakukan prediksi data ke-11 sampai data ke-20, *input* yang digunakan adalah data ke-1 sampai data ke-10. Hasil prediksi ditunjukkan oleh Tabel 4.10.

Tabel 4.10 Hasil Prediksi Data *Real AIS* Kapal Lurongyuanyu 105 di Perairan Batam yang Diasumsikan Terdapat Data yang Hilang

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (knot)
1	104.0684	1.2491	145	2.4
2	104.0692	1.2484	103	2.4
3	104.0696	1.2483	96	2.5
4	104.07	1.2484	90	2.6
5	104.0704	1.2485	89	2.7
6	104.0708	1.2486	89	2.8
7	104.0711	1.2487	88	2.8
8	104.0716	1.2488	87	2.9
9	104.0721	1.2489	88	2.9
10	104.0725	1.2490	88	2.8
11	104.0729	1.24908	87.54	2.27
12	104.0732	1.24916	87.54	1.51
13	104.0735	1.24921	87.54	1.76
14	104.0737	1.24927	87.54	1.10
15	104.0739	1.24931	87.44	1.07

Tabel 4. 10 (Lanjutan)

No	<i>Longitude</i> (°)	<i>Latitude</i> (°)	<i>Heading</i> (°)	<i>Speed</i> (knot)
16	104.0740	1.24935	87.38	0.56
17	104.0741	1.24938	87.38	0.60
18	104.0742	1.24940	87.28	0.31
19	104.0743	1.24942	87.23	0.40
20	104.0743	1.24943	87.13	0.39

4.6.1.1 Perbandingan Hasil Validasi I Prediksi Data AIS *Longitude* dan *Latitude* terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam

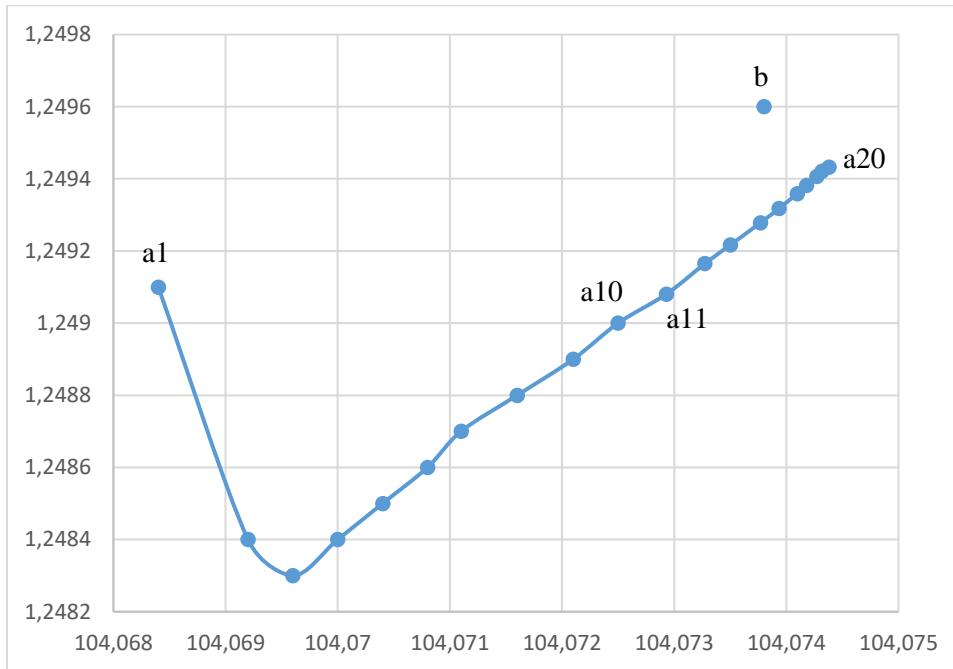
Perbandingan hasil prediksi data AIS *longitude* dan *latitude* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam dapat dilihat pada Tabel 4.11.

Tabel 4. 11 Perbandingan Hasil Validasi I Prediksi Data AIS *Longitude* dan *Latitude* Terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam

No	<i>Longitude</i> Aktual (°)	<i>Latitude</i> Aktual (°)	<i>Longitude</i> Prediksi (°)	<i>Latitude</i> Prediksi (°)	MAPE <i>Longitude</i> (%)	MAPE <i>Latitude</i> (%)
11	104.073	1.2491	104.0729	1.24908	0.00015	0.00296
12	104.073	1.2491	104.0733	1.24916		
13	104.073	1.2492	104.0735	1.24922		
14	104.074	1.2492	104.0738	1.24928		
15	104.074	1.2493	104.0739	1.24932		
16	104.074	1.2493	104.0741	1.24936		
17	104.074	1.2494	104.0742	1.24938		
18	104.074	1.2494	104.0743	1.24941		
19	104.074	1.2494	104.0743	1.24942		
20	104.074	1.2495	104.0744	1.24943		

Hasil prediksi data AIS posisi Kapal Lurongyuanyu 105 di Perairan Batam yang diasumsikan terdapat data yang hilang jika diplot ke dalam trayektori (titik a11 s.d. titik a20) maka akan terlihat seperti pada Gambar 4.5. Data AIS posisi kapal lainnya yaitu kapal Eagle Seville juga diplot (titik b). Kapal Eagle Seville berada

pada koordinat 104.0738° dan 1.2496° (*longitude & latitude*) dengan posisi diam (0 knot).



Gambar 4. 5 Hasil prediksi pergerakan Kapal Lurongyuanyu 105 dengan adanya data yang hilang dan posisi Kapal Eagle Seville

Pada subsistem prediktor yang telah dirancang ini, menghasilkan *error MAPE* $\leq 10\%$ untuk prediksi data AIS kapal pelaku *illegal transhipment* yang hilang, di mana hasil tersebut menunjukkan bahwa subsistem prediktor memiliki akurasi yang tinggi. Selain itu, trayektori hasil prediksi juga hampir sama dengan trayektori data aktual. Hal ini membuktikan bahwa hasil yang diperoleh dari subsistem prediktor yang telah dirancang sudah cukup valid sehingga keluaran hasil prediksi data AIS *longitude* dan *latitude* kapal *illegal transhipment* yang hilang ini bisa digunakan sebagai masukan untuk subsistem ANN *selection*.

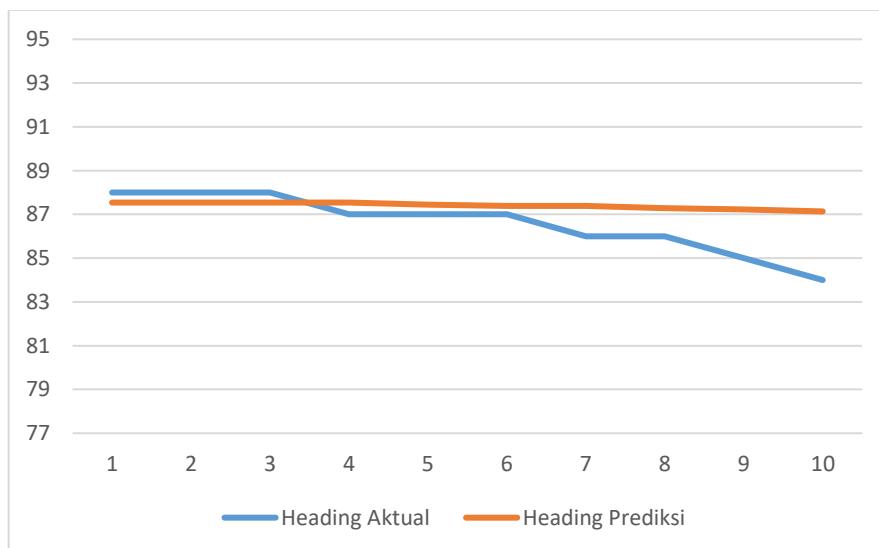
4.6.1.2 Perbandingan Hasil Validasi I Prediksi Data AIS *Heading* terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam

Perbandingan hasil prediksi data AIS *heading* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam dapat dilihat pada Tabel 4.12.

Tabel 4.12 Perbandingan Hasil Validasi I Prediksi Data AIS *Heading* Terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam

No	Heading Aktual (°)	Heading Prediksi (°)	MAPE Heading (%)
11	88	87.54	1.26
12	88	87.54	
13	88	87.54	
14	87	87.54	
15	87	87.44	
16	87	87.38	
17	86	87.38	
18	86	87.29	
19	85	87.23	
20	84	87.14	

Perbandingan hasil prediksi data AIS *heading* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam pada Tabel 4.12 jika ditampilkan dalam bentuk grafik dapat dilihat pada Gambar 4.6.



Gambar 4.6 Grafik perbandingan hasil prediksi data AIS *heading* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam

Skala dengan nilai 1 sampai 10 pada sumbu horizontal grafik mewakili nilai dari data ke-11 sampai dengan data ke-20. Pada subsistem prediktor yang telah dirancang ini, menghasilkan *error* $MAPE \leq 10\%$, di mana hasil tersebut

menunjukkan bahwa subsistem prediktor memiliki akurasi yang tinggi. Hal ini membuktikan bahwa hasil prediksi yang diperoleh sudah valid sehingga keluaran hasil prediksi data AIS *heading* kapal *illegal transhipment* yang hilang ini bisa digunakan sebagai masukan untuk subsistem ANN *selection*.

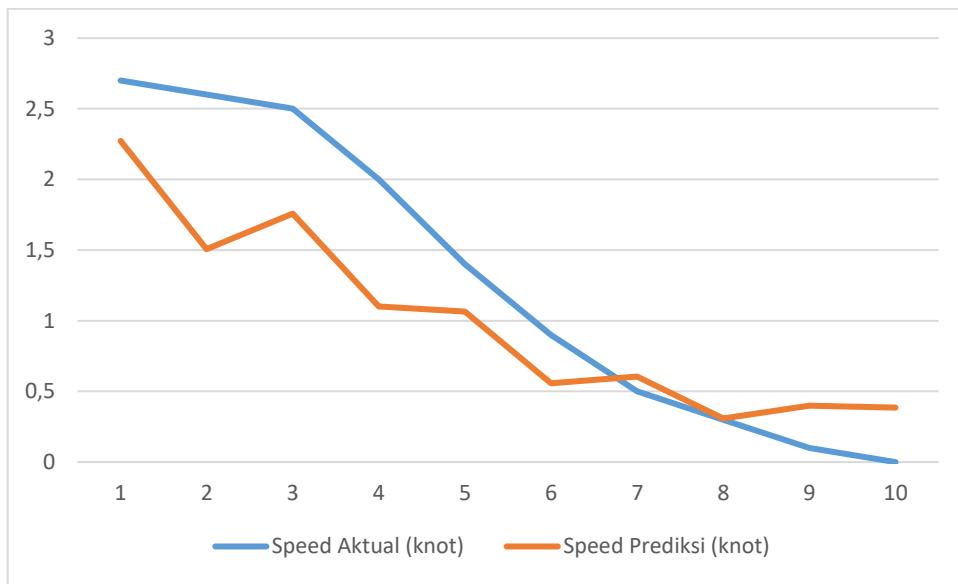
4.6.1.3 Perbandingan Hasil Validasi I Prediksi Data AIS *Speed* terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam

Perbandingan hasil prediksi data AIS *speed* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam dapat dilihat pada Tabel 4.13.

Tabel 4. 13 Perbandingan Hasil Validasi I Prediksi Data AIS *Speed* Terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam

No	Speed Aktual (knot)	Speed Prediksi (knot)	SE	MSE	RMSE Speed (knot)
11	2.7	2.27	0.18	0.32	0.57
12	2.6	1.51	1.20		
13	2.5	1.76	0.55		
14	2	1.10	0.81		
15	1.4	1.07	0.11		
16	0.9	0.56	0.12		
17	0.5	0.60	0.01		
18	0.3	0.31	0.00		
19	0.1	0.40	0.09		
20	0	0.39	0.15		

Perbandingan hasil prediksi data AIS *speed* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam pada Tabel 4.13 jika ditampilkan dalam bentuk grafik dapat dilihat pada Gambar 4.7.



Gambar 4. 7 Grafik perbandingan hasil prediksi data AIS *speed* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam

Skala dengan nilai 1 sampai 10 pada sumbu horizontal grafik mewakili nilai dari data ke-11 sampai dengan data ke-20. Pada subsistem prediktor yang telah dirancang ini, menghasilkan *error RMSE* yang kecil yaitu 0.57 knot. Semakin kecil nilai RMSE yang didapat maka semakin tinggi akurasi yang didapat. Hal ini membuktikan bahwa hasil prediksi yang diperoleh sudah valid sehingga keluaran hasil prediksi data AIS *speed* kapal *illegal transhipment* yang hilang ini bisa digunakan sebagai masukan untuk subsistem ANN *selection*.

4.6.2 Hasil Validasi Subsistem Prediktor Menggunakan Data *Real AIS Kapal Illegal Transhipment (Lurongyuanyu 105 dan Eagle Seville) di Perairan Batam (Validasi Prediktor Transhipment II)*

Pada validasi *transhipment* kedua ini dilakukan prediksi terhadap data AIS Kapal Lurongyuanyu 105 dengan mengasumsikan terdapat data yang hilang secara berselang. Data yang diasumsikan hilang adalah data ke-5 sampai data ke-8 dan data ke-13 sampai data ke-16 seperti ditunjukkan oleh Tabel 4.14.

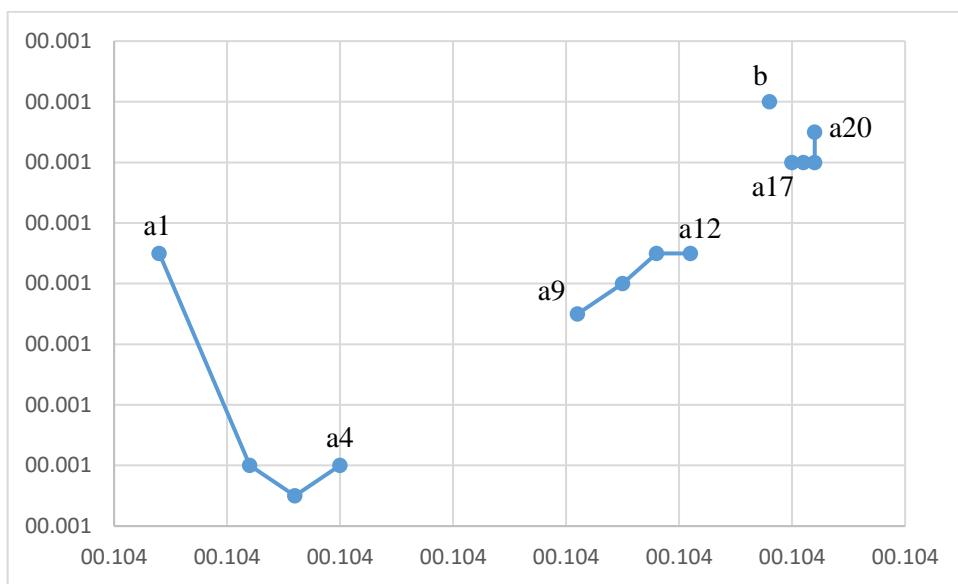
Tabel 4. 14 Data *Real AIS* Kapal Lurongyuanyu 105 di Perairan Batam yang Diasumsikan Terdapat Data yang Hilang Secara Berselang

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (knot)
1	104.0684	1.2491	145	2.4
2	104.0692	1.2484	103	2.4

Tabel 4.14 (Lanjutan)

No	<i>Longitude</i> (°)	<i>Latitude</i> (°)	<i>Heading</i> (°)	<i>Speed</i> (knot)
3	104.0696	1.2483	96	2.5
4	104.07	1.2484	90	2.6
5				
6				
7				
8				
9	104.0721	1.2489	88	2.9
10	104.0725	1.2490	88	2.8
11	104.0728	1.2491	88	2.7
12	104.0731	1.2491	88	2.6
13				
14				
15				
16				
17	104.0740	1.2494	86	0.5
18	104.0741	1.2494	86	0.3
19	104.0742	1.2494	85	0.1
20	104.0742	1.2495	84	0

Data posisi AIS Kapal Lurongyuanyu 105 di Perairan Batam yang diasumsikan terdapat data yang hilang secara berselang pada Tabel 4.13 jika diplot ke dalam trayektori (titik a1 s.d. titik a4, titik a9 s.d. titik a12, dan titik a17 s.d. titik a20) maka akan terlihat seperti pada Gambar 4.8. Data AIS posisi kapal lainnya yaitu kapal Eagle Seville juga diplot (titik b). Kapal Eagle Seville berada pada koordinat 104.0738° dan 1.2496° (*longitude & latitude*) dengan posisi diam (0 knot).



Gambar 4.8 Pergerakan Kapal Lurongyuanyu 105 dengan adanya data yang hilang secara berselang dan posisi Kapal Eagle Seville

Untuk melakukan prediksi data ke-5 sampai data ke-8, *input* yang digunakan adalah data ke-1 sampai data ke-4 sedangkan untuk melakukan prediksi data ke-13 sampai data ke-16, *input* yang digunakan adalah data ke-9 sampai data ke-12. Hasil prediksi ditunjukkan oleh Tabel 4.15.

Tabel 4.15 Hasil Prediksi Data *Real AIS* Kapal Lurongyuanyu 105 di Perairan Batam yang Diasumsikan Terdapat Data yang Hilang Secara Berselang

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (knot)
1	104.0684	1.2491	145	2.4
2	104.0692	1.2484	103	2.4
3	104.0696	1.2483	96	2.5
4	104.07	1.2484	90	2.6
5	104.0702	1.2484	87.53	2.59
6	104.0705	1.2485	86.56	2.09
7	104.0706	1.2485	86.43	1.55
8	104.0708	1.2485	86.27	1.50
9	104.0721	1.2489	88	2.9
10	104.0725	1.2490	88	2.8
11	104.0728	1.2491	88	2.7
12	104.0731	1.2491	88	2.6
13	104.0731	1.2491	88	0.47

Tabel 4.15 (Lanjutan)

No	<i>Longitude</i> (°)	<i>Latitude</i> (°)	<i>Heading</i> (°)	<i>Speed</i> (knot)
14	104.0731	1.2491	88	0.27
15	104.0731	1.2491	87.89	0.20
16	104.0732	1.2491	87.80	0.17
17	104.0740	1.2494	86	0.5
18	104.0741	1.2494	86	0.3
19	104.0742	1.2494	85	0.1
20	104.0742	1.2495	84	0

4.6.2.1 Perbandingan Hasil Validasi II Prediksi Data AIS *Longitude* dan *Latitude* terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam

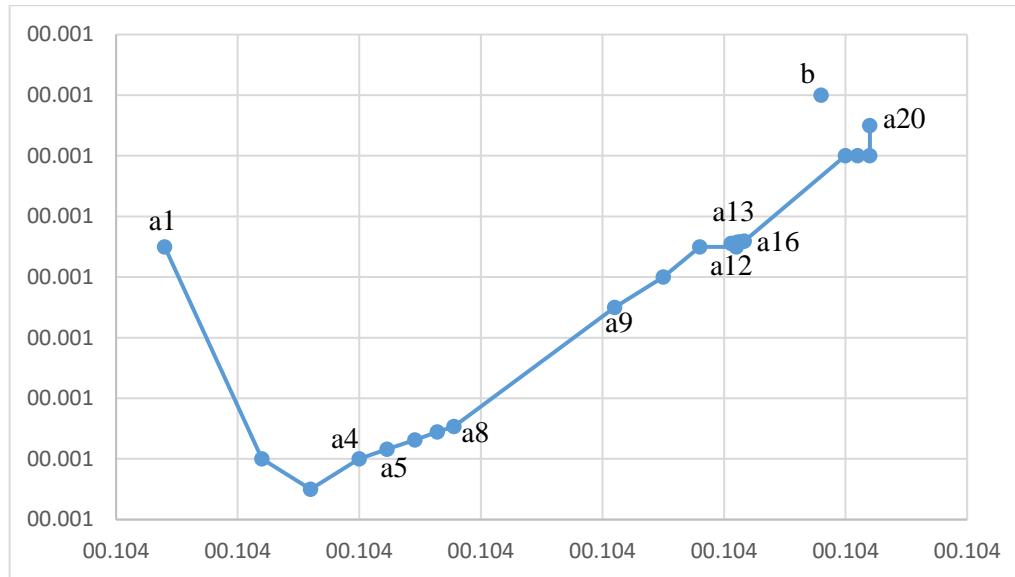
Perbandingan hasil prediksi data AIS *longitude* dan *latitude* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam dapat dilihat pada Tabel 4.16.

Tabel 4.16 Perbandingan Hasil Validasi II Prediksi Data AIS *Longitude* dan *Latitude* Terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam

No	<i>Longitude</i> Aktual (°)	<i>Latitude</i> Aktual (°)	<i>Longitude</i> Prediksi (°)	<i>Latitude</i> Prediksi (°)	MAPE <i>Longitude</i> (%)	MAPE <i>Latitude</i> (%)
5	104.0704	1.2485	104.07023	1.24843	0.00043	0.01419
6	104.0708	1.2486	104.07046	1.24846		
7	104.0711	1.2487	104.07064	1.24849		
8	104.0716	1.2488	104.07078	1.24851		
13	104.0734	1.2492	104.07306	1.24911	0.00053	0.01078
14	104.0736	1.2492	104.07311	1.24912		
15	104.0738	1.2493	104.07314	1.24912		
16	104.0739	1.2493	104.07317	1.24912		

Hasil prediksi data AIS posisi Kapal Lurongyuanyu 105 di Perairan Batam yang diasumsikan terdapat data yang hilang secara berselang jika diplot ke dalam trayektori (titik a) maka akan terlihat seperti pada Gambar 4.9. Data AIS posisi kapal lainnya yaitu kapal Eagle Seville juga diplot (titik b). Kapal Eagle Seville

berada pada koordinat 104.0738° dan 1.2496° (*longitude & latitude*) dengan posisi diam (0 knot).



Gambar 4. 9 Hasil prediksi pergerakan Kapal Lurongyuanyu 105 dengan adanya data yang hilang secara berselang dan posisi Kapal Eagle Seville

Pada subsistem prediktor yang telah dirancang ini, menghasilkan *error MAPE* $\leq 10\%$ untuk prediksi data AIS kapal pelaku *illegal transhipment* yang hilang, di mana hasil tersebut menunjukkan bahwa subsistem prediktor memiliki akurasi yang tinggi. Hasil prediksi data ke-5 sampai data ke-8 menghasilkan trayektori yang hampir sama dengan trayektori aktual, tetapi hasil prediksi data ke-13 sampai data ke-16 menghasilkan trayektori yang tidak mendekati trayektori aktual. Jika dibandingkan dengan hasil validasi *transhipment I*, hasil dari validasi *transhipment II* ini masih kurang mampu memprediksi trayektori kapal *illegal transhipment* yang terdapat data hilang berselang, hal ini dikarenakan dalam kasus data AIS kapal yang hilang secara berselang menyebabkan jumlah data *input* yang digunakan sebagai masukan untuk memprediksi lebih sedikit oleh karena itu hasil yang dihasilkan tidak maksimal.

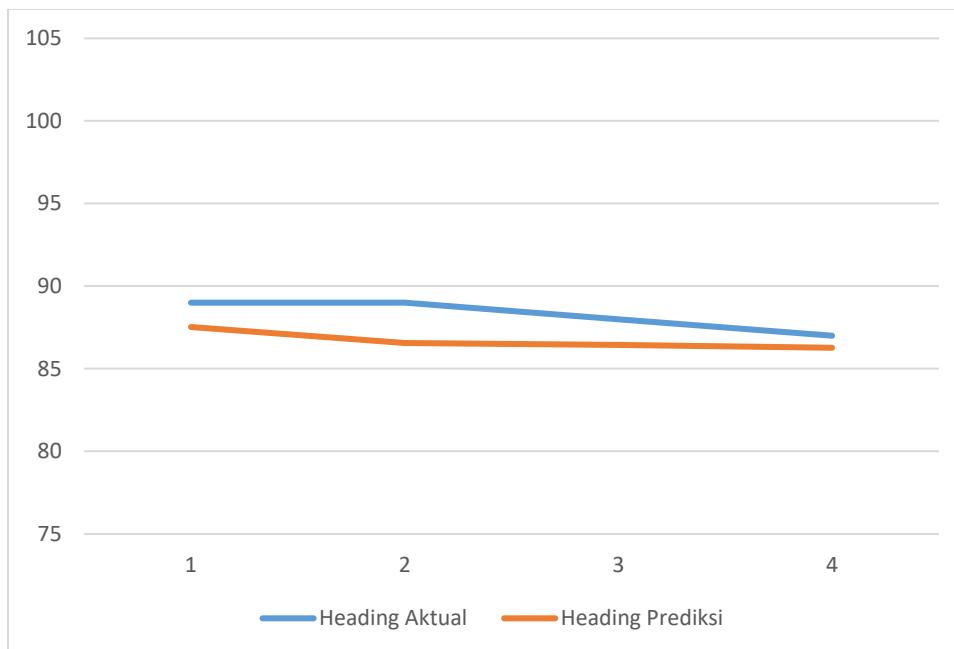
4.6.2.2 Perbandingan Hasil Validasi II Prediksi Data AIS *Heading* terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam

Perbandingan hasil prediksi data AIS *heading* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam dapat dilihat pada Tabel 4.17.

Tabel 4.17 Perbandingan Hasil Validasi II Prediksi Data AIS *Heading* Terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam

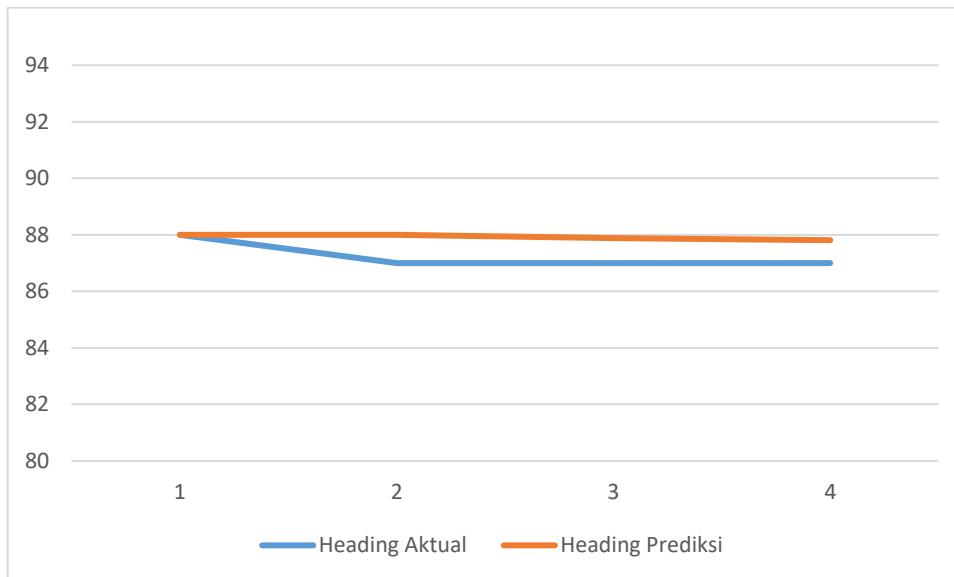
No	Heading Aktual (°)	Heading Prediksi (°)	MAPE Heading (%)
5	89	87.53	1.75
6	89	86.56	
7	88	86.43	
8	87	86.27	
13	88	88	0.77
14	87	88	
15	87	87.89	
16	87	87.80	

Perbandingan hasil prediksi data AIS *heading* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam yang diasumsikan terdapat data yang hilang secara berselang pada Tabel 4.17 jika ditampilkan dalam bentuk grafik dapat dilihat pada Gambar 4.10 dan Gambar 4.11.



Gambar 4.10 Grafik perbandingan hasil prediksi data ke-5 sampai dengan data ke-8 AIS *heading* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam

Pada Gambar 4.10 merupakan grafik perbandingan hasil prediksi data ke-5 sampai dengan data ke-8, skala dengan nilai 1 sampai dengan 4 pada sumbu horizontal grafik mewakili nilai dari data ke-5 sampai dengan data ke-8.



Gambar 4. 11 Grafik perbandingan hasil prediksi data ke-13 sampai dengan data ke-16 AIS *heading* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam

Pada Gambar 4.11 merupakan grafik perbandingan hasil prediksi data ke-13 sampai dengan data ke-16, skala dengan nilai 1 sampai dengan 4 pada sumbu horizontal grafik mewakili nilai dari data ke-13 sampai dengan data ke-18. Pada subsistem prediktor yang telah dirancang ini, menghasilkan $error MAPE \leq 10\%$, di mana hasil tersebut menunjukkan bahwa subsistem prediktor memiliki akurasi yang tinggi. Hal ini membuktikan bahwa hasil prediksi yang diperoleh sudah valid sehingga keluaran hasil prediksi data AIS *heading* kapal *illegal transhipment* yang hilang ini bisa digunakan sebagai masukan untuk subsistem ANN *selection*.

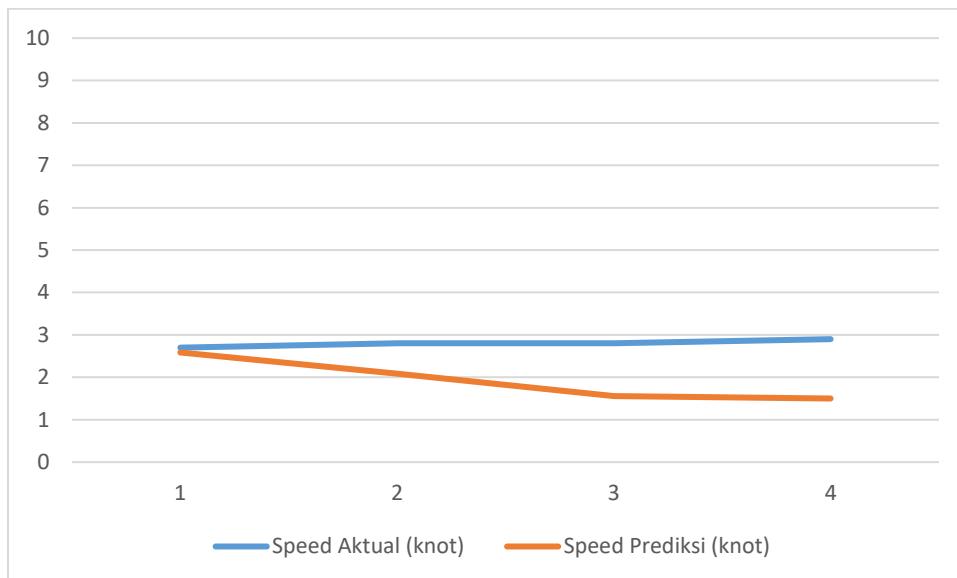
4.6.2.3 Perbandingan Hasil Validasi II Prediksi Data AIS Speed terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam

Perbandingan hasil prediksi data AIS *speed* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam dapat dilihat pada Tabel 4.18.

Tabel 4. 18 Perbandingan Hasil Validasi II Prediksi Data AIS *Speed* Terhadap Data AIS Aktual Kapal Lurongyuanyu 105 di Perairan Batam

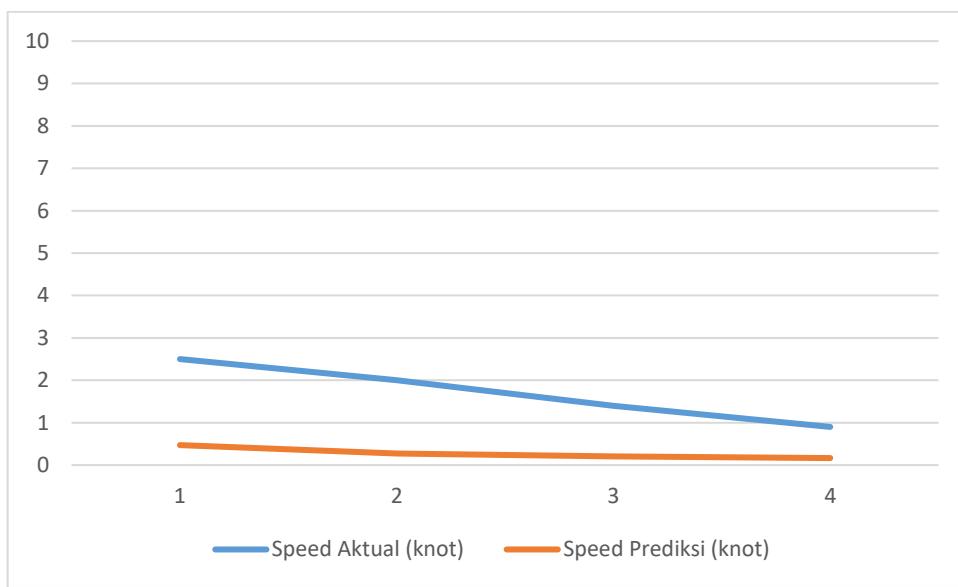
No	Speed Aktual (knot)	Speed Prediksi (knot)	SE	MSE	RMSE (knot)
5	2.7	2.59	0.01	1.01	1.00
6	2.8	2.09	0.51		
7	2.8	1.55	1.55		
8	2.9	1.50	1.96		
13	2.5	0.47	4.12	2.27	1.51
14	2	0.27	2.98		
15	1.4	0.20	1.43		
16	0.9	0.17	0.54		

Perbandingan hasil prediksi data AIS *speed* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam pada Tabel 4.18 jika ditampilkan dalam bentuk grafik dapat dilihat pada Gambar 4.12 dan Gambar 4.13.



Gambar 4. 12 Grafik perbandingan hasil prediksi data ke-5 sampai dengan data ke-8 AIS *speed* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam

Pada Gambar 4.12 merupakan grafik perbandingan hasil prediksi data ke-5 sampai dengan data ke-8, skala dengan nilai 1 sampai dengan 4 pada sumbu horizontal grafik mewakili nilai dari data ke-5 sampai dengan data ke-8.



Gambar 4. 13 Grafik perbandingan hasil prediksi data ke-13 sampai dengan data ke-16 AIS *speed* terhadap data AIS aktual Kapal Lurongyuanyu 105 di Perairan Batam

Pada Gambar 4.13 merupakan grafik perbandingan hasil prediksi data ke-13 sampai dengan data ke-16, skala dengan nilai 1 sampai dengan 4 pada sumbu horizontal grafik mewakili nilai dari data ke-13 sampai dengan data ke-18. Pada subsistem prediktor yang telah dirancang ini, menghasilkan *error* RMSE yang cukup kecil pada prediksi data ke-5 sampai dengan data ke-8 dan data ke-13 sampai dengan data ke-16 masing-masing yaitu 1 knot dan 1.51 knot. Semakin kecil nilai RMSE yang didapat maka semakin tinggi akurasi yang didapat. Hal ini membuktikan bahwa hasil prediksi yang diperoleh sudah valid sehingga keluaran hasil prediksi data AIS *speed* kapal *illegal transhipment* yang hilang ini bisa digunakan sebagai masukan untuk subsistem ANN *selection*.

4.6.3 Hasil Validasi Subsistem Prediktor Menggunakan Data *Real AIS* Kapal Ikan *Illegal Fishing* di Selat Singapura (Validasi Prediktor *Fishing I*)

Validasi *illegal fishing* yang pertama ini dilakukan dengan data kapal yang sedang melakukan *illegal fishing* dengan menggunakan alat tangkap cantrang di selat Singapura pada tanggal 21 September 2017 pukul 06.43 WIB sampai tanggal 21 September 2017 pukul 10.45 WIB. Data posisi (*longitude & latitude*), *heading*,

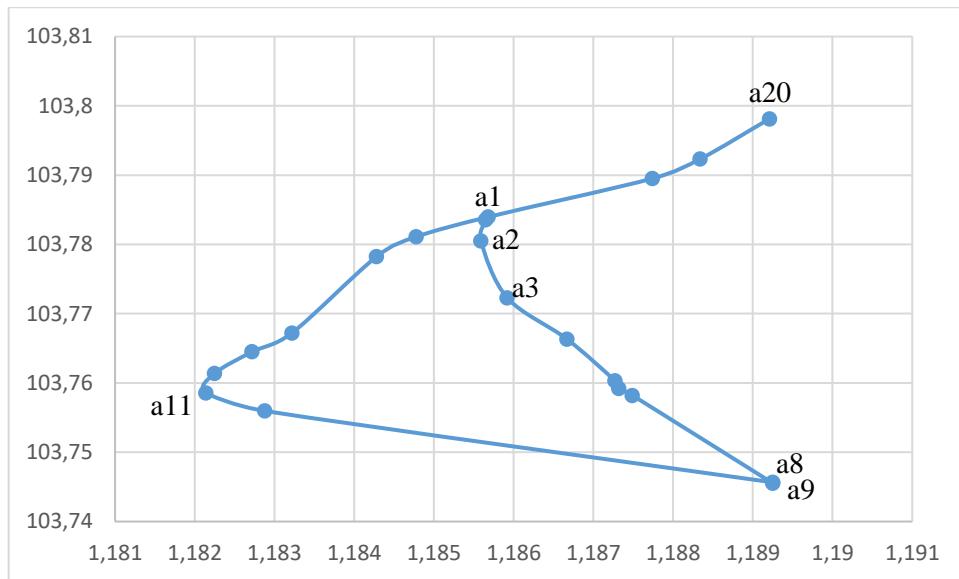
dan kecepatan (*speed*) pada kapal berdasarkan informasi dari AIS yang terpasang pada Kapal Ikan dapat dilihat pada Tabel 4.19.

Tabel 4.19 Data *Real* AIS Kapal Ikan di Selat Singapura

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (knot)
1	103.78357	1.18565	266	0.6
2	103.78050	1.18559	267	0.6
3	103.77229	1.18592	275	0.6
4	103.76632	1.18667	277	0.6
5	103.76031	1.18727	278	0.6
6	103.75921	1.18732	282	0.6
7	103.75821	1.18749	292	0.6
8	103.74554	1.18925	258	0.6
9	103.74566	1.18925	141	0.6
10	103.75596	1.18288	110	0.6
11	103.75857	1.18214	91	0.6
12	103.76138	1.18225	83	0.6
13	103.76450	1.18272	79	0.6
14	103.76722	1.18322	83	0.6
15	103.77823	1.18428	83	0.6
16	103.78110	1.18478	75	0.6
17	103.78396	1.18568	70	0.6
18	103.78951	1.18774	78	0.9
19	103.79233	1.18834	83	0.9
20	103.79813	1.18921	82	0

Data posisi *real* AIS Kapal Ikan di Selat Singapura pada Tabel 4.19 jika diplot ke dalam trayektori (titik a1 s.d. titik a20) maka akan terlihat seperti pada Gambar 4.14. Posisi kapal ikan ini berdasarkan data AIS pada pukul 06.43 WIB sampai pukul 10.45 WIB, kapal ikan dengan alat tangkap cantrang umumnya membutuhkan waktu 3-4 jam untuk menangkap ikan. Pola kapal ikan dengan alat

tangkap cantrang membentuk lingkaran seperti yang ditunjukkan oleh Gambar 4.14.



Gambar 4. 14 Pergerakan Kapal Ikan di Selat Singapura

Kemudian dilakukan prediksi terhadap data AIS Kapal Ikan tersebut dengan mengasumsikan terdapat data yang hilang. Data yang hilang adalah data ke-11 sampai data ke-20 seperti ditunjukkan oleh Tabel 4.20.

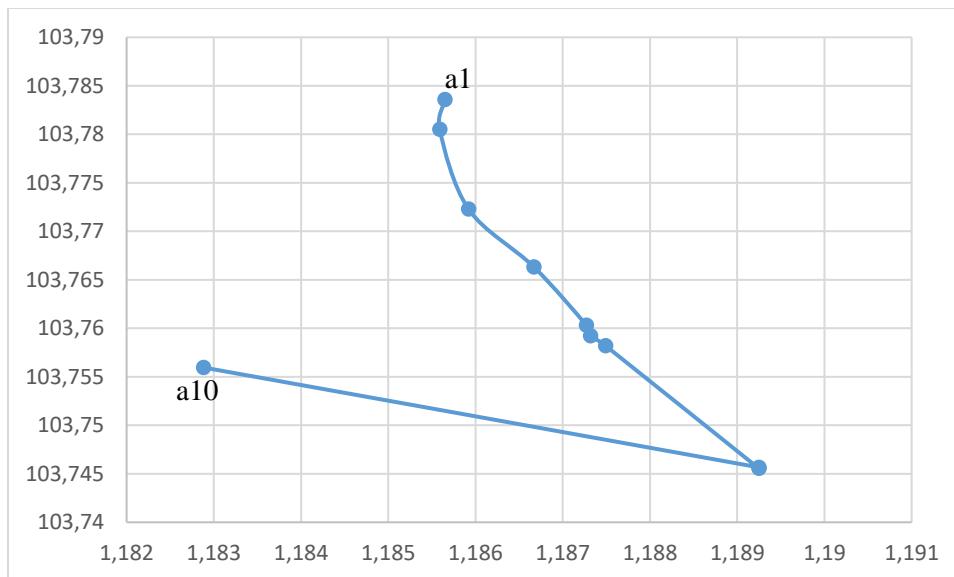
Tabel 4. 20 Data *Real* AIS Kapal Ikan di Selat Singapura yang Diasumsikan Terdapat Data yang Hilang

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (knot)
1	103.78357	1.18565	266	0.6
2	103.78050	1.18559	267	0.6
3	103.77229	1.18592	275	0.6
4	103.76632	1.18667	277	0.6
5	103.76031	1.18727	278	0.6
6	103.75921	1.18732	282	0.6
7	103.75821	1.18749	292	0.6
8	103.74554	1.18925	258	0.6
9	103.74566	1.18925	141	0.6
10	103.75596	1.18288	110	0.6
11				
12				

Tabel 4. 20 (Lanjutan)

No	<i>Longitude</i> (°)	<i>Latitude</i> (°)	<i>Heading</i> (°)	<i>Speed</i> (knot)
13				
14				
15				
16				
17				
18				
19				
20				

Data posisi *real AIS* Kapal Ikan di Selat Singapura yang diasumsikan terdapat data yang hilang pada Tabel 4.20 jika diplot ke dalam trayektori (titik a1 s.d. titik a10) maka akan terlihat seperti pada Gambar 4.15.

**Gambar 4. 15** Pergerakan Kapal Ikan di Selat Singapura dengan adanya data yang hilang

Untuk melakukan prediksi data ke-11 sampai data ke-20, *input* yang digunakan adalah data ke-1 sampai data ke-10. Hasil prediksi ditunjukkan oleh Tabel 4.21.

Tabel 4. 21 Hasil Prediksi Data *Real AIS* Kapal Ikan di Selat Singapura yang Diasumsikan Terdapat Data yang Hilang

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (knot)
1	103.78357	1.18565	266	0.6
2	103.78050	1.18559	267	0.6
3	103.77229	1.18592	275	0.6
4	103.76632	1.18667	277	0.6
5	103.76031	1.18727	278	0.6
6	103.75921	1.18732	282	0.6
7	103.75821	1.18749	292	0.6
8	103.74554	1.18925	258	0.6
9	103.74566	1.18925	141	0.6
10	103.75596	1.18288	110	0.6
11	103.75459	1.18574	99.32	0.6
12	103.76022	1.18572	89.13	0.6
13	103.76202	1.18560	87.45	0.6
14	103.76322	1.18572	87.28	0.6
15	103.76411	1.18592	89.67	0.6
16	103.76688	1.18611	88.79	0.6
17	103.76961	1.18609	85.81	0.6
18	103.76988	1.18634	85.71	2.14
19	103.76879	1.18705	90.15	2.00
20	103.76768	1.18753	89.91	0.89

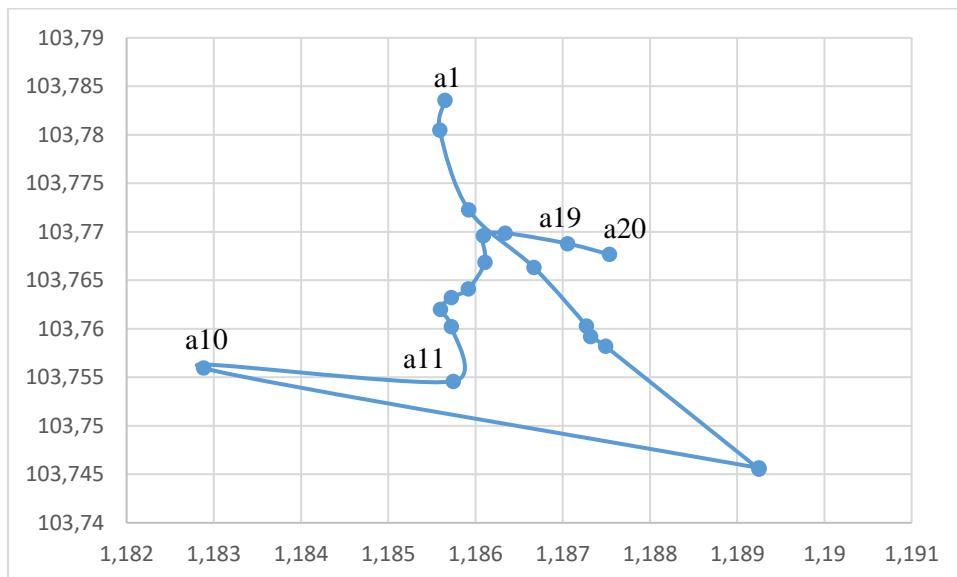
4.6.3.1 Perbandingan Hasil Validasi I Prediksi Data AIS *Longitude* dan *Latitude* terhadap Data AIS Aktual Kapal Ikan di Selat Singapura

Perbandingan hasil prediksi data AIS *longitude* dan *latitude* terhadap data AIS aktual Kapal Ikan di Selat Singapura dapat dilihat pada Tabel 4.22.

Tabel 4. 22 Perbandingan Hasil Validasi I Prediksi Data AIS *Longitude* dan *Latitude* Terhadap Data AIS Aktual Kapal Ikan di Selat Singapura

No	Longitude Aktual (°)	Latitude Aktual (°)	Longitude Prediksi (°)	Latitude Prediksi (°)	MAPE Longitude (%)	MAPE Latitude (%)
11	103.75857	1.18214	103.75459	1.18574	0.012	0.171
12	103.76138	1.18225	103.76022	1.18572		
13	103.76450	1.18272	103.76202	1.18560		
14	103.76722	1.18322	103.76322	1.18572		
15	103.77823	1.18428	103.76411	1.18592		
16	103.78110	1.18478	103.76688	1.18611		
17	103.78396	1.18568	103.76961	1.18609		
18	103.78951	1.18774	103.76988	1.18634		
19	103.79233	1.18834	103.76879	1.18705		
20	103.79813	1.18921	103.76768	1.18753		

Hasil prediksi data AIS posisi Kapal Ikan di Selat Singapura yang diasumsikan terdapat data yang hilang jika diplot ke dalam trayektori (titik a1 s.d. titik a20) maka akan terlihat seperti pada Gambar 4.16.



Gambar 4. 16 Hasil prediksi pergerakan Kapal Ikan di Selat Singapura dengan adanya data yang hilang

Pada subsistem prediktor yang telah dirancang ini, menghasilkan *error MAPE* $\leq 10\%$ untuk prediksi data AIS kapal pelaku *illegal fishing* yang hilang, di mana hasil tersebut menunjukkan bahwa subsistem prediktor memiliki akurasi yang

tinggi. Selain itu, trayektori hasil prediksi juga hampir sama dengan trayektori data aktual yaitu lintasan mengitari seperti melingkar yang mana merupakan pola dari kapal ikan yang menggunakan alat tangkap cantrang. Hal ini membuktikan bahwa hasil yang diperoleh dari subsistem prediktor yang telah dirancang sudah cukup valid sehingga keluaran hasil prediksi data AIS *longitude* dan *latitude* kapal *illegal fishing* yang hilang ini bisa digunakan sebagai masukan untuk subsistem ANN *selection*.

4.6.3.2 Perbandingan Hasil Validasi I Prediksi Data AIS *Heading* terhadap Data AIS Aktual Kapal Ikan di Selat Singapura

Perbandingan hasil prediksi data AIS *heading* terhadap data AIS aktual Kapal Ikan di Selat Singapura dapat dilihat pada Tabel 4. 23.

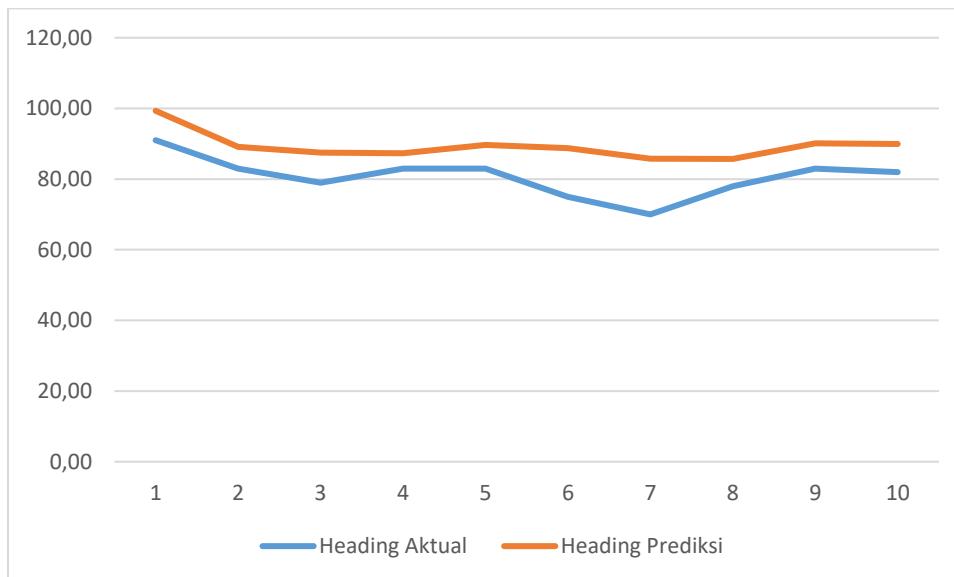
Tabel 4. 23 Perbandingan Hasil Validasi I Prediksi Data AIS *Heading* Terhadap Data AIS Aktual Kapal Ikan di Selat Singapura

No	Heading Aktual (°)	Heading Prediksi (°)	MAPE Heading (%)
11	91	99.32	10.95
12	83	89.13	
13	79	87.45	
14	83	87.28	
15	83	89.67	
16	75	88.79	
17	70	85.81	
18	78	85.71	
19	83	90.15	
20	82	89.91	

Perbandingan hasil prediksi data AIS *heading* terhadap data AIS aktual Kapal Ikan di Selat Singapura pada Tabel 4.18 jika ditampilkan dalam bentuk grafik dapat dilihat pada Gambar 4.17.

Skala dengan nilai 1 sampai 10 pada sumbu horizontal grafik mewakili nilai dari data ke-11 sampai dengan data ke-20. Pada subsistem prediktor yang telah dirancang ini, menghasilkan *error MAPE* = 10.95%, di mana hasil tersebut menunjukkan bahwa subsistem prediktor memiliki akurasi yang hampir tinggi. Hal

ini membuktikan bahwa hasil prediksi yang diperoleh sudah valid sehingga keluaran hasil prediksi data AIS *heading* kapal *illegal fishing* yang hilang ini bisa digunakan sebagai masukan untuk subsistem ANN *selection*.



Gambar 4. 17 Grafik perbandingan hasil prediksi data AIS *heading* terhadap data AIS aktual Kapal Ikan di Selat Singapura

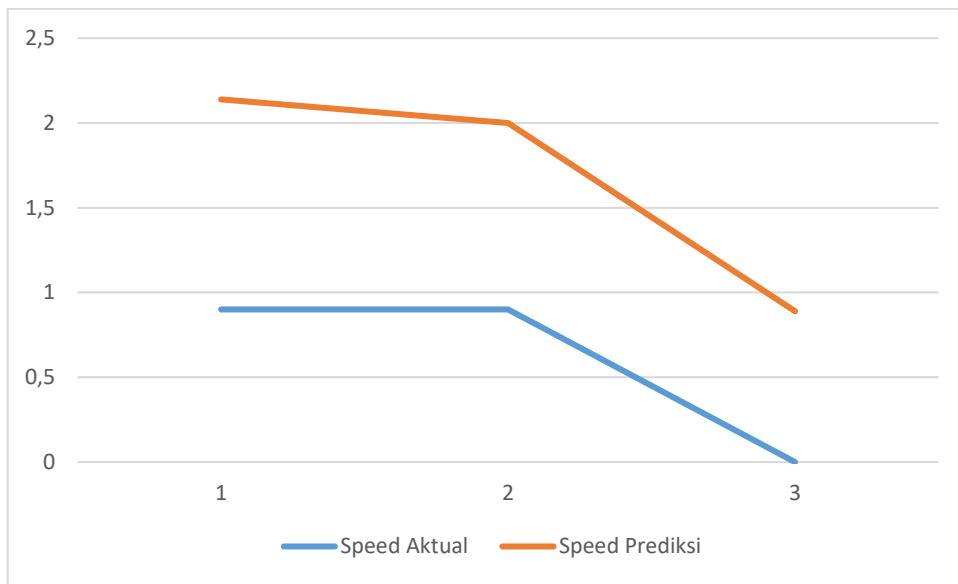
4.6.3.3 Perbandingan Hasil Validasi I Prediksi Data AIS *Speed* terhadap Data AIS Aktual Kapal Ikan di Selat Singapura

Perbandingan hasil prediksi data AIS *speed* terhadap data AIS aktual Kapal Ikan di Selat Singapura dapat dilihat pada Tabel 4.24.

Tabel 4. 24 Perbandingan Hasil Validasi I Prediksi Data AIS *Speed* Terhadap Data AIS Aktual Kapal Ikan di Selat Singapura

No	Speed Aktual (knot)	Speed Prediksi (knot)	SE	MSE	RMSE Speed (knot)
18	0.9	2.14	1.53	1.17	1.08
19	0.9	2.00	1.20		
20	0	0.89	0.79		

Perbandingan hasil prediksi data AIS *speed* terhadap data AIS aktual Kapal Ikan di Selat Singapura pada Tabel 4.24 jika ditampilkan dalam bentuk grafik dapat dilihat pada Gambar 4.18.



Gambar 4. 18 Grafik perbandingan hasil prediksi data AIS *speed* terhadap data AIS aktual Kapal Ikan di Selat Singapura

Validasi prediksi pada data AIS *speed* kapal ikan hanya saat kapal ikan melakukan *towing* dan *hauling* (pada data ke-18 sampai dengan data ke-20) yaitu saat kecepatan kapal ikan meningkat ketika ingin menarik cantrang yang udah ditebar (data ke-18 dan data ke-19) dan berhenti untuk mengangkat cantrang (data ke-20). Hal ini disebabkan data kecepatan ke-11 sampai dengan data kecepatan ke-17 bisa langsung diketahui dengan melihat hasil prediksi trayektori (*longitude* dan *latitude*) saat trayektori membentuk melingkar maka kapal akan melakukan *casting* yang mana kecepatannya akan berada di bawah 1 knot, sama seperti data ke-1 sampai dengan data ke-10. Oleh karena itu, prediksi dengan metode perbandingan senilai dilakukan hanya untuk data ke-18 sampai dengan data ke-20 dengan membandingkan nilai kecepatan dan nilai posisi data sebelumnya.

Pada subsistem prediktor yang telah dirancang ini, menghasilkan *error RMSE* yang kecil yaitu 1.08 knot. Semakin kecil nilai RMSE yang didapat maka semakin tinggi akurasi yang didapat. Selain itu, data kecepatan hasil prediksi yang didapat juga menurun (dari data ke-17 sampai data ke-20) sama seperti data kecepatan aktual dan juga nilai kecepatan hasil prediksi juga telah mampu memprediksi kecepatan ketika *towing* dan *hauling*. Hal ini membuktikan bahwa hasil prediksi yang diperoleh sudah valid sehingga keluaran hasil prediksi data AIS *speed* kapal

illegal fishing yang hilang ini bisa digunakan sebagai masukan untuk subsistem ANN *selection*.

4.6.4 Hasil Validasi Subsistem Prediktor Menggunakan Data *Real AIS* Kapal Ikan *Illegal Fishing* di Selat Singapura (Validasi Prediktor *Fishing II*)

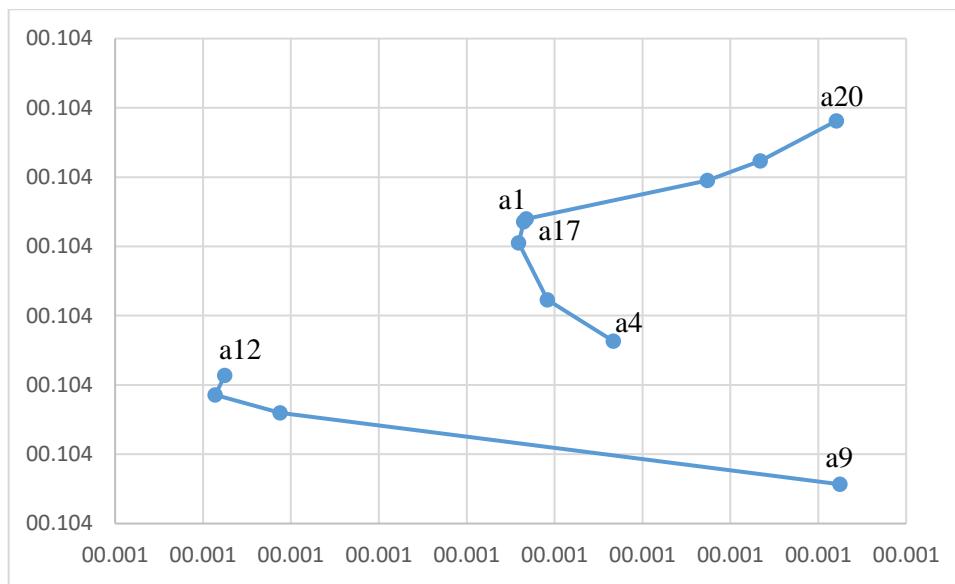
Pada validasi *illegal fishing* yang kedua ini dilakukan prediksi terhadap data AIS kapal yang sedang melakukan *illegal fishing* dengan menggunakan alat tangkap cantrang di selat Singapura dengan mengasumsikan terdapat data yang hilang secara berselang. Data yang diasumsikan hilang adalah data ke-5 sampai data ke-8 dan data ke-13 sampai data ke-16 seperti ditunjukkan oleh Tabel 4. 25.

Tabel 4. 25 Data *Real AIS* Kapal Ikan di Selat Singapura yang Diasumsikan Terdapat Data yang Hilang Secara Berselang

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (knot)
1	103.78357	1.18565	266	0.6
2	103.78050	1.18559	267	0.6
3	103.77229	1.18592	275	0.6
4	103.76632	1.18667	277	0.6
5				
6				
7				
8				
9	103.74566	1.18925	141	0.6
10	103.75596	1.18288	110	0.6
11	103.75857	1.18214	91	0.6
12	103.76138	1.18225	83	0.6
13				
14				
15				
16				
17	103.78396	1.18568	70	0.6
18	103.78951	1.18774	78	0.9
19	103.79233	1.18834	83	0.9
20	103.79813	1.18921	82	0

Data posisi *real AIS* Kapal Ikan di Selat Singapura yang diasumsikan terdapat data yang hilang secara berselang pada Tabel 4. 25 jika diplot ke dalam trayektori (titik

a1 s.d. titik a4, titik a9 s.d. titik a12, dan titik a17 s.d. titik a20) maka akan terlihat seperti pada Gambar 4.19.



Gambar 4. 19 Pergerakan Kapal Ikan di Selat Singapura dengan adanya data yang hilang secara berselang

Untuk melakukan prediksi data ke-5 sampai data ke-8, *input* yang digunakan adalah data ke-1 sampai data ke-4 sedangkan untuk melakukan prediksi data ke-13 sampai data ke-16, *input* yang digunakan adalah data ke-9 sampai data ke-12. Hasil prediksi ditunjukkan oleh Tabel 4.26.

Tabel 4. 26 Hasil Prediksi Data *Real AIS* Kapal Ikan di Selat Singapura yang Diasumsikan Terdapat Data yang Hilang Secara Berselang

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (knot)
1	103.78357	1.18565	266	0.6
2	103.78050	1.18559	267	0.6
3	103.77229	1.18592	275	0.6
4	103.76632	1.18667	277	0.6
5	103.7646	1.1868	277.53	0.6
6	103.7655	1.1869	277.72	0.6
7	103.7664	1.1868	278.25	0.6
8	103.7669	1.1868	279.07	0.6
9	103.74566	1.18925	141	0.6
10	103.75596	1.18288	110	0.6
11	103.75857	1.18214	91	0.6

Tabel 4. 26 (Lanjutan)

No	<i>Longitude</i> (°)	<i>Latitude</i> (°)	<i>Heading</i> (°)	<i>Speed</i> (knot)
12	103.76138	1.18225	83	0.6
13	103.7603	1.1823	77.86	0.6
14	103.7611	1.1823	73.40	0.6
15	103.7618	1.1824	74.70	0.6
16	103.7629	1.1824	75.90	0.6
17	103.78396	1.18568	70	0.6
18	103.78951	1.18774	78	0.9
19	103.79233	1.18834	83	0.9
20	103.79813	1.18921	82	0

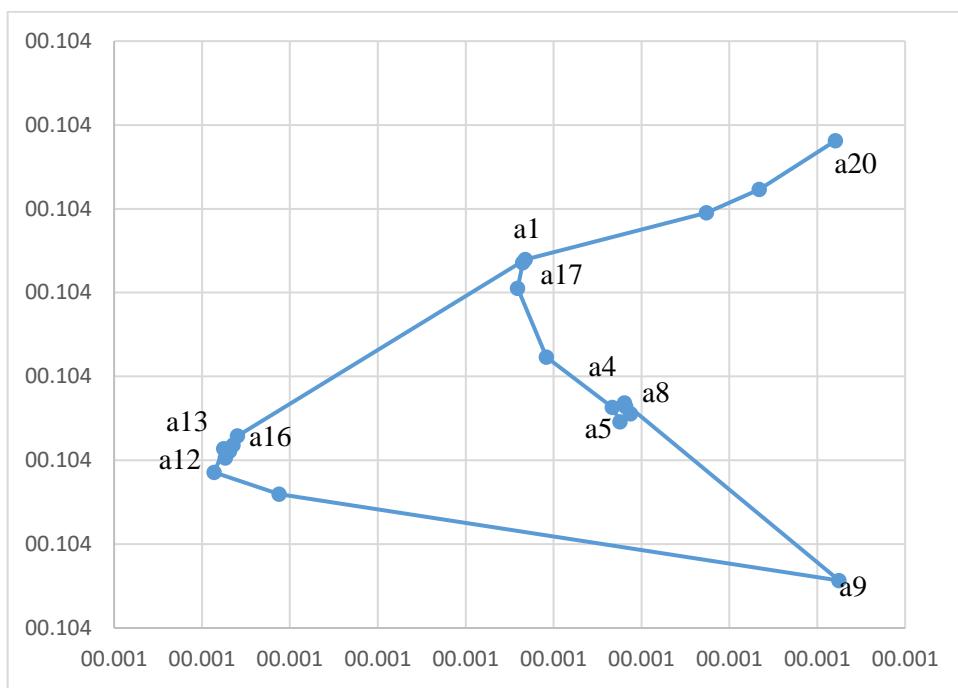
4.6.4.1 Perbandingan Hasil Validasi II Prediksi Data AIS *Longitude* dan *Latitude* terhadap Data AIS Aktual Kapal Ikan di Selat Singapura

Perbandingan hasil prediksi data AIS *longitude* dan *latitude* terhadap data AIS aktual Kapal Ikan di Selat Singapura dapat dilihat pada Tabel 4.27.

Tabel 4. 27 Perbandingan Hasil Validasi II Prediksi Data AIS *Longitude* dan *Latitude* Terhadap Data AIS Aktual Kapal Ikan di Selat Singapura

No	<i>Longitude</i> Aktual (°)	<i>Latitude</i> Aktual (°)	<i>Longitude</i> Prediksi (°)	<i>Latitude</i> Prediksi (°)	MAPE <i>Longitude</i> (%)	MAPE <i>Latitude</i> (%)
5	103.76031	1.18727	103.7646	1.1868	0.0096	0.0854
6	103.75921	1.18732	103.7655	1.1869		
7	103.75821	1.18749	103.7664	1.1868		
8	103.74554	1.18925	103.7669	1.1868		
13	103.76450	1.18272	103.7603	1.1823	0.0108	0.1195
14	103.76722	1.18322	103.7611	1.1823		
15	103.77823	1.18428	103.7618	1.1824		
16	103.78110	1.18478	103.7629	1.1824		

Hasil prediksi data AIS posisi Kapal Ikan di Selat Singapura yang diasumsikan terdapat data yang hilang secara berselang jika diplot ke dalam trayektori (titik a) maka akan terlihat seperti pada Gambar 4.20.



Gambar 4. 20 Hasil prediksi pergerakan Kapal Ikan di Selat Singapura dengan adanya data yang hilang secara berselang

Pada subsistem prediktor yang telah dirancang ini, menghasilkan *error MAPE* $\leq 10\%$ untuk prediksi data AIS kapal pelaku *illegal fishing* yang hilang, di mana hasil tersebut menunjukkan bahwa subsistem prediktor memiliki akurasi yang tinggi. Tetapi, hasil prediksi menghasilkan trayektori yang tidak mendekati trayektori aktual. Jika dibandingkan dengan hasil validasi *transhipment I*, hasil dari validasi *transhipment II* ini masih kurang mampu memprediksi trayektori kapal *illegal transhipment* yang terdapat data hilang berselang, hal ini dikarenakan dalam kasus data AIS kapal yang hilang secara berselang menyebabkan jumlah data *input* yang digunakan sebagai masukan untuk memprediksi lebih sedikit oleh karena itu hasil yang dihasilkan tidak maksimal

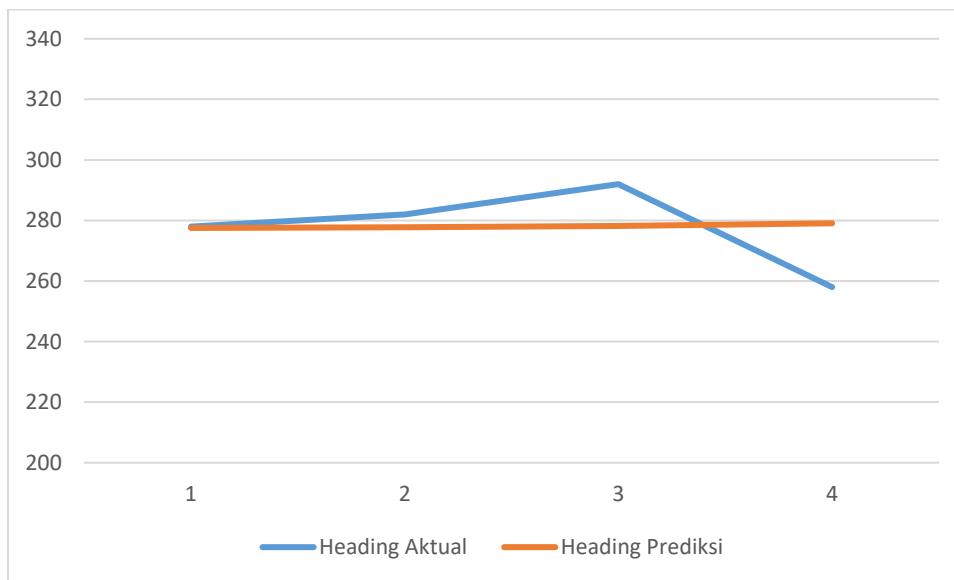
4.6.4.2 Perbandingan Hasil Validasi II Prediksi Data AIS *Heading* terhadap Data AIS Aktual Kapal Ikan di Selat Singapura

Perbandingan hasil prediksi data AIS *heading* terhadap data AIS aktual Kapal Ikan di Selat Singapura dapat dilihat pada Tabel 4. 28.

Tabel 4. 28 Perbandingan Hasil Validasi II Prediksi Data AIS *Heading* Terhadap Data AIS Aktual Kapal Ikan di Selat Singapura

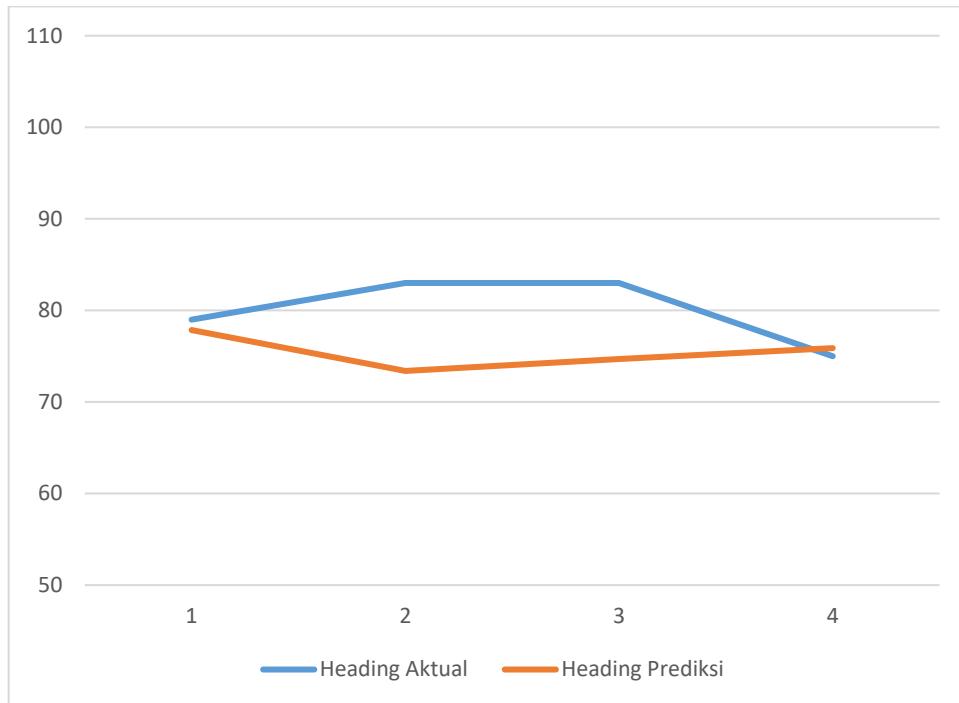
No	Heading Aktual (°)	Heading Prediksi (°)	MAPE Heading (%)
5	278	277.53	3.64
6	282	277.72	
7	292	278.25	
8	258	279.07	
13	79	77.86	6.05
14	83	73.40	
15	83	74.70	
16	75	75.90	

Perbandingan hasil prediksi data AIS *heading* terhadap data AIS aktual Kapal Ikan di Selat Singapura yang diasumsikan terdapat data yang hilang secara berselang pada Tabel 4.28 jika ditampilkan dalam bentuk grafik dapat dilihat pada Gambar 4.21 dan Gambar 4.22.



Gambar 4. 21 Grafik perbandingan hasil prediksi data ke-5 sampai dengan data ke-8 AIS *heading* terhadap data AIS aktual Kapal Ikan di Selat Singapura

Pada Gambar 4.21 merupakan grafik perbandingan hasil prediksi data ke-5 sampai dengan data ke-8, skala dengan nilai 1 sampai dengan 4 pada sumbu horizontal grafik mewakili nilai dari data ke-5 sampai dengan data ke-8.



Gambar 4. 22 Grafik perbandingan hasil prediksi data ke-13 sampai dengan data ke-16 AIS *heading* terhadap data AIS aktual Kapal Ikan di Selat Singapura

Pada Gambar 4.22 merupakan grafik perbandingan hasil prediksi data ke-13 sampai dengan data ke-16, skala dengan nilai 1 sampai dengan 4 pada sumbu horizontal grafik mewakili nilai dari data ke-13 sampai dengan data ke-18. Pada subsistem prediktor yang telah dirancang ini, menghasilkan $error MAPE \leq 10\%$, di mana hasil tersebut menunjukkan bahwa subsistem prediktor memiliki akurasi yang tinggi. Hal ini membuktikan bahwa hasil prediksi yang diperoleh sudah valid sehingga keluaran hasil prediksi data AIS *heading* kapal *illegal transhipment* yang hilang ini bisa digunakan sebagai masukan untuk subsistem ANN *selection*.

4.6.4.3 Perbandingan Hasil Validasi II Prediksi Data AIS *Speed* terhadap Data

AIS Aktual Kapal Ikan di Selat Singapura

Perbandingan hasil prediksi data AIS *speed* terhadap data AIS aktual Kapal Ikan di Selat Singapura dapat dilihat pada Tabel 4.29.

Tabel 4.29 Perbandingan Hasil Validasi II Prediksi Data AIS *Speed* Terhadap Data AIS Aktual Kapal Ikan di Selat Singapura

No	Speed Aktual (knot)	Speed Prediksi (knot)	SE	MSE	RMSE (knot)
5	0.6	0.6	0	0	0
6	0.6	0.6	0		
7	0.6	0.6	0		
8	0.6	0.6	0		
13	0.6	0.6	0	0	0
14	0.6	0.6	0		
15	0.6	0.6	0		
16	0.6	0.6	0		

Validasi prediksi pada data AIS *speed* kapal ikan hanya saat kapal ikan melakukan *towing* dan *hauling* (pada data ke-18 sampai dengan data ke-20) yaitu saat kecepatan kapal ikan meningkat ketika ingin menarik cantrang yang udah ditebar (data ke-18 dan data ke-19) dan berhenti untuk mengangkat cantrang (data ke-20). Hal ini disebabkan data kecepatan ke-5 sampai dengan data kecepatan ke-8 dan data kecepatan ke-13 sampai dengan data kecepatan ke-16 bisa langsung diketahui dengan melihat hasil prediksi trayektori (*longitude* dan *latitude*) saat trayektori membentuk melingkar maka kapal akan melakukan *casting* yang mana kecepatannya akan berada di bawah 1 knot, sama seperti data kecepatan ke-1 sampai dengan data ke-4 dan data ke-9 sampai dengan data ke-12. Oleh karena itu, prediksi dengan metode perbandingan senilai dilakukan hanya untuk data ke-18 sampai dengan data ke-20 dengan membandingkan nilai kecepatan dan nilai posisi data sebelumnya seperti yang dilakukana pada validasi yang pertama (Validasi Prediktor *Fishing* I). Pada subsistem prediktor yang telah dirancang ini, menghasilkan *error* RMSE yang bernilai 0 knot atau tidak ada *error*. Hal ini membuktikan bahwa hasil prediksi yang diperoleh sudah valid sehingga keluaran hasil prediksi data AIS *speed* kapal *illegal fishing* yang hilang ini bisa digunakan sebagai masukan untuk subsistem ANN *selection*.

4.7 Hasil Perancangan Subsistem ANN Selection

Pada perancangan subsistem ANN *selection* dilakukan observasi terhadap kombinasi dari model arsitektur jaringan dan parameter untuk mendapatkan kombinasi model arsitektur jaringan terbaik dan parameter paling optimal yang meliputi jumlah *unit neuron* pada *hidden layers* dan nilai *learning rate*. Berikut adalah variasi nilai parameter yang diuji.

- Jumlah *unit neuron* pada *hidden layers* : 5, 10, 15, 20, 25
- Nilai *learning rate* : 0.001, 0.005, 0.01, 0.05, 0.1

Untuk masing-masing parameter yang dikombinasikan dilakukan dengan pengimplementasian k-fold cross validation dengan k=5.

4.7.1 Hasil Pengimplementasian K-Fold Cross Validation pada Perancangan Subsistem ANN Selection

Pada pengimplementasian k-fold cross-validation untuk perancangan ANN *selection* ini digunakan sebanyak 4515 pengamatan yang terkandung dalam dataset, yang dibagi menjadi lima set.

Tabel 4. 30 Hasil Pengimplementasian K-Fold Cross Validation pada Perancangan ANN Selection

Learning Rate	Neurons pada Hidden Layer	Akurasi (Rata-rata)	Standard Deviasi (Rata-rata)
0.0001	5	0.972	0.010
0.0005	5	0.990	0.005
0.001	5	0.995	0.004
0.005	5	0.996	0.004
0.01	5	0.998	0.003
0.0001	10	0.977	0.010
0.0005	10	0.993	0.004
0.001	10	0.996	0.002
0.005	10	0.995	0.003
0.01	10	0.999	0.001
0.0001	15	0.982	0.008
0.0005	15	0.994	0.004
0.001	15	0.998	0.003

Tabel 4. 30 (Lanjutan)

<i>Learning Rate</i>	<i>Neurons</i> pada <i>Hidden Layer</i>	Akurasi (Rata-rata)	Standard Deviasi (Rata-rata)
0.005	15	0.997	0.004
0.01	15	0.995	0.005
0.0001	20	0.983	0.007
0.0005	20	0.994	0.004
0.001	20	0.994	0.001
0.005	20	0.998	0.003
0.01	20	0.996	0.002
0.0001	25	0.985	0.006
0.0005	25	0.995	0.003
0.001	25	0.996	0.003
0.005	25	0.999	0.002
0.01	25	0.994	0.005

Dalam pendekatan ini, empat set (80% pengamatan atau sebanyak 3612 pengamatan) digunakan untuk melatih *neural network*, dan set yang tersisa (20% dari pengamatan atau sebanyak 903 pengamatan) disimpan untuk menguji kinerja model. Proses ini dilakukan lima kali karena lima kombinasi yang berbeda digunakan untuk membagi lima set menjadi empat set untuk mengembangkan model dan set lainnya untuk melakukan tes yang sesuai.

Dari pengimplementasian proses ini dihasilkan 25 model *neural networks*, sebagai hasil dari kombinasi lima variasi *neurons* pada *hidden layer* untuk lima nilai *learning rate*. Hasil dari pengimplementasian *k-fold cross validation* pada perancangan ANN *selection* ditunjukkan oleh Tabel 4. 30.

Berdasarkan Tabel 4.30, diketahui bahwa penggunaan nilai *learning rate* 0.01 dan 10 *neurons* pada *hidden layer* menghasilkan rata-rata akurasi terbesar yaitu 0.999 dan nilai standard deviasi yang kecil yaitu 0.001.

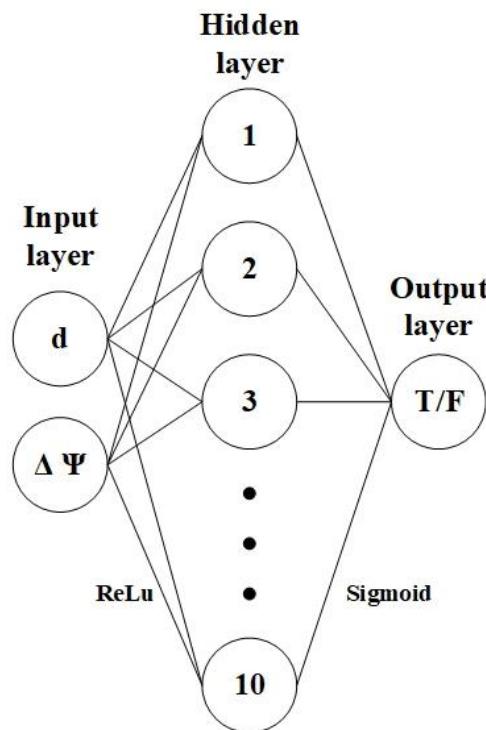
4.7.2 Model Arsitektur Jaringan ANN *Selection*

Berdasarkan pengimplementasian *k-fold cross validation* yang telah dilakukan, dipilih model arsitektur jaringan ANN *selection* terbaik dengan menggunakan parameter yang paling optimal berdasarkan model yang

menghasilkan rata-rata akurasi paling tinggi dan standard deviasi rendah. Parameter-parameter tersebut adalah:

- Jumlah hidden layers: 1
- Jumlah neurons pada hidden layer: 10
- Fungsi aktivasi: rectified linear unit (ReLU) pada *input layer* dan *hidden layer*, sigmoid pada *output layer*
- Optimizer: adaptative moment estimation (Adam)
- Nilai learning rate: 0.01
- Jumlah epochs: 100

Model arsitektur jaringan ANN *selection* terbaik dengan menggunakan parameter-parameter di atas ditunjukkan oleh Gambar 4. 23.



Gambar 4. 23 Model arsitektur jaringan ANN *selection*

4.7.3 Hasil Evaluasi Model Arsitektur Jaringan ANN *Selection*

Evaluasi model arsitektur jaringan ANN *selection* dilakukan dengan membandingkan hasil keluaran identifikasi dari ANN *selection* terhadap hasil dari keluaran subsitem *selection* dari rancangan penelitian sebelumnya (Fatmawati, 2018).

Pada penelitian sebelumnya telah dilakukan pengujian rancangan subsistem *selection* untuk mensortir kapal pelaku *illegal transhipment* dan *illegal fishing* dengan menggunakan logika fuzzy. Pengujian dilakukan dengan berbagai variasi gerak kapal yang telah dibangkitkan. Variabel yang divariasikan adalah variabel masukan pada sistem pengambilan keputusan *selection* untuk mensortir kapal pelaku *illegal transhipment* dan *illegal fishing*.

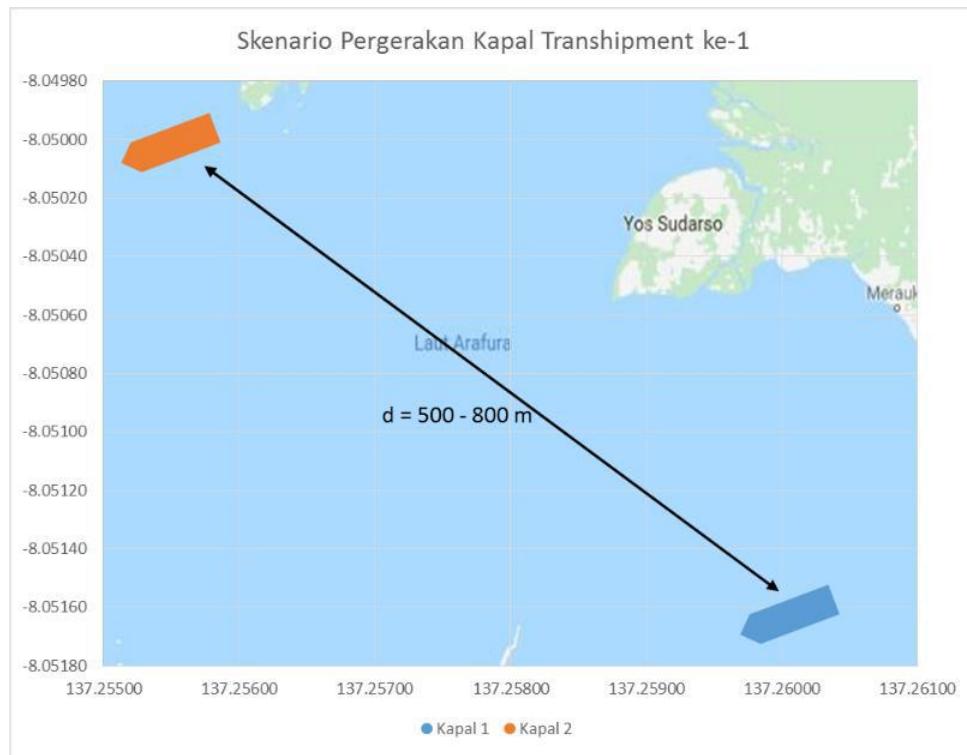
Pembangkitan data posisi dua kapal untuk uji pola pergerakan kapal *illegal transhipment* dilakukan di Laut Arafura dengan tiga variasi pola kapal *illegal transhipment*. Pembangkitan data posisi kapal untuk uji pola pergerakan kapal *illegal fishing* dilakukan di perairan Natuna dan perairan Brondong dengan dua variasi pola kapal *illegal fishing*.

4.7.3.1 Hasil Perbandingan Uji Pola *Transhipment* Ke-1

Pada pengujian pertama dilakukan pembangkitan data untuk menguji tahap sortir yaitu data kecepatan, data *heading* dan data posisi (*longitude* dan *latitude*) dua kapal ikan yang selanjutnya akan diolah sebagai kebutuhan variabel masukan sistem. Karena tahap sortir adalah tahapan awal, maka akan dibangkitkan data kapal pada masing-masing koordinat kapal yang akan disortir.

Gambar 4.24 menjelaskan bahwa sedang terjadi tahap sortir di tengah laut dengan objek sortir kapal 1 dan kapal 2. Kapal 1 dilakukan pembangkitan data dengan koordinat posisi -8.0516150, 137.2600936 dan sudut *heading* 112°. Kapal 2 dilakukan pembangkitan data dengan koordinat posisi -8.05004286, 137.2552657 dan sudut *heading* 77°. Koordinat *longitude* dan *latitude* di atas masih dalam satuan

degree, untuk masuk ke *selection* dilakukan konversi data *latitude* dan *longitude* dalam satuan meter dengan persamaan (3. 9).



Gambar 4. 24 Sortir dua kapal diduga *transhipment* pola ke-1

Pada Tabel 4. 31 hasil perhitungan jarak antara kedua kapal dan selisih *heading* kedua kapal.

Tabel 4. 31 Data Masukan *Selection* Pola *Transhipment* ke-1

No	Data Masukan <i>Selection</i>	Keterangan
1	Selisih Sudut <i>Heading</i> (<i>degree</i>)	35
2	Jarak (meter)	565.2399319

Jarak antara kedua kapal dan selisih sudut heading pada Tabel 4. 31 dimasukkan ke subsistem fuzzy *selection* pada penelitian sebelumnya dan ke subsistem ANN *selection* pada penelitian ini. Keluaran dari subsistem fuzzy *selection* pada penelitian sebelumnya dan keluaran subsistem ANN *selection* pada penelitian ini untuk pola *transhipment* ke-1 ditunjukkan oleh Tabel 4. 32.

Tabel 4.32 Hasil Perbandingan Keluaran Subsistem *Selection* Pola Kapal *Transhipment* ke-1

Hasil Keluaran <i>Fuzzy Selection</i> (Fatmawati, 2018)	Hasil Keluaran ANN <i>Selection</i>
84%	100%

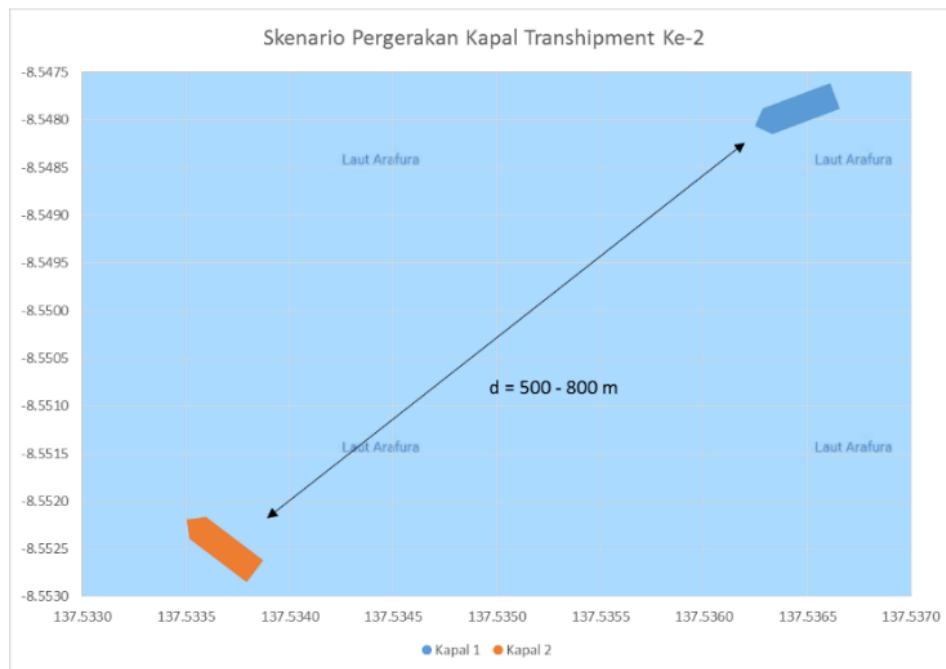
Bisa dilihat pada Tabel 4. 32, keluaran dari subsistem ANN *selection* pada pola *transhipment* yang pertama ini sebesar 100%, sedangkan pada keluaran fuzzy *selection* sebesar 84%. Nilai keluaran *selection* pada kedua subsistem tersebut menunjukkan besar presentase dua kapal diduga akan melakukan praktik *illegal transhipment*. Nilai keluaran menunjukkan lebih dari 50%. Tetapi hasil keluaran yang didapat oleh ANN *selection* lebih tinggi dibandingkan hasil keluaran pada fuzzy *selection*. Ini menunjukkan bahwa subsistem ANN *selection* memberikan hasil yang lebih tegas dibandingkan fuzzy *selection*.

4.7.3.2 Hasil Perbandingan Uji Pola *Transhipment* Ke-2

Pada pengujian kedua dilakukan pembangkitan data untuk menguji tahap sortir yaitu data kecepatan, data *heading* dan data posisi (*longitude* dan *latitude*) dua kapal ikan yang selanjutnya akan diolah sebagai kebutuhan variabel masukan sistem. Karena tahap sortir adalah tahapan awal, maka akan dibangkitkan data kapal pada masing-masing koordinat kapal yang akan disortir.

Gambar 4.25 menjelaskan bahwa sedang terjadi tahap sortir di tengah laut dengan objek sortir kapal 1 dan kapal 2. Kapal 1 dilakukan pembangkitan data dengan koordinat posisi -8.547886, 137.536468 dan sudut *heading* 143°. Kapal 2 dilakukan pembangkitan data dengan koordinat posisi -8.552395, 137.53363 dan sudut *heading* -38°. Koordinat *longitude* dan *latitude* di atas masih dalam satuan

degree, untuk masuk ke *selection* dilakukan konversi data *latitude* dan *longitude* dalam satuan meter dengan persamaan (3. 9).



Gambar 4. 25 Gambar dua kapal diduga *transhipment* pola ke-2

Pada Tabel 4. 33 hasil perhitungan jarak antara kedua kapal dan selisih *heading* kedua kapal.

Tabel 4. 33 Data Masukan *Selection* Pola *Transhipment* ke-2

No	Data Masukan <i>Selection</i>	Keterangan
1	Selisih Sudut <i>Heading</i> (<i>degree</i>)	181
2	Jarak (meter)	593

Jarak antara kedua kapal dan selisih sudut heading pada Tabel 4. 33 dimasukkan ke subsistem fuzzy *selection* pada penelitian sebelumnya dan ke subsistem ANN *selection* pada penelitian ini. Keluaran dari subsistem fuzzy *selection* pada penelitian sebelumnya dan keluaran subsistem ANN *selection* pada penelitian ini untuk pola *transhipment* ke-2 ditunjukkan oleh Tabel 4. 34.

Bisa dilihat pada Tabel 4. 34, keluaran dari subsistem ANN *selection* pada pola *transhipment* yang kedua ini sebesar 100%, sedangkan pada keluaran fuzzy *selection* sebesar 84%. Nilai keluaran *selection* pada kedua subsistem tersebut

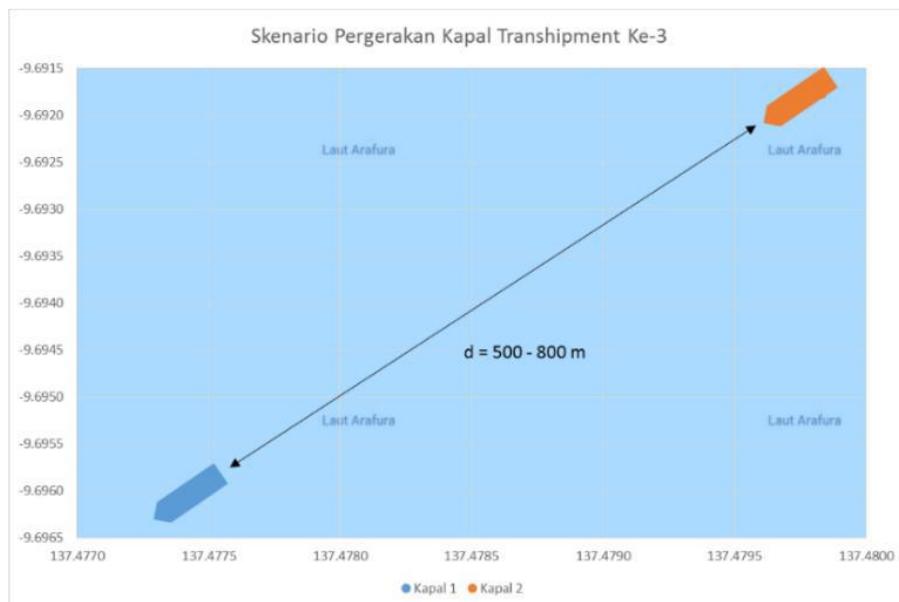
menunjukkan besar presentase dua kapal diduga akan melakukan praktik illegal *transhipment*. Nilai keluaran menunjukkan lebih dari 50%. Tetapi hasil keluaran yang didapat oleh ANN *selection* lebih tinggi dibandingkan hasil keluaran pada fuzzy *selection*. Ini menunjukkan bahwa subsistem ANN *selection* memberikan hasil yang lebih tegas dibandingkan fuzzy *selection*.

Tabel 4.34 Hasil Perbandingan Keluaran Subsistem *Selection* Pola Kapal *Transhipment* ke-2

Hasil Keluaran Fuzzy Selection (Fatmawati, 2018)	Hasil Keluaran ANN Selection
83.4%	100%

4.7.3.3 Hasil Perbandingan Uji Pola *Transhipment* Ke-3

Pada pengujian ketiga dilakukan pembangkitan data untuk menguji tahap sortir yaitu data kecepatan, data *heading* dan data posisi (*longitude* dan *latitude*) dua kapal ikan yang selanjutnya akan diolah sebagai kebutuhan variabel masukan sistem. Karena tahap sortir adalah tahapan awal, maka akan dibangkitkan data kapal pada masing-masing koordinat kapal yang akan disortir.



Gambar 4.26 Sortir dua kapal diduga *transhipment* pola ke-3

Gambar 4.26 menjelaskan bahwa sedang terjadi tahap sortir di tengah laut dengan objek sortir kapal 1 dan kapal 2. Kapal 1 dilakukan pembangkitan data dengan koordinat posisi -9.06723, 136.9680, dan sudut *heading* 143°. Kapal 2 dilakukan pembangkitan data dengan koordinat posisi -9.06358, 136.97274, dan sudut *heading* 147°. Koordinat *longitude* dan *latitude* di atas masih dalam satuan *degree*, untuk masuk ke *selection* dilakukan konversi data *latitude* dan *longitude* dalam satuan meter dengan persamaan (3. 9).

Pada Tabel 4. 35 hasil perhitungan jarak antara kedua kapal dan selisih *heading* kedua kapal.

Tabel 4. 35 Data Masukan *Selection* Pola *Transhipment* ke-3

No	Data Masukan <i>Selection</i>	Keterangan	
1	Selisih Sudut <i>Heading</i> (<i>degree</i>)	-4	<i>Overtake</i>
2	Jarak (meter)	664	<i>Near</i>

Jarak antara kedua kapal dan selisih sudut heading pada Tabel 4. 35 dimasukkan ke subsistem fuzzy *selection* pada penelitian sebelumnya dan ke subsistem ANN *selection* pada penelitian ini. Keluaran dari subsistem fuzzy *selection* pada penelitian sebelumnya dan keluaran subsistem ANN *selection* pada penelitian ini untuk pola *transhipment* ke-3 ditunjukkan oleh Tabel 4. 36.

Tabel 4. 36 Hasil Perbandingan Keluaran Subsistem *Selection* Pola Kapal *Transhipment* ke-3

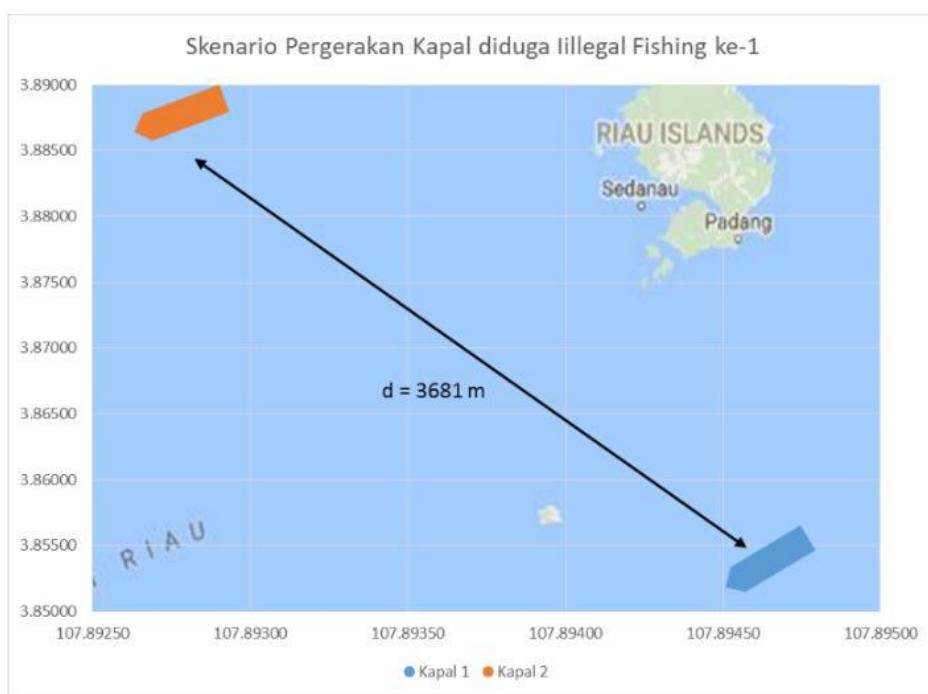
Hasil Keluaran Fuzzy <i>Selection</i> (Fatmawati, 2018)	Hasil Keluaran ANN <i>Selection</i>
81.5%	100%

Bisa dilihat pada Tabel 4. 36, keluaran dari subsistem ANN *selection* pada pola *transhipment* yang ketiga ini sebesar 100%, sedangkan pada keluaran fuzzy *selection* sebesar 81.5%. Nilai keluaran *selection* pada kedua subsistem tersebut menunjukkan besar presentase dua kapal diduga akan melakukan praktik *illegal transhipment*. Nilai keluaran menunjukkan lebih dari 50%. Tetapi hasil keluaran yang didapat oleh ANN *selection* lebih tinggi dibandingkan hasil keluaran pada

fuzzy *selection*. Ini menunjukkan bahwa subsistem ANN *selection* memberikan hasil yang lebih tegas dibandingkan fuzzy *selection*.

4.7.3.4 Hasil Perbandingan Uji Pola *Illegal Fishing* Ke-1

Pada pengujian pertama dilakukan pembangkitan data untuk menguji tahap sortir yaitu data kecepatan, data *heading* dan data posisi (*longitude* dan *latitude*) dua kapal ikan yang selanjutnya akan diolah sebagai kebutuhan variabel masukan sistem. Karena tahap sortir adalah tahapan awal, maka akan dibangkitkan data kapal pada masing-masing koordinat kapal yang akan disortir.



Gambar 4. 27 Sortir dua kapal diduga *illegal fishing* pola ke-1

Gambar 4.27 menjelaskan bahwa sedang terjadi tahap sortir di tengah laut dengan objek sortir kapal 1 dan kapal 2. Kapal 1 dilakukan pembangkitan data dengan koordinat posisi 3.85493, 107.89466 dan sudut *heading* 112°. Kapal 2 dilakukan pembangkitan data dengan koordinat posisi 3.88795, 107.89278 dan sudut *heading* 112°. Koordinat *longitude* dan *latitude* di atas masih dalam satuan

degree, untuk masuk ke *selection* dilakukan konversi data *latitude* dan *longitude* dalam satuan meter dengan persamaan (3. 9).

Pada Tabel 4. 37 hasil perhitungan jarak antara kedua kapal dan selisih *heading* kedua kapal.

Tabel 4. 37 Data Masukan *Selection* Pola *Illegal Fishing* ke-1

No	Data Masukan <i>Selection</i>	Keterangan
1	Selisih Sudut <i>Heading</i> (<i>degree</i>)	0
2	Jarak (meter)	3681

Jarak antara kedua kapal dan selisih sudut *heading* pada Tabel 4. 37 dimasukkan ke subsistem fuzzy *selection* pada penelitian sebelumnya dan ke subsistem ANN *selection* pada penelitian ini. Keluaran dari subsistem fuzzy *selection* pada penelitian sebelumnya dan keluaran subsistem ANN *selection* pada penelitian ini untuk pola *illegal fishing* ke-1 ditunjukkan oleh Tabel 4. 38.

Tabel 4. 38 Hasil Perbandingan Keluaran Subsistem *Selection* Pola Kapal *Illegal Fishing* ke-1

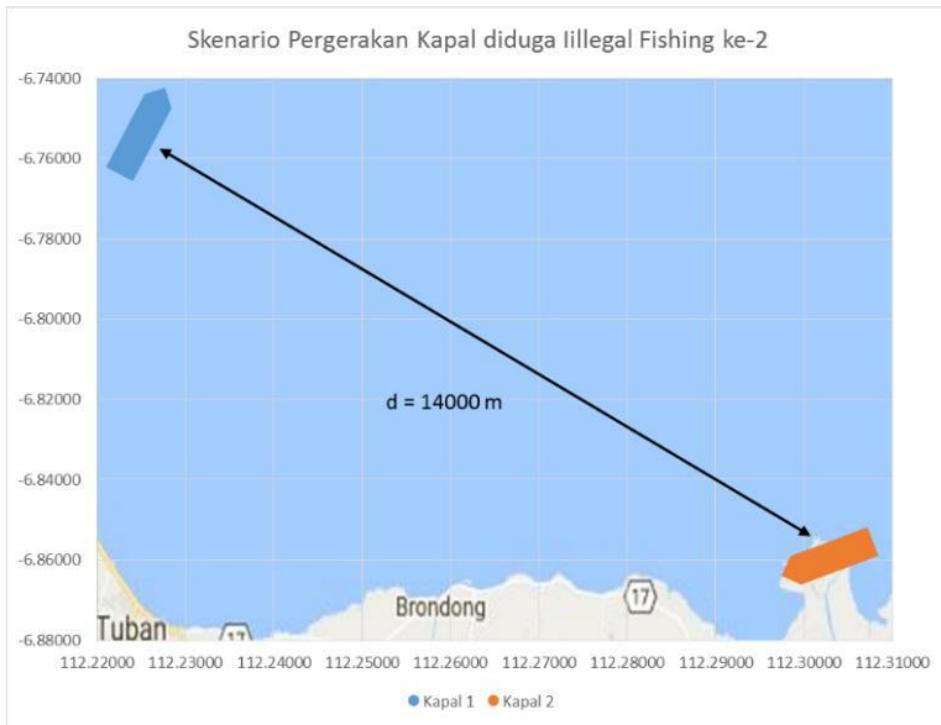
Hasil Keluaran Fuzzy <i>Selection</i> (Fatmawati, 2018)	Hasil Keluaran ANN <i>Selection</i>
20.4%	0%

Bisa dilihat pada Tabel 4. 38, keluaran dari subsistem ANN *selection* pada pola *illegal fishing* yang pertama ini sebesar 0%, sedangkan pada keluaran fuzzy *selection* sebesar 20.4%. Nilai keluaran *selection* pada kedua subsistem tersebut menunjukkan besar presentase dua kapal diduga akan melakukan praktik *illegal fishing*. Nilai keluaran menunjukkan kurang dari 50%. Tetapi, hasil keluaran yang didapat oleh ANN *selection* lebih kecil dibandingkan hasil keluaran pada fuzzy *selection*. Ini menunjukkan bahwa subsistem ANN *selection* memberikan hasil yang lebih tegas dibandingkan fuzzy *selection*.

4.7.3.5 Hasil Perbandingan Uji Pola *Illegal Fishing* Ke-2

Pada pengujian pertama dilakukan pembangkitan data untuk menguji tahap sortir yaitu data kecepatan, data *heading* dan data posisi (*longitude* dan *latitude*)

dua kapal ikan yang selanjutnya akan diolah sebagai kebutuhan variabel masukan sistem. Karena tahap sortir adalah tahapan awal, maka akan dibangkitkan data kapal pada masing-masing koordinat kapal yang akan disortir.



Gambar 4. 28 Sortir dua kapal diduga *illegal fishing* pola ke-2

Gambar 4.28 menjelaskan bahwa sedang terjadi tahap sortir di tengah laut dengan objek sortir kapal 1 dan kapal 2. Kapal 1 dilakukan pembangkitan data dengan koordinat posisi $-6.75448, 112.22568$ dan sudut *heading* 66° . Kapal 2 dilakukan pembangkitan data dengan koordinat posisi $-6.85798, 112.30567$ dan sudut *heading* 112° . Koordinat *longitude* dan *latitude* di atas masih dalam satuan *degree*, untuk masuk ke *selection* dilakukan konversi data *latitude* dan *longitude* dalam satuan meter dengan persamaan (3. 9).

Pada Tabel 4. 39 hasil perhitungan jarak antara kedua kapal dan selisih *heading* kedua kapal.

Tabel 4. 39 Data Masukan *Selection* Pola *Illegal Fishing* ke-2

No	Data Masukan <i>Selection</i>		Keterangan
1	Selisih Sudut <i>Heading</i> (<i>degree</i>)	46	<i>Crossing</i>
2	Jarak (meter)	14561	<i>Far</i>

Jarak antara kedua kapal dan selisih sudut *heading* pada Tabel 4. 39 dimasukkan ke subsistem fuzzy *selection* pada penelitian sebelumnya dan ke subsistem ANN *selection* pada penelitian ini. Keluaran dari subsistem fuzzy *selection* pada penelitian sebelumnya dan keluaran subsistem ANN *selection* pada penelitian ini untuk pola *illegal fishing* ke-2 ditunjukkan oleh Tabel 4. 40.

Tabel 4. 40 Hasil Perbandingan Keluaran Subsistem *Selection* Pola Kapal *Illegal Fishing* ke-2

Hasil Keluaran Fuzzy Selection (Fatmawati, 2018)	Hasil Keluaran ANN Selection
17%	0%

Bisa dilihat pada Tabel 4. 30, keluaran dari subsistem ANN *selection* pada pola *illegal fishing* yang kedua ini sebesar 0%, sedangkan pada keluaran fuzzy *selection* sebesar 17%. Nilai keluaran *selection* pada kedua subsistem tersebut menunjukkan besar presentase dua kapal diduga akan melakukan praktik *illegal fishing*. Nilai keluaran menunjukkan kurang dari 50%. Tetapi, hasil keluaran yang didapat oleh ANN *selection* lebih kecil dibandingkan hasil keluaran pada fuzzy *selection*. Ini menunjukkan bahwa subsistem ANN *selection* memberikan hasil yang lebih tegas dibandingkan fuzzy *selection*.

4.8 Hasil Perancangan Subsistem ANN *Decision Transhipment*

Pada perancangan subsistem ANN *decision transhipment* dilakukan observasi terhadap kombinasi dari model arsitektur jaringan dan parameter untuk mendapatkan kombinasi model arsitektur jaringan terbaik dan parameter paling optimal yang meliputi jumlah *unit neuron* pada *hidden layers* dan nilai *learning rate*. Berikut adalah variasi nilai parameter yang diuji.

- Jumlah *unit neuron* pada *hidden layers* : 5, 10, 15, 20, 25
- Nilai *learning rate* : 0.001, 0.005, 0.01, 0.05, 0.1

Untuk masing-masing parameter yang dikombinasikan dilakukan dengan pengimplementasian k-fold cross validation dengan k=5.

4.8.1 Hasil Pengimplementasian K-Fold Cross Validation pada Perancangan Subsistem ANN Decision Transhipment

Pada pengimplementasian *k-fold cross-validation* untuk perancangan ANN *decision transhipment* ini digunakan sebanyak 4500 pengamatan yang terkandung dalam dataset, yang dibagi menjadi lima set.

Dalam pendekatan ini, empat set (80% pengamatan atau sebanyak 3600 pengamatan) digunakan untuk melatih *neural network*, dan set yang tersisa (20% dari pengamatan atau sebanyak 900 pengamatan) disimpan untuk menguji kinerja model. Proses ini dilakukan lima kali karena lima kombinasi yang berbeda digunakan untuk membagi lima set menjadi empat set untuk mengembangkan model dan set lainnya untuk melakukan tes yang sesuai.

Dari pengimplementasian proses ini dihasilkan 25 model *neural networks*, sebagai hasil dari kombinasi lima variasi *neurons* pada *hidden layer* untuk lima nilai *learning rate*. Hasil dari pengimplementasian *k-fold cross validation* pada perancangan ANN *decision transhipment* ditunjukkan oleh Tabel 4. 41.

Tabel 4. 41 Hasil Pengimplementasian K-Fold Cross Validation pada Perancangan ANN Decision Transhipment

<i>Learning Rate</i>	<i>Neurons</i> pada <i>Hiddden Layer</i>	Akurasi (Rata-rata)	Standard Deviasi (Rata-rata)
0.0001	5	0.674	0.299
0.0005	5	0.748	0.215
0.001	5	0.827	0.135
0.005	5	0.852	0.128
0.01	5	0.895	0.109
0.0001	10	0.691	0.281
0.0005	10	0.761	0.216
0.001	10	0.804	0.159
0.005	10	0.903	0.112
0.01	10	0.824	0.206
0.0001	15	0.712	0.249
0.0005	15	0.753	0.208
0.001	15	0.788	0.208

Tabel 4. 41 (Lanjutan)

<i>Learning Rate</i>	<i>Neurons pada Hidden Layer</i>	Akurasi (Rata-rata)	Standard Deviasi (Rata-rata)
0.005	15	0.881	0.117
0.01	15	0.855	0.158
0.0001	20	0.712	0.251
0.0005	20	0.772	0.203
0.001	20	0.810	0.170
0.005	20	0.846	0.173
0.01	20	0.825	0.191
0.0001	25	0.713	0.247
0.0005	25	0.776	0.195
0.001	25	0.841	0.131
0.005	25	0.878	0.116
0.01	25	0.827	0.193

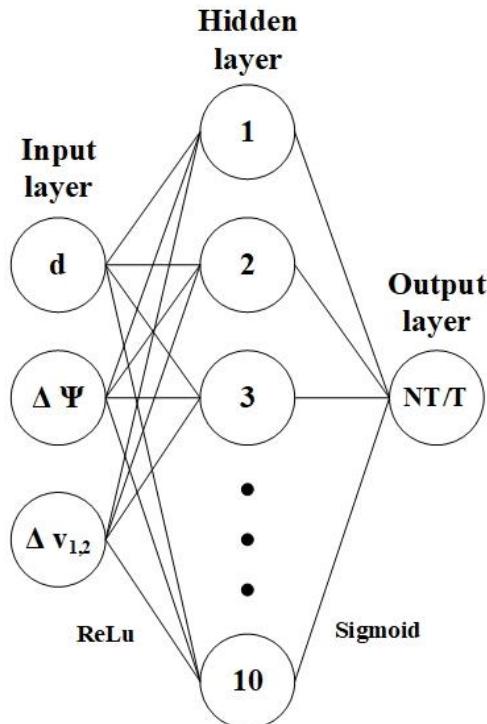
Berdasarkan Tabel 4. 41, diketahui bahwa penggunaan nilai *learning rate* 0.005 dan 10 *neurons* pada *hidden layer* menghasilkan rata-rata akurasi terbesar yaitu 0.903 dan nilai standard deviasi yang kecil yaitu 0.112.

4.8.2 Model Arsitektur Jaringan ANN *Decision Transhipment*

Berdasarkan pengimplementasian *k-fold cross validation* yang telah dilakukan, dipilih model arsitektur jaringan ANN *decision transhipment* terbaik dengan menggunakan parameter yang paling optimal berdasarkan model yang menghasilkan rata-rata akurasi paling tinggi dan standard deviasi rendah. Parameter-parameter tersebut adalah:

- Jumlah hidden layers: 1
- Jumlah neurons pada hidden layer: 10
- Fungsi aktivasi: *rectified linear unit* (ReLU) pada *input layer* dan *hidden layer*, *sigmoid* pada *output layer*
- Optimizer: *adaptative moment estimation* (Adam)
- Nilai learning rate: 0.005
- Jumlah epochs: 100

Model arsitektur jaringan ANN *decision transhipment* terbaik dengan menggunakan parameter-parameter di atas ditunjukkan oleh Gambar 4. 29.



Gambar 4. 29 Model arsitektur jaringan ANN *decision transhipment*

4.8.3 Hasil Evaluasi Model Arsitektur Jaringan ANN *Decision Transhipment*

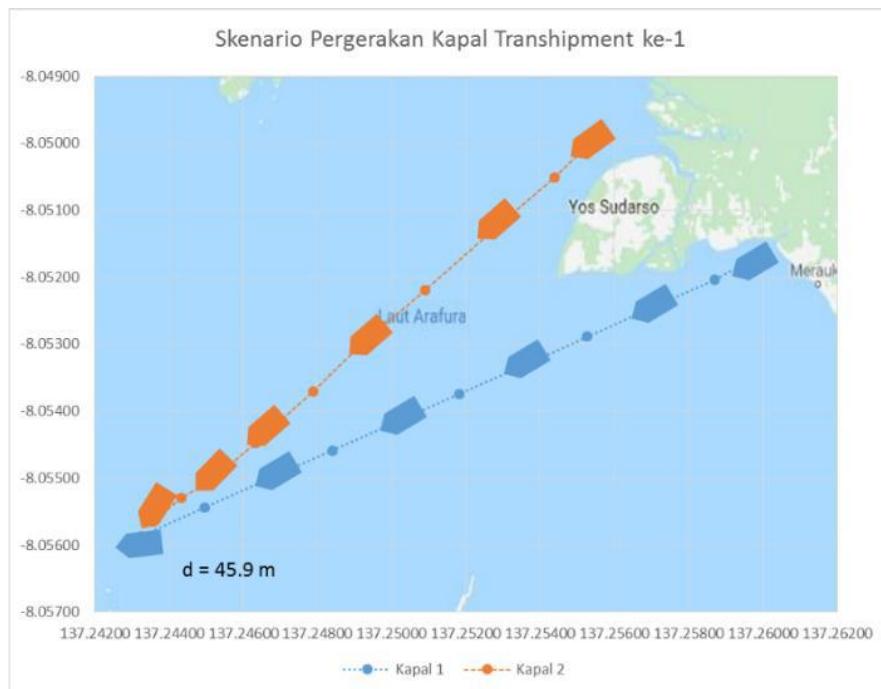
Evaluasi model arsitektur jaringan ANN *decision transhipment* dilakukan dengan membandingkan hasil keluaran identifikasi dari ANN *decision transhipment* terhadap hasil dari keluaran subsistem *decision transhipment* dari rancangan penelitian sebelumnya (Fatmawati, 2018).

Pada penelitian sebelumnya telah dilakukan pengujian rancangan subsistem *decision transhipment* untuk identifikasi pola kapal pelaku *illegal transhipment* dengan menggunakan logika fuzzy. Pengujian dilakukan dengan berbagai variasi gerak kapal yang telah dibangkitkan. Variabel yang divariasikan adalah variabel masukan pada sistem pengambilan keputusan *decision transhipment* untuk identifikasi pola kapal pelaku *illegal transhipment*.

Pembangkitan data posisi dua kapal untuk uji pola pergerakan kapal *illegal transhipment* dilakukan di Laut Arafura dengan tiga variasi pola kapal *illegal transhipment*.

4.8.3.1 Hasil Perbandingan Uji Pola *Transhipment* Ke-1

Pada pengujian pertama ini, variabel yang dibutuhkan adalah jarak kedua kapal, selisih *heading*, dan juga selisih *kecepatan*. Variabel masukan tersebut didapatkan dengan menghitung data yang telah didapatkan dari AIS Kapal dengan persamaan yang ada pada Bab III. Data yang masuk pada subsistem *decision transhipment* merupakan data dari dua kapal dengan waktu kurang lebih 30 menit.



Gambar 4. 30 Pola gerak kapal *illegal transhipment* ke-1

Gambar 4. 30 menunjukkan kapal 2 mendekati kapal 1 dengan kecepatan tertentu, dan kecepatan kapal 1 lebih rendah dibandingkan kapal 2 dengan selisih *heading* menunjukkan *crossing*. Kapal 2 mulai mengurangi kecepatan pada saat mendekati kapal 1 dan kapal 1 juga mengurangi kecepatan. Kapal 1 dan kapal 2 diduga benar-benar melakukan *illegal transhipment* dengan jarak kedua kapal 45 Meter dan selisih kecepatan 0.2 knot. Hasil perhitungan selisih *heading*, selisih jarak kedua kapal, dan selisih kecepatan kedua kapal sebagai variabel masukan *decision transhipment*. Pada Tabel 4. 42 merupakan masukan dari subsistem *decision transhipment*.

Tabel 4. 42 Data Masukan *Decision Pola Transhipment* ke-1

No	Data Masukan <i>Decision Transhipment</i>	Keterangan
1	Jarak Kedua Kapal (meter)	12 <i>Near</i>
2	Selisih Sudut <i>Heading</i> (<i>degree</i>)	33 <i>Crossing</i>
3	Selisih Kecepatan Kedua Kapal (<i>knot</i>)	0.2 <i>Small</i>

Jarak antara kedua kapal, selisih sudut *heading*, dan selisih kecepatan kedua kapal pada Tabel 4. 42 dimasukkan ke subsistem fuzzy *decision transhipment* pada penelitian sebelumnya dan ke subsistem ANN *decision transhipment* pada penelitian ini. Keluaran dari subsistem fuzzy *decision transhipment* pada penelitian sebelumnya dan keluaran subsistem ANN *decision transhipment* pada penelitian ini untuk pola *transhipment* ke-1 ditunjukkan oleh Tabel 4. 43.

Tabel 4. 43 Hasil Perbandingan Keluaran Subsistem *Decision Transhipment* Pola Kapal *Transhipment* ke-1

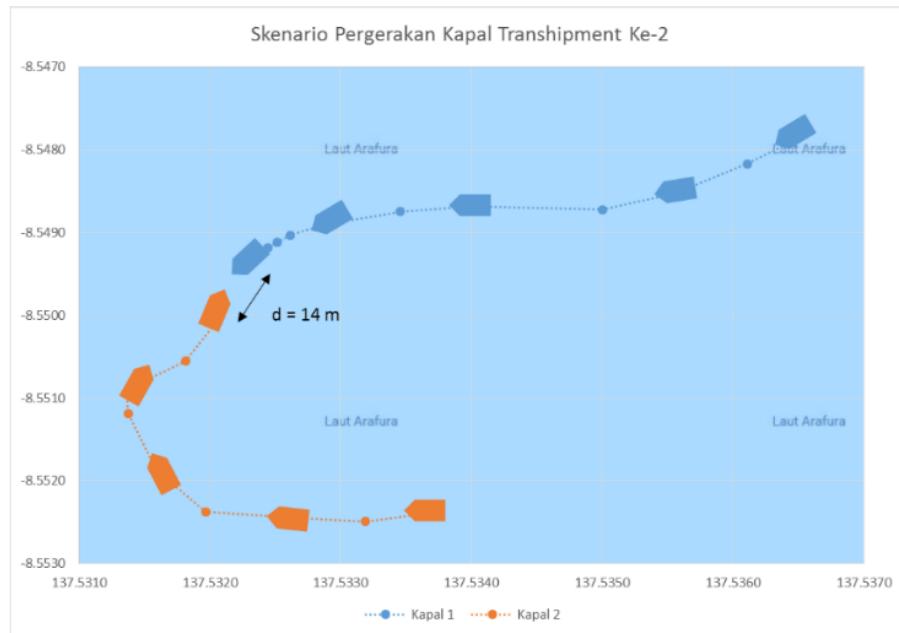
Hasil Keluaran Fuzzy <i>Decision</i> (Fatmawati, 2018)	Hasil Keluaran ANN <i>Decision</i>
83.67%	99.52%

Bisa dilihat pada Tabel 4. 43, keluaran dari subsistem ANN *decision transhipment* pada pola *transhipment* yang pertama ini sebesar 99.52%, sedangkan pada keluaran fuzzy *decision transhipment* sebesar 83.67%. Nilai keluaran *decision transhipment* pada kedua subsistem tersebut menunjukkan besar presentase dua kapal diduga melakukan praktik illegal *transhipment*. Nilai keluaran menunjukkan lebih dari 50%. Tetapi hasil keluaran yang didapat oleh ANN *decision transhipment* lebih tinggi dibandingkan hasil keluaran pada fuzzy *decision transhipment*. Ini menunjukkan bahwa subsistem ANN *decision transhipment* memberikan hasil yang lebih tegas dibandingkan fuzzy *decision transhipment*.

4.8.3.2 Hasil Perbandingan Uji Pola *Transhipment* Ke-2

Pada pengujian kedua ini, variabel yang dibutuhkan adalah jarak kedua kapal, selisih *heading*, dan juga selisih *kecepatan*. Variabel masukan tersebut

didapatkan dengan menghitung data yang telah didapatkan dari AIS Kapal dengan persamaan yang ada pada Bab III. Data yang masuk pada subsistem *decision transhipment* merupakan data dari dua kapal dengan waktu kurang lebih 30 menit.



Gambar 4. 31 Pola gerak kapal *illegal transhipment* ke-2

Gambar 4. 31 menunjukkan kedua kapal saling berdekatan *head to head* atau *head on*, dengan kecepatan kapal 1 adalah 4.1 knot lebih tinggi dibandingkan kapal 2 hanya 2.3 knot. Kedua kapal saat berdekatan saling mengurangi kecepatan hingga hanya berselisih 0.09 knot yang artinya hampir tidak ada gerakan selama 10 menit. Kapal 1 dan kapal 2 diduga benar-benar melakukan *illegal transhipment* dengan jarak 2 kapal 14 Meter dan selisih kecepatan 0.09 knot. Hasil perhitungan selisih *heading*, selisih jarak kedua kapal, dan selisih kecepatan kedua kapal sebagai variabel masukan *decision transhipment*. Pada Tabel 4. 44 merupakan masukan dari subsistem *decision transhipment*.

Tabel 4. 44 Data Masukan *Decision Transhipment* ke-2

No	Data Masukan <i>Decision Transhipment</i>	Keterangan	
1	Jarak Kedua Kapal (meter)	14.8	<i>Near</i>
2	Selisih Sudut <i>Heading</i> (<i>degree</i>)	183.6	<i>Head On</i>
3	Selisih Kecepatan Kedua Kapal (<i>knot</i>)	0.09	<i>Small</i>

Jarak antara kedua kapal, selisih sudut *heading*, dan selisih kecepatan kedua kapal pada Tabel 4. 44 dimasukkan ke subsistem fuzzy *decision transhipment* pada penelitian sebelumnya dan ke subsistem ANN *decision transhipment* pada penelitian ini. Keluaran dari subsistem fuzzy *decision transhipment* pada penelitian sebelumnya dan keluaran subsistem ANN *decision transhipment* pada penelitian ini untuk pola *transhipment* ke-2 ditunjukkan oleh Tabel 4. 45.

Tabel 4. 45 Hasil Perbandingan Keluaran Subsistem *Decision Transhipment* Pola Kapal *Transhipment* ke-2

Hasil Keluaran Fuzzy <i>Decision</i> (Fatmawati, 2018)	Hasil Keluaran ANN <i>Decision</i>
83.67%	99.45%

Bisa dilihat pada Tabel 4. 45, keluaran dari subsistem ANN *decision transhipment* pada pola *transhipment* yang kedua ini sebesar 99.52%, sedangkan pada keluaran fuzzy *decision transhipment* sebesar 83.67%. Nilai keluaran *decision transhipment* pada kedua subsistem tersebut menunjukkan besar presentase dua kapal diduga melakukan praktik illegal *transhipment*. Nilai keluaran menunjukkan lebih dari 50%. Tetapi hasil keluaran yang didapat oleh ANN *decision transhipment* lebih tinggi dibandingkan hasil keluaran pada fuzzy *decision transhipment*. Ini menunjukkan bahwan subsistem ANN *decision transhipment* memberikan hasil yang lebih tegas dibandingkan fuzzy *decision transhipment*.

4.8.3.3 Hasil Perbandingan Uji Pola *Transhipment* Ke-3

Pada pengujian ketiga ini, variabel yang dibutuhkan adalah jarak kedua kapal, selisih *heading*, dan juga selisih *kecepatan*. Variabel masukan tersebut didapatkan dengan menghitung data yang telah didapatkan dari AIS Kapal dengan persamaan yang ada pada Bab III. Data yang masuk pada subsistem *decision transhipment* merupakan data dari dua kapal dengan waktu kurang lebih 30 menit.



Gambar 4. 32 Pola gerak kapal *illegal transhipment* ke-3

Gambar 4. 32 menunjukkan kedua kapal saling berdekatan dengan selisih *heading* -2° termasuk kategori *overtake*. Kapal 1 dengan kecepatan 4.1 knot yaitu lebih rendah dari kapal 2 dengan kecepatan 8.1 knot. Kapal 2 terlihat seolah mendekati kapal 1 dan mengurangi kecepatannya, saat kapal 1 dengan kecepatan rendah kapal 2 juga memiliki kecepatan yang sama rendahnya yaitu 0.01 knot dan pada posisi akhir kedua kapal sejajar. Hasil perhitungan selisih *heading*, selisih jarak kedua kapal, dan selisih kecepatan kedua kapal sebagai variabel masukan *decision transhipment*. Pada Tabel 4. 46 merupakan masukan dari subsistem *decision transhipment*.

Tabel 4. 46 Data Masukan *Decision Transhipment* ke-3

No	Data Masukan <i>Decision Transhipment</i>	Keterangan
1	Jarak Kedua Kapal (meter)	18
2	Selisih Sudut <i>Heading</i> ($degree$)	-2
3	Selisih Kecepatan Kedua Kapal (<i>knot</i>)	0.01

Jarak antara kedua kapal, selisih sudut *heading*, dan selisih kecepatan kedua kapal pada Tabel 4. 46 dimasukkan ke subsistem fuzzy *decision transhipment* pada penelitian sebelumnya dan ke subsistem ANN *decision transhipment* pada penelitian ini. Keluaran dari subsistem fuzzy *decision transhipment* pada penelitian

sebelumnya dan keluaran subsistem ANN *decision transhipment* pada penelitian ini untuk pola *transhipment* ke-3 ditunjukkan oleh Tabel 4. 47.

Tabel 4. 47 Hasil Perbandingan Keluaran Subsistem *Decision Transhipment* Pola Kapal *Transhipment* ke-3

Hasil Keluaran Fuzzy <i>Decision</i> (Fatmawati, 2018)	Hasil Keluaran ANN <i>Decision</i>
80.50%	99.26%

Bisa dilihat pada Tabel 4. 47, keluaran dari subsistem ANN *decision transhipment* pada pola *transhipment* yang ketiga ini sebesar 99.26%, sedangkan pada keluaran fuzzy *decision transhipment* sebesar 80.50%. Nilai keluaran *decision transhipment* pada kedua subsistem tersebut menunjukkan besar presentase dua kapal diduga melakukan praktik illegal *transhipment*. Nilai keluaran menunjukkan lebih dari 50%. Tetapi hasil keluaran yang didapat oleh ANN *decision transhipment* lebih tinggi dibandingkan hasil keluaran pada fuzzy *decision transhipment*. Ini menunjukkan bahwa subsistem ANN *decision transhipment* memberikan hasil yang lebih tegas dibandingkan fuzzy *decision transhipment*.

4.9 Hasil Perancangan Subsistem ANN *Decision Fishing*

Pada perancangan subsistem ANN *decision fishing* dilakukan observasi terhadap kombinasi dari model arsitektur jaringan dan parameter untuk mendapatkan kombinasi model arsitektur jaringan terbaik dan parameter paling optimal yang meliputi jumlah *unit neuron* pada *hidden layers* dan nilai *learning rate*. Berikut adalah variasi nilai parameter yang diuji.

- Jumlah *unit neuron* pada *hidden layers* : 5, 10, 15, 20, 25
- Nilai *learning rate* : 0.001, 0.005, 0.01, 0.05, 0.1

Untuk masing-masing parameter yang dikombinasikan dilakukan dengan pengimplementasian k-fold cross validation dengan k=5.

4.9.1 Hasil Pengimplementasian K-Fold Cross Validation pada Perancangan Subsistem ANN Decision Fishing

Pada pengimplementasian *k-fold cross-validation* untuk perancangan ANN *decision fishing* ini digunakan sebanyak 4745 pengamatan yang terkandung dalam dataset, yang dibagi menjadi lima set.

Dalam pendekatan ini, empat set (80% pengamatan atau sebanyak 3796 pengamatan) digunakan untuk melatih *neural network*, dan set yang tersisa (20% dari pengamatan atau sebanyak 949 pengamatan) disimpan untuk menguji kinerja model. Proses ini dilakukan lima kali karena lima kombinasi yang berbeda digunakan untuk membagi lima set menjadi empat set untuk mengembangkan model dan set lainnya untuk melakukan tes yang sesuai.

Dari pengimplementasian proses ini dihasilkan 25 model *neural networks*, sebagai hasil dari kombinasi lima variasi *neurons* pada *hidden layer* untuk lima nilai *learning rate*. Hasil dari pengimplementasian *k-fold cross validation* pada perancangan ANN *decision fishing* ditunjukkan oleh Tabel 4. 48.

Tabel 4. 48 Hasil Pengimplementasian K-Fold Cross Validation pada Perancangan ANN Decision Fishing

<i>Learning Rate</i>	<i>Neurons</i> pada <i>Hiddden Layer</i>	Akurasi (Rata-rata)	Standard Deviasi (Rata-rata)
0.0001	5	0.877	0.166
0.0005	5	0.879	0.177
0.001	5	0.899	0.166
0.005	5	0.878	0.173
0.01	5	0.880	0.167
0.0001	10	0.894	0.177
0.0005	10	0.879	0.177
0.001	10	0.884	0.166
0.005	10	0.881	0.167
0.01	10	0.880	0.167
0.0001	15	0.890	0.177
0.0005	15	0.884	0.166
0.001	15	0.884	0.166

Tabel 4. 48 (Lanjutan)

<i>Learning Rate</i>	<i>Neurons</i> pada <i>Hidden Layer</i>	Akurasi (Rata-rata)	Standard Deviasi (Rata-rata)
0.005	15	0.882	0.165
0.01	15	0.882	0.164
0.0001	20	0.895	0.177
0.0005	20	0.883	0.168
0.001	20	0.885	0.165
0.005	20	0.885	0.163
0.01	20	0.880	0.166
0.0001	25	0.891	0.177
0.0005	25	0.883	0.168
0.001	25	0.889	0.157
0.005	25	0.887	0.157
0.01	25	0.885	0.160

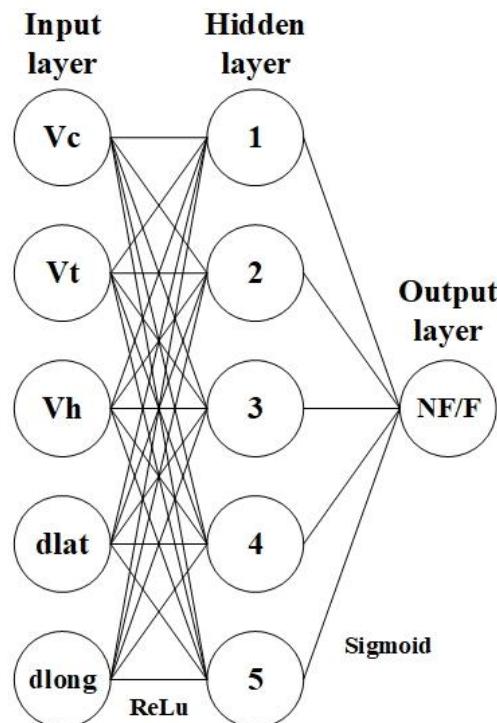
Berdasarkan Tabel 4. 48 diketahui bahwa penggunaan nilai *learning rate* 0.001 dan 5 *neurons* pada *hidden layer* menghasilkan rata-rata akurasi terbesar yaitu 0.899 dan nilai standard deviasi yang kecil yaitu 0.166.

4.9.2 Model Arsitektur Jaringan ANN *Decision Fishing*

Berdasarkan pengimplementasian *k-fold cross validation* yang telah dilakukan, dipilih model arsitektur jaringan ANN *decision fishing* terbaik dengan menggunakan parameter yang paling optimal berdasarkan model yang menghasilkan rata-rata akurasi paling tinggi dan standard deviasi rendah. Parameter-parameter tersebut adalah:

- Jumlah hidden layers: 1
- Jumlah neurons pada hidden layer: 5
- Fungsi aktivasi: *rectified linear unit* (ReLU) pada *input layer* dan *hidden layer*, sigmoid pada *output layer*
- Optimizer: *adaptative moment estimation* (Adam)
- Nilai learning rate: 0.001
- Jumlah epochs: 100

Model arsitektur jaringan ANN *decision fishing* terbaik dengan menggunakan parameter-parameter di atas ditunjukkan oleh Gambar 4. 33.



Gambar 4. 33 Model arsitektur jaringan ANN *decision fishing*

4.9.3 Hasil Evaluasi Model Arsitektur Jaringan ANN *Decision Fishing*

Evaluasi model arsitektur jaringan ANN *decision fishing* dilakukan dengan membandingkan hasil keluaran identifikasi dari ANN *decision fishing* terhadap hasil dari keluaran subsistem *decision fishing* dari rancangan penelitian sebelumnya (Fatmawati, 2018).

Pada penelitian sebelumnya telah dilakukan pengujian rancangan subsistem *decision fishing* untuk identifikasi pola kapal pelaku *illegal fishing* dengan menggunakan logika fuzzy. Pengujian dilakukan dengan berbagai variasi gerak kapal yang telah dibangkitkan. Variabel yang divariasikan adalah variabel masukan pada sistem pengambilan keputusan *decision fishing* untuk identifikasi pola kapal pelaku *illegal fishing*.

Pembangkitan data posisi kapal untuk uji pola pergerakan kapal *illegal fishing* dilakukan di perairan Natuna dan perairan Brondong dengan dua variasi pola kapal *illegal fishing*.

4.9.3.1 Hasil Perbandingan Uji Pola *Illegal Fishing* Ke-1

Pada pengujian pertama ini, variabel yang dibutuhkan adalah kecepatan kapal saat melakukan *casting*, *towing*, *hauling*, laju perubahan posisi *latitude* dan

longitude. Data yang masuk pada subsistem *decision fishing* merupakan data dari dua kapal dengan waktu kurang lebih 30 menit.



Gambar 4. 34 Pola gerak kapal 1 *illegal fishing* ke-1

Gambar 4. 34 merupakan pergerakan kapal 1 yang melakukan *casting* dengan kecepatan 0.7 knot, karena kapal cantrang biasanya untuk menebar jaring dengan kecepatan dibawah 1 knot dengan pola *zig-zag* dan melingkar. Kapal 1 selanjutnya melakukan *towing* dengan rata-rata kecepatan 1.3 knot, dan melakukan *hauling* dengan kecepatan 0.1 knot. Laju perubahan posisi dari kapal 1 juga menunjukkan indikasi kapal cantrang, karena rata-rata pergerakan kapal cantrang ± 0.025 nautical mile atau setara dengan ± 45 meter. Jaring selambar yang ditebarkan ± 1000 meter, dengan kecepatan rata-rata seperti demikian maka proses *casting* 20 s.d 25 menit. Pada Tabel 4. 49 merupakan masukan dari subsistem *decision fishing* kapal 1.

Tabel 4. 49 Data Masukan *Decision Fishing* Kapal 1 Pola ke-1

No	Data Masukan <i>Decision Fishing</i>	Keterangan Fuzzy <i>Decision</i>	Keterangan ANN <i>Decision</i>
1	Kecepatan <i>Casting</i> (knot)	0.7	<i>Medium</i>
2	Kecepatan <i>Towing</i> (knot)	1.3	<i>Medium</i>
3	Kecepatan <i>hauling</i> (knot)	0.1	<i>Low</i>
4	Laju Perubahan Posisi <i>Latitude</i> (<i>nautical mile</i>)	0.001	<i>Low</i>
5	Laju Perubahan Posisi <i>Longitude</i> (<i>nautical mile</i>)	0.005	<i>Medium</i>

Kecepatan kapal 1 saat melakukan *casting*, *towing*, *hauling*, laju perubahan posisi *latitude* dan *longitude* pada Tabel 4. 49 dimasukkan ke subsistem fuzzy *decision fishing* pada penelitian sebelumnya dan ke subsistem ANN *decision fishing* pada penelitian ini. Keluaran dari subsistem fuzzy *decision fishing* pada penelitian sebelumnya dan keluaran subsistem ANN *decision fishing* pada penelitian ini untuk kapal 1 pola *fishing* ke-1 ditunjukkan oleh Tabel 4. 50.

Tabel 4. 50 Hasil Perbandingan Keluaran Subsistem *Decision Fishing* Kapal 1 Pola *Fishing* ke-1

Hasil Keluaran Fuzzy <i>Decision</i> (Fatmawati, 2018)	Hasil Keluaran ANN <i>Decision</i>
76.55%	100%

Bisa dilihat pada Tabel 4. 50, keluaran dari subsistem ANN *decision fishing* pada kapal 1 pola *fishing* yang pertama ini sebesar 100%, sedangkan pada keluaran fuzzy *decision fishing* sebesar 76.55%. Nilai keluaran *decision fishing* pada kedua subsistem tersebut menunjukkan besar presentase kapal 1 diduga melakukan praktik *illegal fishing*. Nilai keluaran menunjukkan lebih dari 50%. Tetapi hasil keluaran yang didapat oleh ANN *decision fishing* lebih tinggi dibandingkan hasil

keluaran pada fuzzy *decision fishing*. Ini menunjukkan bahwa subsistem ANN *decision fishing* memberikan hasil yang lebih tegas dibandingkan fuzzy *decision fishing*.



Gambar 4. 35 Pola gerak kapal 2 *illegal fishing* ke-1

Gambar 4. 35 merupakan pergerakan kapal 2. Laju perubahan posisi *latitude* yang dibuat oleh kapal 2 adalah 0.02 *nautical mile* dan *longitude* 0.025 *nautical mile*. Laju perubahan posisi dari kapal 2 memang sama dengan kapal cantrang, namun kapal 2 tidak melakukan proses *casting*, *towing*, dan juga *hauling*, karena kecepatan rata-rata kapal adalah 8 knot. Pada Tabel 4. 51 merupakan masukan dari subsistem *decision fishing* kapal 2.

Kecepatan kapal 2 dan laju perubahan posisi *latitude* dan *longitude* pada Tabel 4. 51 dimasukkan ke subsistem fuzzy *decision fishing* pada penelitian sebelumnya dan ke subsistem ANN *decision fishing* pada penelitian ini. Keluaran dari subsistem fuzzy *decision fishing* pada penelitian sebelumnya dan keluaran

subsistem ANN *decision fishing* pada penelitian ini untuk kapal 2 pola *fishing* ke-1 ditunjukkan oleh Tabel 4. 52.

Tabel 4. 51 Data Masukan *Decision Fishing* Kapal 2 Pola ke-1

No	Data Masukan <i>Decision Fishing</i>		Keterangan Fuzzy <i>Decision</i>	Keterangan ANN <i>Decision</i>
1	Kecepatan <i>Casting</i> (knot)	7.28	<i>High</i>	<i>High</i>
2	Kecepatan <i>Towing</i> (knot)	9.02	<i>High</i>	<i>High</i>
3	Kecepatan <i>hauling</i> (knot)	8.43	<i>High</i>	<i>High</i>
4	Laju Perubahan Posisi <i>Latitude (nautical mile)</i>	0.02	<i>Medium</i>	<i>Medium</i>
5	Laju Perubahan Posisi <i>Longitude (nautical mile)</i>	0.02	<i>Medium</i>	<i>Medium</i>

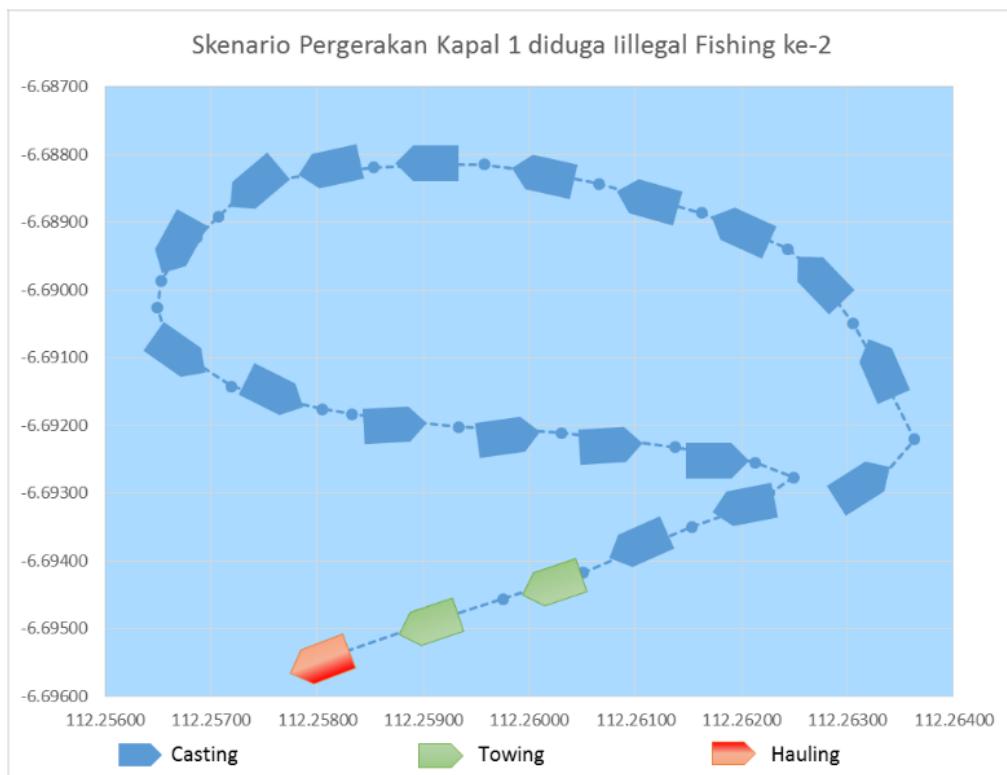
Bisa dilihat pada Tabel 4. 52, keluaran dari subsistem ANN *decision fishing* pada kapal 2 pola *fishing* yang pertama ini sebesar 0%, sedangkan pada keluaran fuzzy *decision fishing* sebesar 20%. Nilai keluaran *decision fishing* pada kedua subsistem tersebut menunjukkan besar presentase kapal 2 tidak diduga melakukan praktik *illegal fishing*. Nilai keluaran menunjukkan kurang dari 50%. Tetapi hasil keluaran yang didapat oleh ANN *decision fishing* lebih kecil dibandingkan hasil keluaran pada fuzzy *decision fishing*. Ini menunjukkan bahwa subsistem ANN *decision fishing* memberikan hasil yang lebih tegas dibandingkan fuzzy *decision fishing*.

Tabel 4. 52 Hasil Perbandingan Keluaran Subsistem *Decision Fishing* Kapal 2 Pola *Fishing* ke-1

Hasil Keluaran Fuzzy <i>Decision</i> (Fatmawati, 2018)	Hasil Keluaran ANN <i>Decision</i>
20%	0%

4.9.3.2 Hasil Perbandingan Uji Pola *Illegal Fishing* Ke-2

Pada pengujian kedua ini, variabel yang dibutuhkan adalah kecepatan kapal saat melakukan *casting*, *towing*, *hauling*, laju perubahan posisi *latitude* dan *longitude*. Data yang masuk pada subsistem *decision fishing* merupakan data dari dua kapal dengan waktu kurang lebih 30 menit.



Gambar 4. 36 Pola gerak kapal 1 *illegal fishing* ke-2

Gambar 4. 36 merupakan pergerakan kapal 1 yang melakukan *casting* dengan kecepatan rata-rata 0.5 knot, karena kapal cantrang biasanya untuk menebar jaring dengan kecepatan dibawah 1 knot. Kapal 1 selanjutnya melakukan *towing* dengan rata-rata kecepatan 1.3 knot, dan melakukan *hauling* dengan kecepatan 0.08 knot. Laju perubahan posisi dari kapal secara *latitude* 0.05 nautical mile dan *longitude* 0.02 nautical mile. Jaring selambar yang ditebarkan \pm 1000 meter, dengan kecepatan rata-rata seperti demikian maka proses *casting* pada kapal 1 pola ke-2 lebih cepat dibandingkan pola ke-1. Pada Tabel 4. 53 merupakan masukan dari subsistem *decision fishing* kapal 1 pola ke-2.

Tabel 4. 53 Data Masukan *Decision Fishing* Kapal 1 Pola ke-2

No	Data Masukan <i>Decision Fishing</i>	Keterangan Fuzzy Decision	Keterangan ANN Decision
1	Kecepatan <i>Casting</i> (knot)	0.5	<i>Medium</i>
2	Kecepatan <i>Towing</i> (knot)	1.3	<i>Medium</i>
3	Kecepatan <i>hauling</i> (knot)	0.08	<i>Low</i>
4	Laju Perubahan Posisi <i>Latitude</i> (<i>nautical mile</i>)	0.05	<i>High</i>
5	Laju Perubahan Posisi <i>Longitude</i> (<i>nautical mile</i>)	0.029	<i>Medium</i>

Kecepatan kapal 1 saat melakukan *casting*, *towing*, *hauling*, laju perubahan posisi *latitude* dan *longitude* pada Tabel 4. 53 dimasukkan ke subsistem fuzzy *decision fishing* pada penelitian sebelumnya dan ke subsistem ANN *decision fishing* pada penelitian ini. Keluaran dari subsistem fuzzy *decision fishing* pada penelitian sebelumnya dan keluaran subsistem ANN *decision fishing* pada penelitian ini untuk kapal 1 pola *fishing* ke-2 ditunjukkan oleh Tabel 4. 54.

Tabel 4. 54 Hasil Perbandingan Keluaran Subsistem *Decision Fishing* Kapal 1 Pola *Fishing* ke-2

Hasil Keluaran Fuzzy Decision (Fatmawati, 2018)	Hasil Keluaran ANN Decision
79.62%	100%

Bisa dilihat pada Tabel 4. 54, keluaran dari subsistem ANN *decision fishing* pada kapal 1 pola *fishing* yang kedua ini sebesar 100%, sedangkan pada keluaran fuzzy *decision fishing* sebesar 79.62%. Nilai keluaran *decision fishing* pada kedua subsistem tersebut menunjukkan besar presentase kapal 1 diduga melakukan praktik *illegal fishing*. Nilai keluaran menunjukkan lebih dari 50%. Tetapi hasil keluaran yang didapat oleh ANN *decision fishing* lebih tinggi dibandingkan hasil keluaran pada fuzzy *decision fishing*. Ini menunjukkan bahwa subsistem ANN

decision fishing memberikan hasil yang lebih tegas dibandingkan fuzzy *decision fishing*.



Gambar 4. 37 Pola gerak kapal 2 *illegal fishing* ke-2

Gambar 4. 37 merupakan pergerakan kapal 2. Laju perubahan posisi yang dibuat oleh kapal 2 adalah 0 *nautical mile* dan kecepatan rata-rata kapal adalah 0 knot, artinya bahwa kapal 2 dalam posisi sandar. Kapal 2 pada pola pergerakan ke-2 benar-benar dinyatakan tidak melakukan praktik *illegal fishing*. Pada Tabel 4. 55 merupakan masukan dari subsistem *decision fishing* kapal 2.

Tabel 4. 55 Data Masukan *Decision Fishing* Kapal 2 Pola ke-2

No	Data Masukan <i>Decision Fishing</i>		Keterangan Fuzzy <i>Decision</i>	Keterangan ANN <i>Decision</i>
1	Kecepatan <i>Casting</i> (knot)	0	<i>Low</i>	<i>Low</i>
2	Kecepatan <i>Towing</i> (knot)	0	<i>Low</i>	<i>Low</i>
3	Kecepatan <i>hauling</i> (knot)	0	<i>Low</i>	<i>Low</i>
4	Laju Perubahan Posisi <i>Latitude</i> (<i>nautical mile</i>)	0	<i>Low</i>	<i>Low</i>
5	Laju Perubahan Posisi <i>Longitude</i> (<i>nautical mile</i>)	0	<i>Low</i>	<i>Low</i>

Kecepatan kapal 2 dan laju perubahan posisi *latitude* dan *longitude* pada Tabel 4. 55 dimasukkan ke subsistem fuzzy *decision fishing* pada penelitian sebelumnya dan ke subsistem ANN *decision fishing* pada penelitian ini. Keluaran dari subsistem fuzzy *decision fishing* pada penelitian sebelumnya dan keluaran subsistem ANN *decision fishing* pada penelitian ini untuk kapal 2 pola *fishing* ke-2 ditunjukkan oleh Tabel 4. 56.

Tabel 4. 56 Hasil Perbandingan Keluaran Subsistem *Decision Fishing* Kapal 2 Pola *Fishing* ke-2

Hasil Keluaran Fuzzy <i>Decision</i> (Fatmawati, 2018)	Hasil Keluaran ANN <i>Decision</i>
49%	0%

Bisa dilihat pada Tabel 4. 56, keluaran dari subsistem ANN *decision fishing* pada kapal 2 pola *fishing* yang kedua ini sebesar 0%, sedangkan pada keluaran fuzzy *decision fishing* sebesar 49%. Nilai keluaran *decision fishing* pada kedua subsistem tersebut menunjukkan besar presentase kapal 2 tidak diduga melakukan praktik *illegal fishing*. Nilai keluaran menunjukkan kurang dari 50%. Tetapi hasil keluaran yang didapat oleh ANN *decision fishing* lebih kecil dibandingkan hasil keluaran pada fuzzy *decision fishing*. Ini menunjukkan bahwa subsistem ANN *decision fishing* memberikan hasil yang lebih tegas dibandingkan fuzzy *decision fishing*.

4.10 Analisis Akurasi Integrasi Sistem untuk Identifikasi

Perancangan integrasi sistem untuk identifikasi IUU *Transhipment* dan *Fishing* telah dilakukan. Pada keluaran identifikasi final (ANN *decision*) rentang nilai untuk identifikasi tidak terjadi IUU *Fishing* dan *Transhipment* adalah 0% - 50%, sedangkan untuk identifikasi terjadinya IUU *Transhipment* dan *Fishing* adalah 51% - 100%. Hasil evaluasi dengan pengujian menunjukkan nilai identifikasi IUU *Transhipment* adalah 99.52%, 99.45%, dan 99.26%. Hasil pengujian untuk menunjukkan nilai identifikasi IUU *Fishing* adalah 100% dan

100%. Hasil tersebut menunjukkan sistem berhasil mengidentifikasi pola gerak kapal uji yang tidak melakukan dan melakukan praktik IUU *Transhipment* dan *Fishing*.

Akurasi ditentukan dengan membagi jumlah konversi hasil uji evaluasi dengan banyaknya uji evaluasi yang telah dilakukan pada sistem. Total uji yang dilakukan pada integrasi sistem untuk identifikasi ini adalah 5 kali pengujian pola pergerakan kapal, dapat dilihat perhitungannya sebagai berikut.

$$\text{Akurasi} = \frac{99.52\% + 99.45\% + 99.26\% + 100\% + 100\%}{5} = 99.64\%$$

Pada Tabel 4.57 merupakan perbandingan hasil akurasi yang didapat pada perancangan integrasi sistem dengan ANN pada penelitian ini dan perancangan integrasi sistem dengan *Fuzzy Logic* pada penelitian sebelumnya.

Tabel 4.57 Perbandingan Hasil Akurasi yang Didapat dengan *Fuzzy Logic* dan ANN

Hasil Akurasi <i>Fuzzy Logic</i> (Fatmawati, 2018)	Hasil Akurasi ANN
97.70%	99.64%

4.11 Hasil Validasi Integrasi Sistem untuk Identifikasi

Validasi sistem dilakukan untuk mengetahui integrasi sistem untuk identifikasi yang telah dirancang berhasil mengidentifikasi adanya praktik *illegal*. Validasi dilakukan menggunakan data *real* kapal yang diduga melakukan praktik *illegal transhipment* maupun *illegal fishing*. Data *real* kapal tersebut didapatkan dari website marinetraffic.com dan NASDEC ITS.

4.11.1 Hasil Validasi Integrasi Sistem untuk Identifikasi Menggunakan Data *Real Kapal Illegal Transhipment* (Nordic Bahari) di Pelabuhan Sorong Papua

Validasi integrasi sistem dilakukan dengan menggunakan variabel masukan sistem berupa data kecepatan kapal dan *heading* selama operasi kapal *transhipment*.

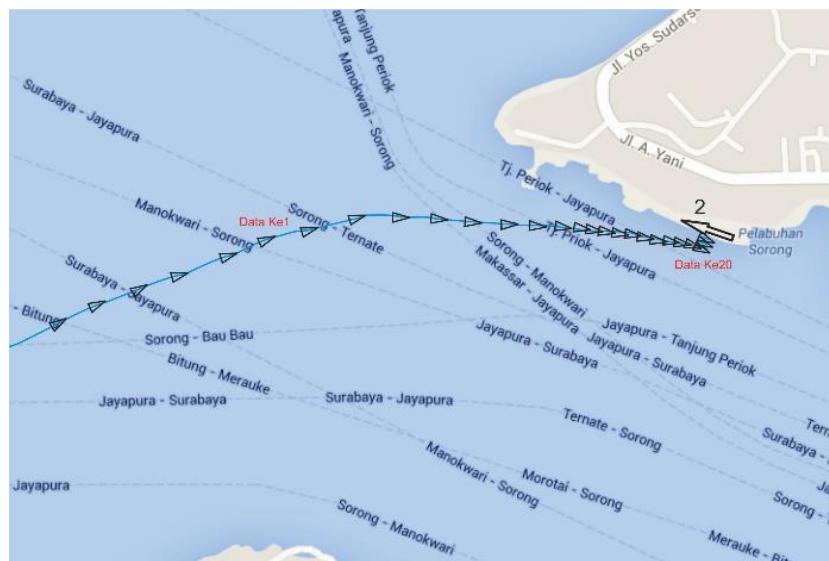
Pada pelabuhan dan perubahan posisi kapal tersebut per satuan waktu yang diperoleh dari data *real* Kapal “Nordic Bahari” yang dikirimkan oleh AIS (<http://marinetrack.com>). Pendekatan ini dilakukan dengan asumsi bahwa pelabuhan adalah sebuah kapal diam di tengah laut yang sedang menunggu kapal lain untuk melakukan *transhipment*. Data validasi tersebut merupakan kapal yang sedang bersandar di Pelabuhan Sorong, Papua pada tanggal 16 April 2016 pukul 11.00 WIB sampai tanggal 16 April 2016 pukul 11.15 WIB. Data *real* AIS kapal *transhipment* pada Pelabuhan Sorong, Papua ditunjukkan oleh Tabel 4. 58.

Tabel 4. 58 Data *Real* AIS Kapal *Transhipment* pada Pelabuhan Sorong, Papua

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (Knot)
1	131.2399	-0.8781	91	4.5
2	131.2404	-0.8781	91	4.4
3	131.2409	-0.8781	91	4.4
4	131.2414	-0.8781	91	4.3
5	131.2419	-0.8781	92	4.3
6	131.2423	-0.8781	92	4.2
7	131.2427	-0.8781	92	4.2
8	131.2431	-0.8781	93	4.1
9	131.2434	-0.8781	93	4
10	131.2436	-0.8781	93	3.9
11	131.2438	-0.8781	93	3.5
12	131.244	-0.8781	94	3
13	131.2443	-0.8782	96	2.5
14	131.2445	-0.8782	96	2
15	131.2447	-0.8782	96	1.2
16	131.2449	-0.8783	100	0.5
17	131.2451	-0.8783	101	0.2
18	131.2453	-0.8783	101	0.2
19	131.2454	-0.8783	101	0.2
20	131.2455	-0.8783	107	0.2

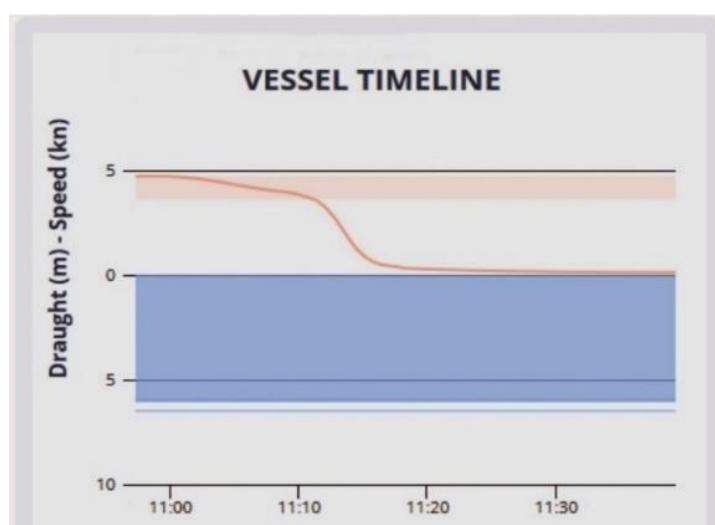
Gambar 4. 38 posisi kapal pada nomor 2 adalah posisi kapal akhir yang mana tidak mengalami banyak perubahan selisih *heading* lagi dengan Pelabuhan Sorong yang dianggap seolah-olah kapal diam yang sedang menunggu untuk *transhipment*. Selisih *heading* pada posisi ini adalah head on, di mana selisih *heading* sebelumnya

adalah *crossing*. Kapal yang akan melakukan *transhipment*, maka pada jarak tertentu memiliki selisih *heading head on* atau *overtake* (Masroeri, 2018).



Gambar 4. 38 Pergerakan kapal Nordic Bahari dan pelabuhan Sorong Papua
(<https://marinetrack.com>)

Gambar 4. 39 menunjukkan grafik kecepatan Kapal Nordic Bahari di Pelabuhan Sorong. Grafik menunjukkan bahwa terjadi penurunan kecepatan pada Kapal Nordic Bahari, hal tersebut merupakan salah satu indikasi kapal diduga akan melakukan *transhipment*. Tahapan pertama memasukan variabel masukan pada subsistem ANN *selection* untuk mensortir awal kapal. Variabel masukan yang digunakan adalah jarak antara kedua kapal dan selisih heading kedua kapal.



Gambar 4. 39 Grafik kecepatan kapal Nordic Bahari (<https://marinetrack.com>)

Tabel 4. 59 Data Masukan Subsistem ANN Selection pada Validasi 1

No	Data Masukan ANN Selection	Keterangan
1	Selisih Sudut <i>Heading (degree)</i>	19 <i>Crossing</i>
2	Jarak (meter)	634.63 <i>Near</i>

Subsistem ANN *selection* yang telah dirancang memiliki aturan jika keluaran sistem memiliki presentase nilai diatas 50%, maka terindikasi diduga akan melakukan *illegal transhipment* begitu juga sebaliknya. Hasil penelitian yang telah dirancang sebelumnya dengan logika fuzzy mempunyai nilai keluaran fuzzy *selection* sebesar 84%, sedangkan keluaran subsistem ANN *selection* pada rancangan ini adalah 100%. Berdasarkan keluaran yang dihasilkan pada ANN *selection*, maka perhitungan ini dilanjutkan ke subsistem ANN *decision transhipment*. ANN *decision transhipment* merupakan keputusan terakhir dari integrasi sistem identifikasi yang telah dirancang. Variabel masukan yang diberikan pada subsistem ANN *decision transhipment* adalah selisih jarak kedua kapal, selisih *heading* kedua kapal, dan selisih kecepatan kedua kapal pada posisi terakhir.

Tabel 4. 60 Data Masukan Subsistem ANN Decision Transhipment pada Validasi ke-1

No	Data Masukan ANN Decision Transhipment	Keterangan
1	Jarak Kedua Kapal (meter)	15.74 <i>Near</i>
2	Selisih Sudut <i>Heading (degree)</i>	183 <i>Head On</i>
3	Selisih Kecepatan Kedua Kapal (<i>knot</i>)	0.2 <i>Small</i>

Subsistem ANN *decision transhipment* untuk identifikasi terjadinya praktik *illegal transhipment* mempunyai aturan, jika nilai presentase keluaran menunjukkan lebih dari 50% dapat dipastikan terjadi *illegal transhipment*. Pada subsistem yang telah dirancang sebelumnya, menghasilkan keputusan akhir dengan presentase 83.67%. Pada sistem integrasi identifikasi yang telah dirancangan ini, menghasilkan keputusan akhir dengan presentasi 99.44%, presentase tersebut menunjukkan bahwa praktik *illegal* benar-benar terjadi. Maka dapat disimpulkan

bahwa data validasi ini sesuai dengan desain integrasi sistem identifikasi yang sudah dirancang dan dibahas di metode penelitian.

Hal ini membuktikan bahwa hasil yang diperoleh dari sistem identifikasi yang telah dirancang sudah cukup valid karena sesuai dengan realita dan relevan digunakan sebagai alat bantu dalam pengawasan terhadap kapal-kapal asing yang melakukan *illegal transhipment* di perairan Indonesia.

4.11.2 Hasil Validasi Integrasi Sistem untuk Identifikasi Menggunakan Data Real Kapal *Illegal Transhipment* (Eagle Seville dan Lurongyuanyu 105) di Perairan Batam

Validasi sistem dilakukan dengan menggunakan variabel masukan sistem berupa data kecepatan kapal dan *heading* selama operasi kapal (Eagle Seville & Lurongyuanyu 105). Kedua kapal tersebut sedang transhipment minyak mentah di Perairan Batam. Perubahan posisi kapal per satuan waktu diperoleh dari data *real* masing - masing kapal yang dikirimkan oleh AIS (<http://marinetrack.com>). Data validasi tersebut merupakan kapal yang sedang *transhipment* di Perairan Batam pada tanggal 02 Mei 2016 pukul 11.30 WIB sampai tanggal 02 Mei 2016 pukul 11.45 WIB. Data kecepatan dan posisi kapal berdasarkan informasi dari AIS yang terpasang pada Kapal Lurongyuanyu 105 dapat dilihat pada Tabel 4.61.

Tabel 4. 61 Data *Real* AIS Kapal Lurongyuanyu 105 di Perairan Batam

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (°)
1	104.0684	1.2491	145	2.4
2	104.0692	1.2484	103	2.4
3	104.0696	1.2483	96	2.5
4	104.07	1.2484	90	2.6
5	104.0704	1.2485	89	2.7
6	104.0708	1.2486	89	2.8
7	104.0711	1.2487	88	2.8
8	104.0716	1.2488	87	2.9
9	104.0721	1.2489	88	2.9
10	104.0725	1.249	88	2.8
11	104.0728	1.2491	88	2.7
12	104.0731	1.2491	88	2.6
13	104.0734	1.2492	88	2.5
14	104.0736	1.2492	87	2

Tabel 4. 61 (Lanjutan)

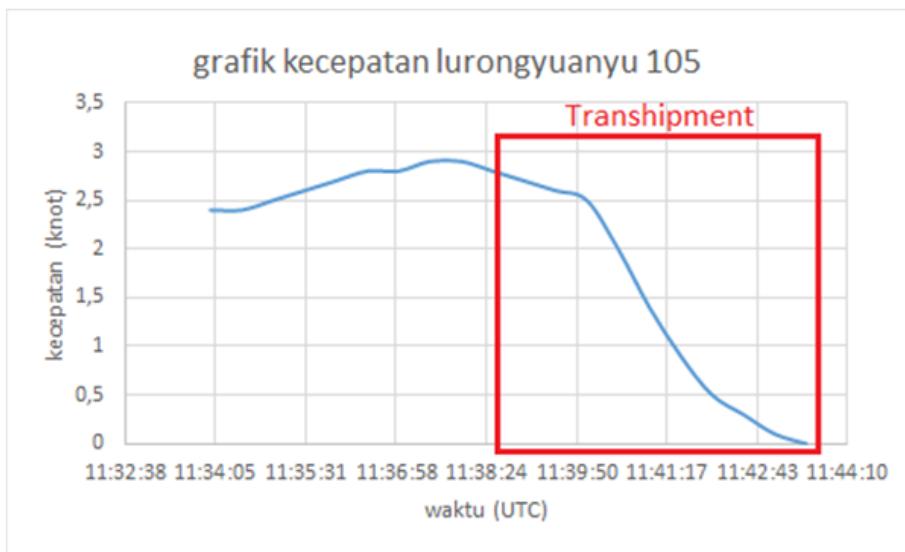
No	Longitude (°)	Latitude (°)	Heading (°)	Speed (°)
15	104.0738	1.2493	87	1.4
16	104.0739	1.2493	87	0.9
17	104.074	1.2494	86	0.5
18	104.0741	1.2494	86	0.3
19	104.0742	1.2494	85	0.1
20	104.0742	1.2495	84	0

Tabel 4. 61 merupakan data *real AIS* kapal Lurongyuanyu di perairan Batam. Posisi kapal Eagle Seville berdasarkan data AIS pada pukul 11.30 sampai pukul 11.45 berada pada koordinat 1.2496° , 104.0738° (lintang & bujur) dengan posisi diam (0 knot).



Gambar 4. 40 Pergerakan Kapal Lurongyuanyu 105 dan Kapal Eagle Seville di perairan Batam (<https://marinetraffic.com>)

Gambar 4. 40 merupakan pergerakan kapal Lurongyuanyu 105 pada AIS *online* (<https://marinetraffic.com>). Nomor 1 pada gambar adalah posisi untuk melakukan sortir kapal di tengah laut yang nilai variabelnya dijadikan sebagai masukan pada subsistem ANN *selection*, sedangkan nomor 2 adalah posisi kapal Lurongyuanyu 105 setelah 10 menit dari tahap sortir yang nilai variabelnya dijadikan sebagai masukan pada subsistem ANN *decision*.



Gambar 4. 41 Grafik kecepatan Kapal Lurongyuanyu 105

Gambar 4. 41 menunjukkan grafik kecepatan kapal Lurongyuanyu 105 di perairan Batam. Grafik menunjukkan bahwa terjadi penurunan kecepatan pada kapal Lurongyuanyu 105, hal tersebut merupakan salah satu indikasi kapal diduga akan melakukan *transhipment*. Tahapan pertama memasukan variabel masukan pada subsistem ANN *selection* untuk mensortir awal kapal. Variabel masukan yang digunakan adalah jarak antara kedua kapal dan selisih *heading* kedua kapal.

Tabel 4. 62 Data Masukan Subsistem ANN *Selection* pada Validasi 2

No	Data Masukan ANN <i>Selection</i>		Keterangan
1	Selisih Sudut <i>Heading</i> (degree)	116	<i>head on</i>
2	Jarak (meter)	648	<i>near</i>

Subsistem ANN *selection* yang telah dirancang memiliki aturan jika keluaran subsistem memiliki presentase nilai di atas 50%, maka terindikasi diduga akan melakukan *illegal transhipment* begitu juga sebaliknya. Hasil 3 penelitian yang telah dirancang dengan logika fuzzy sebelumnya mempunyai nilai keluaran fuzzy *selection* sebesar 80.5%, 83.7%, dan 84% sedangkan keluaran subsistem ANN *selection* pada rancangan ini adalah 100%. Berdasarkan keluaran yang dihasilkan pada ANN *selection*, maka perhitungan ini dilanjutkan ke subsistem ANN *decision transhipment*. ANN *decision transhipment* merupakan keputusan terakhir dari

integrasi sistem identifikasi yang telah dirancang. Variabel masukan yang diberikan pada subsistem ANN *decision transhipment* adalah selisih jarak kedua kapal, selisih *heading* kedua kapal, dan selisih kecepatan kedua kapal pada posisi terakhir.

Tabel 4. 63 Data Masukan Subsistem ANN *Decision Transhipment* pada Validasi ke- 2

No	Data Masukan ANN <i>Decision Transhipment</i>	Keterangan	
1	Jarak Kedua Kapal (meter)	12.7	<i>Near</i>
2	Selisih Sudut <i>Heading</i> (degree)	175	<i>Head On</i>
3	Selisih Kecepatan Kedua Kapal (knot)	0	<i>Small</i>

Subsistem ANN *decision* untuk identifikasi terjadinya praktik *illegal transhipment* mempunyai aturan, jika nilai presentase keluaran menunjukkan lebih dari 50% dapat dipastikan terjadi *illegal transhipment*. Pada 2 sistem yang telah dirancang sebelumnya, menghasilkan keputusan akhir dengan presentase 81.2% dan 83.67%. Pada integrasi sistem identifikasi yang telah dirancang ini, menghasilkan keputusan akhir dengan presentasi 99.67%, presentase tersebut menunjukkan bahwa praktik *illegal* benar-benar terjadi. Maka dapat disimpulkan bahwa data validasi ini sesuai dengan desain integrasi sistem identifikasi yang sudah dirancang dan dibahas di metode penelitian.

Hal ini membuktikan bahwa hasil yang diperoleh dari integrasi sistem identifikasi yang telah dirancang sudah cukup valid karena sesuai dengan realita dan relevan digunakan sebagai alat bantu dalam pengawasan terhadap kapal-kapal asing yang melakukan *Illegal Transhipment* di perairan Indonesia.

4.11.3 Hasil Validasi Integrasi Sistem untuk Identifikasi Menggunakan Data Real Kapal Ikan *Illegal Fishing* di Selat Singapura

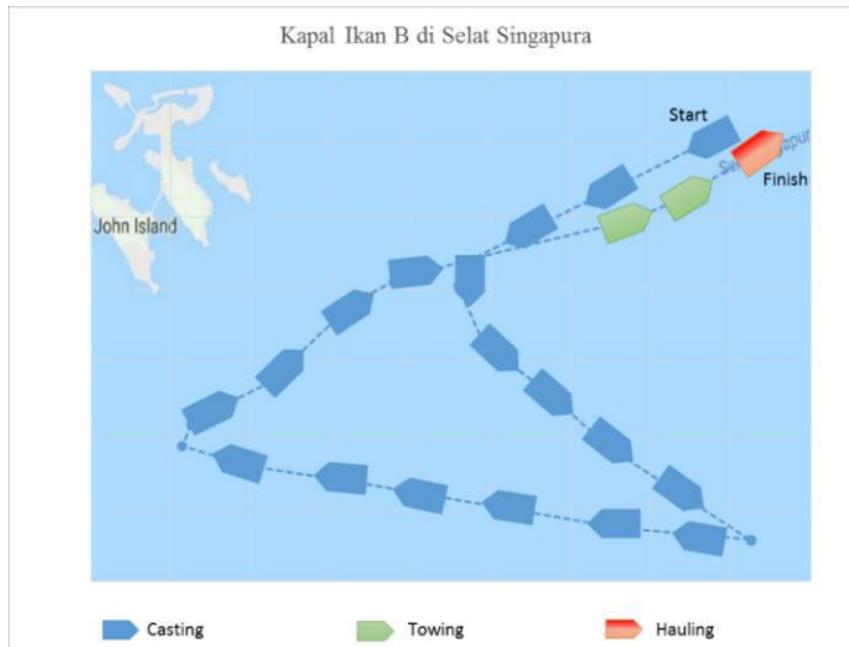
Validasi sistem dilakukan dengan menggunakan variabel masukan sistem berupa data kecepatan kapal selama operasi kapal ikan. Kapal tersebut melakukan praktik *illegal fishing* dengan menggunakan alat tangkap cantrang di selat Singapura. Perubahan posisi kapal per satuan waktu diperoleh dari data *real* masing - masing kapal yang dikirimkan oleh AIS. Data validasi tersebut merupakan kapal ikan menggunakan alat tangkap cantrang di selat Singapura pada tanggal 21

September 2017 pukul 06.43 WIB sampai tanggal 21 September 2017 pukul 10.45 WIB. Data kecepatan dan posisi kapal berdasarkan informasi dari AIS yang terpasang pada kapal ikan B dapat dilihat pada Tabel 4.64.

Tabel 4. 64 Data *Real* AIS Kapal Ikan B di Selat Singapura

No	Longitude (°)	Latitude (°)	Heading (°)	Speed (Knot)
1	103.78357	1.18565	266	0.6
2	103.7805	1.18559	267	0.6
3	103.77229	1.18592	275	0.6
4	103.76632	1.18667	277	0.6
5	103.76031	1.18727	278	0.6
6	103.75921	1.18732	282	0.6
7	103.75821	1.18749	292	0.6
8	103.74554	1.18925	258	0.6
9	103.74566	1.18925	141	0.6
10	103.75596	1.18288	110	0.6
11	103.75857	1.18214	91	0.6
12	103.76138	1.18225	83	0.6
13	103.7645	1.18272	79	0.6
14	103.76722	1.18322	83	0.6
15	103.77823	1.18428	83	0.6
16	103.7811	1.18478	75	0.6
17	103.78396	1.18568	70	0.6
18	103.78951	1.18774	78	0.9
19	103.79233	1.18834	83	0.9
20	103.79813	1.18921	82	0

Tabel 4. 64 merupakan data *real* AIS kapal ikan B di selat Singapura. Posisi kapal ikan B berdasarkan data AIS pada pukul 06.43 WIB sampai pukul 10.45 WIB, kapal ikan dengan alat tangkap cantrang umumnya membutuhkan waktu 3-4 jam untuk menangkap ikan.



Gambar 4. 42 Pergerakan kapal Ikan B di Selat Singapura

Gambar 4. 42 merupakan pergerakan kapal ikan B yang telah di *plot* berdasarkan data lintang dan bujur yang didapatkan dari AIS NASDEC ITS. Posisi kapal dimulai dengan *start* pada gambar adalah posisi untuk melakukan sortir kapal di tengah laut. Variabel jarak dan heading kapal tersebut dimasukkan pada ANN *selection*, selanjutnya memasukkan nilai kecepatan kapal saat melakukan *casting*, *towing*, *hauling*, dan laju perpindahan lintang dan bujur dari kapal pada ANN *decision*.

Tabel 4. 65 Data Masukan Subsistem ANN Selection pada Validasi 3

No	Data Masukan <i>Selection</i>	Keterangan
1	Selisih Sudut <i>Heading</i> (degree)	66
2	Jarak (meter)	-

Subsistem ANN *selection* yang telah dirancang memiliki aturan jika keluaran subsistem memiliki presentase nilai di bawah 50%, maka terindikasi diduga akan melakukan *illegal fishing* begitu juga sebaliknya. Keluaran subsistem ANN *selection* yang telah dirancang menunjukkan nilai presentase 0%. Berdasarkan keluaran yang dihasilkan pada ANN *selection*, maka perhitungan ini dilanjutkan ke subsistem ANN *decision fishing*. ANN *decision fishing* merupakan keputusan

terakhir dari integrasi sistem identifikasi yang telah dirancang. Variabel masukan yang diberikan pada subsistem ANN *decision fishing* adalah kecepatan kapal saat melakukan *casting*, *towing*, *hauling*, dan laju perpindahan lintang dan bujur kapal.

Tabel 4. 66 Data Masukan Subsistem ANN *Decision Fishing* pada Validasi 3

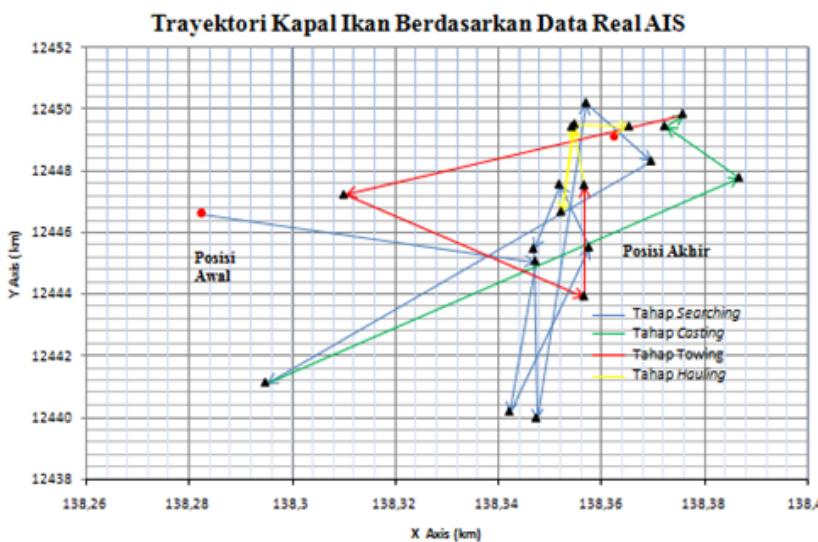
No	Data Masukan <i>Decision Fishing</i>	Keterangan	
1	Kecepatan <i>Casting</i> (knot)	0.6	<i>Medium</i>
2	Kecepatan <i>Towing</i> (knot)	0.9	<i>Low</i>
3	Kecepatan <i>hauling</i> (knot)	0.001	<i>Low</i>
4	Laju Perubahan Posisi <i>Latitude</i> (<i>nautical mile</i>)	0.001	<i>Medium</i>
5	Laju Perubahan Posisi <i>Longitude</i> (<i>nautical mile</i>)	0.007	<i>Medium</i>

Subsistem ANN *decision* untuk identifikasi terjadinya praktik *illegal fishing* mempunyai aturan, jika nilai presentase keluaran menunjukkan lebih dari 50% dapat dipastikan terjadi *illegal fishing*. Pada subsistem integrasi identifikasi yang telah dirancang ini, menghasilkan keputusan akhir dengan presentase 99%, presentase tersebut menunjukkan bahwa praktik *illegal* benar-benar terjadi. Maka dapat disimpulkan bahwa data validasi ini sesuai dengan desain integrasi sistem identifikasi yang sudah dirancang dan dibahas di metode penelitian.

4.11.4 Hasil Validasi Integrasi Sistem untuk Identifikasi Menggunakan Data *Real Kapal Ikan Illegal Fishing* di Laut Natuna

Validasi sistem dilakukan dengan menggunakan variabel masukan sistem berupa data kecepatan kapal selama operasi kapal ikan. Kapal tersebut melakukan praktik *illegal fishing* di Laut Natuna, perubahan posisi kapal per satuan waktu diperoleh dari data *real* masing-masing kapal yang dikirimkan oleh AIS. Data validasi di Laut Natuna, Kepulauan Riau pada tanggal 5 September 2015 pukul 12.00 WIB sampai tanggal 7 September 2015 pukul 12.00 WIB karena menggunakan alat tangkap terlarang berupa trawl. Pola pergerakan kapal

berdasarkan informasi dari AIS yang terpasang pada kapal ikan dapat dilihat pada Gambar 4. 43.



Gambar 4. 43 Pola pergerakan Kapal Ikan berdasarkan data *real AIS*

Gambar 4. 43 merupakan pergerakan kapal ikan yang telah di-*plot* berdasarkan data lintang dan bujur yang di dapatkan dari AIS NASDEC ITS. Posisi kapal dimulai dengan posisi awal pada gambar adalah posisi untuk melakukan sortir kapal di tengah laut. Variabel jarak dan *heading* kapal tersebut dimasukkan pada ANN *selection*, selanjutnya memasukkan nilai kecepatan kapal saat melakukan *casting*, *towing*, *hauling*, dan laju perpindahan lintang dan bujur dari kapal pada ANN *decision*.

Tabel 4. 67 Data Masukan Subsistem ANN *Selection* pada Validasi 4

No	Data Masukan ANN <i>Selection</i>	Keterangan
1	Selisih Sudut <i>Heading</i> (degree)	109
2	Jarak (meter)	-

Subsistem ANN *selection* yang telah dirancang memiliki aturan jika keluaran sistem memiliki presentase nilai dibawah 50%, maka terindikasi diduga akan melakukan *illegal fishing* begitu juga sebaliknya. Keluaran subsistem ANN *selection* yang telah dirancang menunjukkan nilai presentase 0%. Berdasarkan keluaran yang dihasilkan pada ANN *selection*, maka perhitungan ini dilanjutkan ke subsistem ANN *decision fishing*. ANN *decision fishing* merupakan keputusan

terakhir dari integrasi sistem identifikasi yang telah dirancang. Variabel masukan yang diberikan pada subsistem ANN *decision fishing* adalah kecepatan kapal saat melakukan *casting*, *towing*, *hauling*, dan laju perpindahan lintang dan bujur kapal.

Tabel 4. 68 Data Masukan Subsistem ANN *Decision Fishing* pada Validasi 4

No	Data Masukan <i>Decision Fishing</i>		Keterangan
1	Kecepatan <i>Casting</i> (knot)	3	<i>High</i>
2	Kecepatan <i>Towing</i> (knot)	0.46	<i>Low</i>
3	Kecepatan <i>hauling</i> (knot)	4	<i>High</i>
4	Laju Perubahan Posisi <i>Latitude</i> (<i>nautical mile</i>)	0.0001	<i>Low</i>
5	Laju Perubahan Posisi <i>Longitude</i> (<i>nautical mile</i>)	0.22	<i>High</i>

Subsistem ANN *decision* untuk identifikasi terjadinya praktik *illegal fishing* mempunyai aturan, jika nilai presentase keluaran menunjukkan lebih dari 50% dapat dipastikan terjadi *illegal fishing*. Integrasi sistem yang dirancang mempunyai hasil 0% karena tidak sesuai dengan ciri-ciri kapal menggunakan kapal cantrang. Hal tersebut dikarenakan kapal menggunakan alat tangkap jenis *trawl*. Kapal ikan dengan alat tangkap cantrang dan *trawl* mempunyai perbedaan pada saat melakukan tahapan-tahapan dalam menangkap ikan. Pada saat melakukan *casting* atau menebar jaring, kapal dengan alat tangkap *trawl* cenderung lebih cepat dibandingkan kapal dengan alat tangkap cantrang. Pada saat melakukan *towing* atau penarikan jaring terjadi kemiripan pada kapal dengan alat tangkap *trawl* dengan cantrang. Pada saat proses *hauling* atau penarikan jaring ke atas kapal, kapal dengan alat tangkap *trawl* cenderung melakukan pergerakan namun kapal ikan dengan alat tangkap cantrang dalam posisi bertahan. Laju perpindahan posisi lintang dan bujur dari kapal *trawl* juga lebih besar nilainya bila dilihat pada data AIS kapal sebesar 12.57 km, sedangkan kapal ikan dengan alat tangkap cantrang biasanya menebar jaring \pm 500 m sampai 1 km.

Hal ini membuktikan bahwa hasil yang diperoleh dari integrasi sistem identifikasi yang telah dirancang sudah cukup valid karena sesuai dengan realita dan relevan digunakan sebagai alat bantu dalam pengawasan terhadap kapal-kapal asing yang melakukan *Illegal Fishing* di perairan Indonesia.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Dari perancangan dan analisa yang telah dilakukan pada pengerjaan tugas akhir ini diperoleh beberapa kesimpulan:

- a) Integrasi sistem untuk identifikasi terbagi menjadi 2 subsistem yaitu, ANN *selection* untuk mensoritir dua kapal, dan ANN *decision* sebagai identifikasi akhir apakah kapal-kapal melakukan praktik IUU *fishing* atau *transhipment*. Prediktor untuk prediksi data AIS yang hilang terbagi menjadi 2 subsistem yaitu, RNN *predictor* untuk prediksi data AIS *longitude*, *latitude*, dan *heading* kapal pelaku *illegal fishing* dan *transhipment* yang hilang, dan *speed predictor* untuk prediksi data AIS *speed* kapal pelaku *illegal fishing* dan *transhipment* yang hilang.
- b) Prediktor untuk prediksi data AIS *longitude*, *latitude*, dan *heading* yang hilang dirancang menggunakan model *recurrent neural networks* (RNN) dan untuk prediksi data AIS *speed* yang hilang dirancang menggunakan metode perbandingan senilai. Prediktor menghasilkan akurasi yang tinggi dengan nilai MAPE masing-masing untuk prediksi posisi (*longitude* dan *latitude*) dan *heading* yaitu 0.055% dan 8.01%, sedangkan untuk prediksi *speed* menghasilkan akurasi tinggi dengan nilai RMSE 0.83 knot.
- c) Hasil keluaran dari prediktor dapat digunakan sebagai masukan untuk integrasi sistem identifikasi kapal *illegal fishing* dan *transhipment* dibuktikan dengan hasil validasi prediktor yang mampu menghasilkan akurasi yang tinggi.
- d) Model pada integrasi sistem untuk identifikasi kapal-kapal yang diduga melakukan *illegal fishing* dan *transhipment* dibangun menggunakan arsitektur jaringan untuk ANN *selection*, ANN *decision transhipment*, dan ANN *decision fishing* masing-masing dengan satu *hidden layer* yaitu sebagai berikut:

- ANN *selection*
 $2 - 10 - 1$ (2 neuron *input*, 10 neuron *hidden layer*, dan 1 neuron *output*)
- ANN *decision transhipment*
 $3 - 10 - 1$ (3 neuron *input*, 10 neuron *hidden layer*, dan 1 neuron *output*)
- ANN *decision fishing*
 $5 - 5 - 1$ (5 neuron *input*, 5 neuron *hidden layer*, dan 1 neuron *output*)

Dengan menggunakan model tersebut, integrasi sistem untuk identifikasi mampu menghasilkan akurasi tinggi dengan nilai akurasi sebesar 99.64%.

5.2 Saran

Prediktor yang telah dirancang pada penelitian ini hanya mampu untuk memprediksi 10 data yang hilang. Oleh karena itu, adapun saran yang penulis berikan untuk pengembangan rancangan selanjutnya yaitu agar melakukan perancangan prediktor yang mampu untuk memprediksi data yang hilang lebih banyak (lebih dari 10 data yang hilang).

DAFTAR PUSTAKA

- Aisjah, A. S., & A.A Masroeri, M. Y. (2013). Pemetaan Pola Gerak Illegal Fishing dan Transhipment pada Vessel Monitoring System Berdasarkan Data AIS. 2.
- Aisjah, A. S., Arifin, S., Masroeri, A. A., & Saiko. (2011). Perancangan Sistem Pengendalian pada Kapal Berbasis Data AIS (Automatic Identification System) untuk menghindari Tabrakan di Perairan Tanjung Perak Surabaya. *Seminar Nasional Senta*, 1-10.
- Almuzzamil, T. (2015). *Kebijakan Pemerintah Indonesia Dalam Menanggulangi Illegal Fishing Pada Tahun 2014-2015*.
- Ambari, M. (2018). *Nelayan Ajukan Jaminan untuk Proses Untuk Pergantian Cantrang*. Dipetik 01 28, 2018, dari Mongabay: <http://www.mongabay.co.id/2018/01/19/nelayan-ajukan-jaminan-untuk-proses-pergantian-cantrang-apa-saja/>
- Badan Standardisasi Nasional. (2006). *Bentuk baku konstruksi pukat tarik cantrang*.
- Bai, L. (2011). Electric Drive System with BLDC Motor. *International Conference on Electric Information and Control Engineering* (hal. 254). Kuala Lumpur: Universiti Malaya.
- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Madison Ave. New York, NYUnited States: Oxford University Press.
- Blanke, M. (1999). *Fault Tolerant Control Systems*. London: Adventure Workd Press.
- BPK. (2016). *Audit IUU Fishing. Road Map E-Commerce*.
- Bramer, M. (2007). *Principles Of Data Mining*. London: Springer-Verlag.
- Bridle, J. (1990). Probabilistic interpretation of feedforward classification network. Dalam F. F. Soulié, & J. Hérault, *Neurocomputing* (hal. 227-236). Berlin, Heidelberg: Springer.
- Brown, G. W. (1982). Standard Deviation, Standard Error. *American Journal of Diseases of Children*, 136, 937-941.
- Elman, J. (1990). Finding structure in time. *Cognitive Science*, 179-211.

- Errabelli, R. (2012). Fault-Tolerant Voltage Source Inverter for Permanent Magnet Drives. *IEEE Transactions on Power Electronics*, 27.
- Farahdiba, C. (2018). Perancangan Integrasi Sistem Pengambilan Keputusan Berbasis Data Automatic Identification System (AIS) Untuk Pemodelan IUU Fishing dan Transhipment Menggunakan Adaptive Neuro-Fuzzy Inference System (ANFIS).
- Fatmawati, N. N. (2018). PERANCANGAN INTEGRASI SISTEM PENGAMBILAN KEPUTUSAN UNTUK IDENTIFIKASI TERJADINYA IUU TRANSHIPMENT DAN FISHING BERBASIS DATA AIS (AUTOMATIC IDENTIFICATION SYSTEM) MENGGUNAKAN LOGIKA FUZZY.
- Gao, Y. (2001). Electronic Braking System of EV and HEV--Integration of Regenerative Braking, Automatic Braking Force Control and ABS. *42 Volt Technology and Advanced Vehicle Electrical Systems*.
- Ghaffari, A., Abdollahi, H., Khoshayand, M., Bozchalooi, I. S., Dadgar, A., & & Rafiee-Tehrani, M. (2008). Performance Comparison of Neural Network Training Algorithms in Modeling of Bimodal Drug Delivery. *International Journal of Pharmaceutics*, 126-138.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. Cambridge: MIT Press Cambridge.
- Graves, A. (2012). *Supervised Sequence Labelling with Recurrent Neural Networks*. Berlin Heidelberg: Springer.
- Gustina, A. (2014). Analisis Transhipment Pasal 69 Ayat (3) Peraturan Menteri Kelautan Perikanan No. 30 Tahun 2012 Tentang Usaha Perikanan Tangkap. *Jurnal Dinamika Hukum*, 14, 340-349.
- Harati-Mokhtar, A., Wall, A., Brook, P., & Wang, J. (2007). Automatic Identification System (AIS): Data Reliability and Human Error Implications. *Journal of Navigation*, 373-389.
- Hermawan, A. (2006). *Jaringan Saraf Tiruan Teori dan Aplikasi*. Yogyakarta: ANDI.

- Huang, J. C., Nieh, C. Y., & Kuo, H. C. (2019). Risk assessment of ships maneuvering in an approaching channel based on AIS data. *Ocean Engineering*, 399-414.
- IMO. (1998). *Resolution MSC.74(69): Adoption of new and amended performance standards*. Legal Document.
- Karpathy, A. (2015, 05 21). *The Unreasonable Effectiveness of Recurrent Neural Networks*. Diambil kembali dari Andrej Karpathy Blog: <http://karpathy.github.io/2015/05/21/rnn-effectiveness/>
- Keshavarzi, A., & Sarmadian, F. (2010). Comparison of artificial neural network and multivariate regression methods in prediction of soil cation exchange capacity (Case study: Ziaran region). *Desert*, 167-174.
- Kingma, D., & Ba, J. L. (2015). Adam: A method for stochastic. *Proceedings of the 3rd international conference on learning representations (ICLR 2015)*.
- KKP. (2019). *Kinerja Pengawasan KKP Sepanjang Triwulan I/2019 Tunjukkan Capaian Positif*. Diambil kembali dari KKP.
- Klimberg, R. K., Sillup, G. P., Boyle, K. J., & Tavva, V. (2010). Forecasting performance measures - What are their practical meaning?
- Lewis, C. D. (1982). *Industrial and business forecasting methods : a practical guide to exponential smoothing and curve fitting*. London: Butterworth Scientific.
- Longépé, N., Ardianto, R., & Hajduch, G. (2017). Completing fishing monitoring with spaceborne Vessel Detection System (VDS) and Automatic Identification System (AIS) to assess illegal fishing in Indonesia. *Marine Pollution Bulletin*.
- Lorenz, C., Ferrando, A. S., & Suesdek, L. (2015). Artificial Neural Network Applied as a Methodology of Mosquito Species Identification. *Acta Tropica*.
- Lubbers, K. (2014). Design and Analysis of a Model Based Low Level Slip Controller Based on a Hybrid Braking System. *Science in Systems and Control Delft University*.

- Makarynskyy, O. (2004). Predicting Sea Level Variations with Artificial Neural Networks at Hillary Boat Harbour, Western Australia. *Estuarine, Coastal and Shelf Science*, 351-360.
- Masroeri, A. A. (2018, Maret 1). Penentuan Variebel Masukan dan Keluaran Sistem Pengambilan Keputusan, Tingkatan Fungsi Keanggotaan pada Logika Fuzzy serta Tingkatan (Numerik) untuk Mengkategorikan Illegal/Non Illegal Transhipment dan Illegal Fishing. (Novia, Pewawancara)
- Masroeri, A. A., & Nuryahya, D. (2003). Automatic Collision Avoidance System Base On AIS Data in West Voyage Lines of Surabaya.
- Maulida, S. (2018). Perancangan Integrasi Sistem Pengambilan Keputusan Berbasis Data Automatic Identification System (AIS) untuk Pemodelan Illegal Unregulated and Unreported (IUU) Fishing dan Transhipment Menggunakan Jaringan Saraf Tiruan (JST).
- Murali, T. (2017). Four Quadrant Operation and Control of Three Phase BLDC Motor. *International Conference on Circuits Power and Computing Technology*.
- Nuryahya, D., & Masroeri, A. A. (2003). Automatic Collision Avoidance System Base On AIS Data in West Voyage Lines of Surabaya.
- Offer, G. J. (2010). Comparative analysis of battery electric, hydrogen fuel cell, and hybrid vehicle in a future sustainable road transport system. *energy policy*, 38, 24-29.
- Papslinka-Swerpel, B. (2006). Application of Neural Network to the Prediction of Significant Wave Height at Selected Locations on the Baltic Sea. *Hydro-Engineering and Environmental Mechanics* =, 183-201.
- Picard, R. R., & Cook, R. D. (1984). Cross-validation of regression models. *Journal of the American Statistical Association*, 575-583.
- Rahman. (2017). *Tangkap Ikan Pakai Cantrang 5 Kapal Nelayan dari Pulau Jawa Diamankan Polisi*. Diambil kembali dari Tribunnews: <http://www.tribunnews.com/regional/2017/04/17/tangkap-ikan-pakai-cantrang-5-kapal-nelayan-dari-pulau-jawa-diamankan-polisi>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1987). Learning Internal Representations by Error Propagation. Dalam D. E. Rumelhart, & J. L.

- McClelland, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations* (hal. 318 - 362). Cambridge, Massachusetts: MIT Press.
- Saputra, H., & Istardi, D. (2016). Penggunaan Data Automatic Identification System (AIS) untuk Mengetahui Pergerakan Kapal (Studi Kasus pada Lalu Lintas Kapal di Selat Singapura dan Perairan Batam). 139-143.
- Sasmita, S. (2013). *Kesesuaian Desain dan Konstruksi Cantrang pada Kapal 20 GT untuk Peningkatan Performa Operasional. Kesesuaian Desain dan Konstruksi Cantrang pada Kapal 20 GT untuk Peningkatan Performa Operasional*. Bogor: IPB.
- Shiosansi, R. (2008). Emissions Impacts and Benefits of Plug-in Hybrid Electric Vehicles and Vehicle-to-Grid Services. *Environmental Science Technology*, 1199-1204.
- Singh, C. P. (2012). State-space Based Simulink Modeling of BLDC Motor and its Speed Control Using Fuzzy PID Controller. *International Journal of Advances in Engineering Science and Technology*, 2, 359-369.
- Suratno. (2009). Pengaruh Perbedaan Tipe Fungsi Keanggotaan Pada Pengendali Logika Fuzzy Terhadap Tanggapan Waktu Sistem Orde Dua Secara Umum. 1-10.
- Sutojo, T. (2010). Kecerdasan Buatan.
- Tashakori, A. (2011). Modeling of BLDC Motor with Ideal Back-EMF for Automotive Applications. *World Congress on Engineering*. London.
- Trihendradi, C. (2012). Step by Step SPSS 20 Analisis Data Statistik.
- Tsamenvyi, M., & et.al. (2010). The European Council Regulation on Illegal, Unreported and Unregulated Fishing: An International Fisheries Law Perspective. *The International Journal of Marine and Coastal Law*, 25, 5-31.
- Tur, O. (2007). An Introduction to Regenerative Braking of Electric Vehicles as Anti-Lock Braking System. *Proceedings of 2007 IEEE Intelligent Vehicles Symposium*, (hal. 13-15). Istanbul.
- U.S. Coast Guard Navigation Center. (2010). Diambil kembali dari U.S. Coast Guard Navigation Center: <https://www.navcen.uscg.gov/>

Werbos, P. (1988). Generalization of backpropagation with application to a recurrent gas. *Neural Networks*, 339-356.

Westbrook, M. H. (2005). *Development and future of battery, hybrid, and fuel-cell cars*. London: The Institution of Electrical Engineers.

LAMPIRAN

Lampiran 1. Kode Program RNN Predictor untuk Prediksi data AIS *Longitude dan Latitude yang Hilang pada Kapal Pelaku Illegal Transhipment*

```
# Recurrent Neural Network
# Predictor for predicting missing longitude and latitude position
# data of illegal transhipment ships

# Part 1 - Data Preprocessing

# Importing the libraries
import numpy as np
import pandas as pd

# Importing the training set
dataset_train = pd.read_csv('DATASET_VALIDATION_LONGLAT.csv')
training_set = dataset_train.iloc[:10, 1:3].values

# Feature Scaling with Normalization
from sklearn.preprocessing import MinMaxScaler
sc = MinMaxScaler(feature_range = (0, 1))
training_set_scaled = sc.fit_transform(training_set)

# Creating a data structure with 2 timesteps and 2 output
X_train = []
y_train = []
for i in range(2, 10):
    X_train.append(training_set_scaled[i-2:i, 0:2])
    y_train.append(training_set_scaled[i, 0:2])
X_train, y_train = np.array(X_train), np.array(y_train)

# Reshaping
X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1],
                               2))

# Part 2 - Building the RNN

# Importing the Keras libraries and packages
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from keras.layers import Dropout
from keras.optimizers import Adam

# Initialising the RNN
regressor = Sequential()

# Adding the input layer, the first LSTM layer and some Dropout
# regularisation
```

```

regressor.add(LSTM(units = 5, return_sequences = False,
input_shape = (X_train.shape[1], 2)))
regressor.add(Dropout(0.2))

# Adding the output layer
regressor.add(Dense(units = 2))

# Compiling the RNN
#learning_rate = 0.001, 0.005, 0.01, 0.05, 0.1
opt = Adam(learning_rate = 0.005)
regressor.compile(optimizer = opt, loss = 'mean_squared_error')

# Fitting the RNN to the Training set
regressor.fit(X_train, y_train, epochs = 100, batch_size = 2)

# Part 3 - Making the predictions and validating the results

dataset_test = pd.read_csv('DATASET_VALIDATION_LONGLAT.csv')
actual_data = dataset_test.iloc[10:, 1:3].values

inputs = dataset_test.iloc[8:, 1:3].values
inputs = sc.transform(inputs)
X_test = []
for i in range(2, 12):
    X_test.append(inputs[i-2:i, 0:2])
X_test = np.array(X_test)
X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 2))
predicted_longlat_trans = regressor.predict(X_test)
predicted_longlat_trans =
sc.inverse_transform(predicted_longlat_trans)

# Evaluating
import math
from sklearn.metrics import mean_squared_error
rmse = math.sqrt(mean_squared_error(actual_data,
predicted_longlat_trans))
mape_longlat = np.abs((actual_data - predicted_longlat_trans) /
actual_data).mean(axis=0) * 100

```

Lampiran 2. Kode Program RNN *Predictor* untuk Prediksi data AIS *Heading* yang Hilang pada Kapal Pelaku *Illegal Transhipment*

```
# Recurrent Neural Network
# Predictor for predicting missing heading data of illegal
transhipment ships

# Part 1 - Data Preprocessing

# Importing the libraries
import numpy as np
import pandas as pd

# Importing the training set
dataset_train = pd.read_csv('DATASET_VALIDATION_HEAD.csv')
training_set = dataset_train.iloc[:10, 7:8].values

# Feature Scaling with Normalization
from sklearn.preprocessing import MinMaxScaler
sc = MinMaxScaler(feature_range = (0, 1))
training_set_scaled = sc.fit_transform(training_set)

# Creating a data structure with 2 timesteps and 1 output
X_train = []
y_train = []
for i in range(2, 10):
    X_train.append(training_set_scaled[i-2:i, 0])
    y_train.append(training_set_scaled[i, 0])
X_train, y_train = np.array(X_train), np.array(y_train)

# Reshaping
X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1],
1))

# Part 2 - Building the RNN

# Importing the Keras libraries and packages
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from keras.layers import Dropout
from keras.optimizers import Adam

# Initialising the RNN
regressor = Sequential()

# Adding the input layer, the first LSTM layer and some Dropout
regularisation
regressor.add(LSTM(units = 10, return_sequences = False,
input_shape = (X_train.shape[1], 1)))
regressor.add(Dropout(0.2))

# Adding the output layer
regressor.add(Dense(units = 1))
```

```

# Compiling the RNN
#learning_rate = 0.001, 0.005, 0.01, 0.05, 0.1
opt = Adam(learning_rate = 0.1)
regressor.compile(optimizer = opt, loss = 'mean_squared_error')

# Fitting the RNN to the Training set
regressor.fit(X_train, y_train, epochs = 100, batch_size = 2)

# Part 3 - Making the predictions and validating the results

dataset_test = pd.read_csv('DATASET_VALIDATION_HEAD.csv')
actual_data = dataset_test.iloc[10:, 7:8].values

inputs = dataset_test.iloc[8:, 7:8].values
inputs = sc.transform(inputs)
X_test = []
for i in range(2, 12):
    X_test.append(inputs[i-2:i, 0])
X_test = np.array(X_test)
X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 1))
predicted_heading_trans = regressor.predict(X_test)
predicted_heading_trans =
sc.inverse_transform(predicted_heading_trans)

# Evaluating
import math
from sklearn.metrics import mean_squared_error
rmse = math.sqrt(mean_squared_error(actual_data,
predicted_heading_trans))
mape_Heading = np.abs((actual_data - predicted_heading_trans) /
actual_data).mean(axis=0) * 100

```

Lampiran 3. Kode Program RNN Predictor untuk Prediksi data AIS *Longitude* dan *Latitude* yang Hilang pada Kapal Pelaku *Illegal Fishing*

```
# Recurrent Neural Network
# Predictor for predicting missing longitude and latitude position
# data of illegal fishing ships

# Part 1 - Data Preprocessing

# Importing the libraries
import numpy as np
import pandas as pd

# Importing the training set
dataset_train = pd.read_csv('DATASET_VALIDATION_LONGLAT.csv')
training_set = dataset_train.iloc[:10, 3:5].values

# Feature Scaling with Normalization
from sklearn.preprocessing import MinMaxScaler
sc = MinMaxScaler(feature_range = (0, 1))
training_set_scaled = sc.fit_transform(training_set)

# Creating a data structure with 2 timesteps and 2 output
X_train = []
y_train = []
for i in range(2, 10):
    X_train.append(training_set_scaled[i-2:i, 0:2])
    y_train.append(training_set_scaled[i, 0:2])
X_train, y_train = np.array(X_train), np.array(y_train)

# Reshaping
X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1],
                               2))

# Part 2 - Building the RNN

# Importing the Keras libraries and packages
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from keras.layers import Dropout
from keras.optimizers import Adam

# Initialising the RNN
regressor = Sequential()

# Adding the input layer, the first LSTM layer and some Dropout
# regularisation
regressor.add(LSTM(units = 5, return_sequences = False,
                   input_shape = (X_train.shape[1], 2)))
regressor.add(Dropout(0.2))

# Adding the output layer
regressor.add(Dense(units = 2))
```

```

# Compiling the RNN
#learning_rate = 0.001, 0.005, 0.01, 0.05, 0.1
opt = Adam(learning_rate = 0.005)
regressor.compile(optimizer = opt, loss = 'mean_squared_error')

# Fitting the RNN to the Training set
regressor.fit(X_train, y_train, epochs = 100, batch_size = 2)

# Part 3 - Making the predictions and validating the results

dataset_test = pd.read_csv('DATASET_VALIDATION_LONGLAT.csv')
actual_data = dataset_test.iloc[10:, 3:5].values

inputs = dataset_test.iloc[8:, 3:5].values
inputs = sc.transform(inputs)
X_test = []
for i in range(2, 12):
    X_test.append(inputs[i-2:i, 0:2])
X_test = np.array(X_test)
X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 2))
predicted_longlat_fish = regressor.predict(X_test)
predicted_longlat_fish =
sc.inverse_transform(predicted_longlat_fish)

# Evaluating
import math
from sklearn.metrics import mean_squared_error
rmse = math.sqrt(mean_squared_error(actual_data,
predicted_longlat_fish))
mape_longlat = np.abs((actual_data - predicted_longlat_fish) /
actual_data).mean(axis=0) * 100

```

Lampiran 4. Kode Program RNN *Predictor* untuk Prediksi data AIS *Heading* yang Hilang pada Kapal Pelaku *Illegal Fishing*

```
# Recurrent Neural Network
# Predictor for predicting missing heading data of illegal fishing
ships

# Part 1 - Data Preprocessing

# Importing the libraries
import numpy as np
import pandas as pd

# Importing the training set
dataset_train = pd.read_csv('DATASET_VALIDATION_HEAD.csv')
training_set = dataset_train.iloc[:10, 8:9].values

# Feature Scaling with Normalization
from sklearn.preprocessing import MinMaxScaler
sc = MinMaxScaler(feature_range = (0, 1))
training_set_scaled = sc.fit_transform(training_set)

# Creating a data structure with 2 timesteps and 1 output
X_train = []
y_train = []
for i in range(2, 10):
    X_train.append(training_set_scaled[i-2:i, 0])
    y_train.append(training_set_scaled[i, 0])
X_train, y_train = np.array(X_train), np.array(y_train)

# Reshaping
X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1],
1))

# Part 2 - Building the RNN

# Importing the Keras libraries and packages
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from keras.layers import Dropout
from keras.optimizers import Adam

# Initialising the RNN
regressor = Sequential()

# Adding the input layer, the first LSTM layer and some Dropout
regularisation
regressor.add(LSTM(units = 10, return_sequences = False,
input_shape = (X_train.shape[1], 1)))
regressor.add(Dropout(0.2))

# Adding the output layer
regressor.add(Dense(units = 1))
```

```

# Compiling the RNN
#learning_rate = 0.001, 0.005, 0.01, 0.05, 0.1
opt = Adam(learning_rate = 0.1)
regressor.compile(optimizer = opt, loss = 'mean_squared_error')

# Fitting the RNN to the Training set
regressor.fit(X_train, y_train, epochs = 100, batch_size = 2)

# Part 3 - Making the predictions and validating the results

dataset_test = pd.read_csv('DATASET_VALIDATION_HEAD.csv')
actual_data = dataset_test.iloc[10:, 8:9].values

inputs = dataset_test.iloc[8:, 8:9].values
inputs = sc.transform(inputs)
X_test = []
for i in range(2, 12):
    X_test.append(inputs[i-2:i, 0])
X_test = np.array(X_test)
X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 1))
predicted_heading_fish = regressor.predict(X_test)
predicted_heading_fish =
sc.inverse_transform(predicted_heading_fish)

# Evaluating
import math
from sklearn.metrics import mean_squared_error
rmse = math.sqrt(mean_squared_error(actual_data,
predicted_heading_fish))
mape_Heading = np.abs((actual_data - predicted_heading_fish) /
actual_data).mean(axis=0) * 100

```

Lampiran 5. Kode Program ANN Selection

```
# Artificial Neural Network
# ANN Selection

# Part 1 - Data Preprocessing

# Importing the libraries
import numpy as np
import pandas as pd

# Importing the dataset
dataset = pd.read_csv('datasetFIX_ann_selection.csv')
X = dataset.iloc[:, 0:2].values
y = dataset.iloc[:, 2].values

# Feature Scaling with Standardization
from sklearn.preprocessing import StandardScaler
sc = StandardScaler()
X = sc.fit_transform(X)

# Part 2 - Train, Test and Evaluate wih 5-Cross Validation

import keras
from keras.wrappers.scikit_learn import KerasClassifier
from sklearn.model_selection import cross_val_score
from keras.models import Sequential
from keras.layers import Dense
from keras.optimizers import Adam

def build_classifier():
    classifier = Sequential()
    classifier.add(Dense(units = 10, kernel_initializer =
'uniform', activation = 'relu', input_dim = 2))
    classifier.add(Dense(units = 1, kernel_initializer =
'uniform', activation = 'sigmoid'))
    #learning_rate = 0.0001, 0.0005, 0.001, 0.005, 0.01
    opt = Adam(learning_rate = 0.01)
    classifier.compile(optimizer = opt, loss =
'binary_crossentropy', metrics = ['accuracy'])
    return classifier
classifier = KerasClassifier(build_fn = build_classifier,
batch_size = 10, epochs = 100)
accuracies = cross_val_score(estimator = classifier, X = X, y = y,
cv = 5)
mean_accuracies = accuracies.mean()
variance = accuracies.std()

# After did the Part 2, restart kernel and run only the Part 3

# Part 3 - Making Prediction for Classification using The Best
Parameter from 5 Cross Validation Implementation
```

```

import numpy as np
import pandas as pd

# Importing the dataset
dataset = pd.read_csv('datasetFIX_ann_selection.csv')
X = dataset.iloc[:, 0:2].values
y = dataset.iloc[:, 2].values

# Splitting the dataset into the Training set and Test set
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size = 0.2, random_state = 1)

# Feature Scaling with Standardization
from sklearn.preprocessing import StandardScaler
sc = StandardScaler()
X_train = sc.fit_transform(X_train)
X_test = sc.transform(X_test)

# Importing the Keras libraries and packages
import keras
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import Dropout
from keras.optimizers import Adam

# Initialising the ANN
classifier = Sequential()

# Adding the input layer and the first hidden layer
classifier.add(Dense(units = 10, kernel_initializer = 'uniform',
activation = 'relu', input_dim = 2))
# classifier.add(Dropout(p = 0.1))

# Adding the output layer
classifier.add(Dense(units = 1, kernel_initializer = 'uniform',
activation = 'sigmoid'))

# Compiling the ANN
opt = Adam(learning_rate = 0.01)
classifier.compile(optimizer = opt, loss = 'binary_crossentropy',
metrics = ['accuracy'])

# Fitting the ANN to the Training set
classifier.fit(X_train, y_train, batch_size = 10, epochs = 100)

# replace 'a' in code below with delta heading value input
# replace 'b' in code below with distance value input
new_prediction = classifier.predict(sc.transform(np.array([[a,
b]])))
#new_prediction = (new_prediction > 0.5)

```

Lampiran 6. Kode Program ANN *Decision Transhipment*

```
# Artificial Neural Network
# ANN Decision Transhipment

# Part 1 - Data Preprocessing

# Importing the libraries
import numpy as np
import pandas as pd

# Importing the dataset
dataset = pd.read_csv('datasetFIX_ann_decision_trans.csv')
X = dataset.iloc[:, 0:3].values
y = dataset.iloc[:, 3].values

# Feature Scaling with Standardization
from sklearn.preprocessing import StandardScaler
sc = StandardScaler()
X = sc.fit_transform(X)

# Part 2 - Train, Test and Evaluate with 5-Cross Validation

import keras
from keras.wrappers.scikit_learn import KerasClassifier
from sklearn.model_selection import cross_val_score
from keras.models import Sequential
from keras.layers import Dense
from keras.optimizers import Adam

def build_classifier():
    classifier = Sequential()
    classifier.add(Dense(units = 10, kernel_initializer =
'uniform', activation = 'relu', input_dim = 3))
    classifier.add(Dense(units = 1, kernel_initializer =
'uniform', activation = 'sigmoid'))
    #learning_rate = 0.0001, 0.0005, 0.001, 0.005, 0.01
    opt = Adam(learning_rate = 0.005)
    classifier.compile(optimizer = opt, loss =
'binary_crossentropy', metrics = ['accuracy'])
    return classifier
classifier = KerasClassifier(build_fn = build_classifier,
batch_size = 10, epochs = 100)
accuracies = cross_val_score(estimator = classifier, X = X, y = y,
cv = 5)
mean_accuracies = accuracies.mean()
variance = accuracies.std()

# After did the Part 2, restart kernel and run only the Part 3

# Part 3 - Making Prediction for Classification using The Best
Parameter from 5 Cross Validation Implementation
```

```

import numpy as np
import pandas as pd

# Importing the dataset
dataset = pd.read_csv('datasetFIX_ann_decision_trans.csv')
X = dataset.iloc[:, 0:3].values
y = dataset.iloc[:, 3].values

# Splitting the dataset into the Training set and Test set
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size = 0.2, random_state = 1)

# Feature Scaling with Standardization
from sklearn.preprocessing import StandardScaler
sc = StandardScaler()
X_train = sc.fit_transform(X_train)
X_test = sc.transform(X_test)

# Importing the Keras libraries and packages
import keras
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import Dropout
from keras.optimizers import Adam

# Initialising the ANN
classifier = Sequential()

# Adding the input layer and the first hidden layer
classifier.add(Dense(units = 10, kernel_initializer = 'uniform',
activation = 'relu', input_dim = 3))
classifier.add(Dropout(p = 0.25))

# Adding the output layer
classifier.add(Dense(units = 1, kernel_initializer = 'uniform',
activation = 'sigmoid'))

# Compiling the ANN
opt = Adam(learning_rate = 0.005)
classifier.compile(optimizer = opt, loss = 'binary_crossentropy',
metrics = ['accuracy'])

# Fitting the ANN to the Training set
classifier.fit(X_train, y_train, batch_size = 10, epochs = 100)

# replace 'a' in code below with delta heading value input
# replace 'b' in code below with distance value input
# replace 'c' in code below with delta speed value input
new_prediction = classifier.predict(sc.transform(np.array([[a, b,
c]])))
#new_prediction = (new_prediction > 0.5)

```

Lampiran 7. Kode Program ANN *Decision Fishing*

```
# Artificial Neural Network
# ANN Decision Fishing

# Part 1 - Data Preprocessing

# Importing the libraries
import numpy as np
import pandas as pd

# Importing the dataset
dataset = pd.read_csv('datasetFIX_ann_decision_fish.csv')
X = dataset.iloc[:, 0:5].values
y = dataset.iloc[:, 5].values

# Feature Scaling with Standardization
from sklearn.preprocessing import StandardScaler
sc = StandardScaler()
X = sc.fit_transform(X)

# Part 2 - Train, Test and Evaluate wih 5-Cross Validation

import keras
from keras.wrappers.scikit_learn import KerasClassifier
from sklearn.model_selection import cross_val_score
from keras.models import Sequential
from keras.layers import Dense
from keras.optimizers import Adam

def build_classifier():
    classifier = Sequential()
    classifier.add(Dense(units = 5, kernel_initializer =
'uniform', activation = 'relu', input_dim = 5))
    classifier.add(Dense(units = 1, kernel_initializer =
'uniform', activation = 'sigmoid'))
    #learning_rate = 0.0001, 0.0005, 0.001, 0.005, 0.01
    opt = Adam(learning_rate = 0.001)
    classifier.compile(optimizer = opt, loss =
'binary_crossentropy', metrics = ['accuracy'])
    return classifier
classifier = KerasClassifier(build_fn = build_classifier,
batch_size = 10, epochs = 100)
accuracies = cross_val_score(estimator = classifier, X = X, y = y,
cv = 5)
mean_accuracies = accuracies.mean()
variance = accuracies.std()

# After did the Part 2, restart kernel and run only the Part 3

# Part 3 - Making Prediction for Classification using The Best
Parameter from 5 Cross Validation Implementation
```

```

import numpy as np
import pandas as pd

# Importing the dataset
dataset = pd.read_csv('datasetFIX_ann_decision_fish.csv')
X = dataset.iloc[:, 0:5].values
y = dataset.iloc[:, 5].values

# Splitting the dataset into the Training set and Test set
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size = 0.2, random_state = 1)

# Feature Scaling with Standardization
from sklearn.preprocessing import StandardScaler
sc = StandardScaler()
X_train = sc.fit_transform(X_train)
X_test = sc.transform(X_test)

# Importing the Keras libraries and packages
import keras
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import Dropout
from keras.optimizers import Adam

# Initialising the ANN
classifier = Sequential()

# Adding the input layer and the first hidden layer
classifier.add(Dense(units = 5, kernel_initializer = 'uniform',
activation = 'relu', input_dim = 5))
#classifier.add(Dropout(p = 0.1))

# Adding the output layer
classifier.add(Dense(units = 1, kernel_initializer = 'uniform',
activation = 'sigmoid'))

# Compiling the ANN
opt = Adam(learning_rate = 0.001)
classifier.compile(optimizer = opt, loss = 'binary_crossentropy',
metrics = ['accuracy'])

# Fitting the ANN to the Training set
classifier.fit(X_train, y_train, batch_size = 10, epochs = 100)

# replace 'a' in code below with casting speed value input
# replace 'b' in code below with towing speed value input
# replace 'c' in code below with hauling speed value input
# replace 'd' in code below with dlat value input
# replace 'e' in code below with dlong value input
new_prediction = classifier.predict(sc.transform(np.array([[a, b,
c, d, e]])))
#new_prediction = (new_prediction > 0.5)

```

BIODATA PENULIS

Penulis lahir di Kota Banjarmasin pada 4 Juli 1997. Penulis menempuh pendidikan di SD Islam Sabilal Muhtadin Banjarmasin (2003 – 2009), SMP Islam Sabilal Muhtadin Banjarmasin (2009 – 2012), SMAN 3 Banjarmasin (2012 – 2015), dan sejak tahun 2016 hingga sekarang sedang menempuh pendidikan S-1 di Departemen Teknik Fisika, Fakultas Teknologi Industri dan Rekayasa Sistem, Institut Teknologi Sepuluh Nopember. Selama menjadi mahasiswa, saat awal tahun perkuliahan penulis pada mulanya tertarik dengan bidang *material science* dan saat memasuki tahun kedua perkuliahan penulis akhirnya bergabung dengan Laboratorium Rekayasa Bahan sebagai asisten lab. Selama menjadi asisten lab Rekayasa Bahan, penulis pernah melakukan beberapa penelitian tentang superkapasitor untuk dilombakan. Selain itu, penulis bertanggung jawab dalam pengembangan dan *maintenance website* untuk lab. Untuk kegiatan non-akademik, penulis aktif bermain basket untuk departemen Teknik Fisika dan sempat mewakili fakultas FT-IRS ITS dalam berbagai lomba basket di dalam dan luar kampus. Saat memasuki tahun ketiga perkuliahan penulis mulai tertarik dengan bidang rekayasa instrumentasi dan kontrol sehingga penulis melakukan kerja praktek di PT Yokogawa Indonesia pada Juni 2019 – September 2019 untuk belajar lebih banyak tentang instrumentasi dan sistem kontrol. Untuk kegiatan di luar kampus, penulis sering menyempatkan untuk belajar otodidak tentang pemrograman komputer dan dari mengenal dunia pemrograman komputer ini membuat penulis semenjak tahun terakhir perkuliahan akhirnya mulai menekuni bidang *data science*, khususnya *machine learning*. Pada Juni 2020, penulis telah menyelesaikan Tugas Akhir dengan judul **Perancangan Integrasi Sistem dengan Prediktor untuk Identifikasi Terjadinya IUU Fishing dan Transhipment Berbasis Data Automatic Identification System (AIS) dengan Neural Networks**.

Apabila pembaca ingin berdiskusi lebih lanjut mengenai Tugas Akhir ini, serta memberikan kritik dan saran maka dapat menghubungi penulis melalui *e-mail*: m.mukhlisjamali@gmail.com.