

Tugas Akhir

**OPTIMASI MODEL PREDIKSI *CARGO THROUGHPUT* DI SELURUH  
PELABUHAN INDONESIA BERDASARKAN RISIKO RANTAI PASOK:  
APLIKASI *ARTIFICIAL NEURAL NETWORK* (ANN)**

Diajukan untuk memenuhi salah satu syarat ujian  
guna memperoleh gelar Sarjana Teknik  
di Fakultas Teknik  
Universitas Hasanuddin



Disusun Oleh:

YESI SUKMAH

D071181005

**FAKULTAS TEKNIK  
DEPARTEMEN TEKNIK INDUSTRI  
UNIVERSITAS HASANUDDIN**

**GOWA**

**2022**

Tugas Akhir

**OPTIMASI MODEL PREDIKSI *CARGO THROUGHPUT* DI SELURUH  
PELABUHAN INDONESIA BERDASARKAN RISIKO RANTAI PASOK:  
APLIKASI *ARTIFICIAL NEURAL NETWORK* (ANN)**

Diajukan untuk memenuhi salah satu syarat ujian  
guna memperoleh gelar Sarjana Teknik  
di Fakultas Teknik  
Universitas Hasanuddin



Disusun Oleh:

YESI SUKMAH

D071181005

**FAKULTAS TEKNIK**

**DEPARTEMEN TEKNIK INDUSTRI**

**UNIVERSITAS HASANUDDIN**

**GOWA**

**2022**

LEMBAR PENGESAHAN

Judul Tugas Akhir:

**OPTIMASI MODEL PREDIKSI *CARGO THROUGHPUT* DI SELURUH  
PELABUHAN INDONESIA BERDASARKAN RISIKO RANTAI PASOK:  
APLIKASI *ARTIFICIAL NEURAL NETWORK* (ANN)**

Disusun Oleh:

**YESI SUKMAH**

**D071181005**

Tugas akhir ini diajukan untuk memenuhi salah satu persyaratan dalam menyelesaikan studi guna memperoleh gelar Sarjana Teknik pada Departemen Teknik Industri Fakultas Teknik Universitas Hasanuddin.

Gowa, 19 Oktober 2022

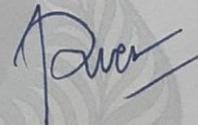
Telah diperiksa dan disetujui oleh:

Dosen Pembimbing I

Dosen Pembimbing II



Dr. Ir. Rosmalina Hanafi, M.Eng.  
NIP. 19660128 199103 2 003



Dr. Ir. Irwan Setiawan, ST., MT  
NIP. 19760602 200501 1 002

Mengetahui,

Ketua Departemen Teknik Industri Fakultas Teknik  
Universitas Hasanuddin



Ir. Kifayah Amar, S.T., M.Sc., Ph. D, IPU  
NIP. 19740621 200604 2 001

## PERNYATAAN KEASLIAN

Yang bertanda tangan dibawah ini

Nama : Yesi Sukmah

NIM : D071181005

Program Studi : Teknik Industri

Jenjang : S1

Judul Skripsi : Optimasi Model Prediksi *Cargo Throughput* Di Seluruh Pelabuhan Indonesia Berdasarkan Risiko Rantai Pasok: Aplikasi *Artificial Neural Network (ANN)*

Menyatakan dengan sesungguhnya bahwa skripsi ini merupakan hasil, pemikiran dan pemapanan asli dari saya sendiri. Saya tidak mencantumkan tanpa pengakuan orang lain atas seabagai bahan yang pernah diajukan untuk gelar atau ijazah pada Universitas Hasanuddin atau perguruan tinggi lainnya.

Apabila dikemudian hari terdapat penyimpanan dan ketidakbenaran dalam pernyataan ini, maka saya bersedia menerima sanksi akademik sesuai dengan peraturan yang berlaku di Universitas Hasanuddin.

Demikian pernyataan ini saya buat.

Gowa, 20 Oktober 2022

Yang membuat pernyataan



Yesi Sukmah

## ABSTRAK

Indonesia sebagai negara kepulauan menghadapi tantangan berat dalam mencapai efisiensi sistem logistik maritim. Permasalahan logistik masih menjadi kendala dalam meningkatkan daya saing dan memperlancar arus distribusi komoditas wilayah, selain itu logistik yang tidak efisien mengubah kinerja perdagangan karena dapat menimbulkan biaya yang mempengaruhi perkembangan ekonomi lokal. Pelabuhan Indonesia memegang simpul penting dalam rantai pasokan yang terintegrasi secara global, dan peran mereka telah berubah dari pusat transportasi atau distribusi menjadi pusat layanan logistik terintegrasi. Dalam mengukur kinerja pelabuhan, peran *cargo throughput* sangat penting dikarenakan bukan hanya indeks produksi paling dasar untuk mengukur pembangunan pelabuhan, tetapi juga referensi yang signifikan untuk mengatur produksinya, membuat rencana pengembangan dan konstruksi pelabuhan.

Penelitian ini dilakukan untuk memprediksi *cargo throughput* pelabuhan di seluruh Indonesia dengan melihat pola risiko *supply chain* menggunakan *Artificial Neural Network* agar dapat digunakan sebagai perancangan dan pengambilan keputusan dan antisipasi risiko yang menghambat proses logistik pelabuhan yang ada di Indonesia. Data yang digunakan dalam penelitian ini yakni data *timeseries cargo throughput* dari tahun 2007-2020 dan data kuesioner faktor risiko *supply chain* yang diambil dari Pelindo Regional II dan Regional III serta Kantor Kesyahbandaran dan Otoritas Pelabuhan Indonesia.

Hasil dari perhitungan menunjukkan bahwa dengan menggunakan *Artificial Neural Network* (ANN) dengan pengujian 10 model ANN, Model yang paling optimal untuk dilakukan prediksi pada *domestic ship call* yakni pada model 5 dengan selisih MSE *error* paling rendah sebesar 0.08%, untuk *domestic cargo loading* model yang paling optimal yakni pada model 5 dengan MSE *error* sebesar 0.15%, sedangkan untuk *domestic cargo unloading* model yang paling optimal yakni model 10 dengan MSE *error* sebesar 0.46%. Hasil prediksi keseluruhan *cargo throughput* menunjukkan pola yang hampir sama dengan aktual, dimana pola mendekati dengan nilai target. Untuk pola risiko berdasarkan estimasi dampaknya terhadap prediksi *cargo throughput* dengan menggunakan *Neural Network Clustering* (NNC) dengan visualisasi *Self-Organizing Map* (SOM) diperoleh risiko yang memiliki dampak pada *domestic ship calls* yakni variabel variabel  $X_{26}$ ,  $X_{34}$ ,  $X_{36}$ ,  $X_{51}$ ,  $X_{52}$ ,  $X_{62}$ ,  $X_{63}$ ,  $X_{64}$ ,  $X_{65}$ ,  $X_{71}$  dan  $X_{73}$ . Untuk *domestic cargo loading* yakni variabel  $X_{19}$ ,  $X_{26}$ ,  $X_{34}$ ,  $X_{51}$ ,  $X_{62}$ ,  $X_{63}$ ,  $X_{64}$ ,  $X_{65}$ ,  $X_{71}$  dan  $X_{73}$ . Sedangkan untuk *domestic cargo unloading* yakni  $X_{19}$ ,  $X_{26}$ ,  $X_{33}$ ,  $X_{34}$ ,  $X_{37}$ ,  $X_{51}$ ,  $X_{52}$ ,  $X_{62}$ ,  $X_{63}$ ,  $X_{64}$ ,  $X_{65}$ ,  $X_{71}$  dan  $X_{73}$

Kata Kunci: Pelabuhan Seluruh Indonesi, Prediksi, *Cargo Throughput*, *Artificial Neural Network*, *Self-Organizing Map*

## ABSTRACT

*Indonesia as an archipelagic country faces serious challenges in achieving the efficiency of the maritime logistics system. Logistics problems are still an obstacle in increasing competitiveness and facilitating the flow of regional commodity distribution, in addition to inefficient logistics changing trade performance because it can cause costs that affect local economic development. Indonesian ports hold important nodes in globally integrated supply chains, and their role has changed from being a transportation or distribution center to an integrated logistics service center. In measuring port performance, the role of cargo throughput is very important because it is not only the most basic production index to measure port development, but also a significant reference for regulating its production, making plans for port development and construction.*

*This research was conducted to predict cargo throughput of ports throughout Indonesia by looking at supply chain using Artificial Neural Networks so that they can be used as design and decision making and anticipate risks that hinder the port logistics process in Indonesia. The data used in this study are time series cargo throughput from 2007-2020 and supply chain taken from Pelindo Regional II and Regional III as well as the Indonesian Port Authority and Port Authority.*

*The results of the calculations show that by using the Artificial Neural Network (ANN) by testing 10 ANN Architecture models, the most optimal model for prediction on domestic ship calls model 5 with the lowest MSE error of 0.08%, for domestic cargo loading the most optimal model is model 5 with an MSE error of 0.15%, while for domestic cargo unloading the most optimal model is model 10 with an MSE error of 0.46%. The prediction results of the overall cargo throughput show a pattern that is almost the same as the actual, where the pattern is close to the target value. For risk patterns based on the estimated impact on cargo throughput predictions using Neural Network Clustering (NNC) with Self-Organizing Map (SOM) visualization, it is obtained that the risks that have an impact on domestic ship calls are the variables  $x_{26}$ ,  $x_{34}$ ,  $x_{36}$ ,  $x_{51}$ ,  $x_{52}$ ,  $x_{62}$ ,  $x_{63}$ ,  $x_{64}$ ,  $x_{65}$ ,  $x_{71}$  and  $x_{73}$ . For domestic cargo loading the variables are  $x_{19}$ ,  $x_{26}$ ,  $x_{34}$ ,  $x_{51}$ ,  $x_{62}$ ,  $x_{63}$ ,  $x_{64}$ ,  $x_{65}$ ,  $x_{71}$  and  $x_{73}$ . As for domestic cargo unloading namely  $x_{19}$ ,  $x_{26}$ ,  $x_{33}$ ,  $x_{34}$ ,  $x_{37}$ ,  $x_{51}$ ,  $x_{52}$ ,  $x_{62}$ ,  $x_{63}$ ,  $x_{64}$ ,  $x_{65}$ ,  $x_{71}$  and  $x_{73}$ .*

**Keywords:** *Port of All Indonesia, Prediction, Cargo Throughput, Artificial Neural Network, Self-Organizing Map*

## KATA PENGANTAR

Puji syukur penulis panjatkan atas kehadiran Tuhan Yang Maha Esa atas rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan tugas akhir ini dengan judul “Optimasi Model Prediksi *Cargo Throughput* Di Seluruh Pelabuhan Indonesia Berdasarkan Risiko Rantai Pasok: Aplikasi *Artificial Neural Network* (ANN)”.

Tugas akhir ini dapat selesai berkat bantuan baik pikiran, tenaga, dukungan, maupun doa dari banyak pihak. Pada halaman kata pengantar ini penulis ucapkan banyak terima kasih kepada:

1. Allah SWT sebagai pemberi rahmat dan pengabul doa-doa penulis hingga penulis mampu menyelesaikan tugas akhir ini.
2. Teruntuk diri sendiri.
3. Orang tua, kakak-kakak dan adik sebagai pendukung yang selalu memberikan semangat kepada penulis untuk segera menyelesaikan tugas akhir.
4. Bapak Ir. Kifayah Amar, S.T., M.Sc., Ph. D, IPU selaku Ketua Departemen Teknik Industri FT-UH.
5. Ibu Dr. Ir. Rosmalina Hanafi, M.Eng selaku pembimbing I dan Bapak Dr. Ir. Irwan Setiawan, ST.,MT selaku pembimbing II yang senantiasa dengan sabar meluangkan waktu serta memberi bantuan kepada penulis dalam menyelesaikan tugas akhir ini.
6. Bapak Dr. Ir. Syarifuddin M. Parenreng,ST.,MT.,IPU dan Ibu Dwi Handayani,ST.,MT selaku dosen penguji yang telah memberikan masukan dan saran dalam perbaikan tugas akhir ini.

7. Bapak/Ibu Dosen serta Staf Departemen Teknik Industri FT-UH yang telah berjasa dalam membantu penulis menyelesaikan masa studinya.

Penulis menyadari bahwa dalam penulisan tugas akhir ini masih banyak kekurangan dan kesalahan, oleh karena itu kritik dan saran sangat diharapkan untuk membangun dan menyempurnakan tugas akhir ini. Semoga tugas akhir ini dapat bermanfaat bagi semua pihak yang membutuhkan.

Gowa, 20 Oktober 2022

Penulis



## DAFTAR ISI

|   |     |
|---|-----|
| LEMBAR PENGESAHAN .....   | iii |
| PERNYATAAN KEASLIAN .....   | iv  |
| ABSTRAK .....   | v   |
| ABSTRACT .....  | vi  |
| KATA PENGANTAR.....   | vii |
| DAFTAR ISI.....   | ix  |
| DAFTAR GAMBAR.....  | xii |
| DAFTAR TABEL .....  | xiv |
| NOTASI SINGKATAN .....  | xv  |
| BAB I PENDAHULUAN.....  | 1   |
| 1.1 Latar Belakang.....   | 1   |
| 1.2 Rumusan Masalah .....   | 6   |
| 1.3 Tujuan Penelitian.....  | 6   |
| 1.4 Manfaat Penelitian.....   | 7   |
| 1.5 Batasan Masalah .....   | 7   |
| 1.6 Sistematika Penelitian .....  | 8   |
| BAB II TINJAUAN PUSTAKA.....  | 10  |
| 2.1 Dasar Teori.....  | 10  |
| 2.1.1 Optimasi .....  | 10  |
| 2.1.2 <i>Risk Supply Chain</i> .....  | 10  |
| 2.1.3 Jaringan Syaraf Tiruan (JST)/ <i>Artificial Neural Network</i> (ANN)<br>..... | 16  |
| 2.1.4 Algoritme <i>Backpropagation</i> .....  | 20  |
| 2.1.5 Fungsi Aktivasi <i>Backpropagation Neural Network</i> (BPNN).....<br>.....    | 25  |
| 2.1.6 <i>Parameter BPNN</i> .....   | 28  |
| 2.1.7 <i>Genetic Algorithm</i> (GA).....  | 29  |
| 2.1.8 Integrasi GA dan ANN.....   | 31  |
| 2.1.9 Performa Prediksi .....   | 32  |
| 2.1.10 <i>Self-Organizing Map</i> (SOM) .....                                       | 34  |

|  |           |
|--|-----------|
| 2.1.11 Pelabuhan Indonesia .....   | 35        |
| 2.1.12 MATLAB.....   | 38        |
| <b>2.2 Penelitian Terdahulu .....</b>  | <b>42</b> |
| <b>BAB III METODOLOGI PENELITIAN .....</b>   | <b>46</b> |
| <b>3.1 Objek Penelitian.....</b>   | <b>46</b> |
| <b>3.2 Tempat Penelitian.....</b>  | <b>46</b> |
| <b>3.3 Jenis Data.....</b>   | <b>47</b> |
| <b>3.4 Metode Pengumpulan Data.....</b>  | <b>48</b> |
| <b>3.5 Kerangka Pikir Penelitian.....</b>  | <b>49</b> |
| <b>3.6 Flowchart Penelitian .....</b>  | <b>53</b> |
| 3.6.1 Studi Literatur.....   | 54        |
| 3.6.2 Pengumpulan Data .....   | 54        |
| 3.6.3 Pengolahan Data.....   | 54        |
| 3.6.4 Analisis dan Pembahasan .....  | 55        |
| 3.6.5 Penarikan Kesimpulan.....  | 56        |
| <b>BAB IV PENGUMPULAN DAN PENGOLAHAN DATA.....</b>   | <b>57</b> |
| <b>4.1 Pengumpulan Data .....</b>  | <b>57</b> |
| 4.1.1 Data <i>Cargo Throughput</i> Pelabuhan Indonesia .....                               | 57        |
| 4.1.2 Data Kuesioner Risiko <i>Supply Chain</i> Pelabuhan .....                            | 59        |
| <b>4.2 Pengolahan Data .....</b>   | <b>64</b> |
| 4.2.1 Model ANN.....   | 64        |
| 4.2.2 Implementasi Aplikasi ANN.....   | 66        |
| 4.2.3 Model Prediksi ANN.....  | 71        |
| 4.2.4 Prediksi <i>Cargo Throughput</i> .....   | 73        |
| 4.2.5 Prediksi <i>Cargo Throughput</i> dengan Pola Faktor Risiko <i>Supply Chain</i> ..... | 87        |
| <b>BAB V HASIL DAN PEMBAHASAN .....</b>  | <b>98</b> |
| <b>5.1 Hasil Implementasi Model .....</b>  | <b>98</b> |
| 5.1.1 <i>Domestic Ship Calls</i> .....   | 98        |
| 5.1.2 <i>Domestic Cargo Loading</i> .....  | 100       |
| 5.1.3 <i>Domestic Cargo Unloading</i> .....  | 102       |

|  |            |
|--|------------|
| <b>5.2 Analisa Hasil Prediksi <i>Next Period</i></b> .....                     | 104        |
| 5.2.1 <i>Domestic Ship Calls</i> .....   | 105        |
| 5.2.2 <i>Domestic Cargo Loading</i> .....                                      | 106        |
| 5.2.3 <i>Domestic Cargo Unloading</i> .....                                    | 108        |
| <b>5.3 Analisa Prediksi dengan Melihat Faktor Risiko <i>Supply Chain</i></b>   | 110        |
| <b>BAB VI KESIMPULAN</b> .....   | <b>119</b> |
| 6.1 Kesimpulan.....  | 119        |
| 6.2 Saran .....  | 121        |
| <b>DAFTAR PUSTAKA</b> .....  | <b>122</b> |
| <b>LAMPIRAN</b> .....  | <b>126</b> |
| <b>Lampiran 1. Data <i>Input</i> (Data <i>Time Series</i> 2007-2021)</b> ..... | 127        |
| <b>Lampiran 2. Model Arsitektur ANN</b> .....                                  | 170        |
| <b>Lampiran 3. Hasil <i>Running</i> Model ANN</b> .....                        | 177        |
| <b>Lampiran 4. Kuesioner Penelitian</b> .....                                  | 270        |
| <b>Lampiran 5. Hasil Prediksi</b> .....  | 277        |
| <b>Lampiran 6. ANN Task</b> .....  | 302        |



## DAFTAR GAMBAR

|  |    |
|--|----|
| Gambar 2. 1 Perbandingan mode operasi perusahaan pelabuhan dan rantai pasokan manufaktur ..... | 13 |
| Gambar 2. 2 Jaringan Saraf Manusia .....   | 17 |
| Gambar 2. 3 <i>Multi Layer ANN</i> .....   | 18 |
| Gambar 2. 4 <i>ANN Backpropagation</i> .....   | 20 |
| Gambar 2. 5 Fungsi <i>Binary Sigmoid</i> .....   | 26 |
| Gambar 2. 6 Fungsi <i>Bipolar Sigmoid</i> .....  | 27 |
| Gambar 2. 7 Fungsi <i>Bipolar Treshold</i> .....   | 27 |
| Gambar 2. 8 Fungsi <i>Linear</i> .....   | 28 |
| Gambar 2. 9 <i>Gradient Descent</i> .....  | 28 |
| Gambar 2. 10 <i>Flowchart</i> algoritma genetika .....   | 32 |
| Gambar 2. 11 Kombinasi GA-ANN.....   | 32 |
| Gambar 2. 12 Struktur SOM .....  | 35 |
| Gambar 3. 1 Kerangka Pikir Penelitian.....   | 49 |
| Gambar 3. 2 <i>Flowchart</i> Penelitian .....  | 53 |
| Gambar 4. 1 Hasil Uji Relibitas .....  | 64 |
| Gambar 4. 2 Fungsi menampilkan data kuantitatif .....  | 66 |
| Gambar 4. 3 <i>Syntax</i> Fungsi <i>Normalization</i> .....                                    | 67 |
| Gambar 4. 4 <i>Syntax</i> Fungsi <i>Testing</i> dan <i>Training</i> .....                      | 68 |
| Gambar 4. 5 Fungsi <i>Network Structure</i> .....  | 70 |
| Gambar 4. 6 Proses <i>Training</i> Model ANN 5 <i>Domestic Ship Calls</i> .....                | 74 |
| Gambar 4. 7 Hasil <i>Testing</i> Model ANN 5 <i>Domestic Ship Call</i> .....                   | 75 |
| Gambar 4. 8 Pola Hubungan <i>Training</i> Model ANN 5 <i>Domestic Ship Calls</i> .....         | 76 |
| Gambar 4. 9 Pola Hubungan <i>Testing</i> Model ANN 5 <i>Domestic Ship Calls</i> .....          | 77 |
| Gambar 4. 10 <i>Trend</i> Hasil Prediksi Model ANN 5 <i>Domestic Ship Calls</i> .....          | 77 |
| Gambar 4. 11 Proses <i>Training</i> Model ANN 5 <i>Domestic Cargo Loading</i> .....            | 78 |
| Gambar 4. 12 Hasil <i>Testing</i> Model ANN 5 <i>Domestic Cargo Loading</i> .....              | 79 |
| Gambar 4. 13 Pola Hubungan <i>Training</i> Model ANN 5 <i>Domestic Cargo Loading</i> .....     | 80 |
| Gambar 4. 14 Pola Hubungan <i>Testing</i> Model ANN 5 <i>Domestic Cargo Loading</i> .....      | 81 |

|   |     |
|---|-----|
| Gambar 4. 15 Trend Hasil Prediksi Model ANN 5 <i>Domestic Cargo Loading</i> ....                | 82  |
| Gambar 4. 16 Proses <i>Training</i> Model ANN 5 <i>Domestic Cargo Unloading</i> .....           | 83  |
| Gambar 4. 17 Hasil <i>Testing</i> Model ANN 5 <i>Domestic Cargo Unloading</i> .....             | 84  |
| Gambar 4. 18 Pola Hubungan <i>Training</i> Model ANN 5 <i>Domestic Cargo Unloading</i><br>..... | 85  |
| Gambar 4. 19 Pola Hubungan <i>Testing</i> Model ANN 5 <i>Domestic Cargo Unloading</i><br>.....  | 86  |
| Gambar 4. 20 Trend Hasil Prediksi Model ANN 5 <i>Domestic Cargo Unloading</i>                   | 87  |
| Gambar 4. 21 SOM <i>Neighbor Distance</i> .....   | 88  |
| Gambar 4. 22 <i>Plot the weight planes</i> .....  | 89  |
| Gambar 4. 23 SOM <i>Neighbor Distance</i> .....   | 91  |
| Gambar 4. 24 <i>Plot the weight planes</i> .....  | 92  |
| Gambar 4. 25 SOM <i>Neighbor Distance</i> .....   | 94  |
| Gambar 4. 26 <i>Plot the weight planes</i> .....  | 95  |
| Gambar 5. 1 MSEtr <i>Domestic Ship Calls</i> .....  | 99  |
| Gambar 5. 2 MSEts <i>Domestic Ship Calls</i> .....  | 99  |
| Gambar 5. 3 Selisih MSE <i>Error</i> .....  | 100 |
| Gambar 5. 4 MSEtr <i>Cargo Loading</i> .....  | 101 |
| Gambar 5. 5 MSEts <i>Cargo Loading</i> .....  | 101 |
| Gambar 5. 6 Selisih MSE <i>error</i> .....  | 102 |
| Gambar 5. 7 MSEtr <i>Domestic Cargo Unloading</i> .....   | 103 |
| Gambar 5. 8 MSEts <i>Domestic Cargo Unloading</i> .....   | 103 |
| Gambar 5. 9 MSE <i>error Domestic Cargo Unloading</i> .....                                     | 104 |
| Gambar 5. 10 Model ANN 5 .....  | 105 |
| Gambar 5. 11 Prediksi <i>Ship Calls</i> .....   | 106 |
| Gambar 5. 12 Model ANN 5 .....  | 107 |
| Gambar 5. 13 Prediksi <i>Cargo Loading</i> .....  | 108 |
| Gambar 5. 14 Model ANN 10 .....   | 109 |
| Gambar 5. 15 Prediksi <i>Cargo unloading</i> .....  | 110 |

## DAFTAR TABEL

|  |     |
|--|-----|
| Tabel 2. 1 Perbandingan antara perusahaan pelabuhan dan rantai pasokan manufaktur .....    | 12  |
| Tabel 2. 2 Penelitian Terdahulu .....  | 43  |
| Tabel 4. 1 Hasil Uji Validitas.....  | 62  |
| Tabel 4. 2 Model ANN.....  | 65  |
| Tabel 4. 3 Hasil <i>Running Model ANN Domestic Ship Calls</i> .....                        | 71  |
| Tabel 4. 4 Hasil <i>Running Model ANN Domestic Cargo Loading</i> .....                     | 72  |
| Tabel 4. 5 Hasil <i>Running Model ANN Domestic Cargo Unloading</i> .....                   | 73  |
| Tabel 4. 6 Skala Klaster Faktor Risiko <i>Supply Chain Domestic Ship Call</i> .....        | 90  |
| Tabel 4. 7 Estimasi Pengelompokan SOM Ship Calls.....                                      | 91  |
| Tabel 4. 8 Skala Klaster Faktor Risiko <i>Supply Chain Domestic Cargo Loading</i> .....    | 93  |
| Tabel 4. 9 Estimasi Pengelompokan SOM <i>Cargo Loading</i> .....                           | 94  |
| Tabel 4. 10 Skala Kluster Faktor Risiko <i>Supply Chain Domestic Cargo Unloading</i> ..... | 96  |
| Tabel 4. 11 Estimasi Pengelompokan SOM <i>Cargo Unloading</i> .....                        | 97  |
| Tabel 5. 1 Estimasi skala risiko <i>supply chain</i> pada <i>ship calls</i> .....          | 111 |
| Tabel 5. 2 Estimasi skala risiko <i>supply chain</i> pada <i>cargo loading</i> .....       | 113 |
| Tabel 5. 3 Estimasi skala risiko <i>supply chain</i> pada <i>cargo unloading</i> .....     | 114 |

## NOTASI SINGKATAN

| Istilah   | Arti   |
|---|--|
| Prediksi/pre.dik.si                                     | : Ramalan; prakiraan   |
| Optimasi  | : Proses, cara, pembuatan untuk menghasilkan yang paling baru  |
| ANN ( <i>Artificial Neural Network</i> )                | : Sebuah sistem pemrosesan data dengan meniru cara kerja sistem saraf manusia.   |
| ARIMA ( <i>Autoregresif Integrated Moving Average</i> ) | : Model yang secara penuh mengabaikan independen variabel dalam membuat peramalan. ARIMA menggunakan nilai masa lalu dan sekarang dari variabel dependen untuk menghasilkan peramalan jangka pendek yang akurat.   |
| <i>Cargo Throughput</i>                                 | : Kegiatan/aktivitas terhadap proses muatan/bongkar (masuk/keluar) barang pada pelabuhan,  |
| <i>Domestic Ship Calls</i>                              | : Kunjungan kapal ke pelabuhan   |
| <i>Domestic Cargo Loading</i>                           | : Proses muat <i>cargo</i> di pelabuhan  |
| <i>Domestic Cargo Unloading</i>                         | : Proses boongkar <i>cargo</i> di pelabuhan  |
| <i>Supply Chain</i>                                     | : Rantai atau jaringan yang menghubungkan antara perusahaan dengan <i>supplier</i> .   |
| PT PELINDO  | : Badan Usaha Milik Negara (BUMN) di bidang jasa kepelabuhanan, yang merupakan operator pelabuhan terbesar di Indonesia.   |
| Kantor Kesyahbandaran dan Otoritas Pelabuhan (KSOP)     | : Unit Pelaksanaan Teknis (UPT) di lingkungan Direktorat Jenderal Perhubungan Laut yang berada dan bertanggung jawab atas pengawasan dan penegakan hukum di bidang keselamatan dan keamanan pelayaran, dan kegiatan kepelabuhanan.                           |
| Risiko ( <i>Risk</i> )/ri.si.ko                         | : Akibat yang kurang menyenangkan (merugikan, membahayakan) dari suatu perbuatan atau tindakan   |
| <i>Ekspor</i> / eks.por                                 | : Pengiriman barang dagangan ke luar negeri  |
| <i>Impor</i> / im.por                                   | : Pemasukan barang dan sebagainya dari luar negeri   |
| <i>Input Layer</i>                                      | : Lapisan yang menghubungkan sumber data ke jaringan pemrosesan.   |
| <i>Hidden Layer</i>                                     | : Lapisan perambat variabel-variabel input untuk mendapatkan hasil <i>output</i> yang lebih mendekati keinginan  |
| <i>Output Layer</i>                                     | : Hasil keluaran dari pemrosesan data ANN  |
| <i>Supervised Learning</i>                              | : Sekumpulan data input dan terdapat contoh keluaran ( <i>output/target</i> ) yang diharapkan  |
| <i>Unsupervised Learning</i>                            | : Sekumpulan data input tanpa terdapat contoh keluaran ( <i>output</i> ).  |
| <i>Genetic Algorithm</i>                                | : Pendekatan modern optimasi numerik yang didasarkan pada teori Charles Darwin tentang " <i>survival of the fittest</i> " dan "seleksi alam"   |
| <i>Backpropagation Algorithm</i>                        | : Salah satu algoritma yang digunakan pada ANN <i>Multi-Layer Network</i> dengan pembelajaran terawasi dimana dilakukan penyesuaian bobot secara berulang untuk mendapatkan nilai <i>error</i> terendah antara hasil prediksi dengan target yang diinginkan. |
| <i>Tansig</i>   | : fungsi <i>sigmoid</i> tangen dimana fungsi ini yang akan menerjemahkan nilai <i>output</i> antara 1 dan -1.  |
| <i>Training</i>   | : Proses pembelajaran data input   |
| <i>Testing</i>  | : Proses pengujian data input  |
| <i>Iterasi/ite.ra.si</i>                                | : Perulangan   |
| <i>Self-Organizing Map (SOM)</i>                        | : Salah satu metode dalam jaringan syaraf tiruan yang menggunakan pembelajaran tanpa pengarahan  |

---

|                                 |  |
|---------------------------------|--|
| <i>Pelabuhan Non commercial</i> | : Pelabuhan yang tidak di usahakan adalah pelabuhan dalam pembinaan pemerintah yang sesuai dengan kondisi, kemampuan dan perkembangan potensinya masih lebih menonjol sifat ke pemerintahannya dan atau yang belum ditetapkan sebagai pelabuhan yang diusahakan. |
| <i>Pelabuhan Commercial</i>     | : Pelabuhan dalam pembinaan pemerintah yang sesuai dengan kondisi, kemampuan dan perkembangan potensinya diusahakan menurut asas-asas/hukum perusahaan atas ketetapan Menteri.   |
| <i>Random Permutation</i>       | : Fungsi matematika secara acak memungkinkan urutan atau mengembalikan rentang yang diizinkan  |
| <i>Error</i>                    | : Suatu informasi yang menunjukkan penyimpangan terhadap kriteria yang ditetapkan.   |

---



# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Prediksi saat ini sudah menjadi hal yang umum digunakan di dunia industri dan juga di instansi pemerintah, seperti memprediksi permintaan produksi, memprediksi fluktuasi persediaan, memprediksi penggunaan internet di suatu daerah, dan memprediksi penjualan produk. Hal ini juga berlaku di instansi pemerintah, seperti prakiraan penerimaan pajak daerah, prakiraan kecelakaan lalu lintas, prakiraan kepadatan lalu lintas, prakiraan penyebaran penyakit, dan seterusnya. Menurut Barry Render and Jay Heizer (2001) menjelaskan bahwa peramalan adalah seni ilmu memprediksi peristiwa masa depan menggunakan data masa lalu dan memproyeksikannya ke masa depan menggunakan pendekatan matematika (Razak Azhar, 2017).

Menurut data Bank Dunia (2018) dalam (Amin et al., 2021), Indonesia sebagai negara kepulauan menghadapi tantangan berat dalam mencapai efisiensi sistem logistik maritim. Indonesia menduduki peringkat ke-46 untuk kinerja logistik di dunia atau nomor 4 di Asia Tenggara, menyusul Singapura (7), Thailand (32), dan Malaysia (41). Hal tersebut menggambarkan bahwa permasalahan logistik masih menjadi kendala dalam meningkatkan daya saing dan memperlancar arus distribusi komoditas antar wilayah. Selain itu logistik yang tidak efisien mengubah kinerja perdagangan karena menimbulkan biaya yang mempengaruhi perkembangan ekonomi lokal (Cho, 2014). Permasalahan logistik dapat dilihat secara luas dengan melihat manajemen rantai pasok yakni

melihat mata rantai penyediaan barang dari pemasok, perusahaan sampai dengan konsumen (Setiawan & Suhardi, 2005).

Berdasarkan pernyataan Carbone dan Martino (2003); Song dan Panayides (2007) di bawah integrasi ekonomi global, pelabuhan tidak lagi dianggap sebagai simpul tunggal; sebaliknya, posisi kompetitifnya lebih bergantung pada perannya dalam rantai pasokan (Jiang et al., 2018). Oleh karena itu, perusahaan pelabuhan *modern* telah menjadi simpul penting dalam rantai pasokan terintegrasi global, dan peran mereka telah berubah dari pusat transportasi atau distribusi menjadi pusat layanan logistik terintegrasi.

*Cargo throughput* pelabuhan mengacu pada jumlah total kargo melalui saluran air masuk dan keluar di kawasan pelabuhan (*waterways into and out of the port area*). *Cargo throughput* pelabuhan merupakan indikator penting untuk mengukur tingkat manajemen pelabuhan dan skala operasi (Chen et al., 2016). *Cargo throughput* sangat penting untuk sebuah pelabuhan, bukan hanya indeks produksi paling dasar untuk mengukur pembangunan pelabuhan, tetapi juga referensi yang signifikan untuk mengatur produksinya, membuat rencana pengembangan dan konstruksinya. Sementara itu, jumlah *cargo throughput* dapat mencerminkan situasi ekonomi dan tingkat perkembangan kota pelabuhan (Zhang et al., 2013).

Dalam situasi ini pentingnya penguatan rantai pasok pelabuhan dengan melihat dan mempertimbang risiko pelabuhan yang dapat mengganggu rantai pasok pelabuhan. Menurut penelitian dan analisa oleh Shiu W.W, Lu C S Tseng WJ dan Yang YL (2000) bahwa dari keseluruhan kejadian kecelakaan

dalam *supply chain management* pelabuhan, 25 % kecelakaan terjadi di *container terminal*. Dan kejadian kecelakaan terbesar disebabkan oleh kelalaian manusia (Putu Artama Wiguna, 2014).

Penelitian ini dilaksanakan di seluruh pelabuhan Indonesia dengan melakukan prediksi *cargo throughput* dengan melibatkan risiko pada pelabuhan. Prediksi *Cargo throughput* secara akurat memainkan peran penting dalam menyesuaikan arah pengembangan pelabuhan, menyiapkan rencana operasi pelabuhan yang wajar, merencanakan pembangunan infrastruktur pelabuhan dan meningkatkan kapasitas pelabuhan. Hal Ini memberikan dasar kuantitatif untuk manajemen dan pengambilan keputusan.

Dalam studi penilaian risiko rantai pasokan, banyak ahli menggunakan *Grey Method*, sementara beberapa ahli menggunakan penilaian jaringan saraf tiruan. Selain metode pendekatan ilmiah, beberapa ilmuwan menerapkan metode baru untuk menilai risiko rantai pasokan. Misalnya, Zhong (2012) menganalisis penerapan model elemen bahan ekspansi bobot variabel untuk penilaian risiko rantai pasokan; Xu dan Tian (2004) dan Yen dkk (2013) Mengedepankan fungsi kerugian untuk menilai risiko rantai pasokan; Shu dkk (2014) Mengevaluasi risiko rantai pasokan melalui algoritma mesin vektor pendukung; Zheng (2015) menggambarkan hubungan timbal balik antara faktor risiko dan risiko, serta di antara peristiwa risiko, menggunakan angka Bayesian (Jiang et al., 2018). Dalam meramalkan *cargo throughput* peneliti menggunakan metode *Artificial Neural Network* (ANN) dengan melihat faktor risiko *supply chain* pelabuhan dengan menggunakan data deret

waktu (*time series*) untuk melakukan prediksi terhadap *cargo throughput* pelabuhan Indonesia dan data kuesioner untuk melihat risiko pada pelabuhan Indonesia.

Sebelumnya telah dilakukan penelitian penerapan ANN terhadap prediksi yang telah berhasil diterapkan. Misalnya pada penelitian prediksi indeks harga saham Bursa Efek Indonesia, telah berhasil dibuat model prediksi IHSG menggunakan metode Jaringan Syaraf Tiruan (JST) dengan algoritma *Backpropagation* (BP) dan algoritma *Backpropagation* yang dikombinasikan dengan algoritma *Particle Swarm Optimization* (PSO). Pembuatan model dilakukan dengan mengatur parameter yang telah disesuaikan untuk mendapatkan hasil waktu komputasi, *error* model dan *error* prediksi yang minimal (Wartati & Masrurroh, 2017). Mataram (2008) menyatakan prediksi beban harian untuk hari-hari libur umat hindu di Bali yang kondisinya tidak tentu, sulit dilakukan oleh metode prediksi konvensional. Pada penelitian ini diusulkan prediksi dengan metode *artificial neural network*. Kelebihan metode ini dapat dengan mudah memformulasikan pengalaman dan pengetahuan peramal. Hasil prediksi memperlihatkan *error* rata-rata sangat kecil, yaitu di bawah 1 %. Adepoju dkk (2007) menyatakan data input yang dipakai untuk jaringan syaraf tiruan seperti data beban harian, data beban mingguan. Kesalahan yang terjadi mencapai sebesar 2.54 % saat jaringan dilatih untuk menguji data beban mingguan. Ini menggambarkan tingkat keakuratannya tinggi dalam prediksi beban. Pderal dan young (2008) menyatakan hubungan *non linier* di antara

beban dan suhu diidentifikasi melalui pendekatan mekanistik yang berdatabase. Jaringan syaraf tiruan dipergunakan untuk mengidentifikasi hubungan *non linier*. Hasil dari *training* sistem jaringan syaraf tiruan sangat baik dalam prediksi ini (Binoto et al., 2015). Menurut Suhada (2009) dalam (Fany Achmalia et al., 2020), prediksi dengan menggunakan pendekatan ANN memberikan nilai MSE yang sangat kecil mendekati nol. Hal ini berarti bahwa ANN memiliki akurasi yang sangat tinggi dalam melakukan prediksi terhadap suatu model sistem. Menurut Walid, dkk (2015) dalam (Fany Achmalia et al., 2020) prediksi menggunakan ANN menghasilkan hasil yang jauh lebih baik dibandingkan dengan model ARIMA (*Autoregressive Integrated Moving Average*). Menurut Kohzadi, dkk (1996) dalam (Fany Achmalia et al., 2020) prediksi dengan ANN jauh lebih akurat dibandingkan dengan model tradisional ARIMA. Alasan mengapa model ANN lebih baik daripada model ARIMA karena data mengandung perilaku *non linier* yang tidak dapat sepenuhnya ditangkap oleh model ARIMA linier.

Berdasarkan permasalahan di atas, penerapan model *Artificial Neural Network* (ANN) belum pernah diterapkan pada prediksi sistem operasional *cargo throughput* di pelabuhan, penerapan model ANN dalam penelitian terdahulu dianggap tepat pada penelitian yang memiliki pola hubungan *non linear* sehingga peneliti mencoba menerapkan model tersebut dalam penelitian yang berjudul **“Optimasi Model Prediksi *Cargo Throughput* Di Seluruh Pelabuhan Indonesia Berdasarkan Risiko Rantai Pasok:**

**Aplikasi *Artificial Neural Network* (ANN)**” dengan berdasarkan kepada studi pustaka dan beberapa penelitian terdahulu.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, adapun rumusan masalah pada penelitian ini adalah sebagai berikut:

1. Bagaimana menentukan model optimal *Artificial Neural Network*?
2. Bagaimana mengaplikasikan model optimal yang telah ditentukan sebelumnya untuk melakukan prediksi *cargo throughput* tahun berikutnya?
3. Bagaimana pola hubungan faktor risiko *supply chain* terhadap prediksi *cargo throughput* pada pelabuhan seluruh Indonesia?

## 1.3 Tujuan Penelitian

Berdasarkan rumusan masalah tersebut, adapun tujuan dari penelitian ini adalah sebagai berikut:

1. Menentukan model optimal *Artificial Neural Network*.
2. Mengaplikasikan model optimal yang telah ditentukan sebelumnya untuk melakukan prediksi *cargo throughput* tahun berikutnya.
3. Melihat pola hubungan faktor risiko *supply chain* terhadap prediksi *cargo throughput* pada pelabuhan seluruh Indonesia

## 1.4 Manfaat Penelitian

Adapun manfaat yang dapat diperoleh dari penelitian ini adalah sebagai berikut:

### 1. Bagi Instansi Bersangkutan

- a. Diharapkan dengan penelitian ini dapat mendorong optimalisasi, efektivitas dan efisiensi alur logistik maritim Indonesia.
- b. Model, hasil Analisis, dan aplikasi prediksi yang dihasilkan dalam penelitian ini diharapkan dapat digunakan oleh instansi bersangkutan untuk memprediksi *cargo throughput* pada pelabuhan dengan mempertimbangkan risiko pelabuhan.

### 2. Bagi Mahasiswa

Memahami teori dan penerapan ilmu pengetahuan dan kajian ilmiah akademis dalam pemecahan masalah di lingkungan masyarakat, pemerintah dan perusahaan khususnya bidang Teknik Prediksi, Pengendalian Data dan Analisa bisnis.

## 1.5 Batasan Masalah

Dalam penelitian ini, diuraikan batasan permasalahan yang akan dibahas dalam tugas akhir ini agar materi tidak menyimpang dari topik yang telah ditetapkan. Penelitian ini dilakukan untuk melakukan prediksi terhadap *cargo throughput* di seluruh pelabuhan Indonesia dengan mempertimbangkan risiko (*Risk Supply Chain*) yang terjadi pada alur logistik pelabuhan Indonesia dengan menggunakan model prediksi *Artificial Neural Network* (ANN). Pada penelitian ini dilakukan pengambilan data *time series* diantaranya data *time*

*series* perusahaan PT PELINDO yaitu data *cargo throughput* untuk pelabuhan *commercial* dan Kantor Kesyahbandaran dan Otoritas Pelabuhan Indonesia untuk *noncommercial* dari tahun 2007-2020. Sedangkan untuk data kuesioner risiko *supply chain* diambil pada beberapa pelabuhan di Indonesia diantaranya di Kantor Kesyahbandaran dan Otoritas Pelabuhan Indonesia, Pelindo Regional II dan Pelindo Regional III dengan mewawancarai *stakeholder* bagian operasional pelabuhan, bagian Teknik, dan bagian Lalu Lintas Kepelabuhanan dan Angkutan Laut.

#### **1.6 Sistematika Penelitian**

Untuk mempermudah dalam memahami alur penelitian, maka penelitian ini terdiri dari beberapa bab dengan sistematika penulisan sebagai berikut:

##### **BAB I PENDAHULUAN**

Bab pertama menjelaskan latar belakang dilakukannya penelitian serta terdapat penjelasan mengenai rumusan masalah yang dibahas dalam penelitian, batasan masalah, manfaat serta pembaca sistematika penulisan laporan akhir.

##### **BAB II TINJAUAN PUSTAKA**

Bab ke-2 memuat penjelasan dan dasar teori yang digunakan dalam melakukan penelitian untuk membantu pemahaman dalam mengelola dan analisis data. Landasan teori diperoleh dari studi literatur melalui buku, jurnal, dan skripsi.

### **BAB III METODOLOGI PENELITIAN**

Bab ke-3 berisi tentang tempat dan waktu penelitian dilakukan, subjek dan objek penelitian, data penelitian (jenis-jenis data, metode pengambilan data dan pengukuran data).

### **BAB IV PENGUMPULAN DAN PENGOLAHAN DATA**

Bab ke-4 berisi tentang data-data yang digunakan dan berkaitan dengan objek penelitian. Bab ini juga menjelaskan proses implementasi hasil dari tahapan perancangan, seperti penggunaan tools Matlab dan hasil dari proses prediksi.

### **BAB V HASIL DAN PEMBAHASAN**

Bab ke-5 berisi tentang hasil dan pembahasan yang didapatkan pada pengolahan data hasil penelitian yang telah dilakukan sebelumnya.

### **BAB VI PENUTUP**

Bab ke-6 berisi tentang pernyataan singkat yang dideskripsikan berdasarkan hasil penelitian yang dilakukan untuk menjawab tujuan penelitian. Pada bab ini berisikan poin kesimpulan dan saran dari hasil penelitian.

## BAB II

### TINJAUAN PUSTAKA

Bab ini menjelaskan mengenai dasar teori yang dijadikan sebagai acuan atau landasan dalam pengerjaan penelitian ini dan penelitian terdahulu. Landasan teori akan memberikan gambaran secara umum dari landasan penelitian ini.

#### 2.1 Dasar Teori

Konsep atau teori yang dijadikan sebagai acuan dalam penulisan tugas akhir ini dijelaskan pada bagian sub-bab dasar teori.

##### 2.1.1 Optimasi

Optimasi adalah menemukan solusi yang berada dalam daerah yang mungkin (*feasible region*) yang memiliki nilai minimum atau maksimum dari fungsi objektif. Optimasi merupakan permasalahan komputasional yang bertujuan untuk menemukan solusi terbaik dari beberapa solusi yang mungkin dari sejumlah alternatif solusi dengan memenuhi sejumlah batasan (*constraints*) (Devita & Wibawa, 2020). Optimasi merupakan proses mencari solusi optimal untuk masalah tertentu yang menarik, dan proses pencarian ini dapat dilakukan dengan menggunakan beberapa agen yang pada dasarnya membentuk sistem (Styawati et al., 2021).

##### 2.1.2 Risk Supply Chain

Studi tentang risiko rantai pasokan berfokus pada tiga aspek: identifikasi risiko rantai pasokan, penilaian risiko rantai pasokan, dan pencegahan dan pengendalian risiko rantai pasokan (Jiang et al., 2018).

Dalam penelitian identifikasi risiko rantai pasokan, para ahli telah mengidentifikasi faktor risiko dari perspektif yang berbeda. Menurut Hallikas, dkk (2002) Dalam (Jiang et al., 2018) beberapa ahli mempertimbangkan perspektif penawaran dan permintaan, dan membagi risiko rantai pasokan menjadi risiko permintaan dan pasokan. Ghadge, dkk (2012) menunjuk pada identifikasi faktor risiko berdasarkan struktur rantai pasokan, dan membagi risiko rantai pasokan menjadi risiko modal, risiko arus informasi, dan risiko logistik. Mandal (2011) mencatat bahwa risiko rantai pasokan terutama berasal dari ketidakpastian permintaan rantai pasokan dan organisasi rantai pasokan yang tidak sempurna.

Rantai pasokan perusahaan pelabuhan berbeda dari rantai pasokan manufaktur, seperti yang dirangkum dalam tabel berikut (Jiang et al., 2018).

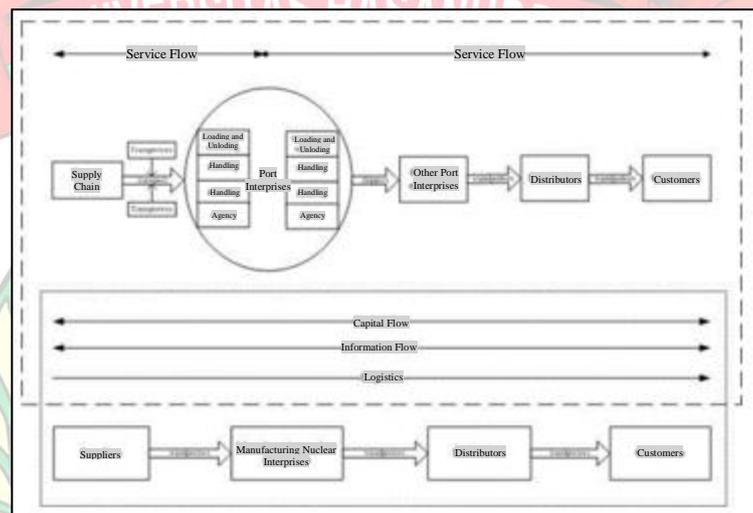
**Tabel 2. 1 Perbedaan antara perusahaan pelabuhan dan rantai pasokan manufaktur**

| <b>Aspek</b>                    | <b>Rantai pasokan Perusahaan Pelabuhan</b>   | <b>Rantai pasokan manufaktur</b>   |
|---------------------------------|--|--|
| <b>Kontrol Inti</b>             | Rantai pasokan layanan, integrasi layanan pelabuhan, menjadikan perusahaan pelabuhan sebagai inti, layanan pelabuhan untuk perancangan, perencanaan, implementasi, dan peningkatan | Rantai pasokan produk, integrasi produk, mengambil perusahaan manufaktur sebagai inti, hulu dan hilir optimalisasi perusahaan dalam memproduksi, merencanakan, menjual dan logistik. |
| <b>Organisasi anggota</b>       | Relatif kompleks, anggota organisasi adalah perusahaan pelabuhan, pelabuhan lain (yang mungkin pesaing atau mitra), pemasok, pengangkut, grosir dan konsumen                       | Relatif sederhana, anggota organisasi adalah perusahaan inti, pemasok, distributor, pengecer, penyedia logistik dan konsumen.  |
| <b>Kontrol benda-benda</b>      | Aliran modal, aliran informasi, aliran layanan, dan logistic   | Aliran modal, aliran informasi dan <i>logistic</i>   |
| <b>Pola respon waktu</b>        | Instansi pasokan dan persepsi permintaan   | Keterlambatan penawaran dan permintaan persepsi  |
| <b>Keterlibatan semua pihak</b> | Penyediaan dan penyampaian layanan secara simultan, para pihak perlu bekerja sama secara erat  | Kombinasi rantai modular, para pihak hanya perlu menyelesaikan tugas yang relevan  |

Tabel 2.1 menunjukkan bahwa perbedaan utama antara perusahaan pelabuhan dan rantai pasokan manufaktur berada di inti kontrol, organisasi anggota, objek kontrol, pola respons waktu, dan keterlibatan semua pihak.

Mempertimbangkan organisasi anggota, rantai pasokan perusahaan pelabuhan terdiri dari perusahaan pelabuhan, pelabuhan lain (yang mungkin merupakan pesaing atau mitra), pemasok, pengangkut, pedagang besar, dan konsumen. Perusahaan pelabuhan sangat bergantung pada lokasi geografis, karena pelabuhan merupakan pusat produksi dan jasa pelabuhan. Namun, perusahaan manufaktur berbeda, dan beberapa perusahaan manufaktur besar memiliki pusat produksi di seluruh tanah air. Karena ketergantungannya pada letak

geografis, perusahaan pelabuhan memiliki penguatan kerjasama dengan pelabuhan lain sebagai salah satu tujuannya. Bagi perusahaan pelabuhan, pelabuhan lain merupakan pesaing sekaligus kooperator. Ini menghasilkan struktur hubungan anggota yang lebih kompleks, lebih banyak kesulitan koordinasi, stabilitas rantai pasokan yang lebih buruk, dan lebih banyak ketidakpastian dan risiko untuk rantai pasokan perusahaan pelabuhan. Dalam hal objek kontrol, mode operasi perusahaan pelabuhan dan rantai pasokan manufaktur ditunjukkan pada gambar berikut (Jiang et al., 2018).



**Gambar 2. 1 Perbandingan mode operasi perusahaan pelabuhan dan rantai pasokan manufaktur**

Gambar 2.1 diatas menunjukkan bahwa objek kontrol rantai pasokan manufaktur terutama terdiri dari arus informasi, logistik, dan arus modal. Selain itu, rantai pasokan perusahaan pelabuhan mencakup aliran layanan. Dalam rantai pasokan yang terakhir, perusahaan pelabuhan tidak hanya perusahaan inti, tetapi juga inti dari aliran layanan. Layanannya meluas ke rantai pasokan hulu dan hilir: di satu

sisi, proses "pemasok - pelabuhan" selalu melibatkan "pemuatan dan pembongkaran," "penanganan" dan "pergudangan" di perusahaan pelabuhan, di samping fungsi logistik yang disediakan oleh penyedia jasa logistik; di sisi lain, layanan perusahaan pelabuhan melibatkan "distribusi" dan "penanganan", yang meluas ke perusahaan hilir. Dapat dilihat bahwa perusahaan pelabuhan akan memasukkan logistik dalam rantai pasokannya (Jiang et al., 2018).

Dalam hal pola respon waktu, perusahaan pelabuhan tidak memiliki persediaan berwujud sendiri, karena jasa tidak memiliki bentuk fisik dan tidak dapat disimpan. Meskipun ada penundaan dalam penyesuaian dan umpan balik permintaan produk, permintaan layanan terus berubah. Fluktuasi permintaan ini memperumit pengambilan keputusan dalam rantai layanan pelabuhan dengan respons permintaan penuh. Ini juga mengarah pada peningkatan ketidakpastian rantai pasokan pelabuhan, peningkatan persyaratan untuk fleksibilitas dan penyesuaian, dan peningkatan risiko rantai pasokan (Jiang et al., 2018).

Mengingat komitmen semua pihak, pasokan dan pengiriman layanan rantai pasokan perusahaan pelabuhan dilakukan secara simultan, dan para pihak perlu bekerja sama erat, yang sulit untuk dikoordinasikan. Dalam rantai pasokan manufaktur, anggota hanya perlu menyelesaikan tugas masing-masing, yang relatif tidak terlalu sulit (Jiang et al., 2018).

Pembahasan di atas menunjukkan bahwa rantai pasokan perusahaan pelabuhan lebih rumit, tidak pasti, dan tidak stabil daripada rantai pasokan manufaktur. Beberapa risiko umum dalam rantai pasokan manufaktur mungkin bukan merupakan risiko dalam rantai pasokan perusahaan pelabuhan. Yang terakhir memiliki karakteristik unik dan lebih sulit untuk dikelola (Jiang et al., 2018).

Kunci untuk mengidentifikasi risiko rantai pasokan perusahaan pelabuhan adalah menemukan faktor penyebab ketidakpastian. Dalam penelitian ini, kami membagi faktor tersebut menjadi faktor eksternal dan internal (Jiang et al., 2018).

Sehubungan dengan pengaruh faktor eksternal, perusahaan pelabuhan (sebagai “jembatan” perdagangan *impor* dan *ekspor* suatu negara) berdampak baik pada perdagangan internasional maupun situasi makro ekonomi domestik. Dari sisi ekonomi, penurunan ekonomi global dan domestik akan mempengaruhi perdagangan impor dan ekspor suatu negara; risiko nilai tukar, yang disebabkan oleh fluktuasi nilai tukar, juga akan mengakibatkan gejolak pada rantai pasokan perusahaan pelabuhan. Dari perspektif politik, perusahaan pelabuhan peka terhadap aspek lingkungan politik asing yang meningkatkan risiko rantai pasokannya, seperti dampak buruk perang terhadap harga minyak, rute transportasi, perkiraan pertumbuhan ekonomi, dan kepercayaan konsumen. Selanjutnya, potongan pajak

ekspor dan perubahan kebijakan subsidi akan mempengaruhi industri dan perdagangan impor dan ekspor perusahaan (Jiang et al., 2018).

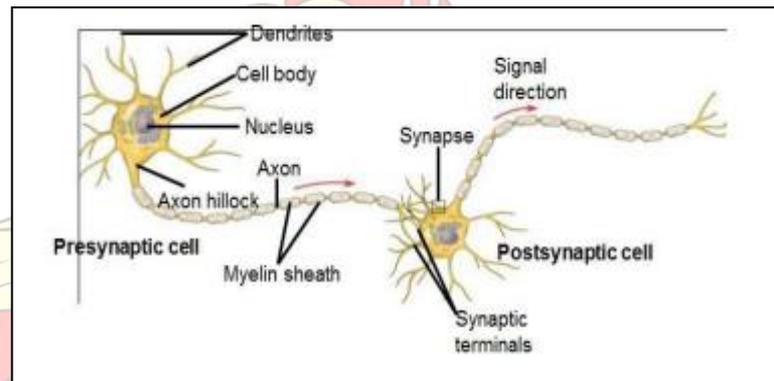
Sehubungan dengan faktor internal, ketidakpastian dalam pengembangan anggota dan mekanisme operasional rantai pasokan secara keseluruhan diidentifikasi sebagai kekhawatiran. Ketidakpastian tentang pengembangan anggota dapat mengakibatkan keresahan dari akumulasi risiko operasional perusahaan pelabuhan (termasuk profitabilitas, solvabilitas, kemampuan operasional, kemampuan pengembangan, dan tingkat manajemen), penurunan kemampuan pemasok dan distributor untuk mengontrol *node*, dan perubahan logistik efisiensi. Stabilitas rantai pasokan dan efisiensi operasional akan sangat dipengaruhi oleh ketidaksempurnaan operasional mekanisme organisasi rantai pasokan, serta mekanisme distribusi bunga, pembagian biaya, dan pembagian informasi (Jiang et al., 2018).

Kesimpulannya, ketika mengidentifikasi risiko rantai pasokan perusahaan pelabuhan, harus dilakukan penggabungan karakteristik pola rantai pasokan perusahaan pelabuhan, dan mempertimbangkan pengaruh faktor internal dan eksternal.

### **2.1.3 Jaringan Syaraf Tiruan (JST)/*Artificial Neural Network* (ANN)**

*Artificial Neural Network* atau Jaringan Syaraf Tiruan merupakan sebuah sistem pemrosesan data dengan meniru cara kerja sistem saraf manusia. Algoritma ANN lahir dari gagasan psikolog, Warren McCulloch dan Walter Pitts pada tahun 1943 yang menjelaskan cara

kerja jaringan saraf dengan perangkat jaringan elektronik (McCulloch & Pitts, 1943). *Artificial Neural Network* adalah sebuah sistem yang terdiri atas banyak elemen pemrosesan sederhana yang terhubung secara paralel (Razak Azhar, 2017).



**Gambar 2.2 Jaringan Saraf Manusia**

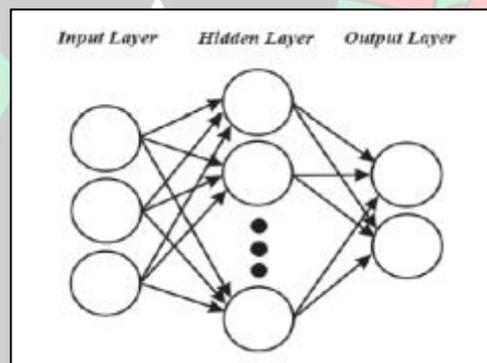
Seperti dijelaskan pada gambar diatas, *impuls* (rangsangan) pada jaringan saraf manusia diterima oleh dendrit dan kemudian diteruskan ke *axon* melalui badan sel (*cell body*). *Axon* akan mengantarkan rangsangan dari sel satu ke sel lainnya melalui *synapse* hingga diteruskan ke efektor. Setiap kegiatan diatur oleh *nucleus* di setiap sel (Razak Azhar, 2017).

ANN (*Artificial Neural Network*) terdiri dari sejumlah satuan masukan (*input*) dan keluaran (*output*) yang terkoneksi, dan pada setiap koneksinya terdapat bobot (*weight*) tersendiri yang dapat diubah-ubah untuk mendapatkan hasil prediksi yang diinginkan. Lapisan-lapisan pada ANN digambarkan pada Gambar 2.3 (Razak Azhar, 2017).

- *Input Layer* (Lapisan Masukan): merupakan lapisan yang menghubungkan sumber data ke jaringan pemrosesan. Dalam

artian, setiap masukan akan merepresentasikan variabel-variabel bebas yang berpengaruh terhadap keluaran (*output*)

- *Hidden Layer* (Lapisan Tersembunyi): merupakan lapisan perambat variabel-variabel input untuk mendapatkan hasil *output* yang lebih mendekati keinginan. Suatu ANN *Multilayer* dapat memiliki satu atau lebih *hidden layer*.
- *Output Layer* (Lapisan Keluaran): merupakan hasil keluaran dari pemrosesan data ANN. Keluaran yang didapatkan bergantung pada bobot, jumlah lapisan tersembunyi (*hidden layer*), dan fungsi aktivasi yang ditetapkan.



Gambar 2.3 *Multi Layer ANN*

Berdasarkan hubungan antara *layer/lapisan* yang digunakan untuk pemrosesan data, ANN dibagi menjadi tiga jenis jaringan, yaitu (Razak Azhar, 2017):

1. *Single Layer Network* adalah ANN yang tidak memiliki *hidden layer*, dalam artian *input layer* langsung terhubung ke *output layer*.
2. *Multi Layer Network* adalah ANN yang memiliki satu atau lebih *hidden layer* sebagai lapisan perambat.

3. *Competitive Layer Network* adalah ANN yang memiliki hubungan umpan balik (*feedback loop*) antara *output layer* dan *input layer*.

Dalam pengaplikasiannya ANN dibagi menjadi metode pembelajaran terawasi (*Supervised Learning*) dan metode pembelajaran tak terawasi (*Unsupervised Learning*), seperti penjelasan berikut (Razak Azhar, 2017) :

1. *Supervised Learning* menggunakan sekumpulan data input dan terdapat contoh keluaran (*output/target*) yang diharapkan
2. *Unsupervised Learning* hanya menggunakan sekumpulan data input tanpa terdapat contoh keluaran (*output*).

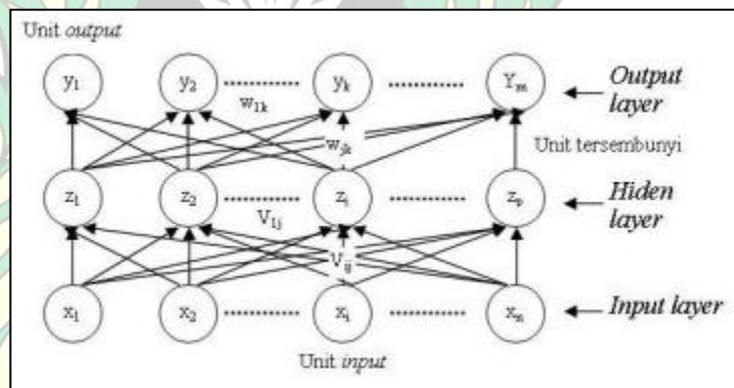
ANN dibagi menjadi dua kelompok, yaitu *Feedforward Neural Network* (FFNN) dan *Recurrent/feedback Neural Network* (RNN). FFNN dapat juga disebut dengan *Backpropagation Neural Network* (BPNN). Menurut Puspitaningrum, FFNN adalah NN yang bergerak maju dan tidak memiliki loop dimana aliran sinyalnya dari neuron input ke neuron output, sedangkan RNN adalah NN berulang atau umpan balik yang dicirikan dengan adanya loop-loop koneksi balik dimana jalur sinyal loop tertutup dari neuron kembali ke dirinya sendiri (Fany Achmalia et al., 2020).

Menurut Kaastra & Boyd (1996) dalam (Fany Achmalia et al., 2020) BPNN adalah suatu kelas dari FFNN dengan aturan pembelajaran terawasi. Proses pembelajaran terawasi adalah proses membandingkan setiap perkiraan jaringan dengan jawaban benar yang

diketahui dan menyesuaikan berat berdasarkan error perkiraan yang dihasilkan untuk meminimalkan fungsi *error*.

#### 2.1.4 Algoritme *Backpropagation*

*Backpropagation* merupakan salah satu algoritma yang digunakan pada ANN *Multi-Layer Network* dengan pembelajaran terawasi dimana dilakukan penyesuaian bobot secara berulang untuk mendapatkan nilai *error* terendah antara hasil prediksi dengan target yang diinginkan. ANN *Backpropagation* memiliki kelebihan yang bersifat *adaptive* dan *fault tolerance* terhadap pemecahan masalah dari sistem. Algoritma *Backpropagation* digambarkan pada Gambar 2.4 (Fany Achmalia et al., 2020).



Gambar 2.4 ANN *Backpropagation*

Umumnya pada setiap metode prediksi, sebelum melakukan prediksi pada periode-periode ke depan, dilakukan dua proses pembelajaran terlebih dahulu, yaitu proses *training* dan *testing*. Training pada ANN *Backpropagation* merupakan proses pengaturan nilai *input* serta bobot (*weight*) (seperti dijelaskan pada Gambar 2.4.) hingga didapatkan model yang optimal. *Training* pada ANN

*Backpropagation* meliputi tiga fase, yaitu: fase pembelajaran (*learning step*), fase maju (*feedforward*), dan fase mundur (*backpropagation*) dari melihat *error-error* yang dihasilkan. *Testing* adalah pengujian kelayakan model yang telah diperoleh dari proses *training* (Fany Achmalia et al., 2020).

Tahapan *training* pada ANN *Backpropagation* adalah sebagai berikut (Razak Azhar, 2017):

a. *Learning Step* (Tahap 1)

Tahapan pembelajaran (*learning step*) dilakukan dengan cara menginisiasi bobot awal kemudian mengulangi tahapan-tahapan yang ada secara berkala hingga kondisi akhir iterasi terpenuhi.

Untuk masing-masing training data, lakukan tahap 2 hingga tahap 7 hingga proses akhir literasi terpenuhi.

b. *Fase Feedforward* (Tahap 2-4)

Tahapan ini dilakukan dengan mengalikan masing-masing *node* dengan *weight* (bobot) dan ditambahkan dengan biasnya hingga *output* didapatkan, tahapan ini bergerak maju dari *input layer* → *hidden layer* → *output layer*

**Tahap 2**

Masing-masing *node input* menerima sinyal masukan berupa  $X_1$  dan menyebarkan *node* tersebut ke bagian *hidden layer*

### Tahap 3

Masing-masing *node* pada *hidden layer* dikalikan dengan bobot (*weight*) dan dijumlahkan dengan biasnya sesuai dengan persamaan 2.1

$$Z_{in_j} = V_{0j} + \sum_{i=1}^n X_i V_{ij} \dots \dots \dots \text{Persamaan 2.1}$$

Dengan  $Z_{in_j}$  merupakan nilai keluaran untuk *node*  $Z_j$ ,  $V_{0j}$  sebagai bobot (*weight*) pada bias *node*  $Z_j$ ,  $X_i$  sebagai *node* ke- $i$  pada *input layer*, dan  $V_{ij}$  sebagai bobot (*weight*) pada *node*  $X_i$  (*input layer*) dan *node*  $Z_j$  (*hidden layer*).

Setelah ditemukan nilai  $Z_{in_j}$ , langkah selanjutnya adalah menghitung nilai *node* pada lapisan tersembunyi (*hidden layer*) berdasarkan fungsi aktivasi yang digunakan sesuai dengan persamaan 2.2

$$Z_j = f(Z_{in_j}) \dots \dots \dots \text{Persamaan 2.2}$$

Dengan  $Z_j$  adalah nilai pada *node* ke- $j$  dan  $f(Z_{in_j})$  merupakan fungsi aktivasi dari  $Z_{in_j}$ . Keluaran dari fungsi aktivasi tersebut dikirim menuju *node* pada lapisan keluaran (*output layer*).

### Tahap 4

Masing-masing *node* pada *output layer* dikalikan dengan bobot (*weight*) dan dijumlahkan dengan biasnya sesuai dengan persamaan (3)

$$Y_{in_k} = W_{0k} + \sum_{j=1}^p Z_j W_{jk} \dots \dots \dots \text{Persamaan 2.3}$$

Dengan  $Y_{in_k}$  merupakan nilai keluaran untuk *node*  $Y_k$ ,  $W_{0k}$  sebagai bobot (*weight*) pada bias *node*  $Y_k$ ,  $Z_j$  sebagai *node* ke- $j$  pada *hidden layer*, dan  $W_{jk}$  sebagai bobot (*weight*) pada *node*  $Z_j$  (*hidden layer*) dan *node*  $Y_k$  (*output layer*).

Setelah ditemukan nilai  $Y_{in_k}$ , langkah selanjutnya adalah menghitung nilai *node* pada lapisan keluaran (*output layer*) berdasarkan fungsi aktivasi yang digunakan sesuai dengan persamaan 2.4

$$Y_k = f(Y_{in_k}) \dots\dots\dots \text{Persamaan 2.4}$$

c. **Fase Backpropagation (Tahap 5-6)**

Pada tahapan ini dilakukan perhitungan nilai error dari keluaran pada *output layer* dibandingkan dengan pola masukan pada *input layer*, kemudian dilakukan perbaikan bobot pada setiap *layer* secara berkala

**Tahap 5**

Masing-masing *node* pada *output layer* menerima pola target sesuai dengan input pada tahapan *learning step*, kemudian dihitung nilai *error*-nya sesuai dengan persamaan 2.5

$$\delta_k = (t_k - y_k)f'(y_{in_k}) \dots\dots\dots \text{Persamaan 2.5}$$

Dimana  $\delta_k$  merupakan faktor pengendali nilai bobot (*weight*) pada lapisan luaran,  $f'(y_{in_k})$  merupakan turunan dari fungsi aktivasi pada  $y_{in_k}$ . Nilai  $t_k$  merupakan nilai target dari model,

sehingga ditemukan selisih antara luaran dari tahapan *feedforward* dengan target yang diharapkan.

Kemudian menghitung perbaikan bobot (*weight*) dan memperbaiki nilai  $W_{jk}$ , sesuai dengan persamaan 2.6 dan 2.7

$$\Delta W_{jk} = \alpha \delta_k Z_j \dots \dots \dots \text{Persamaan 2.6}$$

$$\Delta W_{0k} = \alpha \delta_k \dots \dots \dots \text{Persamaan 2.7}$$

Dimana  $\Delta W_{jk}$  merupakan selisih antara  $W_{jk}$  saat  $t$  dengan  $W_{jk}$  saat  $t+1$  dan  $\alpha$  merupakan konstanta laju pelatihan (*learning rate*) dengan nilai  $0 < \alpha < 1$ .

**Tahap 6**

Masing-masing bobot (*weight*) yang menghubungkan *node* pada *output layer* dengan *node* pada *hidden layer* dikalikan *delta* ( $\delta_k$ ) dan dijumlahkan sebagai masukan (*input*) pada lapisan berikutnya, sesuai dengan persamaan 2.8

$$\delta_{in_j} = \sum_{k=1}^m \delta_k W_{jk} \dots \dots \dots \text{Persamaan 2.8}$$

Dimana  $\delta_{in_j}$  merupakan faktor pengendalian nilai bobot (*weight*) dari luaran lapisan tersembunyi (*hidden layer*).

Selanjutnya, nilai dari  $\delta_{in_j}$  dikalikan dengan turunan dari fungsi aktivasinya untuk menghitung nilai *error*-nya sesuai dengan persamaan 2.9

$$\delta_j \delta_{in_j} f'(y_{in_k}) \dots \dots \dots \text{Persamaan 2.9}$$

Langkah berikutnya adalah menghitung perbaikan bobot (*weight*) yang digunakan untuk memperbaiki  $V_{ij}$  sesuai dengan persamaan

2.10 dan menghitung perbaikan bias untuk memperbaiki  $V_{0j}$  sesuai dengan persamaan 2.11

$$\Delta V_{ij} = \alpha \delta_j X_i \dots \dots \dots \text{Persamaan 2.10}$$

$$\Delta V_{0j} = \alpha \delta_j \dots \dots \dots \text{Persamaan 2.11}$$

**Tahap 7**

Masing-masing luaran (*output*) dari *node* diperbaiki bias dan bobotnya sesuai dengan persamaan 2.12

$$V_{ij} = V_{ij}(\text{lama}) + \Delta V_{ij}$$

$$V_{0j} = V_{0j}(\text{lama}) + \Delta V_{0j} \dots \dots \dots \text{Persamaan 2.13}$$

**Tahap 8**

Uji kondisi akhir iterasi, berikut adalah kondisi dimana iterasi *backpropagation* dihentikan:

- Proses iterasi telah mencapai batas maksimal yang telah ditentukan
- *Error* yang didapatkan dapat ditoleransi
- Membuat global minimum dari SSE, menetapkan nilai *error* minimal.

**2.1.5 Fungsi Aktivasi *Backpropagation Neural Network* (BPNN)**

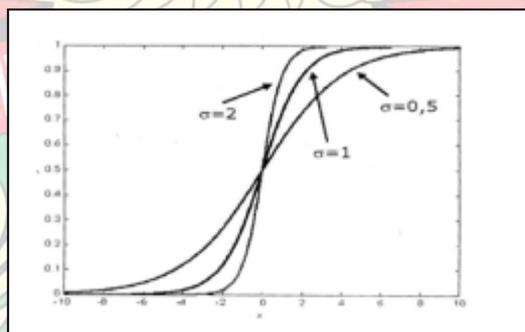
Fungsi Aktivasi BPNN merupakan suatu fungsi yang umumnya digunakan pada metode BPNN untuk mentransformasikan suatu *input* menjadi *output* tertentu. Fungsi Aktivasi BPNN antara lain (Razak Azhar, 2017):

**Binary Sigmoid** biasa digunakan untuk prediksi ANN dengan metode *backpropagation*. *Binary Sigmoid* mengubah masukan (*input*) yang merupakan variabel kontinu menjadi keluaran bernilai *biner* (0 dan 1). Formula perhitungan dengan aktivasi *binary sigmoid* digambarkan seperti pada gambar 2.5. dan persamaan 2.14

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

Dengan:

$$f'(x) = \sigma f(x)[1 - f(x)] \dots\dots\dots \text{Persamaan 2.14}$$



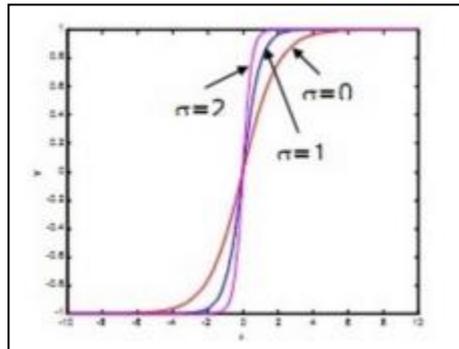
**Gambar 2. 5 Fungsi Binary Sigmoid**

**Bipolar Sigmoid** pada dasarnya hampir sama dengan fungsi *sigmoid biner*, akan tetapi fungsi ini mengubah variabel input menjadi variabel *output* dengan interval -1 hingga 1. Perhitungan fungsi *bipolar sigmoid* dapat dilihat pada persamaan 2.15 dan gambar 2.6.

$$y = f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Dengan:

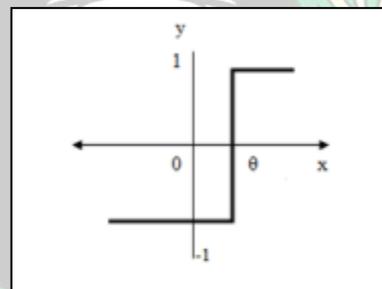
$$f'(x) = [1 + f(x)][1 - f(x)] \dots\dots\dots \text{Persamaan 2.15}$$



Gambar 2. 6 Fungsi *Bipolar Sigmoid*

**Bipolar dengan nilai ambang (*threshold*)**, dimana nilai ambang menjadi garis pemisah antara daerah dengan respon aktivasi positif dan daerah dengan respon aktivasi negatif, keluaran pada aktivasi ini dapat berupa nilai -1, 0, dan 1, seperti pada persamaan 2.16 dan gambar 2.7.

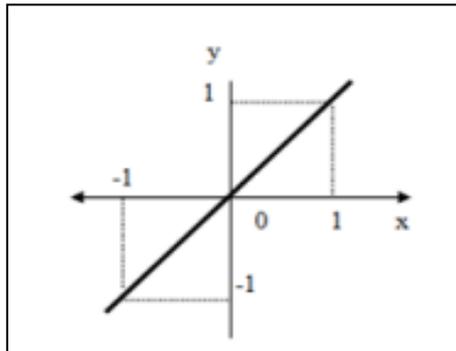
$$y = \begin{cases} 1 & \text{jika } x > 0 \\ 0 & \text{jika } x = 0 \\ -1 & \text{jika } x < 0 \end{cases} \dots\dots\dots \text{Persamaan 2.16}$$



Gambar 2. 7 Fungsi *Bipolar Threshold*

**Linear Function** digunakan apabila hasil keluaran (*output*) yang diinginkan sama dengan masukan (*input*) seperti pada persamaan 2.17 dan Gambar 2.8.

$$y = x \dots\dots\dots \text{Persamaan 2.17}$$



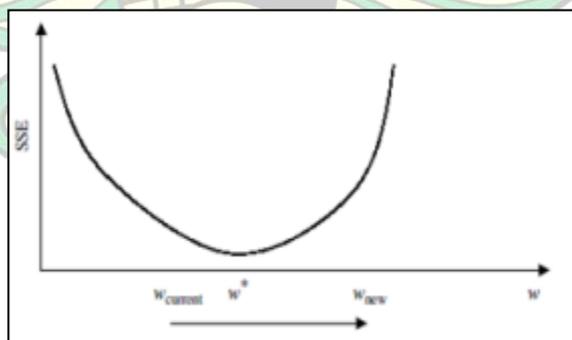
Gambar 2. 8 Fungsi Linear

### 2.1.6 Parameter BPNN

Parameter-parameter yang dapat digunakan dalam metode BPNN, antara lain (Razak Azhar, 2017) :

#### *Learning Rate*

*Learning Rate* memiliki peran penting dalam hal waktu yang digunakan untuk mencapai minimum *error*. Dalam parameter ini digunakan skala dari 0 hingga 1, semakin besar nilai *learning rate*, maka waktu yang dibutuhkan pada proses *training* semakin singkat. Namun disisi lain, apabila nilai *learning rate* terlalu besar, hasil proses *training* dapat melewati keadaan dimana nilai *error* minimal telah dicapai (Makridakis & Spyros, 1998). Pengaruh penggunaan parameter *learning rate* secara optimal digambarkan pada Gambar 2.9 .



Gambar 2. 9 Gradient Descent

Berdasarkan Gambar 2.9., nilai optimal bobot yang memiliki *error* terendah didefinisikan sebagai  $w^*$  dan berdasarkan gambar tersebut dapat dikatakan bahwa nilai bobot baru (iterasi) yang didefinisikan sebagai  $w_{new}$  dapat melampaui nilai optimal. Oleh karena itu, diperlukan percobaan untuk menentukan nilai *learning rate* yang optimal.

### **Momentum**

*Momentum* merupakan salah satu parameter yang digunakan dalam metode BPNN. *Momentum* berkisar antara skala 0 hingga 0.9. Penambahan Momentum dimaksudkan untuk menghindari perubahan bobot yang mencolok (*local minimum/local maximum*) akibat adanya *outlier* (data yang sangat berbeda).

### **Epoch (Lama Iterasi)**

Jumlah maksimal iterasi yang digunakan mempengaruhi penentuan titik optimum bobot yang digunakan, akan tetapi semakin banyak *epoch* tidak semata-mata mempengaruhi semakin kecilnya *error* yang didapatkan pada proses perambatan ulang.

#### **2.1.7 Genetic Algorithm (GA)**

Algoritma genetika (GA) adalah cabang dari AI dan algoritma evolusioner dan merupakan salah satu pendekatan modern optimasi numerik yang didasarkan pada teori Charles Darwin tentang "*survival of the fittest*" dan "seleksi alam". Metode ini pertama kali dikembangkan oleh Holland selama 1960-an dan kemudian dikembangkan oleh

Goldberg. GA dan versi modifikasinya telah banyak digunakan dalam banyak masalah optimasi (Mohamad et al., 2017).

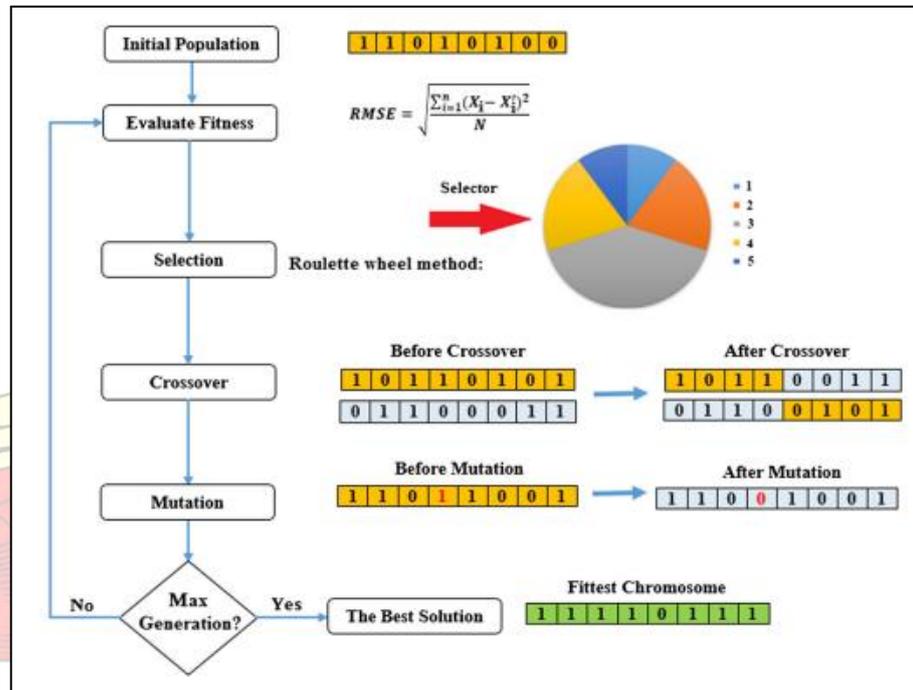
GA dibandingkan dengan metode optimasi tradisional lainnya, memiliki banyak keunggulan. Salah satu keuntungan terpenting yang disebutkan adalah kemampuan perawatan GA dengan masalah optimasi yang kompleks dan paralelisme. Dengan mempertimbangkan bahwa, dalam setiap masalah optimasi, fungsi tujuan (*fitness*) dapat berupa statis atau dinamis (berubah seiring waktu), linier atau nonlinier, kontinu atau terputus-putus atau mengandung noise acak, yang biasanya dapat diselesaikan oleh GA. Terlepas dari semua keuntungan dari algoritma genetika, ia menderita serangkaian masalah. Ekspresi matematis yang tepat dari fungsi kebugaran, menetapkan metode seleksi yang tepat dan penentuan parameter GA seperti: ukuran populasi dan tingkat operator genetik, harus dilakukan dengan hati-hati. Setiap pilihan yang tidak tepat dapat menyebabkan masalah dalam konvergensi algoritma atau memperoleh hasil yang tidak berarti. Namun, GA masih paling banyak digunakan dalam pendekatan optimasi *nonlinier*. Dalam GA, solusi masalah dikodekan dalam *string biner linier* (biasanya 0 dan 1) dengan panjang tetap yang dikenal sebagai kromosom. Populasi kromosom ini mengarah pada pembentukan generasi. Proses algoritma GA (lihat Gambar 2.10) dimulai dengan generasi acak kromosom. Kemudian, kebugaran kromosom individu dalam generasi akan dievaluasi. Operator seleksi

yang mirip dengan seleksi alam Darwin yang memberikan lebih banyak kesempatan untuk solusi yang lebih baik dan lebih sedikit kesempatan untuk solusi yang lebih buruk di generasi berikutnya, akan diterapkan pada individu. Berikut ini, dengan menerapkan operator genetik (mutasi dan *crossover*) pada kromosom yang tersisa, generasi berikutnya dari kromosom dibuat. *Crossover* adalah operator utama yang memilih dua kromosom induk secara acak dan menukar segmennya satu sama lain. Kromosom yang baru dibuat dikenal sebagai anak-anak. Mutasi adalah operator genetik lain yang dapat memilih kromosom secara acak dalam kisaran yang disarankan (misalnya, 1/0) (Mohamad et al., 2017).

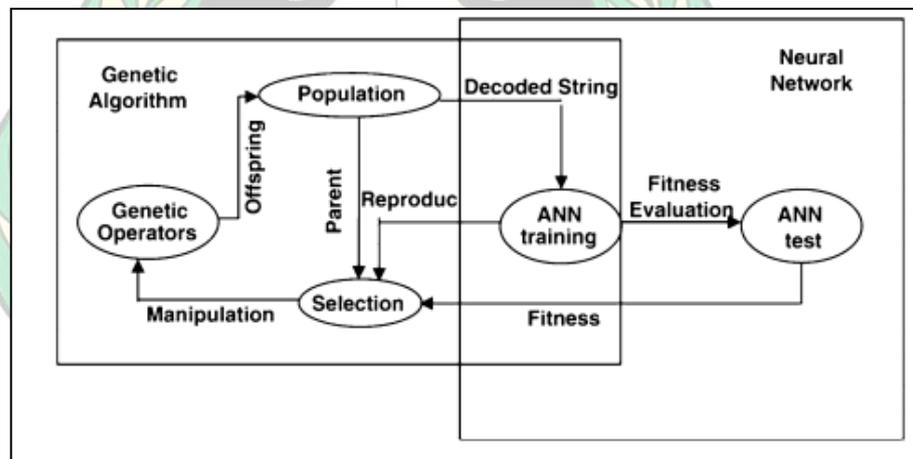
### **2.1.8 Integrasi GA dan ANN**

Terlepas dari semua keuntungan dari jaringan saraf, mereka mengalami beberapa masalah seperti konvergensi yang lambat dan terjebak dalam minimum lokal. Untuk mengatasi masalah ini, baru-baru ini, peneliti menyarankan metode hibrida GA-ANN untuk meningkatkan kinerja JST untuk mencapai minimum global. Dalam metode ini, dengan mempertimbangkan fungsi *fitness* yang sesuai, parameter penting ANN (yaitu, jumlah lapisan tersembunyi dan bobot awal yang optimal) akan ditentukan dan diubah. Tujuan utama menggunakan model GA-ANN *hybrid* adalah menyesuaikan serangkaian bobot dan bias untuk meminimalkan fungsi tujuan. Metode ini telah berhasil digunakan dan dikembangkan untuk memecahkan

banyak masalah teknik(Mohamad et al., 2017). Diagram alir algoritma GA-ANN *hybrid* ditampilkan pada gambar 2.11.



Gambar 2. 10 Flowchart algoritma genetika



Gambar 2. 11 Kombinasi GA-ANN

### 2.1.9 Performa Prediksi

Salman & Prasetyo (2010) dalam (Fany Achmalia et al., 2020) menjelaskan bahwa berdasarkan kemampuan belajar yang dimilikinya, maka ANN dapat dilatih untuk mempelajari dan menganalisa pola data

masa lalu dan berusaha mencari suatu formula atau fungsi yang akan menghubungkan pola data masa lalu dengan *output* yang diinginkan pada saat ini. Hikmah menyebutkan bahwa salah satu kelebihan dari model ANN dalam algoritma prediksi yaitu dapat digunakan untuk meramalkan data *time series non* linier.

Menurut Valipour, dkk (2013) dalam (Fany Achmalia et al., 2020) dengan meningkatkan target *error* pada ANN memungkinkan untuk mencegah variasi pelatihan yang parah dan tidak menguntungkan dan pada gantinya membatalkan pelatihan di dalam jaringan. Lebih banyak neuron di lapisan tersembunyi menyebabkan lebih banyak derajat kebebasan dalam jaringan. Semakin banyak variabel dioptimalkan, waktu perpanjangan pelatihan, dan matriks bobot dan vektor bias menjadi lebih tinggi. Selain itu, jumlah neuron yang lebih tinggi menghasilkan kemungkinan peningkatan penemuan jawaban dan banyak kesempatan untuk mencegah jatuh di minimum lokal.

Pengukuran performa prediksi penggunaan ANN dapat diukur dengan melihat skor *Mean Squared Error* (MSE). Dalam (Puji Widodo et al., 2017) Teknik perhitungan MSE dengan menghitung jumlah selisih dari data prediksi dengan data *actual*. Semakin kecil nilai MSE maka hasil prediksi semakin bagus. Nilai MSE dapat dihitung dengan menggunakan persamaan berikut ini.

$$MSE = \frac{\sum_{t=1}^n |A_t - F_t|}{n} \dots\dots\dots \text{Persamaan 2.18}$$

Dengan,

$A_t$  = Nilai *actual* pada periode t

$F_t$  = Nilai prediksi pada periode t

$n$  = Jumlah data

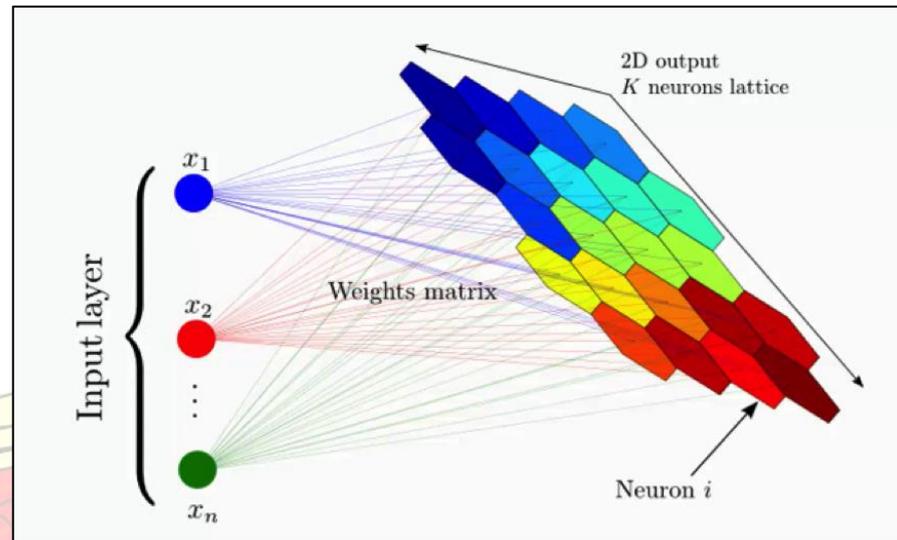
#### 2.1.10 *Self-Organizing Map* (SOM)

*Self Organizing Map* (SOM) atau jaringan kohonen diperkenalkan pertama kali oleh Prof. Teuvo Kohonen pada tahun 1982. SOM merupakan salah satu metode dalam jaringan syaraf tiruan yang menggunakan pembelajaran tanpa pengarahan. Salah satu keunggulan dari algoritma SOM adalah mampu untuk memetakan data berdimensi tinggi ke dalam bentuk peta dimensi rendah. Metode pembelajaran tanpa pengarahan tidak memerlukan target, selama proses pembelajaran unit-unit *input* hampir sama dikelompokkan dalam kelompok tertentu yang berada di unit *output* (*Cluster Units*) (Andriani, 2018).

Pada jaringan SOM, setiap *neuron* akan berkompetisi dan *winner neuron* akan menjadi patokan dalam *update weight*. *Update weight* dilakukan pada *winner neuron* dan *neuron* lainnya yang berada dalam *neighborhood neuron* tersebut. *Neighborhood* akan terus berkurang radiusnya untuk proses pembelajaran selanjutnya, hingga hanya *winner neuron* yang mengalami *update weight* (Andriani, 2018).

Pada SOM, jaringan terdiri dari 2 *layer*, *layer input* dan *layer output*. Setiap node dari input terhubung dengan seluruh node pada *output layer*. Namun *node* pada *output layer* (*neuron*) tidak terhubung satu sama lain. *Node* dalam *output layer* ini disebut juga *map node*.

Untuk memudahkan strukturnya dapat dilihat pada gambar dibawah ini (Andriani, 2018):



Gambar 2. 12 Struktur SOM

*Output layer* dapat berdimensi 1 atau 2. *Layer* ini juga dapat disebut sebagai *computational layer* atau *competitive layer* karena *node-node* ada *layer* ini berkompetisi dan selalu di *update* bobotnya. Baik *input* maupun *output layer* merupakan *array* yang menyimpan informasi karakteristik, atribut maupun ciri. Bobot ini merepresentasikan hal-hal tersebut (Andriani, 2018).

### 2.1.11 Pelabuhan Indonesia

Pelabuhan berfungsi sebagai tempat bersandar dan berlabuhnya kapal-kapal. Sudah sejak dahulu kala, peran dan fungsi pelabuhan sudah menjadi perhatian pemerintah, Dari dulu pelabuhan telah ditetapkan jenis dan macamnya, antara lain sebagai lingkungan kerja dan tempat berlabuhnya berbagai kapal-kapal dan kendaraan air lainnya untuk melakukan bongkar muat barang, hewan dan penumpang.

Menurut Wiwoho (1983) dalam (Gultom, 2017) menjelaskan pelabuhan yang diusahakan adalah pelabuhan dalam pembinaan pemerintah yang sesuai dengan kondisi, kemampuan dan perkembangan potensinya diusahakan menurut asas-asas/hukum perusahaan atas ketetapan Menteri. Pelabuhan yang tidak di usahakan adalah pelabuhan dalam pembinaan pemerintah yang sesuai dengan kondisi, kemampuan dan perkembangan potensinya masih lebih menonjol sifat ke pemerintahannya dan atau yang belum ditetapkan sebagai pelabuhan yang diusahakan.

Wiwoho (1983) dalam (Gultom, 2017) menjelaskan pelabuhan otonom adalah pelabuhan yang diserahkan wewenang untuk mengatur diri sendiri dengan suatu peraturan perundangan sendiri, sedangkan pelabuhan khusus adalah pelabuhan yang khusus untuk melayani suatu kegiatan industri yang penyelenggaraannya dilakukan oleh perusahaan yang bersangkutan. Menurut Wiwoho (1983) pelabuhan sebagai terminal point untuk kapal laut serta kendaraan air lainnya, merupakan komponen *logistic* teknis yang tidak terpisahkan dari penyelenggaraan angkutan laut. Dalam fungsinya sebagai terminal *point*, pelabuhan merupakan lingkungan kerja khusus yang penyelenggaraannya dan pengusahaannya diwujudkan dalam bentuk penanggung jawab tunggal dan umum di bawah Menteri atau pejabat yang ditunjuk. Adapun yang dimaksud dengan lingkungan kerja pelabuhan adalah yang meliputi segala fasilitas yang memungkinkan pelaksanaan penyelenggaraan

angkutan laut maupun usaha-usaha terminal. Lingkungan kepentingan pelabuhan adalah lingkungan di sekeliling lingkungan kerja pelabuhan dimana penggunaan tanah dan pembangunan gedung-gedung dan lain bangunan dilakukan setelah mendapat persetujuan pejabat yang ditunjuk Menteri (Gultom, 2017).

Menurut Wiwoho (1983) dalam (Gultom, 2017) pembinaan dan pengarahan penggunaan fasilitas-fasilitas kepelabuhanan untuk kapal-kapal dan kendaraan air lainnya dilakukan oleh Menteri, dalam hal:

- a. Melabuh dan menambat kapal-kapal guna embarkasi dan penumpang, bongkar muat barang, hewan dan lain-lain;
- b. Pemberian pelbagai fasilitas untuk keperluan kapal;
- c. Pemeriksaan-pemeriksaan bertalian dengan peraturan-peraturan keselamatan dan tata tertib pelayaran serta tata tertib Bandar;
- d. Penyaluran barang-barang untuk ke luar kota dan masuk pelabuhan; dan
- e. Pemeriksaan-pemeriksaan bertalian dengan peraturan-peraturan instansi-instansi pemerintah lainnya yang mempunyai suatu tugas pemeriksaan/tugas pemerintahan terhadap lalu lintas barang dan penumpang seperti bea cukai, kesehatan, pertanian, perdagangan dan lain-lainnya.

### 2.1.12 MATLAB

MATLAB®, dikembangkan oleh The MathWorks, Inc., mengintegrasikan komputasi, visualisasi, dan pemrograman dalam lingkungan terbuka yang fleksibel. Ini menawarkan insinyur, ilmuwan, dan ahli matematika bahasa intuitif untuk mengekspresikan masalah dan solusi mereka secara matematis dan grafis. Masalah numerik dan simbolik yang kompleks dapat diselesaikan dalam waktu yang sangat singkat dengan bahasa pemrograman seperti C, Fortran, atau Java.

Pada sistem Unix Anda dapat masuk ke MATLAB dengan perintah `system matlab` dan keluar dari MATLAB dengan perintah `MATLAB quit` atau `exit`. Di Microsoft Windows dan Macintosh, cukup klik dua kali pada ikon MATLAB. Berikut menu *taskbar* pada MATLAB (Davis & Sigmon, 2005).

#### Tampilan MATLAB

MATLAB memiliki antarmuka pengguna grafis yang luas. Ketika MATLAB dimulai, jendela MATLAB akan muncul, dengan beberapa *subwindows* dan menu bar. Semua jendela MATLAB di *desktop default* di-dok, yang berarti jendela tersebut dipasang di jendela MATLAB utama. Anda dapat melepaskan jendela dengan memilih *item* menu Desktop *Undock* atau dengan mengklik tombol *undock*-nya. Menu bar di bagian atas jendela MATLAB berisi satu set tombol dan menu *pull-down* untuk bekerja dengan M-file, jendela, preferensi dan pengaturan lainnya, sumber daya web untuk MATLAB, dan bantuan MATLAB

*online*. Jika sebuah jendela ditambahkan dan dipilih, bilah menunya muncul di bagian atas jendela MATLAB. Jika Anda lebih suka font yang lebih sederhana daripada font default, pilih File *Preferences*, dan klik *Font*. Pilih *Lucida Console* (di PC) atau *DialogInput* (di Unix) sebagai ganti *font default Monospace*, dan klik OK.

### ***Help Window***

Jendela ini adalah jendela yang paling berguna untuk pengguna MATLAB pemula, dan para ahli MATLAB terus menggunakannya. Pilih Help MATLAB Help atau ketik doc. Jendela Bantuan memiliki sebagian besar fitur yang akan Anda lihat di *browser web* mana pun (tautan yang dapat diklik, tombol kembali, dan mesin pencari, misalnya). Help Navigator di sebelah kiri menunjukkan di mana Anda berada dalam dokumentasi online MATLAB. Bagian Bantuan Online disebut sebagai Bantuan: MATLAB: Memulai: Pendahuluan, misalnya. Klik di samping MATLAB di *Help Navigator*, dan Anda akan melihat MATLAB Roadmap (atau Help: MATLAB untuk singkatnya). Versi dokumentasi yang dapat dicetak tersedia dalam kategori ini (lihat Bantuan: MATLAB: Dokumentasi yang Dapat Dicitak (PDF)). Anda juga dapat menggunakan perintah bantuan, yang diketik di jendela Perintah. Misalnya, perintah *help eig* akan memberikan informasi tentang fungsi nilai *eigen eig*.

### ***Start Button***

Tombol Start di sudut kiri bawah Desktop MATLAB memungkinkan Anda untuk memulai demo, alat, dan jendela lain yang tidak ada saat Anda memulai MATLAB. *Try Start: MATLAB: Demo* dan *run* salah satu *demo* dari jendela Demo MATLAB.

### ***Command Window***

Ekspresi dan pernyataan MATLAB dievaluasi saat Anda mengetiknya di jendela *Command*, dan hasil perhitungan juga ditampilkan di sana. Ekspresi dan pernyataan juga digunakan dalam file-M.

### ***Workspace Window***

Jendela *Workspace* mencantumkan variabel yang telah Anda masukkan atau hitung dalam sesi MATLAB Anda. Ada banyak tipe data dasar (atau kelas) di MATLAB, masing-masing merupakan *array* multidimensi. Kelas-kelas yang akan kita perhatikan paling banyak adalah *array numerik* persegi panjang dengan entri yang mungkin kompleks, dan mungkin jarang. *Array* jenis ini disebut *matriks*. Sebuah *matriks* dengan hanya satu baris atau satu kolom disebut vektor (vektor baris dan vektor kolom berperilaku berbeda; mereka lebih dari sekadar array satu dimensi). *Matriks* 1-kali-1 disebut skalar.

### ***Command History Window***

Jendela ini mencantumkan perintah yang diketik sejauh ini. Anda dapat menjalankan kembali perintah dari jendela ini dengan mengklik dua kali atau menyeret perintah ke jendela Perintah.

### ***Array Editor Window***

Setelah *array* ada, itu dapat dimodifikasi dengan Editor *Array*, yang bertindak seperti spreadsheet untuk matriks. Buka jendela *Workspace* dan klik dua kali pada matriks *C*. Klik entri di *C* dan ubah, dan coba ubah ukuran *C*.

### ***Current Directory Window***

Direktori Anda saat ini adalah tempat MATLAB mencari file-M Anda, dan untuk file ruang kerja (.mat) yang Anda muat dan simpan. Anda juga dapat memuat dan menyimpan matriks sebagai file ASCII dan mengeditnya dengan editor teks favorit Anda. File harus terdiri dari array persegi panjang hanya dari entri matriks numerik. Anda dapat menggunakan menu dan tombol di jendela *Current Directory* untuk membaca dengan teliti file Anda, atau Anda dapat menggunakan perintah yang diketik di jendela *Command*. Perintah `pwd` mengembalikan nama direktori saat ini, dan `cd` akan mengubah direktori saat ini. Perintah `dir` mencantumkan isi direktori kerja, sedangkan perintah yang hanya mencantumkan file khusus MATLAB dalam direktori, dikelompokkan berdasarkan jenis file. Perintah MATLAB hapus dan ketik dapat digunakan untuk menghapus file dan menampilkan file di jendela *Perintah*.

## 2.2 Penelitian Terdahulu

Beberapa *paper* penelitian terkait yang dijadikan sebagai acuan dalam pengerjaan tugas akhir ini disajikan pada tabel 2.1, 2.2, 2.3, 2.4, 2.5, dan 2.6.

Pada penelitian 1 dijelaskan mengenai prediksi harga produksi listrik (SMP) menggunakan ANN 3 *layers* dengan kasus di *Victorian Power System*, Australia. Pada penelitian 2 dilakukan penelitian prediksi tingkah laku pelanggan dalam membeli *item* pada perusahaan ritel skala menengah dengan menggunakan metode gabungan MBA (*Market Basket Analysis*) dan ANN. Pada penelitian 3 dilakukan penelitian mengenai prediksi pola curah hujan bulanan dengan kasus Ketapang, Kalimantan Barat, dikatakan pada penelitian ini metode ANN belum tepat digunakan untuk memprediksi pola curah hujan. Pada penelitian 4 dilakukan penelitian untuk membandingkan dua metode (ARIMA dan ANN) dalam memproduksi barang-barang ritel di Eropa, dikatakan bahwa metode ARIMA lebih baik dibandingkan metode ANN dalam meramalkan produksi barang-barang tersebut. Pada penelitian 5 dilakukan penelitian mengenai pengaruh parameter pada prediksi produksi dan konsumsi hasil tambang, seperti gas alam dan minyak bumi.

**Tabel 2. 2 Penelitian Terdahulu**

| No | Judul   | Identitas   | Tahun | Tujuan   | Hasil  | Kesimpulan   | Persamaan  | Perbedaan  |
|----|---|---|-------|--|--|--|--|--|
| 1  | <i>Electricity Price Short-Term Forecasting Using Artificial Neural Networks</i>                      | 1. B. R. Sakuta<br>2. L. A. Sanabria<br>3. T. S. Dillon<br>4. La Trobe University | 1999  | Melakukan peramalan SMP ( <i>System Marginal Price</i> ) menggunakan 3 layers ANN <i>Backpropagation</i> | Berdasarkan uji sensitivitas, didapatkan bahwa variabel input berpengaruh terhadap variabel <i>output</i> yang dihasilkan. Berdasarkan perhitungan APE ( <i>Absolute Percentage Error</i> ) dan ESD ( <i>Error Standard Deviation</i> ) yang kecil, dikatakan bahwa hasil prediksi sangat memuaskan  | ANN <i>Backpropagation</i> cukup baik digunakan untuk memprediksi harga produksi listrik dengan menggunakan parameter-parameter yang sesuai  | Menggunakan metode yang sama, yaitu <i>Artificial Neural Network</i> dengan algoritma <i>Backpropagation</i> | Perbedaan pada data set dan nilai-nilai parameter yang mungkin digunakan   |
| 2  | <i>Product Inventory Predictions at Small Medium Enterprise Using Market Basket Analysis Approach</i> | 1. Agus Mansur<br>2. Trioyoso Kuncoro<br>3. Universitas Islam Indonesia           | 2012  | Memahami perilaku pelanggan untuk memprediksi penjualan dengan menggunakan metode gabungan MBA dan ANN   | Proses <i>training</i> hanya berjalan hingga 7 iterasi dan mendapatkan nilai <i>error</i> 0.000788252, sehingga dapat dikatakan performa model berjalan baik<br>Dari grafik yang dipaparkan, terdapat korelasi yang sangat baik antara data target dan data <i>output</i> pada jaringan<br>Didapatkan hasil prediksi 17 <i>item</i> dengan nilai prediksi tertinggi pada <i>item</i> "Black couplers K" dengan jumlah permintaan 1622 pada periode selanjutnya | Berdasarkan hasil analisa didapatkan kesimpulan:<br>1. Apabila pelanggan membeli <i>item</i> "klik klok" pasti juga akan membeli <i>item</i> "keyhole" dan "key 1.5 cm".<br>2. <i>Item</i> "Black couplers K" merupakan <i>item</i> yang paling diminati pelanggan | Penggunaan salah satu metode yang sama, yaitu BPNN ( <i>Backpropagation Neural Network</i> )                 | Pada <i>paper</i> menggunakan metode gabungan MBA ( <i>Market Based Analysis</i> ) dan ANN <i>Backpropagation</i> , sedangkan pada penelitian hanya menggunakan ANN <i>Backpropagation</i><br>Perbedaan dataset yang digunakan |

|   |   |   |      |   |   |   |   |   |
|---|---|---|------|---|---|---|---|---|
| 3 | Metode Jaringan Saraf Tiruan Propagansi Balik Untuk Estimasi Curah Hujan Bulanan di Ketapang Kalimantan Barat | 1. Andi Ihwan<br>2. Universitas Tanjungpura                   | 2013 | Memprediksi pola curah hujan bulanan di Ketapang, Kalimantan Barat  | Tingkat korelasi data observasi dan data training saat proses pelatihan sangat baik. Nilai sisa ( <i>error</i> ) dari data observasi dan data testing pada proses pengujian berbeda cukup jauh. Perbandingan nilai data observasi dan data forecast memiliki perbedaan cukup jauh pada tahun 2012 | Metode ANN dengan [15 10 5 1] dapat digunakan dalam pengenalan pola curah hujan bulanan di Kab. Ketapang. Apabila dilihat dari nilai residu yang dihasilkan (5,96 mm - 213,74 mm), metode ANN belum tepat untuk memprediksi pola curah hujan.       | Penggunaan metode yang sama, yaitu <i>Backpropagation Neural Network</i> Tujuan yang ingin dicapai hampir mendekati, yaitu untuk melihat keakuratan metode BPNN dalam memprediksi suatu kasus | Tujuan yang ingin dicapai berbeda, yaitu untuk melihat keakuratan metode BPNN dalam memprediksi suatu kasus |
| 4 | <i>Linear versus neural network forecast for European industrial production series</i>                        | 1. Saeed Heravi<br>2. Denise R. Osborn<br>3. C.R. Birchenhall | 2014 | Membandingkan hasil prediksi menggunakan model linear (ARIMA) dan <i>neural network</i> (ANN) pada hasil produksi industri di Eropa | Model <i>neural network</i> hanya memberikan nilai RMSE lebih rendah dibandingkan ARIMA hanya 5 dari 24 <i>series</i> ( <i>variables</i> ), yaitu pada periode 3 - 6 bulan ke depan   | Pemodelan ARIMA lebih baik digunakan untuk meramalkan jumlah produksi barang pada kasus ini dibandingkan metode ANN Dikatakan bahwa pemodelan linear (ARIMA) akan berperan penting dalam kegiatan prediksi produksi barang-barang industri di Eropa | Penggunaan salah satu metode yang sama, yaitu <i>Backpropagation Neural Network</i> Topik yang diangkat sama, yaitu mengenai peramalan produksi   | Tujuan akhir penelitian berbeda   |

|   |  |  |   |   |  |   |  |  |
|---|--|--|---|---|--|---|--|--|
| 5 | <p>Analisis dan Implementasi Jaringan Syaraf Tiruan - Propagansi Balik Dalam Memprediksi Produksi dan Konsumsi Minyak Bumi, Gas Bumi, dan Batu Bara di Indonesia</p> | <ol style="list-style-type: none"> <li>1. Anggit Nourislam</li> <li>2. Jondri, Drs., MST</li> <li>3. Siti Saadah, ST., MT.</li> <li>4. Universitas Telkom</li> </ol> | - | <p>Mendapatkan model keluaran berupa nilai prediksi dari produksi dan konsumsi di masa mendatang dan dikelompokkan menurut indeks</p> | <ol style="list-style-type: none"> <li>1. Mendapatkan model keluaran berupa nilai prediksi dari produksi dan konsumsi di masa mendatang dan dikelompokkan menurut indeks</li> <li>2. Hasil terbaik pada <i>training</i> produksi batu bara adalah dengan <i>hidden layer</i> 6, penggunaan bias, dan <i>learning rate</i> 0,7</li> <li>3. Hasil terbaik pada <i>training</i> konsumsi gas bumi adalah dengan <i>hidden layer</i> 6, penggunaan bias, dan <i>learning rate</i> 0,4</li> <li>4. Hasil terbaik pada <i>training</i> produksi gas bumi adalah dengan <i>hidden layer</i> 8, penggunaan bias, dan <i>learning rate</i> 0,4</li> <li>5. Hasil terbaik pada <i>training</i> konsumsi minyak bumi adalah dengan <i>hidden layer</i> 6, penggunaan bias, dan <i>learning rate</i> 0,7</li> <li>6. Hasil terbaik pada <i>training</i> produksi minyak bumi adalah dengan <i>hidden layer</i> 6, penggunaan bias, dan <i>learning rate</i> 0,9</li> <li>7. Hasil proses <i>testing</i> menghasilkan MAPE dibawah 10%, kecuali pada variabel produksi minyak bumi</li> </ol> | <ol style="list-style-type: none"> <li>1. Semakin besar nilai <i>learning rate</i>, semakin cepat proses pembelajaran pada iterasi. Namun apabila <i>learning rate</i> terlalu besar, maka dapat mengakibatkan kondisi homogen data sulit tercapai</li> <li>2. Penggunaan bias dapat memperkecil MAPE, karena membantu dalam mencapai kondisi homogen data</li> <li>3. Semakin besar jumlah input belum tentu menghasilkan nilai MAPE yang semakin kecil</li> <li>4. Dengan data yang selalu bergerak naik (tren naik), lebih baik menggunakan fungsi aktivasi linear karena pada fungsi aktivasi ini tidak membatasi nilai keluaran</li> </ol> | <ol style="list-style-type: none"> <li>1. Penggunaan metode yang sama, yaitu <i>Artificial Neural Network Backpropagation</i></li> <li>2. Topik yang diangkat sama, yaitu mengenai peramalan produksi</li> </ol> | <p>Topik yang diangkat sama, yaitu mengenai peramalan produksi</p> |
|---|--|--|---|---|--|---|--|--|