

**PREDIKSI DAYA MESIN KAPAL BERBASIS JARINGAN SARAF
TIRUAN**

ARDYAN SAFIU

D052202007



PROGRAM STUDI MAGISTER TEKNIK PERKAPALAN

UNIVERSITAS HASANUDDIN

MAKASSAR

2023

**SHIP ENGINE POWER PREDICTION BASED ON ARTIFICIAL
NEURAL NETWORK (ANN)**

ARDYAN SAFIU

D052202007



**PROGRAM STUDI MAGISTER TEKNIK PERKAPALAN
UNIVERSITAS HASANUDDIN
MAKASSAR
2023**

PREDIKSI DAYA MESIN KAPAL BERBASIS JARINGAN SARAF

TIRUAN

Tesis

sebagai salah satu syarat untuk mencapai gelar magister

Program Studi Teknik Perkapalan

Disusun dan diajukan oleh:

ARDYAN SAFIU

D052202007

Kepada

PROGRAM STUDI MAGISTER TEKNIK PERKAPALAN

UNIVERSITAS HASANUDDIN

MAKASSAR

2023

TESIS

PREDIKSI DAYA MESIN KAPAL BERBASIS JARINGAN SARAF TIRUAN

ARDYAN SAFIU

D052202007

Telah dipertahankan di hadapan Panitia Ujian Tesis yang dibentuk dalam rangka penyelesaian studi pada Program Magister Teknik Perkapalan Fakultas Teknik Universitas Hasanuddin

pada tanggal Januari 2023

dan dinyatakan telah memenuhi syarat kelulusan.

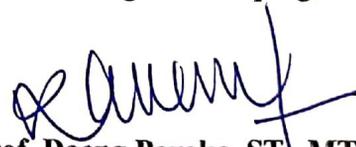
Menyetujui,

Pembimbing Utama,



Dr. Ir. Syamsul Asri, MT.
Nip. 19650318 199103 1 003

Pembimbing Pendamping,



Prof. Daeng Paroka, ST., MT., Ph.D.
Nip. 19720118 199802 1 001

Dekan Fakultas Teknik
Universitas Hasanuddin



Prof. Dr. Eng. Ir. Muhammad Isran Ramli, S.T.
Nip. 19730926 200012 1 002

Ketua Program Studi
Magister Teknik Perkapalan



Dr. Ir. Syamsul Asri, MT.
Nip. 19650318 199103 1 003

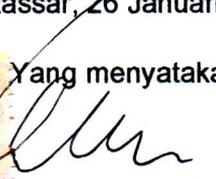
**PERNYATAAN KEASLIAN TESIS
DAN PELIMPAHAN HAK CIPTA**

Dengan ini saya menyatakan bahwa, tesis berjudul "Prediksi Daya Mesin Kapal Berbasis Jaringan Saraf Tiruan" adalah benar karya saya dengan arahan dari komisi pembimbing (Dr. Ir. Syamsul Asri, MT. sebagai Pembimbing Utama dan Prof. Daeng Paroka, ST., MT., PhD. sebagai Pembimbing Pendamping). Karya ilmiah ini belum diajukan dan tidak sedang diajukan dalam bentuk apa pun kepada perguruan tinggi mana pun. Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka tesis ini. Sebagian dari isi tesis ini telah dipublikasikan di Jurnal (E-ISSN. 2548-4087) sebagai artikel dengan judul "Ship Engine Power Prediction Based on Artificial Neural Network (ANN)".

Makassar, 26 Januari 2023



Yang menyatakan,


Ardyan Safiu

UCAPAN TERIMA KASIH

Saya bersyukur bahwa tesis ini akhirnya dapat terselesaikan dengan baik. Banyak kendala yang dihadapi oleh penulis dalam rangka penyusunan tesis ini. Berkat bantuan berbagai pihak, maka tesis ini selesai pada waktunya. Dalam kesempatan ini penulis dengan tulus menyampaikan terima kasih kepada Dr. Ir. Syamsul Asri. MT., sebagai Ketua Komisi Penasihat dan Prof. Daeng Paroka, ST. MT. PhD. selaku anggota komisi penasihat yang telah banyak memberikan masukan mulai pengembangan minat sampai terhadap permasalahan penelitian ini, pelaksanaan penelitiannya sampai dengan penulisannya dan Terima kasih juga penulis sampaikan kepada Dosen penguji Dr. Ir. Ganding Sitepu.Dpl.Ing., Dr. Ir. Misliah, MStr, Dr. A. Sitti Chairunnisa M, ST., MT. Terima kasih juga penulis sampaikan kepada Teman-teman mahasiswa S1 Teknik Perkapalan dan rekan-rekan kuliah S2 Teknik Perkapalan yang telah banyak membantu dalam rangka pengumpulan data dan informasi. Kemudian terima kasih kepada keluarga saya yang telah memberikan support yang tinggi serta teman-teman pascasarjana Teknik Perkapalan Universitas Hasanuddin dan terakhir ucapan terima kasih juga disampaikan kepada mereka yang namanya tidak tercantum tetapi telah banyak membantu penulis dalam menyelesaikan tesis ini.

Makassar, 26 Januari 2023

Ardyan Safiu

ABSTRAK

ARDYAN SAFIU. **Prediksi Daya Mesin Kapal Berbasis Jaringan Saraf Tiruan** (dibimbing oleh Syamsul Arsi dan Daeng Paroka).

Tahap awal perancangan kapal sangat penting untuk memprediksi daya mesin sesuai dengan kecepatan yang diinginkan. Faktor wake field mempunyai pengaruh yang cukup besar terhadap perhitungan daya mesin kapal. Penelitian mengenai hal ini masih terus dikembangkan untuk mendapatkan hasil dengan tingkat akurasi yang tinggi. Beberapa penelitian menggunakan analisis numerik, CFD, dan pengujian di *towing tank*. Tujuan dari penelitian ini adalah untuk memprediksi daya mesin kapal menggunakan jaringan syaraf tiruan (JST) dengan menganalisis data kapal jenis bulk carrier dengan total 1467 kapal berstatus aktif operasi hingga saat ini. Terdapat 5 variabel input yaitu panjang garis air (Lwl), lebar (B), tinggi (H), sarat (T), kecepatan (v), dan daya mesin kapal (kW) sebagai output. Hasil yang diperoleh menunjukkan bahwa model jaringan yang dicapai memiliki kualitas regresi yang tinggi dengan hasil prediksi yang cukup akurat. Hal ini dibuktikan dengan menginput data kapal baru kemudian membandingkan hasil perhitungan JST dengan data daya mesin yang ada. Beberapa data kapal dengan variasi panjang garis air (Lwl) yaitu 143,32 meter hingga 288,42 meter dan daya mesin 5850 kW hingga 15860 kW. Presentasi rata-rata error yang dihasilkan adalah 0.01214 %.

Kata kunci : daya mesin kapal, jaringan saraf tiruan, kapal bulk carrier, *deep learning*

ABSTRACT

ARDYAN SAFIU. **Ship Engine Power Prediction Based on Artificial Neural Network** (supervised by Syamsul Asri dan Daeng Paroka).

The early stages of ship design are very important to predict engine power according to speed required. The wake field factor has a considerable influence on the calculation of ship engine power. Research on this matter is still being developed to obtain results with a high degree of accuracy. Several studies have used numerical analysis, CFD, and testing on towing tanks. The purpose of this research is to predict ship engine power using artificial neural networks (ANN) by analyzing data on bulk carrier vessels with a total of 1467 ships currently in active operation status. There are 5 input variables, namely the length of the waterline (Lwl), breadth (B), depth (H), draft (T), speed (v), and ship engine power (kW) as output. The results obtained indicate that the network model achieved has a high quality regression with fairly accurate prediction results. This is proven by inputting new ship data and then comparing the results of ANN calculations with existing engine power data. Some ship data with variations in waterline length (Lwl), namely 143.32 meters to 288.42 meters and engine power of 5850 kW to 15860 kW. The resulting average percentage error is 0.01214%.

Keywords: ship engine power, artificial neural network, bulk carrier ship, deep learning

DAFTAR ISI

HALAMAN JUDUL.....	i
PERNYATAAN PENGAJUAN.....	ii
LEMBAR PENGESAHAN.....	iii
PERNYATAAN KEASLIAN TESIS.....	iv
UCAPAN TERIMA KASIH.....	v
ABSTRAK.....	vi
ABSTRACT	vii
DAFTAR ISI.....	viii
DAFTAR GAMBAR.....	x
DAFTAR TABEL.....	xii
BAB I PENDAHULUAN	1
1.1. Latar Belakang.....	1
1.2. Rumusan Masalah	3
1.3. Tujuan dan Manfaat	3
BAB II METODE PENELITIAN	4
2.1. Tempat dan Waktu Penelitian	4
2.2. Sumber Data	4
2.3. Teknik Pengolahan Data dan Metode Analisa	4
2.3.1. Kapal Bulk Carrier.....	4
2.3.2. Tahanan Kapal	8
2.3.3. Metode Holtrop-Menen	9

2.3.4. Korelasi antara variable (<i>cross correlation</i>)	12
2.3.5. Machine Learning	17
2.3.6. Jaringan Saraf Tiruan (JST).....	19
2.3.7. Pelatihan Jaringan Saraf Tiruan (JST)	28
2.3.8. Penentuan Tahanan Sisa Kapal dengan Menggunakan JST	31
2.4. Sistematika Pengerjaan Penelitian	36
BAB III HASIL DAN PEMBAHASAN	39
3.1. PENGUMPULAN DATA DAN UNIQUE DATA DARI TIAP VARIABEL	39
3.2. KORELASI ANTARA VARIABEL X DAN VARIABEL Y	41
3.3. ANALISIS DENGAN METODE MULTIPLE LINEAR REGRESI	52
3.4. ANALISIS DENGAN METODE POLYNOMIAL REGREASI.....	58
3.5. ANALISIS DENGAN METODE JARINGAN SARAF TIRUAN (ANN)	64
3.6. GUI APLIKASI.....	87
3.6.1. Design GUI Aplikasi.....	87
3.7. Pengoperasian GUI Aplikasi.....	90
3.8. PERBANDINGAN ANTARA DATA REAL DAN DATA PREDIKSI	93
BAB IV KESIMPULAN DAN SARAN	97
4.1. Kesimpulan	97
4.2. Saran	98
DAFTAR PUSTAKA.....	99
LAMPIRAN	102
LAMPIRAN CODING MATLAB ANN	102
LAMPIRAN CODING APLIKASI GUI MATLAB	106

DAFTAR GAMBAR

Gambar 1. Kapal Bulk Carrier.....	5
Gambar 2. Bentuk analisis regresi linear dari metode holtrop dan menne's.....	11
Gambar 3. Analisis regresi linear keofisien gelombang pada metode holtrop dan mennen's.....	11
Gambar 4. Neural Network	21
Gambar 5. Sebuah ilustrasi dari jaringan feed forward dasar umum.....	22
Gambar 6. Karakteristik Neural Network.....	23
Gambar 7. Backpropagation	26
Gambar 8. Hasil dari algoritma pelatihan untuk algoritma pelatihan yang tersedia dan jumlah iterasi yang diberikan	34
Gambar 9. Koefisien tahanan sisa sebagai fungsi dari bilangan Froude, PSV no.6	35
Gambar 10. Koefisien tahanan sisa sebagai fungsi dari bilangan Froude, AHTS no.79	36
Gambar 11. Korelasi antara Lwl dan Engine Power.....	43
Gambar 12. Korelasi antara Breadth dan Engine Power.....	45
Gambar 13. Korelasi antara Depth dan Engine Power.....	47
Gambar 14. Korelasi antara Draft dan Power	49
Gambar 15. Korelasi antara Speed dan Engine power	51
Gambar 16. Plot Real data dan Predicted data.....	58
Gambar 17. Plot Real data dan Predicted data 30% data test dari 100%	63
Gambar 18. Tabulasi data pada Microsoft Excel.....	64
Gambar 19. Layar kerja pada matlab R2020a	65
Gambar 20. Tampilan data import	66
Gambar 21. Data variabel (x).....	67
Gambar 22. Data variabel (y) atau target.....	68
Gambar 23. Coding pembagian divisi data	69
Gambar 24. Coding fungsi Levenberg-Marquardt bacporpagation.....	70
Gambar 25. Pemodelan Struktur Jaringan Saraf Tiruan (ANN).....	72
Gambar 26. Struktur jaringan saraf tiruan (ANN)	72

Gambar 27. Hidden layer pertama.....	72
Gambar 28. Hidden layer kedua.....	73
Gambar 29. Hidden layer ketiga.....	73
Gambar 30. Struktur jaringan saraf tiruan.....	74
Gambar 31. Neural Network Plot Regression.....	77
Gambar 32. Neural Network Training Performance.....	78
Gambar 33. Jaringan Saraf Tiruan (ANN.Net).....	79
Gambar 34. Constant dan Mux.....	80
Gambar 35. Display.....	81
Gambar 36. ANN.Net setelah dimofikasi.....	81
Gambar 37. ANN.net Simulink.....	82
Gambar 38. Data pengujian dalam format pdf.....	82
Gambar 39. Input data variabel (x).....	85
Gambar 40. Hasil Power kapal ATALANTE.....	86
Gambar 41. Blank GUI (Default).....	87
Gambar 42. Membuat GUI Aplikasi.....	88
Gambar 43. GUI aplikasi prediksi power.....	89
Gambar 44. Tampilan App Prediction Power Vessel.....	89
Gambar 45. Tampilan App Prediction Power Vessel.....	90
Gambar 46. Hasil Power kapal LAGUNO.....	91
Gambar 47. Hasil Power kapal AREQUIPA QUEEN.....	92
Gambar 48. Perbandingan (y) Engine power dan (y) Prediksi Engine power.....	96

DAFTAR TABEL

Tabel 1. Generasi kapal Bulk Carrier	7
Tabel 2. Hasil Training Algoritma	33
Tabel 3. Hasil tahanan sisa dari kapal OSV.....	35
Tabel 4. Minimum and maximum ship data.....	40
Tabel 5. Persentase dari <i>training</i> , validasi and dan data pengujian.....	40
Tabel 6. Koefisien Korelasi Variabel (x) dan target (y)	42
Tabel 7. Korelasi Lwl dan Engine Power.....	43
Tabel 8. Korelasi Breadth dan Engine Power	45
Tabel 9. Korelasi Depth dan Engine Power	47
Tabel 10. Korelasi Draft dan Engine Power	49
Tabel 11. Korelasi Speed dan Engine Power.....	51
Tabel 12. Hasil korelasi variabel (x) dan (y)	52
Tabel 13. Neural Network Training Regression	78
Tabel 14. Data Pengujian ANN.Net	83
Tabel 15. Data kapal Atalante.....	86
Tabel 16. Data kapal Lugano.....	91
Tabel 17. Data kapal Arequipa Queen.....	92
Tabel 18. Perbandingan hasil Ann.Net Simulink dan GUI Aplikasi	93
Tabel 19. Perbandingan (y) real dan (y) prediksi	94

BAB I PENDAHULUAN

1.1. Latar Belakang

Pada tahap awal perancangan kapal sangat penting untuk menghitung atau memprediksi daya mesin yang akan dibutuhkan sesuai dengan kecepatan yang diinginkan. Dalam menghitung atau memprediksi daya mesin kapal yang memiliki nilai ketelitian tinggi dengan waktu yang relatif lebih cepat, menjadi suatu hal yang sangat penting untuk dijadikan landasan utama ke tahap perencanaan berikutnya serta kaitannya dalam menentukan kebutuhan bahan bakar dan hal lainnya.

Dalam perkembangannya untuk menghitung atau memprediksi daya mesin kapal, beberapa pendekatan yang umum digunakan antara lain adalah menentukan daya mesin kapal menggunakan software aplikasi, melalui analisis numerik atau matematik, CFD (Computational Fluid Dynamics), melalui pengujian model pada towing tank dan lainnya. Tentunya, hal ini memiliki proses dan tingkat kesalahan yang berbeda-beda, melalui proses yang cukup panjang, dan membutuhkan biaya yang mahal terutama pada pengujian model di towing tank. (Tsuji moto, M dan Orihara, H 2018)

Faktor *wake field* merupakan salah satu faktor yang memiliki pengaruh terhadap perhitungan daya mesin kapal. Umumnya *wake field* terjadi karena distribusi aliran yang tidak merata pada bagian belakang kapal, *wake field* pada bidang propulsi timbul dari tiga penyebab utama yaitu: aliran arus di sekitar body kapal, pertumbuhan lapisan batas di atas body kapal, dan pengaruh komponen pembuat gelombang (Harvald 1972 dan van Lammeren 1937). Daya mesin yang dihasilkan melalui pengujian tahanan di *towing tank* dan daya mesin yang dihasilkan pada pengujian *propeller* pada kecepatan sama memiliki hasil yang berbeda. Kesesuaian antara body kapal dan sistem propulsi menjadi sangat penting diperhatikan dalam mendesain suatu kapal agar daya mesin yang diperoleh bisa menjadi lebih efektif dan efisien pada saat kapal dioperasikan. Hal tersebut masih menjadi masalah yang cukup serius

dan memerlukan kajian lebih lanjut dalam melakukan simulasi agar mendapatkan nilai daya mesin yang optimal.

Penggunaan metode jaringan saraf tiruan (JST) saat ini sudah cukup sering digunakan, tidak hanya pada dunia medis namun pada hal lainnya juga telah diterapkan dan terbukti cukup baik dalam memprediksi dengan tingkat akurasi hasil tinggi serta error yang sangat kecil. Sebagai contoh penerapan jaringan saraf tiruan (JST) dalam bidang perkapalan yang telah dilakukan yaitu JST digunakan untuk memprediksi hambatan sisa trimaran (Burak Yildiz 2022), JST digunakan untuk memprediksi konsumsi bahan bakar kapal, dan JST digunakan untuk memprediksi tahanan kapal (L.K. Grabowska dan P. Szczuko 2015). Pada penelitian sebelumnya jika menggunakan metode JST masih menggunakan data empiris, skema desain awal kapal, dan desain kapal yang belum diproduksi, atau hanya berdasarkan 1 data kapal saja, ada juga sampai ratusan data kapal.

Oleh karena itu pada kesempatan ini peneliti mencoba menggunakan metode JST untuk memprediksi daya mesin kapal dengan menggunakan ribuan data kapal yang telah dibangun dan aktif beroperasi hingga saat ini dengan tujuan untuk mengembangkan model JST dalam memprediksi daya mesin kapal. Adapun data kapal yang akan dianalisis untuk melatih JST bersumber dari badan klasifikasi kapal dunia yaitu NKK *Classification* (www.classnk.com). Data kapal yang digunakan adalah kapal Bulk carrier sebagai bahan pertimbangan lain mengapa dilakukan penelitian terhadap kapal jenis ini karena memiliki teknologi yang maju, telah diproduksi dalam jumlah yang sangat banyak, dan inketersedian data yang sangat memadai serta mudah diakses. Namun, tidak menutup kemungkinan untuk menggunakan data kapal dengan jenis lainnya. Penelitian ini berjudul: **Prediksi Daya Mesin Kapal Berbasis Jaringa Saraf Tiruan.**

1.2. Rumusan Masalah

Adapun yang menjadi rumusan masalah pada penelitian ini adalah:

1. Bagaimana pengaruh Lwl, B, H, T dan Speed terhadap daya mesin kapal Bulk carrier
2. Bagaimana memodelkan struktur jaringan saraf tiruan yang optimal untuk prediksi daya mesin kapal pada data kapal dengan jumlah yang banyak.
3. Bagaimana memprediksi daya mesin kapal dengan menggunakan pendekatan Multiple linear regresi, Polynomial regresi dan Jaringan saraf tiruan (JST)

1.3. Tujuan dan Manfaat

Adapun tujuan dari penelitian ini adalah;

1. Untuk memprediksi kebutuhan daya mesin dari suatu design kapal bulk carrier dengan menggunakan jaringan saraf tiruan (JST).
2. Membanding hasil daya mesin yang ada dengan hasil daya mesin yang diprediksi dengan menggunakan JST sebagai bahan acuan atau parameter akurasi nilai keberhasilan dari JST yang dibuat.
3. Untuk mengetahui pengaruh perubahan dimensi utama kapal dan kecepatan kapal terhadap nilai daya mesin.
4. Membuat Aplikasi prediksi daya mesin kapal

Adapun manfaat yang diperoleh dari penelitian ini adalah:

1. Dapat digunakan sebagai alat bantu pada tahap awal design kapal untuk mengetahui nilai daya mesin yang dibutuhkan oleh suatu kapal dalam waktu yang lebih cepat.
2. Sebagai bahan acuan dalam suatu perencanaan design kapal utamanya penentuan daya mesin kapal dan perencanaan lainnya.

BAB II METODE PENELITIAN

2.1. Tempat dan Waktu Penelitian

Lokasi penelitian dapat dilakukan di laboratorium perkapalan ataupun bisa dilakukan dimana saja. Sebab pengolahan data menggunakan sistem komputasi. Waktu penelitian dilakukan pada awal bulan Februari 2022. Adapun jenis kapal yang diteliti adalah kapal Bulk Carrier.

2.2. Sumber Data

Data penelitian diperoleh dari situs resmi (www.classnk.com) salah satu badan klasifikasi kapal dunia yaitu NKK classification register shipping. Data kapal yang dikumpulkan yaitu nama kapal, dimensi utama kapal (Lwl, B, H, T), kapasitas muatan kapal, daya mesin kapal, kecepatan kapal, dan Rpm.

2.3. Teknik Pengolahan Data dan Metode Analisa

2.3.1. Kapal Bulk Carrier

Secara umum, kargo yang diangkut melalui kapal laut terbagi atas dua kelompok besar yaitu kargo kering (*dry cargo*) dan kargo basah (*liquid cargo*). Bisnis pengangkutan kedua jenis cargo ini sangat besar dan selama ini dilayani oleh beragam jenis dan ukuran kapal. Ada kapal yang didesain mengikuti standar tertentu sehingga mampu membawa berbagai jenis kargo kering. Sementara, ada juga kapal yang didesain lebih khusus untuk mampu membawa komoditas tertentu yang tidak dapat diangkut oleh kapal standar.

Pengangkutan kargo curah kering adalah segmen yang dilayani oleh paling banyak jenis kapal. Secara umum, Kapal pengangkut kargo kering terdiri atas lima

kategori utama, yaitu: *General Cargo*, *Bulk Carrier*, *Short Sea (Coaster) Ship*, *Containerships*, dan kapal khusus (*Specialised vessels*). Masing-masing kategori terdiri dari beberapa subkategori berdasarkan pada karakteristik teknis dan/atau ukurannya.

Sekilas tentang *General Cargo Ship* dan *Bulk Carrier*. Kapal dalam kategori *Short Sea (Coaster) Ship*, *Container ships*, dan kapal khusus (*Specialised vessels*) akan dibahas pada tulisan terpisah.

Bulk Carrier, atau *bulklers*, adalah kapal yang dirancang terutama untuk pengangkutan kargo curah padat. Kargo tersebut umumnya seragam dalam komposisi dan dimuat langsung ke ruang kargo tanpa bentuk penahanan perantara. Kisaran kargo yang dibawa dalam kapal curah cukup besar. Kargo curah terkemuka dalam perdagangan dunia adalah bijih besi, batu bara, biji-bijian, bauksit/alumina, dan batuan fosfat, bersama dengan sejumlah besar konsentrat, kokas minyak bumi, baja, bijih, semen, gula, kuarsa, garam, pupuk, belerang, skrap, agregat, dan hasil hutan.



Gambar 1. Kapal Bulk Carrier

Pada tahun 1990, perdagangan bijih besi dan batu bara hitam melalui laut di dunia masing-masing sekitar 350 juta ton, dengan 190 juta ton biji-bijian dikapalkan.

Ilustrasi curah kecil adalah semen dan gula, yang masing-masing lebih dari 20 juta ton diangkut pada tahun 1990.

Pengangkut curah berevolusi dari kapal kargo dek penampungan tertutup dan pengangkut bijih, pada pertengahan 1950-an dan setelah itu berkembang pesat dalam ukuran dan jumlah. Sementara pada tahun 1960 hanya sekitar seperempat kargo curah yang diangkut dengan pengangkut curah dek tunggal, situasinya berubah pada tahun 1980 di mana hampir semua kargo curah diangkut oleh kapal curah. Perubahan pada aturan internasional, seperti Konvensi Garis Muat 1966 dan Aturan Butir IMO, memungkinkan para perancang memanfaatkan stabilitas bawaan kapal curah dan mengembangkan karakteristik penyimpanan sendiri. Evolusi lebih lanjut dalam desain terjadi pada 1980-an dengan kapal conbulk yang dirancang untuk memenuhi perubahan pola perdagangan internasional dan untuk mengakomodasi khususnya pertumbuhan kargo peti kemas.

Pada tanggal 1 Januari 1990, armada kapal curah dunia dengan bobot mati 10.000 ton ke atas, tidak termasuk kapal curah yang hanya diperdagangkan di North American Great Lakes, berjumlah sekitar 5.000 kapal. Ukuran kapal curah yang paling umum adalah kapal berukuran dari 25.000-50.000 ton dan draft kurang dari 11,5 meter. Ada sekitar 2.000 kapal yang beroperasi pada tahun 1990, dan 1.500 kapal lebih lanjut dalam kisaran bobot mati 10.000-25.000 ton yang, meskipun lebih kecil dari kapal sebelumnya, memiliki karakteristik yang sama dan dapat dengan mudah dikelompokkan.

Bulk Carrier adalah jenis kapal yang paling besar populasinya. Tercatat 16.892 unit di seluruh dunia sesuai dengan namanya, kapal ini utamanya untuk membawa kargo curah (seperti batubara, bijih besi, biji-bijian, mineral, dan lain-lain). Berbeda dengan kapal general cargo yang dapat memuat beberapa jenis cargo berbeda, Bulk Carrier biasanya mengangkut satu jenis (homogen) kargo. Bulk Carrier termasuk tipe single decker dan tidak dapat mengangkut kontainer. Cargo hold (bagian untuk menempatkan kargo) dilengkapi Hatches (penutup) untuk melindungi kargo. Hatches

didesain dengan bukaan yang luas agar tidak menghalangi perpindahan cargo. Cargo hold dirancang “*self trimming*” agar bongkar muat menjadi mudah dan cepat.

Bulk Carrier, sering disebut “*Bulker*”, dibedakan berdasarkan ukurannya. Tabel 1 memuat berbagai jenis bulker berdasarkan bobot mati, Draft, dimensi panjang dan lebar (LOA x Beam), keberadaan crane kapal, dan jumlah cargo hold.

Tabel 1. Generasi kapal Bulk Carrier

Type	Deadweight, ton	Draught, m	LOA, m	Beam, m	Geared (Yes/No)	Number of Holds
Handysize	32,000	10.2	179.9	28.4	Yes	5
Supramax	52,000	12.2	199	32.2	Yes	5
Ultramax	62,000	13	200	32.24	Yes	5
Panamax	75,000	14.1	225	32.26	No	7
Kamsarmax	82,000	14.5	229	32.26	No	7
Post-panamax	98,000	14.6	240	38	No	7
Capasize	172,000	17.95	289	45	No	9
ULOC (Valemax)	400,000	23	362	65	No	9

Mini Bulker (sekitar 15.000 dwt) terutama digunakan dalam pelayaran jarak pendek. Namun, kebanyakan kapal dengan ukuran ini adalah jenis kapal general cargo atau kargo khusus. Di atas Mini Bulker, ada Handysize bulker yang memiliki bobot mati sekitar 15.000 ton sampai 39.000 ton, dan memiliki 4 – 5 cargo hold. Handysize dengan konstruksi yang lebih berat dapat mengangkat kayu bulat, dikenal dengan sebutan “*Loggers*”. Ada jenis bulker dengan bobot 20.000 dan 30.000 ton, dikenal dengan “*Lakers*”, yang dirancang untuk pelayaran transshipment. Desain lakers adalah: LOA 70 meter, lebar sekitar 21,5 meter, draft 7,92 meter dan freeboard maksimal 35,6 meter.

Handymax bulker memiliki bobot mati sekitar 40.000 ton dan 50.000 ton, dan memiliki 5 cargo hold. Mungkin karena kurang ekonomis, sekarang hanya beberapa kapal yang dibangun dalam rentang bobot mati tersebut di atas. Supramax bulker

dibangun menggantikan handymax, memiliki bobot mati sekitar 50.000 ton sampai 60.000 ton. Seperti handymax, supramax juga memiliki 5 cargo hold. Ultramax adalah desain yang terbilang baru dalam dunia dry bulk. Ultramax biasanya dilengkapi dengan “eco main engine”, memiliki bobot mati 62.000 – 65.000 ton. Karena juga memiliki 5 cargo hold, Ultramax sering dianggap sebagai upgrade dari Supramax.

2.3.2. Tahanan Kapal

Berkaitan dengan sistem propulsi kapal, fakta bahwa badan kapal di air dan udara akan mendapatkan gaya hambatan berupa gaya hidrodinamik dan aerodinamis menjadi fokus utama dalam pembahasan ini.

Hambatan kapal pada tingkat tertentu adalah gaya fluida yang bekerja berlawanan dengan gerakan kapal. Hambatan tersebut akan sama dengan komponen gaya fluida yang bekerja secara paralel dengan gerak kapal (Bertram V., 2000).

Melihat kapal yang bergerak di dalam fluida cair yang nilai densitasnya lebih besar dari udara, terlihat bahwa peningkatan kecepatan dan dimensi kapal akan membuat energi pelepasan untuk menghasilkan energi gelombang meningkat. Gelombang ini akan menimbulkan gesekan dengan lambung kapal yang berlawanan arah dengan kapal dan menimbulkan gaya yang berlawanan.

Tahanan total (RT) pada suatu kapal terdiri dari komponen-komponen atau bagian-bagian kapal yang mempunyai kemungkinan menimbulkan hambatan (Holtrop, 1982). Pada prinsipnya ada dua bagian kapal yang mengalami hambatan, yaitu bagian kapal yang tenggelam dan bagian yang berada di atas permukaan air karena udara juga memiliki faktor penghambat dalam kondisi tertentu. (RT) digunakan untuk menentukan Effective Horse Power (EHP), yang didefinisikan sebagai daya yang dibutuhkan untuk menggerakkan kapal pada kecepatan (V_s) dan mampu mengatasi hambatan (RT) dan yang lebih penting, (EHP) adalah digunakan untuk mengetahui besarnya daya mesin utama agar tidak terjadi kelebihan daya dan daya yang tidak

terpenuhi akibat daya yang tidak dapat mengatasi hambatan kapal. Komponen-komponen hambatan ini ditunjukkan di bawah ini (Harvald, 1992):

$$RT = \frac{1}{2} \cdot Ct \cdot \rho \cdot V^2 \cdot S \quad (1)$$

dimana, RT : Tahanan total (N), Ct : Koefisien tahanan, V : Kecepatan kapal (m/s), S : Luas bidang basah (m^2) dan ρ : Massa jenis (kg/m^3)

Displacement adalah berat cairan yang dipindahkan oleh lambung di bawah permukaan air. Pada saat kapal mengapung dalam keadaan seimbang/tidak bergerak maka tekanan ke bawah sama dengan tekanan cairan terhadap lambung kapal. Dengan demikian berat keseluruhan kapal beserta isinya pada saat itu sama dengan berat zat cair yang dipindahkan oleh lambung kapal yang terendam dalam zat cair di mana kapal tersebut berada (Anthony F. Molland, 2011)

$$Displacement : Lwl \times B \times T \times CB \times \text{massa jenis (ton)} \quad (2)$$

Volume cairan yang dipindahkan oleh lambung kapal di bawah permukaan air tempat kapal itu berada (Anthony F. Molland, 2011).

$$Volume displacement: Lwl \times B \times T \times CB \quad (3)$$

Dalam pemilihan mesin induk perlu diperhitungkan kebutuhan tenaga mesin. Ada beberapa indikator yang perlu dicari untuk mendapatkan hasil yang diinginkan, yaitu daya efektif (EHP), daya dorong (THP), daya pengantar (DHP), daya poros (SHP) daya kuda rem. (BHP) (Anthony F. Molland, 2011).

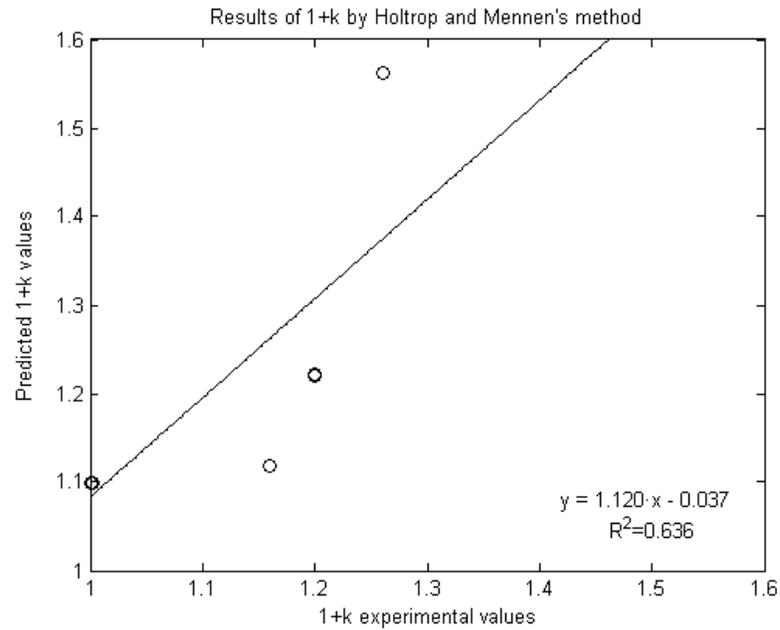
2.3.3. Metode Holtrop-Menen

Holtrop dan Mennen melakukan evaluasi statistik dari hasil uji model, yang dipilih dari arsip *Dutch Ship Model Basin*. Evaluasi dilakukan dengan menggunakan metode analisis regresi berganda. Tujuan dari penelitian ini adalah untuk mengembangkan deskripsi numerik dari hambatan kapal.

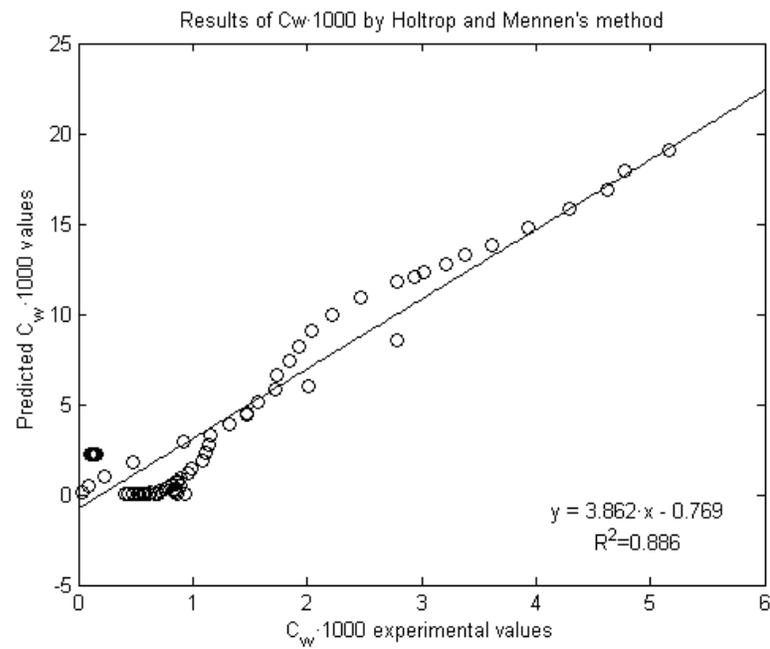
Hambatan total kapal umumnya dibagi menjadi komponen asal yang berbeda. Evaluasi setiap komponen dilakukan dengan menggunakan analisis regresi berganda pada hasil pengukuran tahanan 1707, dilakukan dengan 147 model kapal dan hasil 82 pengukuran eksperimen dilakukan pada 46 kapal baru. Survey range parameter dan tipe kapal, untuk bulk carrier nilai L/B 5.1-7.1, nilai B/T 2.4-3.2, nilai Cp 0.73-0.85, dan nilai Froude number maksimal adalah 0,24.

Hambatan kapal diperkirakan selama tahap desain menggunakan metode Holtrop-Mennen: $1+k$ untuk faktor bentuk, C_w – koefisien gelombang. Evaluasi statistik hasil uji model dilakukan pada data dari model cekungan kapal Belanda dengan melakukan analisis regresi berganda pada setiap komponen 1707 pengukuran hambatan dari 147 model model kapal dan 82 pengukuran eksperimen pada 46 kapal nyata, menghasilkan $R^2 = 0,636$ untuk faktor bentuk dan $R^2 = 0,886$ untuk koefisien gelombang. Metode ini tampaknya mengikuti pengukuran eksperimental dengan hampir baik, dan nilai R^2 dapat diterima. R^2 adalah koefisien determinasi, menunjukkan seberapa cocok model dengan data.

Teknik validasi yang mungkin untuk model Holtrop dan Mennen adalah dengan melakukan analisis regresi linier antara yang diprediksi dan nilai eksperimen yang sesuai (Beaver et al., 1994, ITTC-Quality Manual 1999). Analisis ini mengarah ke garis $y = a + b * x$ dengan koefisien korelasi R^2 . Prediksi yang sempurna akan menghasilkan $a=0$, $b=1$ dan $R^2=1$. Gambar 2 dan Gambar 3 mengilustrasikan output grafis yang disediakan oleh analisis validasi ini. Faktor bentuk yang diprediksi dan koefisien gelombang diplot versus yang eksperimental sebagai lingkaran terbuka. Garis solid menunjukkan kecocokan linier terbaik.



Gambar 2. Bentuk analisis regresi linear dari metode holtrop dan menne's



Gambar 3. Analisis regresi linear keofisien gelombang pada metode holtrop dan mennen's

2.3.4. Korelasi antara variable (*cross correlation*)

Analisis korelasi berkaitan erat dengan regresi, tetapi secara konsep berbeda dengan analisis regresi. Analisis korelasi adalah mengukur suatu tingkat atau kekuatan hubungan linear antara dua variabel. Koefisien korelasi adalah mengukur kekuatan hubungan linear. Untuk mengetahui hubungan antara dua variabel, maka cukup melihat nilai dari koefisien korelasi. Koefisien korelasi (r) merupakan indeks atau bilangan yang digunakan untuk mengukur keeratan hubungan antar variabel.

$$r = \frac{n \sum XY - \sum X \sum Y}{\sqrt{n \sum X^2 - (\sum X)^2 (n \sum Y^2 - (\sum Y)^2)}} \quad (4)$$

dimana :

X = Variabel independen

Y = Variabel depende

n = Banyaknya sampel

a. Regresi Linear

Hasil analisis regresi adalah berupa koefisien regresi untuk masing-masing variable independent. Koefisien ini diperoleh dengan cara memprediksi nilai variable dependen dengan suatu persamaan.

$$\bar{Y}_t = a + bX \quad (5)$$

dimana:

Y = Variabel dependen

X = Variabel Independen

a = Konstanta

b = Koefisien regresi

dengan:

$$b = \frac{n \sum XY - \sum X \sum Y}{n \sum X^2 - (\sum X)^2} \quad (6)$$

$$a = \frac{n \sum XY - \sum X \sum Y}{n \sum X^2 - (\sum X)^2} \quad (7)$$

b. Kesalahan Baku Estimasi

Kesalahan baku atau selisih taksir standar regresi adalah nilai menyatakan seberapa jauh menyimpangnya nilai regresi tersebut terhadap nilai sebenarnya. Nilai ini digunakan untuk mengukur tingkat ketepatan suatu pendugaan dalam menduga nilai. Jika nilai ini sama dengan nol maka penduga tersebut memiliki tingkat ketepatan 100%.

$$S_{X,Y} = \sqrt{\frac{\sum(Y - \bar{Y}_t)^2}{n - 2}} \quad (8)$$

dengan:

$S_{X,Y}$ = Kesalahan baku

Y = Variabel dependen

Y_t = Persamaan regresi

n = Banyaknya sampel

c. Regresi Linear Berganda

Analisis regresi merupakan salah satu teknik analisis data dalam statistika yang seringkali digunakan untuk mengkaji hubungan antara beberapa variabel dan meramal suatu variabel (Kutner, Nachtsheim dan Neter, 2004). Istilah “regresi” pertama kali dikemukakan oleh Sir Francis Galton (1822-1911), seorang

antropolog dan ahli meteorologi terkenal dari Inggris. Dalam makalahnya yang berjudul "Regression towards mediocrity in hereditary stature", yang dimuat dalam *Journal of the Anthropological Institute*, volume 15, hal. 246-263, tahun 1885. Galton menjelaskan bahwa biji keturunan tidak cenderung menyerupai biji induknya dalam hal besarnya, namun lebih medioker (lebih mendekati rata-rata) lebih kecil daripada induknya kalau induknya besar dan lebih besar daripada induknya kalau induknya sangat kecil (Draper dan Smith, 1992).

Dalam mengkaji hubungan antara beberapa variabel menggunakan analisis regresi, terlebih dahulu peneliti menentukan satu variabel yang disebut dengan variabel tidak bebas dan satu atau lebih variabel bebas. Jika ingin dikaji hubungan atau pengaruh satu variabel bebas terhadap variabel tidak bebas, maka model regresi yang digunakan adalah model regresi linier sederhana. Kemudian Jika ingin dikaji hubungan atau pengaruh dua atau lebih variabel bebas terhadap variabel tidak bebas, maka model regresi yang digunakan adalah model regresi linier berganda (multiple linear regression model). Kemudian untuk mendapatkan model regresi linier sederhana maupun model regresi linier berganda dapat diperoleh dengan melakukan estimasi terhadap parameter-parameternya menggunakan metode tertentu. Adapun metode yang dapat digunakan untuk mengestimasi parameter model regresi linier sederhana maupun model regresi linier berganda adalah dengan metode kuadrat terkecil (ordinary least square/OLS) dan metode kemungkinan maksimum (maximum likelihood estimation/MLE) (Kutner et.al, 2004). Pada pelatihan ini dikaji analisis regresi linier berganda atau sering juga disebut dengan regresi klasik (Gujarati, 2003). Kajian meliputi kajian teori dan aplikasinya pada studi kasus disertai dengan teknik analisis dan pengolahan datanya dengan bantuan software SPSS under windows versi 15.0. Model regresi linier berganda merupakan suatu persamaan yang menggambarkan hubungan antara dua atau lebih variabel bebas/ predictor (X_1, X_2, \dots, X_n) dan satu variabel tak bebas/ response (Y). Tujuan dari analisis regresi linier berganda adalah untuk memprediksi nilai variabel tak bebas/ response (Y) jika nilai variabel-variabel bebas/ predictor (X_1, X_2, \dots, X_n) diketahui. Disamping itu

juga untuk mengetahui arah hubungan antara variabel tak bebas dengan variabel-variabel bebas.

Persamaan regresi linier berganda secara matematik diekspresikan oleh :

$$Y = a + b_1X_1 + b_2X_2 + \dots + b_nX_n. \quad (8)$$

yang mana :

Y = variable tak bebas (nilai yang akan diprediksi)

a = konstanta

b_1, b_2, \dots, b_n = koefisien regresi

X_1, X_2, \dots, X_n = variable bebas

Bila terdapat 2 variable bebas, yaitu X_1 dan X_2 , maka bentuk persamaan regresinya

adalah

$$Y = a + b_1X_1 + b_2X_2 \quad (9)$$

Keadaan-keadaan bila nilai koefisien-koefisien regresi b_1 dan b_2 adalah :

bernilai 0, maka tidak ada pengaruh X_1 dan X_2 terhadap Y

bernilai negatif, maka terjadi hubungan yang berbalik arah antara variabel bebas X_1 dan X_2 dengan variabel tak bebas Y

bernilai positif, maka terjadi hubungan yang searah antara variabel bebas X_1 dan X_2 dengan variabel tak bebas Y .

Konstanta a dan koefisien-koefisien regresi b_1 dan b_2 dapat dihitung menggunakan

rumus :

$$a = \frac{(\sum Y) - (b_1 \times \sum x_1) - (b_2 \times \sum x_2)}{n} \quad (10)$$

$$b_1 = \frac{[(\sum x_2^2 \times \sum x_1 y) - (\sum x_2 y \times \sum x_1 x_2)]}{[(\sum x_1^2 \times \sum x_2^2) - (\sum x_1 \times x_2)^2]} \quad (11)$$

$$b_2 = \frac{[(\sum x_1^2 \times \sum x_2 y) - (\sum x_1 y \times \sum x_1 x_2)]}{[(\sum x_1^2 \times \sum x_2^2) - (\sum x_1 \times x_2)^2]} \quad (12)$$

d. Regresi Non-linear Polinomial

Permasalahan dalam mendiskripsikan variasi sistematis suatu variabel atau sekelompok variabel dalam suatu bidang atau ruang dapat dipecahkan dengan suatu regresi berganda (multiple regression). Metode ini dikenal sebagai trend analysis. Selanjutnya dinamakan trend surface analysis apabila titik-titik pengamatan dari variabel tak bebasnya terdistribusi dalam bidang dua dimensi (map area).

Regresi polinomial dapat digunakan untuk membedakan variabel spasial dari suatu variabel ke dalam dua atau lebih komponen-komponennya. Salah satu komponen tersebut hadir dalam bentuk trend, bila diwujudkan dalam bentuk perubahan sistematis nilai rata-rata atau ekspektasi matematik suatu variabel di. Fungsi-fungsi polinomial dapat digunakan untuk menggambarkan suatu trend.

Model regresi non linier polinomial berderajat tiga atau model regresi kubik mempunyai persamaan umum yang berbentuk :

$$Y = \beta_0 X_{0i} + \beta_1 X_i + \beta_2 X_i^2 + \beta_3 X_i^3 + \varepsilon \quad (13)$$

dimana:

Y_i = nilai pengamatan ke-i

X_i = nilai peubah X yang ke-i

0 = titik potong / parameter intersep

1 - 3 = Parameter pengaruh peubah X_1, X_2, X_3 terhadap peubah Y pada derajat atau ordo ke 1, 2, 3.

ε = galat ke-i yang diasumsikan berdistribusi bebas normal dengan nilai rata-rata 0 dan ragam (σ^2)

$$X_{0i} = 1$$

$$i = 1, 2, 3, \dots, n$$

Model regresi polinomial orde kedua dengan tiga variabel bebas adalah

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \beta_{11} x_{i1}^2 + \beta_{22} x_{i2}^2 + \beta_{33} x_{i3}^2 + \beta_{12} x_{i1} x_{i2} + \beta_{13} x_{i1} x_{i3} + \beta_{23} x_{i2} x_{i3} + \varepsilon_i$$

(14)

Koefisien $\beta_{12}, \beta_{13}, \beta_{23}$ merupakan koefisien efek interaksi untuk interaksi antara pasangan variabel bebas.

2.3.5. Machine Learning

Machine Learning adalah Teknik untuk menganalisis data yang mengajarkan komputer untuk melakukan kemampuan alami manusia dan hewan (pembelajaran dari pengalaman). Algoritma Machine Learning menggunakan metode komputasi untuk “mempelajari” informasi dari data tanpa bergantung pada persamaan yang telah ditentukan sebagai model. Algoritma akan beradaptasi untuk meningkatkan kinerja mereka ketika jumlah sampel atau data training yang tersedia untuk pembelajaran meningkat.

Dengan populernya istilah Big Data, teknik Machine Learning merupakan teknik kunci untuk mengatasi berbagai permasalahan tersebut, seperti:

Dalam proses pembelajaran, Machine Learning ini umumnya menggunakan dua skenario pembelajaran yaitu Supervised Learning dan Unsupervised Learning. Perbedaan keduanya ada pada bagaimana cara mereka belajar.

1. Supervised Learning

Pada skenario Supervised Learning, algoritma yang digunakan seolah-olah akan dilatih terlebih dahulu untuk melakukan prediksi maupun klasifikasi menggunakan data latih hingga mencapai target yang ditetapkan oleh user. Biasanya algoritma akan dilatih dengan beberapa macam data latih berbeda untuk mencapai beberapa target tertentu sesuai dengan kualifikasi yang diberikan user. Ketika algoritma sudah mencapai atau sangat mendekati target, maka algoritma sudah siap untuk diuji.

Sebagai contoh untuk klasifikasi buah mangga matang dan mangga busuk berbasis gambar. Sebelum melakukan klasifikasi, perlu disiapkan data latih berupa beberapa foto mangga matang dan mangga busuk. Kedua data latih tersebut kemudian dilatih menggunakan algoritma Neural Network dengan dua target yang berbeda. Setelah data latih yang ditentukan mencapai target, maka algoritma tersebut siap digunakan untuk menguji gambar. Supervised Learning menggunakan dua teknik untuk membangun sebuah model yaitu, model klasifikasi dan model regresi. Ada beberapa algoritma yang termasuk dalam supervised Learning ini seperti: Neural Network, Naïve Bayes Classifier, Decision Tree, Regresi linear berganda, Analisis waktu dan beberapa algoritma lainnya.

2. Unsupervised Learning

Berbeda dengan Teknik supervised, Teknik unsupervised tidak membutuhkan data latih untuk melatih algoritma. Pendekatan yang digunakan oleh Teknik Unsupervised Learning ini adalah dengan melakukan pembelajaran pada pola data tersebut terbentuk, algoritma akan mengelompokkan data sesuai dengan pola data lain yang sejenis. Berdasarkan model matematikanya, Teknik unsupervised ini tidak memiliki target variabel.

Pemodelan yang paling sering digunakan oleh Teknik unsupervised ini adalah Clustering Model. Model ini digunakan untuk menganalisis suatu data untuk menemukan pola tersembunyi atau mengelompokkan suatu data. Model Clustering

ini biasanya diaplikasikan untuk market research, tes psikologi dan lainnya. Algoritma yang biasa digunakan untuk unsupervised Learning ini seperti: Fuzzy C-means, K-means, Hierarchical Clustering dan sebagainya.

Dalam kasus object recognition, saat ini proses Learning sebenarnya bisa melakukan keduanya, tergantung ekstraksi seperti apa yang dijalankan. Tapi dalam beberapa penelitian sebelumnya, Teknik unsupervised dengan metode klasifikasi memberikan hasil dengan akurasi tinggi. Salah satu metode klasifikasi unsupervised Learning yang cukup sering digunakan untuk object recognition adalah model klasifikasi menggunakan algoritma Neural Network (Jaringan Syaraf Tiruan). Algoritma Neural Network ini sering digunakan untuk pengenalan pola seperti kasus object recognition ini karena kemampuannya yang unik, yaitu kemampuan untuk meniru proses pembelajaran seperti otak manusia.

2.3.6. Jaringan Saraf Tiruan (JST)

Jaringan saraf adalah komputer atau model matematika yang mencoba untuk meniru baik bentuk atau fitur fungsi yang dikaitkan dengan sistem saraf yang hidup. ANN sebagian besar merupakan koneksi terbagi dari elemen pemrosesan arbitrer yang dapat disesuaikan (PE); dengan kata lain, mereka terdiri dari serangkaian neuron buatan yang terhubung dan mengubah data menggunakan perspektif koneksionis untuk perhitungan. Namun, diterapkan dalam peralatan komputer, PE adalah tambahan dasar perkalian yang digantikan oleh diskontinuitas (McCulloch-Pitts model). Kekuatan tautan, bernama bobot, dapat dimodifikasi dalam upaya untuk membuat produk akhir sistem sesuai dengan keluaran yang diinginkan.

Biasanya, jaringan saraf adalah struktur fleksibel yang mereplikasi bentuk intrinsik yang dibangun di atas data luar atau dalam, yang bergerak di seluruh sistem selama tahap pelatihan. Adaptasi adalah kemampuan untuk mengganti variabel jaringan yang sesuai dengan perintah (biasanya, meminimalkan fungsi kesalahan). Adaptasi memungkinkan jaringan untuk mencari kinerja terbaik. Jaringan saraf adalah implementasi pemodelan matematika-statistik sewenang-wenang. Ini dapat

digunakan untuk mereproduksi interkoneksi rumit yang menghubungkan informasi yang dimasukkan dan dikirim atau untuk mendeteksi pola dalam informasi. Pemrosesan data yang dialokasikan memiliki keunggulan akurasi, pencadangan, distribusi kalkulasi yang besar, dan komputasi kolaboratif.

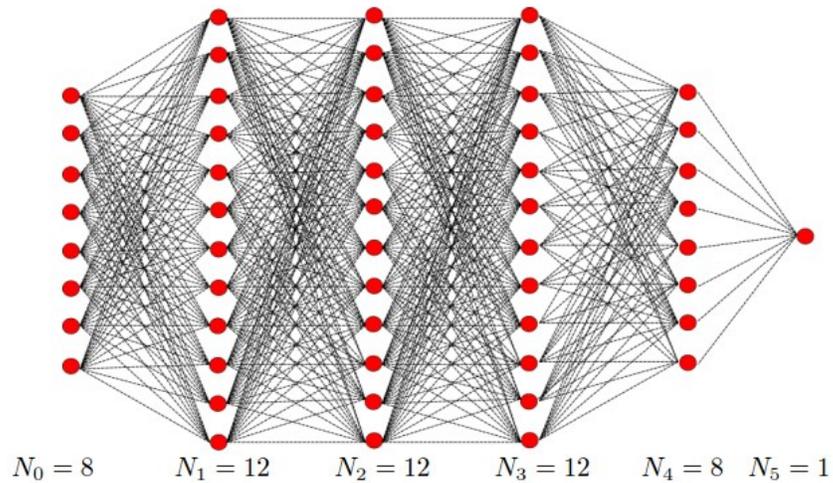
MLP adalah topologi jaringan saraf terapan yang lebih dominan. Lippmann diklasifikasikan di antara bibliografi yang direkomendasikan paling dominan mengenai kemampuan numerik MLP. Umumnya, untuk kategorisasi pola tetap, MLP dengan sepasang lapisan tersembunyi adalah pengklasifikasi pola umum. Artinya, analisis diskriminan dapat mengambil bentuk apa pun, seperti yang diperlukan oleh pengumpulan informasi yang sudah ada. Lagi pula, sementara bobot dan grup keluaran dinormalisasi dengan benar, MLP mencapai kinerja penerima analitis tertinggi, yang sangat baik dari sudut pandang pengklasifikasian. Mengenai kemampuan pemetaan, MLP dianggap mampu memperkirakan proses acak.

MLP biasanya dilatih menggunakan metode backpropagation dan di sini optimasi Levenberg–Marquardt diterapkan. Bobot dan bias dimodifikasi sesuai dengan prosedur optimasi, dan teknik backpropagation digunakan untuk perhitungan matriks Jacobian dari fungsi kinerja sehubungan dengan bobot dan bias. Sebenarnya, perhatian yang direnovasi mengenai jaringan saraf telah diaktifkan sebagian karena adanya backpropagation. Algoritma least mean squares (LMS) yang dikemukakan oleh Bernard Widrow (1960) mungkin tidak dapat diterapkan pada PE tersembunyi, karena sinyal yang diinginkan tidak diketahui dalam metode pembelajaran tersebut. Algoritma backpropagation mendistribusikan kesalahan di sepanjang sistem dan memungkinkan penyesuaian PE tersembunyi.

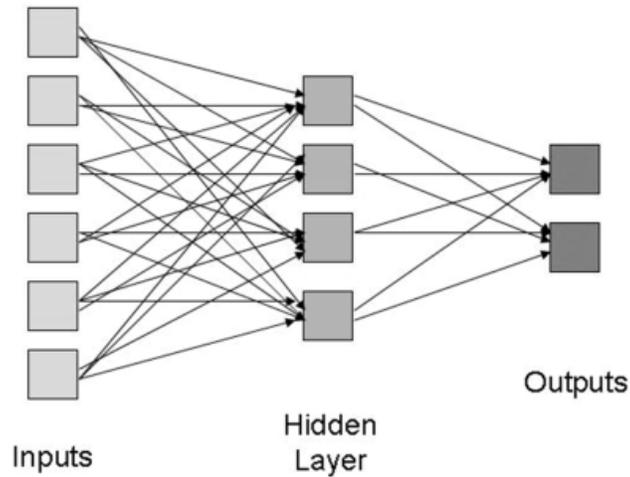
Dua fitur utama MLP adalah Pes arbiternya, yang memiliki diskontinuitas yang seharusnya mulus (fungsi logistik dan tangen hiperbolik lebih dominan dan diadopsi secara universal); dan konektivitasnya yang hebat (dengan kata lain, komponen yang termasuk dalam lapisan tertentu memasok setiap komponen lapisan berikutnya). MLP dilatih menggunakan pembelajaran koreksi kesalahan, yang menandakan bahwa respons yang dibutuhkan jaringan perlu ditemukan. Dalam

identifikasi pola itu biasanya peristiwa, karena informasi yang dimasukkan ditentukan (dengan kata lain, informasi mana yang merupakan bagian dari tes mana yang ditemukan).

Di sini struktur MLP lapisan tersembunyi yang unik diadopsi untuk hubungan domain waktu yang menghubungkan output dan input. Ilustrasi pengaturan umum ditunjukkan pada Gambar 4 dan Gambar 5. Sebuah neuron bias unik akan dijumlahkan ke setiap input PJ dan lapisan tersembunyi yang akan ditambahkan ke input berbobot W_j untuk membentuk input n , yang dapat dinyatakan dengan.



Gambar 4. Neural Network



Gambar 5. Sebuah ilustrasi dari jaringan feed forward dasar umum

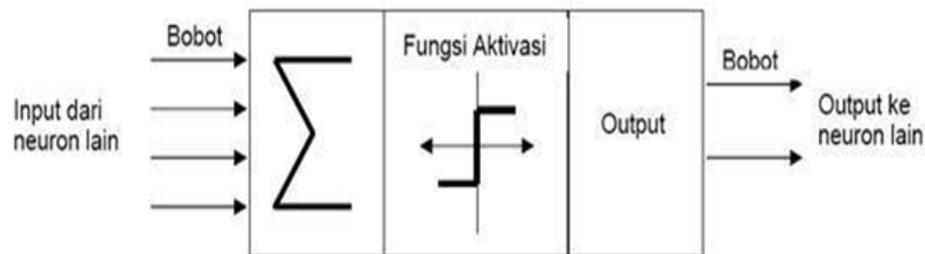
$$n = \sum_{j=1}^n w_j p_j + b \quad (15)$$

Jumlah neuron tersembunyi mengatur kekokohan desain jaringan. Kuantitas ini dipilih dengan cermat dalam rangkaian beberapa pelatihan yang dilakukan untuk konfirmasi melalui analisis sensitivitas hasil.

Di sini dua struktur berbeda dari sistem MLP (feedforward ANNs) dikembangkan di MatLab dan dilatih menggunakan metode Levenberg–Marquardt, dan kemudian dibandingkan dengan algoritme optimisasi backpropagation yang tangguh. MLP pertama terdiri dari tiga lapisan node: lapisan input, lapisan tersembunyi, dan lapisan output; yang kedua memiliki lapisan input, tiga lapisan tersembunyi, dan lapisan output. Kecuali node input, setiap node adalah neuron yang menggunakan fungsi aktivasi nonlinier, dalam hal ini fungsi log sigmoid.

Neural Network memiliki beberapa tipe yang berbeda, akan tetapi hampir semua komponen dan karakteristik yang dimiliki sama. Sama halnya dengan jaringan otak manusia, neural network juga terdiri dari beberapa neuron dan antar neuron juga

berhubungan antar satu sama lain. Neuron-neuron tersebut akan melakukan transformasi informasi yang diterima melalui sambungan keduanya menuju neuron yang lain berdasarkan bobot yang dimiliki antar neuron. Berikut pada Gambar 6. merupakan komponen umum yang ada pada neural network.



Gambar 6. Karakteristik Neural Network

Penyelesaian masalah dengan jaringan syaraf tiruan tidak memerlukan pemrograman. Jaringan syaraf tiruan menyelesaikan masalah melalui proses belajar dari contoh-contoh pelatihan yang diberikan. Biasanya pada jaringan syaraf tiruan diberikan sebuah himpunan pola pelatihan yang terdiri dari sekumpulan contoh pola. Proses belajar jaringan syaraf tiruan berasal dari serangkaian contoh-contoh pola yang diberikan. Metode pelatihan yang sering dipakai adalah metode belajar terbimbing. Selama proses belajar itu pola masukan disajikan bersama-sama dengan pola keluaran yang diinginkan. Jaringan akan menyesuaikan nilai bobotnya sebagai tanggapan atas pola masukan dan sasaran yang disajikan tersebut.

1. Faktor bobot

Bobot merupakan suatu nilai yang mendefinisikan tingkat atau kepentingan hubungan antara suatu node dengan node yang lain. Semakin besar bobot suatu hubungan menandakan semakin pentingnya hubungan kedua node tersebut. Bobot merupakan suatu hubungan berupa bilangan real maupun integer, tergantung dari jenis permasalahan dan model yang digunakan. Bobot-bobot tersebut bisa ditentukan untuk berada didalam interval tertentu. Selama proses pelatihan, bobot

tersebut dapat menyesuaikan dengan pola-pola input. Jaringan dengan sendirinya akan memperbaiki diri terus menerus karena adanya kemampuan untuk belajar. Setiap ada suatu masalah baru, jaringan dapat belajar dari masalah baru tersebut, yaitu dengan mengatur Kembali nilai bobot untuk menyesuaikan karakter nilai.

2. Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi yang menggambarkan hubungan antara tingkat aktivitas internal (summation function) yang mungkin berbentuk linear ataupun non-linear, berfungsi untuk menentukan apakah neuron tersebut harus “aktif” atau tidak berdasarkan dari weighted sum (bobot dari hasil penjumlahan) dari input. Secara umum, ada 2 activation function yang sering digunakan dalam neural network, diantaranya:

1) Fungsi Sigmoid and Tanh (Non-Linear)

Fungsi sigmoid dan fungsi tanh merupakan salah satu fungsi yang sering digunakan untuk fungsi aktivasi pada neural network multi layer. Kedua fungsi aktivasi ini, sama-sama fungsi aktivasi non-linear yang fungsi ini biasanya digunakan untuk klasifikasi 2 class atau kelompok data.

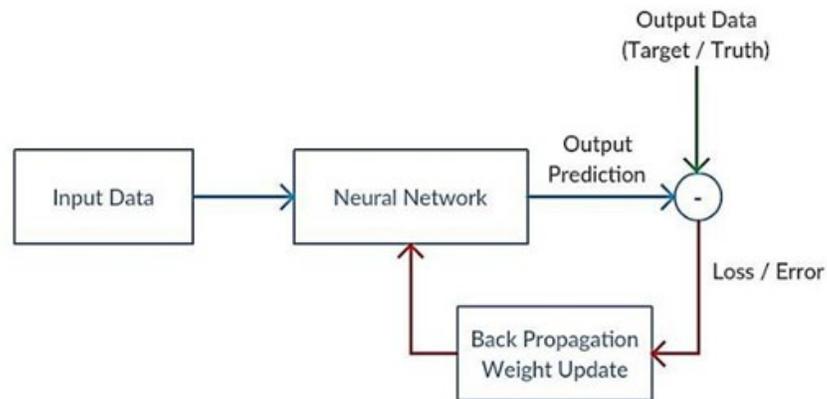
Fungsi sigmoid mempunyai rentang antara 0 hingga 1 sedangkan rentang dari fungsi tanh adalah -1 hingga 1. Kedua fungsi ini hampir sama, hanya saja fungsi tanh merupakan pengembangan dari fungsi sigmoid. Tapi kedua fungsi ini memiliki kelemahan yaitu, dapat mematikan gradient, Ketika aktivasi dari neuron mengeluarkan nilai yang berada pada range 0 atau 1, dimana gradient di wilayah ini hampir bernilai 0. Kemudian output dari sigmoid tidak zero-centered.

2). Fungsi ReLu (non-linear)

ReLU atau Rectified Linear Unit menjadi salah satu activation function yang populer dibelakang ini, Vincent Vanhoucke dalam course Deep Learning-nya di udacity mengatakan bahwa ReLU merupakan activation function favorit para engineer yang malas. Karena ReLU pada intinya hanya membuat pembatas pada bilangan nol, artinya apabila $Z \leq 0$ maka $Z = 0$ dan apabila $Z > 0$ maka $Z = z$.

ReLU bisa diimplementasikan hanya dengan membuat pembatas (threshold) pada bilangan nol. Fungsi aktivasi ini memiliki kelebihan yaitu dapat mempercepat proses konfigurasi yang dilakukan dengan Stochastic Gradient Descent (SGD) jika dibandingkan dengan fungsi Sigmoid dan Tanh. Namun aktivasi ini juga memiliki kelemahan yaitu aktivasi ini bisa menjadi rapuh pada proses training dan bisa membuat unit tersebut mati.

Neural network merupakan suatu model komputasi yang sistemnya mengikuti syaraf otak manusia. Dan salah satu ciri khas dari otak manusia adalah melakukan pembelajaran berdasarkan pengalaman. Neural network juga begitu, model ini membutuhkan proses pembelajaran untuk mengenali pola dari data yang dipelajarinya. Pembelajaran ini bertujuan untuk melakukan suatu proses dalam menentukan nilai bobot (weight) yang tepat untuk masing-masing input. Proses untuk melakukan pembelajaran ini biasanya terjadi pada saat proses pelatihan data (training data) biasanya disebut dengan backpropagation. Backpropagation merupakan salah satu dari metode pelatihan pada jaringan syaraf tiruan, dimana ciri dari metode ini adalah meminimalkan error pada output yang dihasilkan oleh jaringan. Jadi backpropagation ini bekerja dengan cara melakukan update nilai bobot pada neuron di layer sebelumnya.



Gambar 7. Backpropagation

Seperti pada Gambar 7, tugas dari metode backpropagation adalah dengan melakukan update bobot berdasarkan nilai error yang didapatkan dari perbandingan antara nilai output dan target output. Proses training menggunakan backpropagation secara garis besar dari dua tahap; tahap maju (forward pass) dan tahap mundur (backward pass).

Pada tahap maju, akan dilakukan operasi dot antar nilai bobot pada node input dengan node pada layer didepannya. Operasi ini dilakukan untuk mendapatkan nilai output, proses ini disebut dengan forward pass. Kemudian hasil prediksi output akan dibandingkan dengan target dengan menggunakan sebuah fungsi yang biasa disebut dengan loss function. Secara sederhana loss function adalah fungsi yang digunakan untuk mengukur seberapa bagus performa dari neural network kita dalam melakukan prediksi terhadap target. Ada berbagai macam loss function yang bisa digunakan, namun yang paling sering digunakan adalah squared error, loss function yang sering digunakan untuk linear regresi. Sedangkan untuk klasifikasi dengan beberapa kelas yang biasa digunakan untuk mencari loss function menggunakan squared error adalah seperti berikut;

$$Loss = (Prediction - target)^2 \quad (16)$$

Kemudian pada tahap kedua akan dilakukan propagasi mundur (backward pass). Tahapannya hampir sama dengan forward pass, pada backward pass nilai loss yang didapatkan akan mengalir dan dijadikan sebagai bobot pengali menuju semua node pada layer sebelumnya untuk dicari gradient nya. Semisal ingin melakukan update pada parameter W_{k10} , pertama akan dicari seberapa besar perubahan loss berdasarkan output dengan cara mencari turunan parsial dari loss function terhadap output.

Setelah mendapatkan nilai gradient loss dari parameter yang dituju, maka akan diberlakukan update nilai dari parameter tersebut menggunakan algoritma stochastic gradient descent (SGD). Secara sederhana, algoritma SGD ini bertujuan untuk menurunkan nilai loss pada parameter dengan cara mengurangi bobot asli dari parameter tersebut dengan “Sebagian” dari nilai gradient loss yang sudah didapatkan sebelumnya. Sebagian disini diwakili oleh nilai dari Learning rate. Jadi SGD ini akan menurunkan nilai loss pada parameter secara terus menerus hingga mencapai titik minimum secara optimal sebanyak iterasi yang terjadi. Rumus untuk melakukan update parameter menggunakan SGD sebagai berikut.

$$W'_{k10} = W_{k10} - \alpha \left(\frac{\partial Loss}{\partial W_{k10}} \right) \quad (17)$$

Dari persamaan diatas, untuk melakukan update pada parameter W_{k10} maka nilai bobot asli dari parameter W_{k10} akan dikurangi dengan Sebagian dari nilai gradient yang didapat. Sebagian disini adalah nilai dari Learning rate (α) yang dikalikan dengan nilai gradient loss yang sudah dicari sebelumnya. Proses ini akan dilakukan terus menerus pada semua parameter yang terhubung hingga sampai pada node input. Setelah itu akan dilakukan proses forward pass dan backward pass lagi. Proses ini akan dilakukan terus menerus hingga proses iterasi selesai.

2.3.7. Pelatihan Jaringan Saraf Tiruan (JST)

Fungsi aktivasi log-sigmoid digunakan untuk semua neuron yang termasuk dalam lapisan tersembunyi, menghasilkan sistem dengan kemampuan untuk menghasilkan pilihan yang mulus. Fungsi tersebut dijelaskan sebagai berikut:

$$f(x_i) = \frac{1}{1 + e^{-x_i}} \quad (18)$$

Pembelajaran koreksi kesalahan dilakukan sebagai berikut: menurunkan respons jaringan pada PE i pada iterasi n , $Y_i(n)$, dan respons yang diinginkan $d_i(n)$ untuk sampel fed-in yang dinyatakan, kesalahan instan $E_i(n)$ dapat menjadi didirikan melalui.

$$e_i(n) = d_i(n) - (y_i(n)) \quad (19)$$

Backpropagation menghitung sensitivitas fungsi biaya dengan mengacu pada setiap bobot dalam sistem dan menyegarkan semua bobot secara proporsional dengan sensitivitas. Manfaat metode ini adalah dapat diterapkan dengan data lokal dan hanya membutuhkan produk kecil per berat, yang sangat efektif. Kerugiannya adalah karena ini adalah metode penurunan gradien, metode ini secara eksklusif menggunakan data lokal sehingga mungkin terletak relatif minima. Selanjutnya, metode ini secara alami berisik karena pendekatan gradien yang kurang baik diadopsi, menghasilkan konvergensi yang lambat.

Pada saat yang sama dengan backpropagation, dilakukan metode penurunan paling curam, algoritma Levenberg– Marquardt, yang berasal dari metode Newton– Raphson yang digariskan untuk meminimalkan fungsi yang merupakan jumlah kuadrat dari fungsi nonlinier, dari formulir.

$$E = \frac{1}{2} \sum k(e_k)^2 = \frac{1}{2} \|e\|^2 \quad (20)$$

Dimana e_k adalah kesalahan dalam pola k dan e adalah larik komponen e_k . Selama perbedaan antara susunan bobot sebelumnya dan yang sebenarnya kecil, susunan kesalahan dapat didekati ke orde pertama melalui deret Taylor:

$$e(j+1) = e(j) + \frac{\partial e_k}{\partial w_i} (w(j+1) - w(j)) \quad (21)$$

Akibatnya, fungsi kesalahan dapat diberikan oleh:

$$E = \frac{1}{2} \|e(j) + \frac{\partial e_k}{\partial w_i} (w(j+1) - w(j))\|^2 \quad (22)$$

Melalui minimalisasi fungsi kesalahan dengan mengacu pada larik bobot aktual:

$$w(j+1) = w(j) - (J^T J)^{-1} J^T e(j) \quad (23)$$

Dimana $(J)_{ki} = (\partial e_k / \partial w_i)$ adalah Jacobian matrix.

$$(H)_{ij} = \frac{\partial^2 E}{\partial w_i \partial w_j} = \sum \left\{ \left(\frac{\partial e_k}{\partial w_i} \right) \left(\frac{\partial e_k}{\partial w_j} \right) + e_k \frac{\partial^2 e_k}{\partial w_i \partial w_j} \right\} \quad (24)$$

Mengabaikan istilah ke-2 dalam (8), Hessian dapat ditulis ulang dengan cara berikut:

$$H = J^T J \quad (25)$$

Penyegaran bobot membutuhkan Hessian terbalik. Hessian cukup sederhana untuk dihitung karena diformulasikan pada turunan orde 1 sehubungan dengan bobot jaringan, yang dengan mudah disesuaikan melalui backpropagation. Terlepas dari kenyataan bahwa prosedur penyegaran dapat digunakan secara iteratif untuk meminimalkan fungsi kesalahan, hal ini dapat menghasilkan ukuran langkah yang besar yang dapat membatalkan estimasi linier di mana metode tersebut dibuat. Dalam teknik Levenberg-Marquardt, fungsi kesalahan diminimalkan, sedangkan ukuran langkah dipertahankan sebagai kecil meskipun memastikan kelangsungan estimasi linier. Hal ini dicapai melalui adopsi fungsi kesalahan dirumuskan sebagai berikut:

$$E = \frac{1}{2} \|e(j) + \frac{\partial e_k}{\partial w_i} (w(j+1) - w(j))\|^2 + \lambda \|w(j+1) - w(j)\|^2 \quad (26)$$

Di mana λ adalah variabel yang mengontrol ukuran langkah. Meminimalkan kesalahan yang dimodifikasi sehubungan dengan $w(j+1)$:

$$w(j+1) = w(j) - (J^T J + \lambda I)^{-1} J^T e(j) \quad (27)$$

Ketika skalar λ adalah nol, Persamaan (27) mengungkapkan secara tepat metode Newton, menggunakan matriks Hessian perkiraan. Ketika λ besar, formulasi berubah menjadi gradient descent dengan ukuran langkah yang kecil. Metode Newton cepat dan lebih tepat mendekati kesalahan minimum, sehingga tujuannya adalah untuk bergerak ke arah metode Newton dengan cepat. Akibatnya, λ berkurang setelah semua langkah yang menguntungkan (pengurangan fungsi kinerja) dan ditambah hanya ketika langkah awal akan meningkatkan fungsi kinerja. Dengan demikian, fungsi kinerja menurun setiap kali pada setiap iterasi algoritma.

Fungsi transfer sigmoid yang biasanya digunakan oleh jaringan multilayer di lapisan tersembunyi sering disebut fungsi "squashing" karena fungsi tersebut memampatkan rentang input tak terbatas menjadi rentang output terbatas. Fungsi sigmoid dicirikan oleh fakta bahwa kemiringannya harus mendekati nol saat input menjadi besar. Hal ini menyebabkan masalah ketika penurunan paling curam digunakan untuk melatih jaringan multilayer dengan fungsi sigmoid, karena gradien dapat memiliki magnitudo yang sangat kecil dan, oleh karena itu, menyebabkan perubahan kecil pada bobot dan bias, meskipun bobot dan bias jauh dari nilai-nilai optimal mereka.

Tujuan dari algoritma pelatihan backpropagation tangguh adalah untuk menghilangkan efek berbahaya dari besaran turunan parsial. Hanya tanda turunan yang dapat menentukan arah pembaruan bobot; besarnya turunan tidak berpengaruh pada pembaruan bobot. Ukuran perubahan bobot ditentukan oleh nilai pembaruan yang terpisah. Nilai pembaruan untuk setiap bobot dan bias meningkat dengan faktor setiap kali turunan dari fungsi kinerja sehubungan dengan bobot itu memiliki tanda

yang sama untuk dua iterasi yang berurutan. Nilai pembaruan dikurangi dengan faktor setiap kali turunan sehubungan dengan bobot itu berubah tanda dari iterasi sebelumnya. Jika turunannya nol, nilai pembaruannya tetap sama. Setiap kali bobot berosilasi, perubahan berat berkurang. Jika bobot terus berubah ke arah yang sama untuk beberapa iterasi, besarnya perubahan bobot meningkat. Sebuah deskripsi lengkap dari algoritma backpropagation tangguh diberikan dalam. Algoritma pembelajaran ini digunakan untuk membandingkan hasil yang diperoleh dengan metode Levenberg–Marquardt.

2.3.8. Penentuan Tahanan Sisa Kapal dengan Menggunakan JST

Biasanya disarankan untuk menggunakan hanya satu lapisan tersembunyi, karena sebagian besar masalah dapat diselesaikan dengan arsitektur seperti itu. Lapisan input dan output ditentukan berdasarkan dimensi data input dan output yang dibutuhkan, sehingga jumlah neuron lapisan tersembunyi dapat diperkirakan sebagai mean geometrik:

$$N_{hl} = \sqrt{N_{il} \cdot N_{ol}} \quad (28)$$

dimana:

N_{hl} : Jumlah neuron pada hidde layer

N_{il} : Jumlah neuron pada input layer

N_{ol} : Jumlah neuron pada output layer.

Meminimalkan fungsi kesalahan adalah tujuan utama dari pelatihan jaringan saraf. Nilai fungsi error digunakan untuk menilai kualitas jaringan syaraf tiruan. Sum-of Squared-Errors adalah fungsi kesalahan yang paling umum digunakan untuk masalah klasifikasi dan regresi. Ini dihitung sebagai jumlah dari perbedaan kuadrat antara nilai aktual (nilai target) dan keluaran jaringan saraf yang diamati.

$$SSE = \sum_{i=1} N_{i=1} (x_i - \hat{x}_i)^2 \quad (29)$$

dimana:

x_i : nilai target sebenarnya,

\hat{x}_i : nilai prediksi atau perkiraan (nilai output).

Pelatihan algoritma, terdapat 7 evaluasi pelatihan algoritma:

- Quick Propagation,
- Conjugate Gradient Descent,
- Quasi-Newton Programming,
- Limited Memory Quasi-Newton,
- Levenberg-Marquardt,
- Online Back Propagation,
- Batch Back Propagation.

Algoritma pelatihan yang paling sesuai dengan masalah yang dipecahkan harus dipilih. Pengembang Alyuda menyarankan bahwa untuk jaringan dengan sejumlah kecil bobot (biasanya hingga 300), algoritma Levenberg-Marquardt efisien, dan sering kali berkinerja jauh lebih cepat dan menemukan optima yang lebih baik daripada algoritma lain, namun kebutuhan memorinya sebanding dengan kuadrat jumlah bobot, dan dirancang khusus untuk meminimalkan SSE dan tidak dapat digunakan untuk jenis fungsi kesalahan jaringan lainnya.

Untuk jaringan dengan jumlah bobot Quasi-Newton dan Memori Terbatas yang moderat, algoritma Quasi-Newton efisien. Tetapi kebutuhan memori mereka juga sebanding dengan jumlah bobot kuadrat.

Jika jaringan memiliki banyak bobot, disarankan untuk menggunakan Conjugate Gradient Descent, karena memiliki kecepatan konvergensi yang hampir sama dengan metode orde kedua, sambil menghindari kebutuhan untuk menghitung matriks Hessian. Persyaratan memorinya sebanding dengan jumlah bobot.

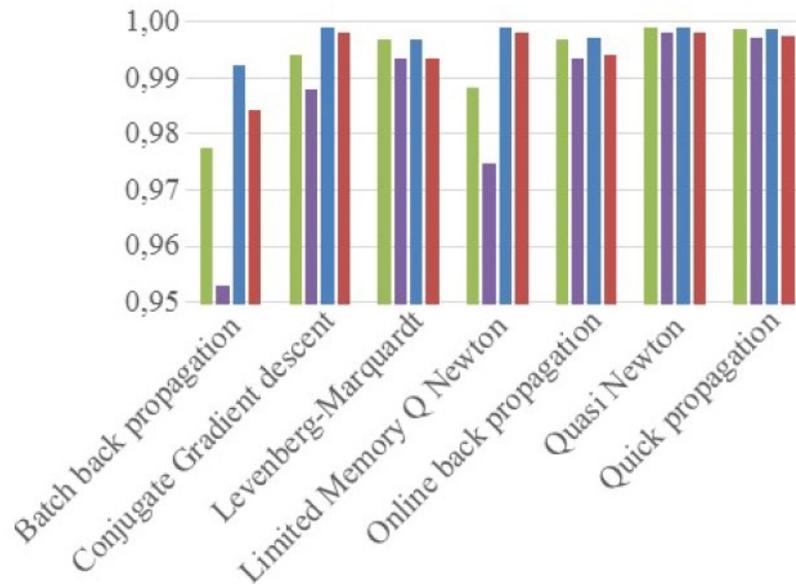
Untuk jaringan dengan ukuran berapa pun juga dapat digunakan algoritma Incremental dan Batch Back Propagation. Back Propagation adalah algoritma yang

paling populer untuk pelatihan multi-layer perceptrons dan sering digunakan oleh peneliti dan praktisi. Kelemahan utamanya adalah konvergensi yang lambat, kebutuhan untuk menyesuaikan kecepatan pembelajaran dan parameter momentum, dan kemungkinan pelatihan yang tinggi tertangkap dalam minimum lokal. Incremental Back Propagation dapat menjadi efisien untuk kumpulan data yang besar jika peneliti memilih kecepatan dan momentum pembelajaran dengan benar. Biasanya berkinerja lebih baik daripada Propagasi Batch Back.

Untuk penelitian ini tujuh algoritma pelatihan diuji, dan asumsi berikut dibuat: jaringan dilatih ulang 3 kali, berhenti pada iterasi 10.000 dan 100.000. Akhirnya, jaringan dengan hasil terbaik dipilih. Hasil penelitian disajikan di bawah ini dalam Tabel 2 dan gambar berikut.

Tabel 2. Hasil Training Algoritma

Training algorithms	100,000 iterations			100,000 iterations		
	Correlation	R ²	AE	Correlation	R ²	AE
Batch Back Propagation	0.997	0.953	147.854	0.992	0.984	43.832
Conjugate Gradient Descent	0.994	0.988	27.141	0.999	0.998	41.599
Levenberg-Marquardt	0.997	0.994	42.235	0.996	0.994	42.236
Limited Memory Q Newton	0.988	0.975	28.292	0.999	0.998	21.413
Online Back Propagation	0.997	0.994	34.347	0.997	0.994	24.999
Quasi Newton	0.999	0.998	22.494	0.999	0.998	22.495
Quick propagation	0.999	0.997	21.77	0.998	0.998	16.737



Gambar 8. Hasil dari algoritma pelatihan untuk algoritma pelatihan yang tersedia dan jumlah iterasi yang diberikan

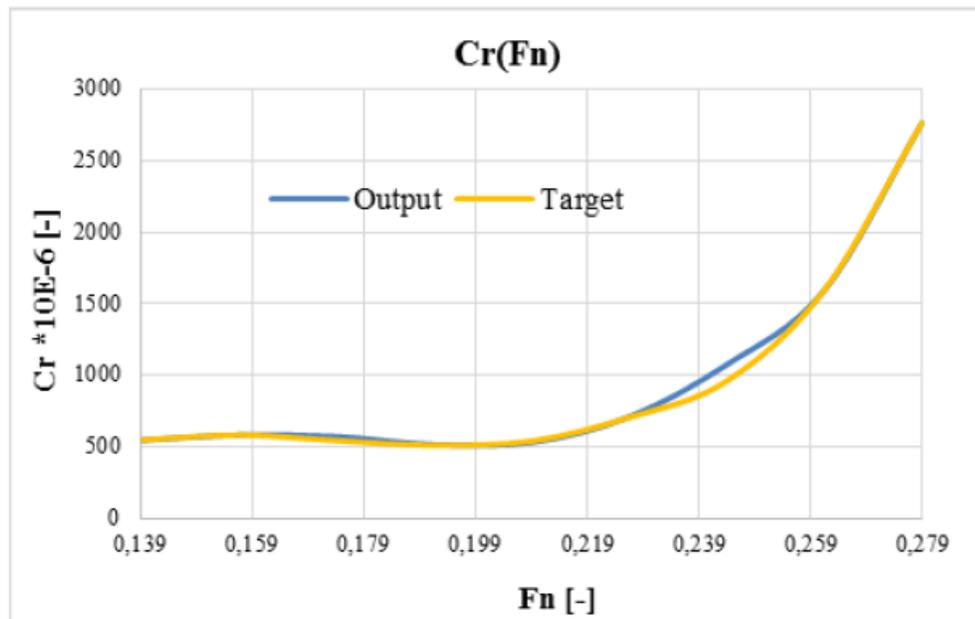
Sebagai hasil sampel, dua kapal, PSV no.6 dan AHTS no. 79 dibahas di sini. Nilai-nilai berikut (Tabel IV) dari koefisien resistansi residual diperoleh:

dimana: F_n :Froude number, dan C_r :Koefisien tahanan sisa.

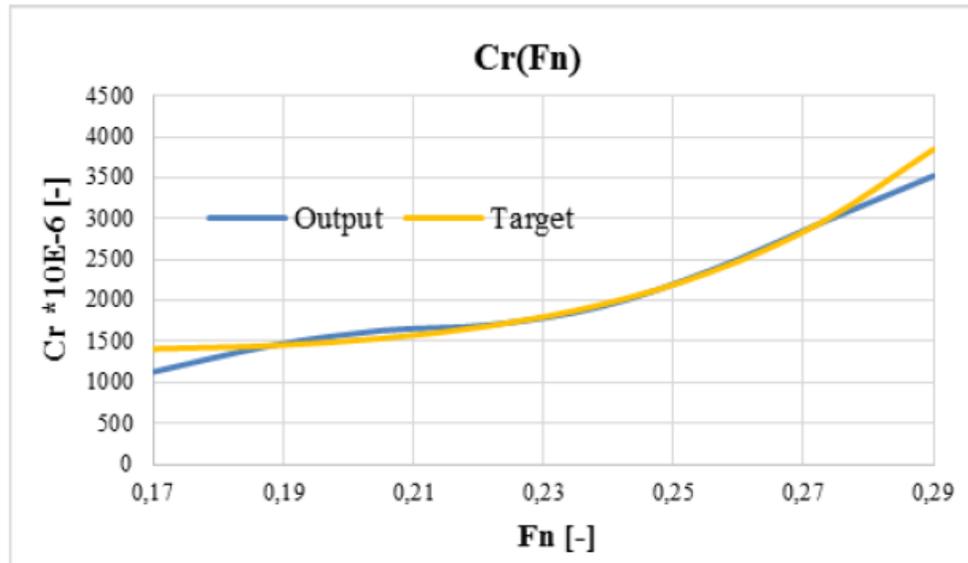
Korespondensi antara nilai aktual dan prediksi C_r untuk dua kapal yang dipilih disajikan pada Gambar 9 dan Gambar 10. Model tidak dapat secara tepat mencocokkan nilai target untuk F_n sedang dalam kasus PSV 6 dan F_n rendah dan tinggi untuk AHTS 79.

Tabel 3. Hasil tahanan sisa dari kapal OSV

PSV no. 6			AHTS no. 79		
Fn [-]	Cr.10e-6[-] Target	Cr.10e-6[-] Output	Fn [-]	Cr.10e-6[-] Target	Cr.10e-6[-] Output
0.139	547	546	0.170	1411	1557
0.157	581	581	0.188	1451	1442
0.174	542	569	0.205	1538	1462
0.192	509	514	0.222	1695	1693
0.209	540	531	0.239	1954	1943
0.227	705	710	0.256	2358	2364
0.224	959	1074	0.273	2965	2959
0.262	1597	1596	0.29	3849	3652
0.279	2762	2762	-	-	-



Gambar 9. Koefisien tahanan sisa sebagai fungsi dari bilangan Froude, PSV no.6



Gambar 10. Koefisien tahanan sisa sebagai fungsi dari bilangan Froude, AHTS no.79

2.4. Sistematika Pengerjaan Penelitian

Ship data was collected from the NKK classification (www.classnk.com), with the number of 1467 ship data collected with the type of bulk carrier ship that has been actively operating until now. The following is a systematic research work.;

1. Input dan pemilihan data pada variabel yang akan dianalisis..
2. Tabulasikan data dari variabel yang telah terkumpul, kemudian bagi menjadi dua bagian yang terdiri dari variabel masukan (x) dan variabel keluaran (y). dan mengelompokkannya berdasarkan kategori yang sama.
3. Menentukan dan menghitung nilai korelasi antara variabel input (x) dengan variabel output atau target (y).
4. Untuk mendapatkan nilai R^2 dari kedua analisis tersebut, dilakukan regresi linier berganda dan regresi polinomial pada variabel (x) dan (y) dengan Python menggunakan modul program skit learn. Pendekatan analisis untuk regresi linier berganda dan regresi polinomial memiliki dua tahap: pelatihan dan

pengujian data. Menggunakan pendekatan split-directly, yaitu membagi data menjadi dua bagian, 70% data digunakan untuk pelatihan dan 30% untuk pengujian, keduanya dipilih secara acak.

5. Kemudian dilakukan pemodelan struktur jaringan syaraf tiruan (JST) menggunakan Mat Lab. Tahapan pemodelan struktur jaringan saraf tiruan (JST) secara umum terdiri dari tiga tahap, yaitu: pertama, menentukan fungsi algoritma, kedua, menentukan jumlah lapisan tersembunyi dan bobotnya, dan ketiga, membagi data menjadi tiga bagian. yaitu data latih, data validasi, dan data. pengujian. Dari 100% data yang ada, 70% data diberikan untuk proses training, 15% data untuk proses validasi, dan 15% data untuk proses testing. Proses tersebut dilakukan dengan tujuan untuk melatih jaringan syaraf tiruan (JST) agar dapat mengembangkan model jaringan yang lebih handal, untuk mengetahui besarnya nilai R2 yang dihasilkan dari setiap proses.
6. Setelah proses pemodelan jaringan syaraf tiruan dilakukan, selanjutnya dilakukan pengujian untuk melihat tingkat keberhasilan JST dalam mengolah data, dengan memberikan data kapal baru, dengan tujuan untuk melihat hasil perbedaan atau error antara JST dengan data uji baru. Jika hasil yang dikeluarkan JST sudah sesuai dengan nilai error minimal maka dapat dikatakan JST berhasil, dan dapat digunakan untuk menganalisa data kapal selanjutnya. Namun jika hasil prediksi belum mencapai target yang diinginkan, maka dilakukan evaluasi ulang terhadap struktur jaringan yang dibebani secara artifisial, misalnya mengubah fungsi algoritma dan mengubah jumlah lapisan tersembunyi beserta neuronnya.

Alur pengerjaan penelitian adalah sebagai berikut:

