



UNIVERSITAS INDONESIA

**MODEL ESTIMASI DURASI *DRY DOCKING* KAPAL
MENGUNAKAN *DATA MINING***

SKRIPSI

RIARA NOVITA

0806337945

**FAKULTAS TEKNIK
PROGRAM STUDI TEKNIK INDUSTRI
DEPOK
JUNI 2012**



UNIVERSITAS INDONESIA

**MODEL ESTIMASI DURASI *DRY DOCKING* KAPAL
MENGUNAKAN *DATA MINING***

SKRIPSI

Diajukan sebagai salah satu syarat untuk memperoleh gelar Sarjana Teknik

RIARA NOVITA

0806337945


**FAKULTAS TEKNIK
PROGRAM STUDI TEKNIK INDUSTRI
DEPOK
JUNI 2012**

HALAMAN PERNYATAAN ORISINALITAS

**Skripsi ini adalah hasil karya saya sendiri,
dan semua sumber baik yang dikutip maupun dirujuk
telah saya nyatakan dengan benar.**

Nama : Riara Novita

NPM : 0806337945

Tanda Tangan : 

Tanggal : 22 Juni 2012

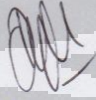
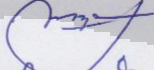
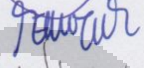
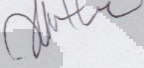
HALAMAN PENGESAHAN

Skripsi ini diajukan oleh:

Nama : Riara Novita
NPM : 0806337945
Program Studi : Teknik Industri
Judul Skripsi : Model Estimasi Durasi *Dry Docking* Kapal Menggunakan
Data Mining

Telah berhasil dipertahankan di hadapan Dewan Penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh gelar Sarjana Teknik pada Program Studi Teknik Industri, Fakultas Teknik, Universitas Indonesia

DEWAN PENGUJI

Pembimbing : Ir. Isti Surjandari, Ph.D ()
Penguji : Ir. Amar Rachman, MEIM ()
Penguji : Ir. Fauzia Dianawati, M.Si ()
Penguji : Maya Arlini, S.T., M.T., MBA ()

Ditetapkan di : Depok

Tanggal : 22 Juni 2012

KATA PENGANTAR

Puji syukur penulis panjatkan kepada Tuhan Yang Maha Esa, karena atas berkat dan rahmat-Nya, penulis dapat menyelesaikan skripsi yang berjudul “Model Estimasi Durasi *Dry Docking* Kapal Menggunakan *Data Mining*.” Penulisan skripsi ini dilakukan dalam rangka memenuhi salah satu syarat untuk mencapai gelar Sarjana Teknik Jurusan Teknik Industri pada Fakultas Teknik Universitas Indonesia. Penulis menyadari bahwa tanpa bantuan dan bimbingan dari berbagai pihak, skripsi ini tidak akan terealisasikan. Oleh karena itu, pada kesempatan ini penulis mengucapkan terima kasih kepada:


1. Ir. Isti Surjandari, Ph.D selaku dosen pembimbing penulis yang telah menyediakan waktu, tenaga, dan pikiran untuk mengarahkan penulis dalam pembuatan skripsi ini;
2. Bapak Amir, Bapak Agus, Bapak Harry, Bapak Marzaeni, Mbak Chichi, Bapak Syafril dan rekan lainnya dari pihak galangan yang telah banyak membantu dalam usaha memperoleh data dan informasi yang penulis butuhkan;
3. Ibu Arian Dhini, ST, MT selaku Pembimbing Akademis dan dosen Teknik Industri lainnya yang telah membimbing penulis selama 4 tahun dan memberikan banyak ilmu yang berguna;
4. Nike, Echa, Linda, Upi, dan Farid yang telah memberikan bantuan, masukan, semangat dalam mengerjakan skripsi dan menjadi rekan asisten laboratorium SQE yang luar biasa;
5. Harumi, Wenty, Gita, Indah, Dwi, Visky dan rekan-rekan TI08 lainnya yang telah memberikan dukungan, bantuan, dan keceriaan pada masa-masa pembuatan skripsi, seminar, dan sidang;
6. Deddy, Ratna, dan Dyah selaku senior yang dengan senang hati membantu memberikan masukan, *ebook*, dan bantuan lainnya selama pembuatan skripsi;

7. Ova, Fauziah, Gety, Shella, Dita Liesdi, dan Naufal yang telah memberikan dukungan moril dan menjadi teman yang luar biasa;
8. *Last but not least*, orang tua dan keluarga penulis yang telah memberikan banyak dukungan moril dan materil, terutama saat pembuatan skripsi.

Akhir kata, penulis ucapkan terima kasih kepada pihak-pihak yang telah memberikan bantuan dalam pembuatan skripsi ini. Semoga skripsi ini kelak akan memberikan manfaat untuk pengembangan ilmu selanjutnya.

Depok, Juni 2012

Penulis



**HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI
TUGAS AKHIR UNTUK KEPENTINGAN AKADEMIS**

Sebagai sivitas akademik Universitas Indonesia, saya yang bertanda tangan di bawah ini:

Nama : Riara Novita
NPM : 0806337945
Program Studi : Teknik Industri
Departemen : Teknik Industri
Fakultas : Teknik
Jenis Karya : Skripsi

demi pengembangan ilmu pengetahuan, saya menyetujui untuk memberikan kepada Universitas Indonesia **Hak Bebas Royalti Noneksklusif** (*Non-exclusive Royalty Free Right*) atas karya ilmiah saya yang berjudul:

Model Estimasi Durasi *Dry Docking* Kapal Menggunakan *Data Mining*

beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Noneksklusif ini Universitas Indonesia berhak menyimpan, mengalihmedia/format-kan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan memublikasikan tugas akhir saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Depok
Pada Tanggal : 22 Juni 2012
Yang Menyatakan,


(Riara Novita)

ABSTRAK

Nama : Riara Novita
Program Studi : Teknik Industri
Judul : Model Estimasi Durasi *Dry Docking* Kapal Menggunakan *Data Mining*

Pemeliharaan kapal merupakan salah satu kegiatan galangan yang mengalami peningkatan seiring dengan jumlah transportasi laut nasional yang terus meningkat. Namun, peningkatan ini tidak diimbangi dengan peningkatan kapasitas galangan nasional sehingga menjadikan estimasi durasi pemeliharaan kapal sebagai suatu hal yang sangat penting bagi galangan. Penelitian ini menggunakan salah satu metode *data mining*, yaitu CART (*Classification and Regression Tree*) untuk mengestimasi durasi pemeliharaan yang dibatasi pada pekerjaan di atas dok saja atau yang dikenal dengan istilah *dry docking*. Dengan menggunakan volume pekerjaan *dry docking* sebagai input dalam melakukan estimasi durasi, didapatkanlah 4 kelas durasi *dry docking* dengan model linier dan kriteria pekerjaan yang berbeda. Model linier ini selanjutnya dapat digunakan untuk mengestimasi durasi *dry docking* berdasarkan kriteria pekerjaannya.

Kata Kunci:

Data Mining, Classification and Regression Tree (CART), Durasi Pemeliharaan, Dry Docking

ABSTRACT

Nama : Riara Novita
Program Studi : Industrial Engineering
Judul : Estimation Model of Dry Docking Duration Using Data Mining

Maintenance is one of the shipbuilding activities that have increased in line with the rising of national marine transportation. However, this increase isn't offset by an increase in the national shipbuilding capacity, thus making an estimate of ship maintenance duration as a very important for the shipyard. This research uses one of data mining method, namely CART (Classification and Regression Tree) to estimate the duration of maintenance that is limited to dock works or which is known as dry docking. By using the volume of dock works as an input to estimate the duration, there are 4 classes of dry docking duration obtained with the different linear model and job criteria for each class. These linear models can then be used to estimate the duration of dry docking based on its job criteria.


Keywords:

Data Mining, Classification and Regression Tree (CART), Duration of Maintenance, Dry Docking

DAFTAR ISI

HALAMAN JUDUL.....	i
HALAMAN PERNYATAAN ORISINALITAS.....	ii
HALAMAN PENGESAHAN.....	iii
KATA PENGANTAR.....	iv
HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR UNTUK KEPENTINGAN AKADEMIS.....	vi
ABSTRAK.....	vii
DAFTAR ISI.....	ix
DAFTAR GAMBAR.....	xi
DAFTAR TABEL.....	xii
DAFTAR LAMPIRAN.....	xiii
BAB 1 PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Diagram Keterkaitan Masalah.....	5
1.3 Rumusan Masalah.....	6
1.4 Tujuan Penelitian.....	6
1.5 Batasan Masalah.....	6
1.6 Metodologi Penelitian.....	7
1.7 Sistematika Penulisan.....	7
BAB 2 DASAR TEORI.....	10
2.1 Data Mining.....	10
2.1.1 Proses Standar Data Mining Antar Industri.....	11
2.1.2 Tipe Pekerjaan Data Mining.....	13
2.1.3 Algoritma Data Mining.....	15
2.1.4 Classification and Regression Tree (CART).....	16
2.1.5 Klasifikasi K-Nearest Neighbor Classifiers.....	21
2.2 Wakaito Environment for Knowledge Analysis (WEKA).....	23
2.2.1 M5P.....	25
2.2.2 IBk.....	26
2.3 Dry Docking Kapal.....	27
BAB 3 PENGUMPULAN DAN PENGOLAHAN DATA.....	32
3.1 PT. Daya Radar Utama.....	32
3.1.1 Profil PT. Daya Radar Utama.....	32
3.1.2 Operasional Pemeliharaan Kapal.....	33
3.2 Pengumpulan Data.....	35
3.3 Penentuan Atribut Dry Docking.....	36
3.4 Reduksi Data dan Eliminasi Missing Value.....	37
3.5 Perhitungan Waktu Dry Docking.....	39
3.6 Uji Validasi Hasil Estimasi.....	41
BAB 4 ANALISIS.....	43
4.1 Analisis Pohon Klasifikasi CART.....	43

4.2 Analisis Performance Measurement.....	50
4.3 Analisis Uji Validasi Hasil.....	53
BAB 5 KESIMPULAN DAN SARAN	57
5.1 Kesimpulan.....	57
5.2 Saran.....	58
DAFTAR REFERENSI.....	60
LAMPIRAN.....	61




DAFTAR GAMBAR

Gambar 1.1	Grafik Peningkatan Jumlah Transportasi Laut di Indonesia.....	1
Gambar 1.2	Diagram Keterkaitan Masalah.....	5
Gambar 1.3	Diagram Alir Metodologi Penelitian	9
Gambar 2.1	Proses CRISP-DM.....	11
Gambar 2.2	<i>Optimal Tree Selection</i>	20
Gambar 2.3	<i>Cross Validation Technique</i>	21
Gambar 2.4	Contoh Klasifikasi 3- <i>Nearest Neighbor</i>	21
Gambar 2.5	Skema Pembelajaran Dasar pada WEKA.....	24
Gambar 2.6	<i>Replating</i> Lambung Kapal.....	27
Gambar 2.7	Pemeliharaan dan Perbaikan <i>Rudder</i>	28
Gambar 2.8	<i>Fouling</i> pada Daun Baling-baling	29
Gambar 2.9	Retak pada <i>Propeller</i>	29
Gambar 3.1	Diagram Alir Kegiatan Operasional Pemeliharaan	34
Gambar 3.2	<i>Syntax</i> Tambahan pada <i>File</i> WEKA.....	40
Gambar 3.3	Estimasi Durasi <i>Dry Docking</i> Menggunakan M5P	41
Gambar 3.4	Estimasi Durasi <i>Dry Docking</i> Menggunakan IBk.....	42
Gambar 4.1	Hasil Pohon Klasifikasi Durasi <i>Dry Docking</i>	43
Gambar 4.2	Hasil Model Linier <i>Dry Docking</i>	44
Gambar 4.3	Grafik LM 4.....	46
Gambar 4.4	Grafik LM 3.....	47
Gambar 4.5	Grafik LM 1.....	48
Gambar 4.6	Grafik LM 2.....	49
Gambar 4.7	<i>Performance Measurement</i> M5P.....	51
Gambar 4.8	Grafik Perbandingan Durasi <i>Dry Docking</i>	54
Gambar 4.9	<i>Performance Measurement</i> M5P.....	56
Gambar 4.10	<i>Performance Measurement</i> IBk.....	56


DAFTAR TABEL

Tabel 1.1	Jumlah Transportasi Laut Menurut Kepemilikan (2005-2009).....	2
Tabel 2.1	Kegiatan-kegiatan Tiap Fase CRISP-DM	12
Tabel 2.2	Perbandingan Penggunaan Algoritma dalam <i>Data Mining</i>	16
Tabel 3.1	Spesifikasi Atribut <i>Dry Docking</i>	37
Tabel 3.2	Atribut Hasil Reduksi Data	38
Tabel 4.1	Hasil Estimasi Menggunakan M5P.....	50
Tabel 4.2	<i>Performance Measurement</i> dalam Prediksi Numerik	51
Tabel 4.3	Tabel Perbandingan Aktual - Estimasi	55



DAFTAR LAMPIRAN

Lampiran 1. <i>Learning Data</i>	61
Lampiran 2. <i>Testing Data</i>	67

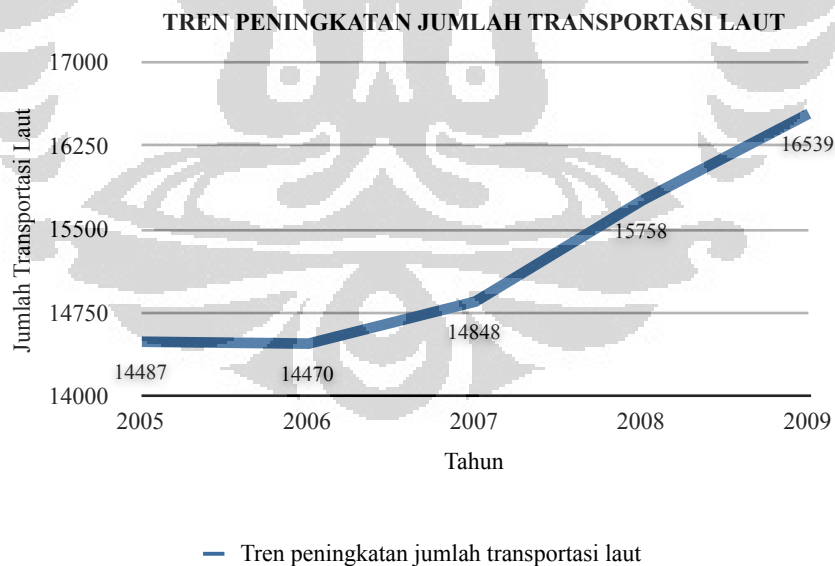


BAB 1

PENDAHULUAN

1.1 Latar Belakang

Indonesia merupakan negara kepulauan terbesar yang memiliki 13.000 pulau dan luas laut sekitar 3,1 juta km² (Kementrian Kelautan & Perikanan, 2012), hal inilah yang menjadikan transportasi laut sebagai salah satu sarana terpenting bagi negara Indonesia. Fungsinya yang dapat menghubungkan masyarakat Indonesia yang tersebar di berbagai pulau dengan harga yang umumnya lebih kompetitif jika dibandingkan dengan transportasi udara ditambah dengan diterapkannya kebijakan pemerintah yang mengharuskan penggunaan kapal nasional untuk pengangkutan produksi lokal (asas cabotage), menjadikan transportasi laut sebagai alternatif utama kebanyakan masyarakat Indonesia dalam melakukan perpindahan antar pulau. Hal inilah yang menyebabkan jumlah transportasi laut di Indonesia terus meningkat tiap tahunnya, seperti yang dapat dilihat pada Gambar 1.1.



Gambar 1.1 Grafik Peningkatan Jumlah Transportasi Laut di Indonesia

(Sumber: Kementerian Perhubungan, 2009)

Adapun jumlah transportasi laut yang terus meningkat di perairan Indonesia terdiri dari berbagai macam kepemilikan, seperti yang dipaparkan pada Tabel 1.1.

Tabel 1.1 Jumlah Transportasi Laut Menurut Kepemilikan (2005-2009)

No	Uraian	Satuan	2005	2006	2007	2008	2009
1	Nasional	Unit	6,012	6,428	7,154	8,165	9,164
		Unit	528	862	1,055	1,137	1,330
		DWT	2,313,240	2,923,875	3,701,184	4,530,275	5,531,902
		Unit	4,252	4,423	4,805	5,612	6,291
		GRT	2,438,959	2,440,893	2,804,803	3,421,240	4,080,138
		Unit	1,232	1,143	1,294	1,416	1,543
		HP	1,182,711	1,134,166	1,242,847	1,435,528	1,900,764
2	Charter Asing	Unit	1,955	1,448	1,154	977	865
		Unit	125	106	90	77	69
		DWT	2,765,025	2,073,769	1,555,327	1,166,495	1,108,170
		Unit	885	841	799	759	683
		GRT	1,956,218	1,467,164	1,100,373	1,467,164	1,247,089
		Unit	945	501	265	141	113
		HP	1,167,334	875,501	656,625	875,501	656,625
3	Keagenan Asing	Unit	6,520	6,594	6,540	6,616	6,562
		Unit	6,498	6,563	6,511	6,576	6,510
		DWT	186,728,332	132,577,116	192,330,182	136,554,429	122,898,986
		Unit	22	31	29	40	52
		GRT	18,455	25,837	23,992	33,588	43,664
		Unit	0	0	0	0	0
		HP	0	0	0	0	0
Jumlah / Total	Unit	14,487	14,470	14,848	15,758	16,591	
	DWT	191,806,597	137,574,760	197,586,693	142,251,199	129,539,058	
	GRT	4,413,632	3,933,894	3,929,168	4,921,992	5,370,891	
	HP	2,350,045	2,009,667	1,899,472	2,311,029	2,557,389	

(Sumber: Kementerian Perhubungan, 2009)

Dalam bidang transportasi laut, pemeliharaan kapal merupakan salah satu kegiatan yang sangat penting karena dapat menentukan kelaikan suatu kapal. Selain itu, pemeliharaan kapal merupakan suatu proses yang sangat kompleks dan dinamis dengan interdependensi antar variabel yang cukup tinggi, salah satunya adalah informasi. Namun, sebagian besar informasi yang tersebar di beberapa tahapan proses umumnya tidak lengkap dan handal. Estimasi durasi pemeliharaan kapal merupakan bagian dari informasi tersebut. Tingkat keakuratan dari estimasi durasi pemeliharaan kapal mempengaruhi kualitas pelayanan galangan dan menjadi sangat penting untuk hasil proses bisnis galangan kapal. Jika estimasi durasi pemeliharaan terlalu panjang, maka galangan kapal akan menjadi tidak

kompetitif dan jika estimasi durasinya menjadi terlalu pendek, maka jadwal penyediaan material akan berantakan dan mengurangi kualitas performa pekerjaan para pekerja dikarenakan estimasi durasi yang tidak realistis (Srdoc et al., 2006).

Saat ini banyak perusahaan yang telah membuat *database* dengan tujuan untuk mendapatkan pengetahuan mengenai hal tersebut, tetapi belum digunakan lebih lanjut sebagai bahan untuk melakukan *continuos improvement* (Srdoc et al., 2006) sehingga menyebabkan banyak perusahaan ‘tenggelam’ di dalam data. Seperti halnya *database* mengenai pemeliharaan kapal, yang terdiri dari berbagai jenis pemeliharaan dengan berbagai volume pekerjaan yang mempengaruhi durasi pemeliharaan kapal. Estimasi durasi waktu pemeliharaan kapal saat ini masih dibuat berdasarkan pengalaman dari operator yang bersangkutan, padahal seharusnya data pemeliharaan kapal yang telah didapatkan bisa diolah lebih lanjut untuk menghasilkan estimasi durasi yang lebih akurat. Salah satu metode yang dapat mengakomodir semua hal itu adalah metode *data mining*.

Data mining adalah metode analisis data dalam jumlah besar untuk mengetahui hubungan yang tidak terduga sebelumnya dan merangkum data tersebut ke dalam suatu bentuk baru sehingga dapat dipahami dan berguna bagi pemilik data (Hand et al., 2006). *Data mining* sudah banyak diaplikasikan di berbagai bidang, termasuk didalamnya adalah transportasi atau otomotif. Namun, untuk aplikasi *data mining* sendiri pada pemeliharaan transportasi laut masih sangat minim. Srdoc et al. (2006) merupakan salah satu dari sedikit contoh, penelitian yang telah dilakukannya menggunakan *data mining* untuk mengestimasi durasi pemeliharaan kapal dengan memperhatikan volume pekerjaan dari tiap-tiap jenis pemeliharaan kapal yang dilakukan.

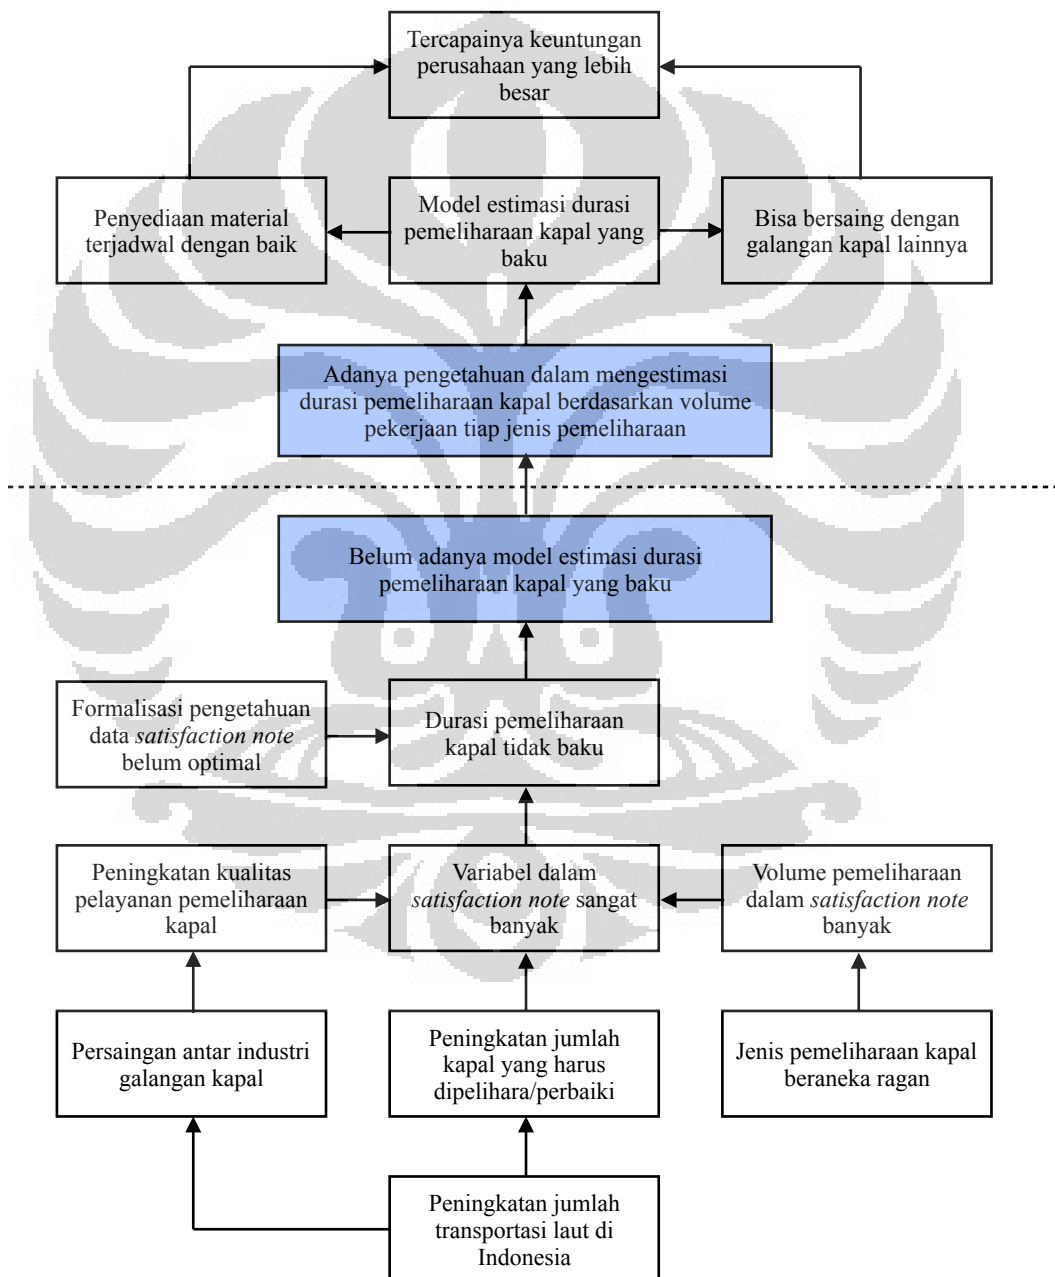
Galangan kapal adalah suatu tempat yang dirancang untuk membangun, memelihara, dan memperbaiki kapal. Saat ini telah terdapat sekitar 240 perusahaan galangan dalam negeri yang tersebar di Indonesia, 37% berada di pulau Jawa, 26% di Sumatera, 25% di Kalimantan, dan 12% berada di kawasan timur Indonesia, dengan kapasitas pembangunan kapal terpasang sebesar 140.000 GT (*Gross Tonnage*) per tahun (Windyandari, 2008). PT Daya Radar Utama

merupakan salah satu galangan kapal di Jakarta yang telah berdiri sejak tahun 1972 dan merupakan salah satu galangan kapal yang aktif membangun berbagai jenis kapal hingga ukuran 1000 DWT (*Dead Weight Ton*) dan memperbaiki kapal hingga ukuran 8000 DWT. Hal ini dapat dilihat selama periode Januari - Mei 2009, saat PT Daya Radar Utama menerima pesanan pembuatan kapal baru yang melebihi target perusahaan pada tahun itu, sehingga menyebabkan jumlah dan kegiatan pemeliharaan kapal menjadi meningkat. Peningkatan yang tidak diimbangi dengan kapasitas galangan yang mencukupi, menyebabkan PT Daya Radar Utama untuk melakukan ekspansi terhadap galangan yang sudah ada dan membuat galangan baru (*graving dock*), seperti yang saat ini sedang berlangsung di Lamongan. Fakta inilah yang menjadikan PT Daya Radar Utama sebagai salah satu galangan terbesar di Indonesia.

Berfokus pada kegiatan pemeliharaan kapal, PT Daya Radar Utama biasanya hanya memanfaatkan *database* pemeliharaan kapal, yang disebut dengan *satisfaction note*, untuk menentukan besar harga pemeliharaan kapal saja. Di sisi lain, belum ada *database* yang dimanfaatkan oleh PT Daya Radar Utama untuk mengestimasi durasi pemeliharaan kapal secara lebih baku, padahal durasi memiliki pengaruh terhadap besar harga pemeliharaan. Salah satu fungsi *data mining* adalah estimasi, yang dalam hal ini dapat dimanfaatkan untuk mengestimasi durasi pemeliharaan kapal dengan mencari pola durasi pemeliharaan berdasarkan klasifikasi volume dari berbagai jenis pemeliharaan. Dengan demikian, setelah operator mendapatkan volume pekerjaan dari tiap jenis pemeliharaan, operator dapat langsung mengestimasi durasi pemeliharaan kapal yang sedang ditangani. Aplikasi *data mining* dalam mengestimasi durasi pemeliharaan kapal akan membantu perusahaan dalam menentukan target penyelesaian pemeliharaan kapal yang tidak terlalu lama dan tidak terlalu cepat.

1.2 Diagram Keterkaitan Masalah

Untuk memberikan gambaran yang jelas mengenai latar belakang penelitian, maka pada Gambar 1.2 ditampilkan sebuah diagram keterkaitan masalah atau yang biasa dikenal dengan *interrelationship diagram* yang menggambarkan keterkaitan antara masalah dengan solusi yang diberikan untuk mencapai kondisi aktual yang lebih baik.



Gambar 1.2 Diagram Keterkaitan Masalah

1.3 Rumusan Masalah

Berdasarkan latar belakang penelitian dapat diketahui bahwa rumusan masalah dari penelitian ini adalah belum adanya model estimasi durasi pemeliharaan di atas dok (*dry docking*) yang baku.

1.4 Tujuan Penelitian

Adapun tujuan yang ingin dicapai dari penelitian ini adalah untuk membuat model yang dapat mengestimasi durasi pemeliharaan *dry docking* kapal dengan menggunakan metode *data mining*.

1.5 Batasan Masalah

Terdapat beberapa batasan pada masalah yang diangkat dalam penelitian ini. Hal ini bertujuan agar penelitian dapat berjalan lancar dengan cakupan yang jelas. Berikut adalah beberapa batasan yang telah ditetapkan:

1. Penelitian dilakukan di PT Daya Radar Utama.
2. Dikarenakan kapasitas dok galangan yang terbatas, penelitian dibatasi pada pemeliharaan yang dilakukan di atas dok saja atau yang biasa dikenal dengan istilah *dry docking* pada saat *annual docking* yang dilakukan minimal dua kali setahun untuk kapal penumpang dan setahun sekali untuk kapal barang.
3. Data yang digunakan untuk mengestimasi durasi pemeliharaan adalah volume pekerjaan berbagai jenis pemeliharaan yang dilakukan di atas dok selama delapan tahun terakhir, dimana jumlah transportasi laut mulai mengalami peningkatan.

1.6 Metodologi Penelitian

Metodologi penelitian yang digunakan dalam skripsi ini dapat dibagi menjadi empat tahap. Tahap pertama adalah tahap identifikasi awal masalah yang dilanjutkan dengan tahap pengumpulan data. Setelah data yang dibutuhkan terkumpul, data diolah dengan metode yang telah ditentukan dan dianalisis untuk dapat ditarik kesimpulan yang merupakan tahapan akhir dari penelitian. Untuk gambaran lebih detail, maka pada Gambar 1.3 akan ditampilkan diagram alir (*flowchart*) dari empat tahapan tersebut.

1.7 Sistematika Penulisan

Skripsi ini tersusun ke dalam lima bagian, yaitu pendahuluan, dasar teori, metodologi penelitian, analisis hasil pengolahan data, dan kesimpulan.

Bab pertama, pendahuluan akan membahas mengenai latar belakang penelitian, diagram keterkaitan masalah, rumusan masalah, tujuan penelitian, pembatasan masalah, metodologi penelitian, dan sistematika penulisan.

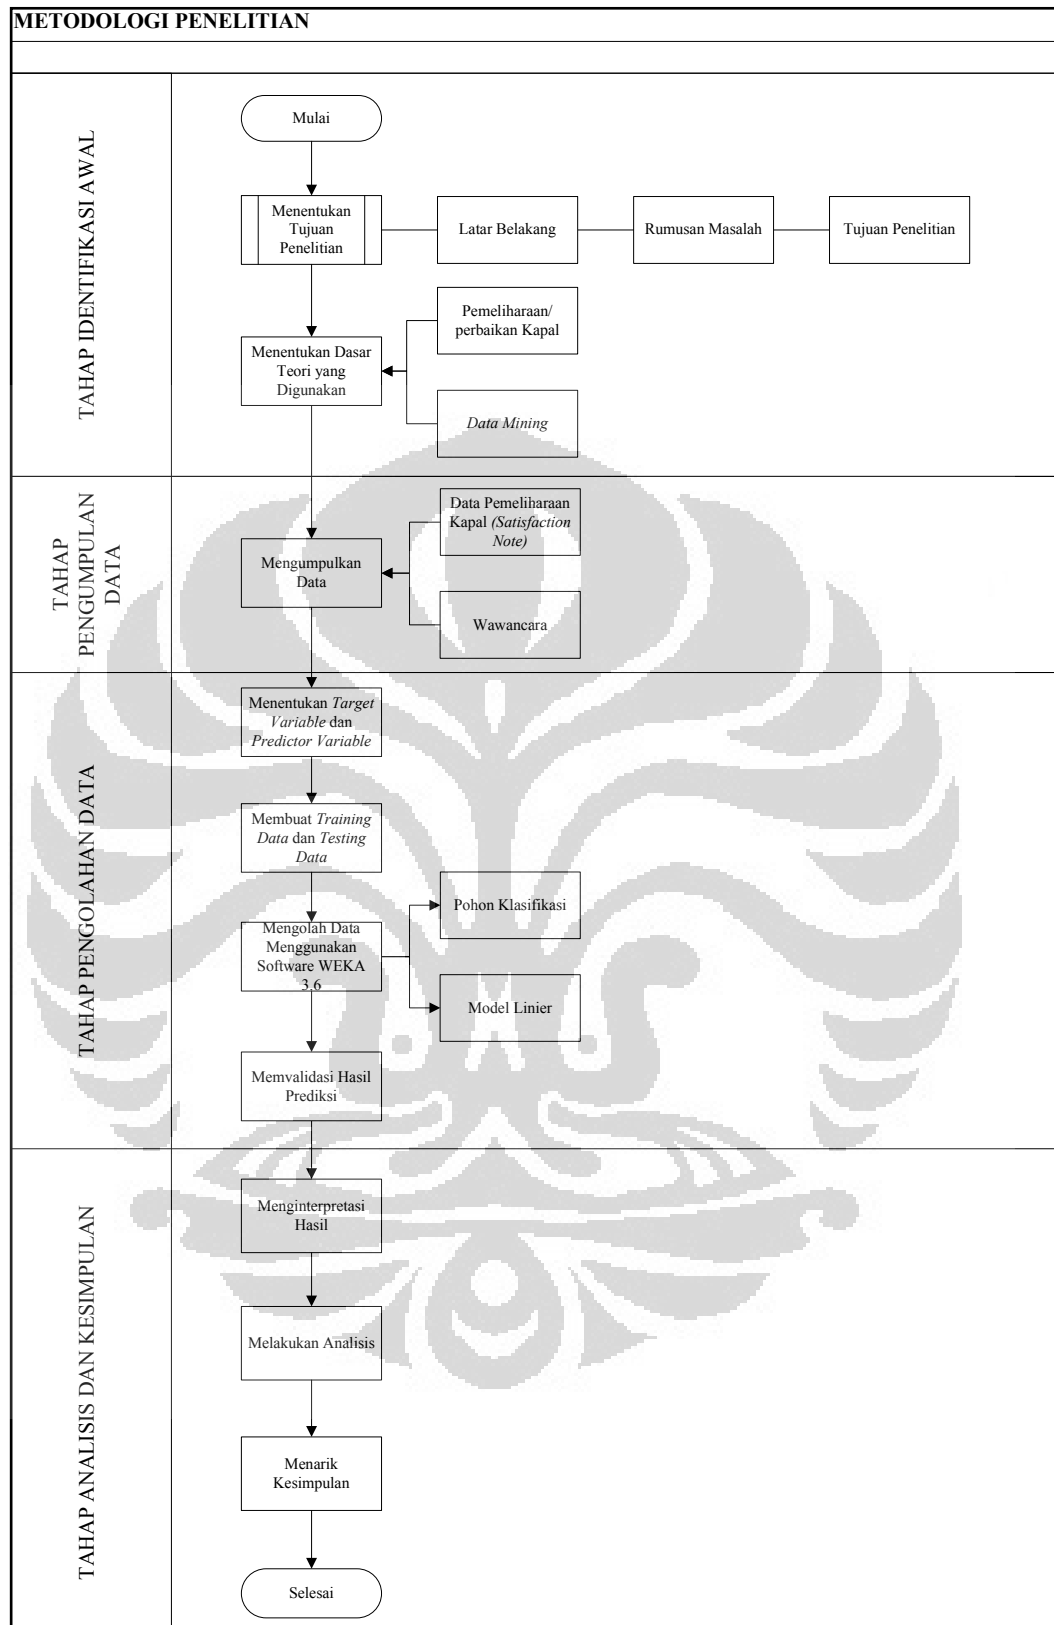
Bab dua, dasar teori terbagi ke dalam beberapa sub bab, antara lain mengenai *dry docking* kapal dan metode serta perangkat lunak yang digunakan untuk mendukung penelitian. Pada subbab *dry docking* kapal akan dibahas mengenai jenis-jenis pekerjaan *dry docking* kapal dan ukuran-ukuran yang mempengaruhi estimasi durasi pemeliharaan *dry docking* dari tiap jenis pemeliharaan kapal.

Bab tiga, pengumpulan dan pengolahan data terbagi ke dalam tiga sub bab, yaitu profil PT Daya Radar Utama beserta dengan operasional pemeliharaan kapal, pengumpulan data, penentuan atribut *dry docking*, reduksi dan eliminasi *missing values*, perhitungan waktu *dry docking*, dan validasi hasil estimasi. Pada sub bab profil akan dibahas mengenai sejarah, visi dan misi, serta fasilitas yang dimiliki PT Daya Radar Utama. Pada sub bab pengumpulan data akan dibahas mengenai data-data yang akan diolah. Pada sub bab penentuan atribut *dry docking* akan dipaparkan mengenai atribut yang digunakan pada setiap pekerjaan *dry docking*. Pada sub bab reduksi dan eliminasi *missing value* akan dijelaskan

mengenai proses reduksi atribut beserta hasil reduksinya dan alasan mengeliminasi *missing value*. Pada sub bab perhitungan waktu *dry docking* akan dibahas mengenai langkah-langkah pengolahan data dan hasil yang akan didapatkan. Setelah mendapatkan hasil pengolahan data, hasil akan divalidasi menggunakan metode lain dan pada sub bab ini akan dipaparkan mengenai cara validasi yang disertai dengan hasilnya.

Bab empat, analisis hasil pengolahan data yang diperoleh. Pada bab ini, akan dianalisis hasil pengolahan yang berupa pohon klasifikasi model linier hasil perhitungan, *measurement performance* dari model yang dihasilkan, dan hasil validasi model durasi *dry docking* kapal dengan menggunakan dua metode yang berbeda.

Bab lima, kesimpulan yang merupakan bab terakhir dalam penelitian dan terdiri dari dua sub bab, yaitu kesimpulan dan saran. Pada sub bab kesimpulan akan diberikan poin-poin kesimpulan dari hasil penelitian, sedangkan pada sub bab saran akan dimuat saran-saran yang kelak dapat digunakan untuk mengembangkan penelitian ini lebih lanjut.



Gambar 1.3 Diagram Alir Metodologi Penelitian

BAB 2 DASAR TEORI

2.1 *Data Mining*

Perkembangan komputer yang didukung dengan berkembangnya teknik pengumpulan dan penyimpanan data menyebabkan pertumbuhan *database* menjadi sangat besar. *Database* ini umumnya terdiri dari data yang sangat banyak. Namun, pengetahuan yang didapatkan seringkali tidak sebanding dengan peningkatan jumlah data yang tersimpan. Hal ini dikarenakan tingkat kesulitan untuk mendapatkan pengetahuan semakin tinggi seiring dengan jumlah data yang terus meningkat. Oleh karena itu, pengetahuan yang berguna menjadi sulit didapatkan dari *database* yang sedang berkembang saat ini. Akan tetapi, pada perkembangan selanjutnya, analisis terhadap *database* menjadi cukup sering dilakukan sehingga dapat memberikan pengetahuan bagi pemiliknya. Metode *data mining* merupakan metode analisis *database* yang saat ini cukup sering digunakan. Menurut Hand et al. (2006) dalam bukunya yang berjudul *Principle of Data mining*, *data mining* merupakan metode analisis data dalam jumlah besar untuk mengetahui hubungan yang tidak terduga sebelumnya dan merangkum data tersebut ke dalam suatu bentuk baru yang lebih dipahami oleh pemilik data.

Awalnya, *data mining* menekankan analisis yang digunakan pada data pengamatan, yang tentunya berbeda dengan data eksperimen. Hal inilah yang membedakan *data mining* dengan statistik karena *data mining* tidak memainkan peranan dalam strategi pengambilan data. Namun, pada perkembangannya, *data mining* juga menekankan analisisnya pada data eksperimen. Pada dasarnya analisis *data mining* akan memunculkan hubungan baru antar variabel yang berhubungan dengan pengetahuan pemilik data sebelumnya. *Data mining* merupakan bagian dari *Knowledge Discovery in Databases* (KDD). KDD ini melibatkan beberapa tahap, antara lain:

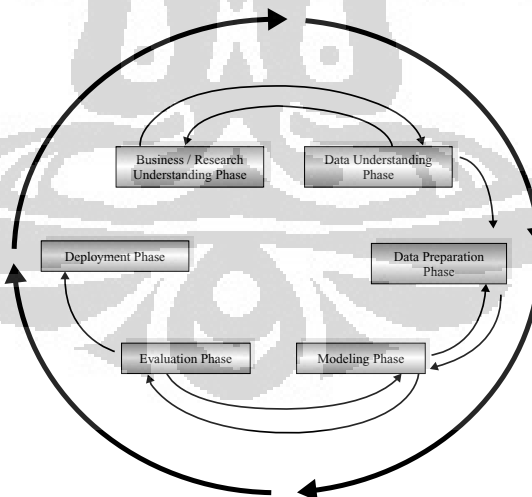
1. Memilih target data
2. Pre-proses data
3. Mentransformasikan data jika diperlukan

4. Melakukan *data mining* untuk mendapatkan pola dan hubungan
5. Interpretasi dan menilai struktur yang ditemukan

Data mining lebih menekankan pada algoritma untuk membangun struktur sehingga pre-proses data tidak diperhatikan secara detail seperti dalam statistik. Pre-proses *data mining* biasanya hanya melibatkan *data cleaning*, *data verification*, dan *defining variables*.

2.1.1 Proses Standar *Data Mining* Antar Industri

Proses Standar *Data Mining* Antar Industri atau yang lebih dikenal dengan istilah *Cross Industry Standard Process for Data Mining (CRISP-DM)* merupakan proses standar penggunaan *data mining* sebagai strategi dalam memecahkan permasalahan di dalam suatu bisnis unit. CRISP-DM dikembangkan pada tahun 1996 oleh analis-analis perwakilan Daimler Chrysler, SPSS, dan NCR. Dalam CRISP-DM, *data mining* dilihat sebagai sebuah siklus yang terdiri dari enam fase yang tergambarkan pada Gambar 2.1. Fase-fase tersebut terdiri dari fase pemahaman permasalahan bisnis, fase pemahaman data, fase persiapan data, fase permodelan, fase evaluasi, dan fase penggunaan.



Gambar 2.1 Proses CRISP-DM

(Sumber: Larose, 2005)

Fase pemahaman permasalahan bisnis merupakan fase dimana permasalahan-permasalahan yang ada ingin dipecahkan dengan pendekatan *data mining* dipahami lebih lanjut sehingga tujuan, metode yang digunakan, dan data

yang dibutuhkan menjadi lebih jelas. Fase pemahaman data merupakan fase dimana data yang dibutuhkan diteliti lebih lanjut. Fase ini bertujuan untuk memastikan data yang diambil sesuai dengan metode dan tujuan yang telah ditetapkan sebelumnya. Fase persiapan data merupakan fase dimana data diubah sedemikian rupa sehingga siap untuk diolah dan dimodelkan. Fase permodelan merupakan fase dimana data yang sudah disiapkan dimodelkan dengan pendekatan *data mining* sehingga didapat informasi-informasi tersembunyi untuk menjawab tujuan proyek. Fase evaluasi merupakan fase dimana akurasi model diteliti lebih lanjut. Fase ini meneliti mengenai kemampuan model dalam merepresentasikan keadaan sesungguhnya. Fase penggunaan merupakan fase dimana hasil yang didapat dari metode ini digunakan lebih lanjut untuk kepentingan lain. Tabel 2.1 menjabarkan kegiatan-kegiatan yang dilakukan pada setiap fase.

Tabel 2.1 Kegiatan-kegiatan Tiap Fase CRISP-DM

No.	Fase	Kegiatan
1	Pemahaman permasalahan bisnis	Menentukan tujuan proyek
		Mengasosiasikan tujuan dengan metode yang terdapat dalam <i>data mining</i>
		Membuat rencana untuk mencapai tujuan proyek
2	Pemahaman data	Mengumpulkan data
		Melakukan analisis awal untuk menemukan informasi awal
		Mengevaluasi kualitas data
3	Persiapan data	Mempersiapkan data akhir yang akan digunakan dari data mentah
		Memilih variabel yang ingin dianalisis dan sesuai dengan tujuan penelitian
		Mentransformasi data jika dibutuhkan

Tabel 2.1 Kegiatan-kegiatan Tiap Fase CRISP-DM (Sambungan)

No.	Fase	Kegiatan
4	Permodelan	Memilih dan menggunakan model
		Mengkalibrasi pengaturan untuk meraih model yang optimal
5	Evaluasi	Mengevaluasi kualitas dan efektivitas model
		Menentukan apakah model mencapai tujuan proyek
		Membuat kesimpulan
6	Penggunaan	Menggunakan model yang dibuat
		Membuat laporan proyek

(Sumber: Larose, 2005)

Setiap fase bergantung kepada hasil dari fase sebelumnya. Kebergantungan ini diwakili dengan tanda panah pada Gambar 2.1. Urutan pada tiap fase dapat disesuaikan dengan keadaan. Contoh, fase permodelan terkadang memerlukan penyesuaian ulang pada fase persiapan data sebelum berlanjut ke fase evaluasi yang bergantung pada model yang digunakan. Hal tersebut diwakili dengan panah yang berbalik arah. Iteratif proses pada CRISP-DM digambarkan dengan panah tebal di bagian luar gambar. Terkadang, permasalahan bisnis mengarah kepada pertanyaan yang bisa dijawab dengan menggunakan proses yang sama pada proyek sebelumnya. Dalam kasus ini, output proyek terdahulu menjadi input proyek baru.

2.1.2 Tipe Pekerjaan *Data Mining*

Data mining memiliki banyak metode yang dapat melakukan berbagai tipe pekerjaan. Menurut Larose (2005), secara umum, terdapat enam tipe pekerjaan yang bisa dilakukan *data mining*, yaitu:

1. Deskripsi, merupakan tipe pekerjaan yang bertujuan untuk menginterpretasikan dan menampilkan pola dan *trend* yang terdapat di dalam data.

2. Estimasi, dibuat berdasarkan data lengkap yang terdiri dari *target variable* dan *predictor variable*. *Target variable* merupakan variabel yang diestimasi. *Predictor variable* merupakan variabel yang menjadi pertimbangan dalam mengestimasi *target variable*. Estimasi serupa dengan klasifikasi, perbedaannya adalah *target variable* pada estimasi berupa data numerik sedangkan pada klasifikasi berupa data kategorikal. Contoh kasus dalam estimasi adalah estimasi tekanan darah pasien berdasarkan umur, jenis kelamin, indeks massa tubuh, dan tingkat sodium dalam darah pasien.
3. Kluster, adalah pengelompokkan objek yang sama ke dalam grup atau kelas. Kluster berbeda dengan klasifikasi, perbedaan paling mendasarnya adalah kluster tidak memiliki *target variable*. Kluster bertujuan untuk mengelompokkan seluruh data ke dalam grup atau kelas yang relatif homogen, dimana persamaan data di luar grup atau kelas diminimalkan. Umumnya, kluster dilakukan sebagai tahap awal dari sebuah proyek dan hasil yang didapat digunakan sebagai input untuk metode lain. Contoh kluster adalah pengelompokkan pengunjung pusat perbelanjaan.
4. Asosiasi, atau yang lebih dikenal dengan *affinity analysis* atau *market based analysis*. Tujuan asosiasi dalam *data mining* adalah untuk menemukan hubungan antar variabel, lebih detailnya adalah untuk menemukan aturan-aturan yang mengkuantifikasikan hubungan antar dua atau lebih variabel. Aturan asosiasi yang telah dihasilkan dapat digunakan untuk kepentingan perusahaan. Contohnya adalah penggunaan asosiasi untuk mengetahui barang apa saja yang dibeli secara bersamaan di pusat perbelanjaan.
5. Klasifikasi, merupakan salah satu tipe pekerjaan dalam *data mining* yang bertujuan untuk mempartisi data hingga terbagi ke dalam kelas-kelas dengan berdasar pada data historis (Anyanwu dan Shiva, 2005). Terdapat dua tipe variabel dalam klasifikasi, yaitu *target variable* dan *predictor variable*. *Target variable* merupakan variabel yang berbentuk kategorikal dan berisikan kategori-kategori. Kategori-kategori tersebut menjadi kelas-kelas dalam klasifikasi. Sedangkan *predictor variable* merupakan variabel yang menjadi

dasar pertimbangan dalam mengklasifikasi data ke dalam kelas-kelas. Untuk mencapai tujuannya, klasifikasi memiliki algoritma. Algoritma merupakan sekumpulan perintah atau instruksi untuk memecahkan sebuah masalah. Pertama, data dibagi ke dalam *learning data* dan *testing data*. Data pada *learning data* diperiksa untuk menemukan kombinasi dari *predictor variable* yang berasosiasi dengan kategori pada *target variable*. Fungsi dari *learning data* adalah membuat model klasifikasi. Kemudian model tersebut digunakan untuk mengklasifikasi data pada *testing data*. Fungsi dari *testing data* adalah memvalidasi model yang sudah dibuat sebelumnya. Jika valid, model akan menghasilkan tingkat akurasi yang tinggi yang dapat digunakan untuk mengklasifikasi data baru di luar *learning* dan *testing data*. Ada beberapa metode klasifikasi dalam *data mining*, diantaranya adalah *neural networks*, *rule induction*, *fuzzy*, dan *decision tree*.

6. Prediksi, serupa dengan klasifikasi dan estimasi, perbedaannya terletak pada jangka waktu. Prediksi bertujuan untuk meramalkan suatu kejadian di masa mendatang. Contohnya adalah penggunaan *data mining* untuk memprediksi persentase kenaikan tingkat kematian selama satu tahun ke depan.

2.1.3 Algoritma Data Mining

Data mining membutuhkan suatu algoritma untuk mendefinisikan dengan baik prosedur input data dan prosedur untuk menghasilkan output dalam bentuk model ataupun pola. Spesifikasi dari algoritma *data mining* untuk menyelesaikan suatu pekerjaan didefinisikan dalam komponen algoritma yang spesifik, antara lain:

1. Tugas (*task*) *data mining* digunakan untuk menentukan tujuan.
2. Tipe struktur (*structure*) *data mining* menjelaskan batasan yang mengantarkan kepada model atau pola tertentu.
3. *Score function* digunakan untuk menilai kualitas dari kesesuaian model atau pola berdasarkan data observasi (ditunjukkan dalam batasan *accuracy* dan *support*).

4. *Search* atau *optimization method* digunakan untuk mencari parameter dan struktur secara sistematis.
5. *Data management technique* digunakan untuk menyimpan, mengurutkan, dan menerima data.

Tabel 2.2 Perbandingan Penggunaan Algoritma dalam *Data Mining*

	CART	Backpropogation	A Priori
Task	Classification and Regression	Regression	Rule Pattern Discovery
Structure	Decision Tree	Neural Network (non linear function)	Association Rules
Score Function	Cross-validated Loss Function	Squared Error	Support/Accuracy
Search Method	Greedy Search over Structure	Gradient Descent on Parameters	Breath First with Pruning
Data Management Technique	Unspecified	Unspecified	Linear Scans

(Sumber: Hand, 2001)

2.1.4 *Classification and Regression Tree (CART)*

Solomon et al. (2006) menyimpulkan bahwa model pohon keputusan adalah suatu alat perhitungan yang ampuh dan populer untuk mengklasifikasi, memprediksi, dan mengestimasi pola data sejak aturan yang dihasilkan menjadi relatif lebih mudah untuk diinterpretasikan. Dari sudut pandang *Business Management*, pohon keputusan dapat menghasilkan seperangkat aturan dari data yang telah diklasifikasi yang kemudian dapat diterapkan pada sekumpulan data yang tidak terklasifikasi dan memprediksi hasilnya (Lee dan Siau, 2001). *Classification and Regression Tree (CART)* merupakan salah satu algoritma yang cukup sering digunakan pada model-model pohon keputusan (Solomon et al., 2006; Rokach et al., 2007).

CART adalah salah satu algoritma pohon keputusan untuk klasifikasi dengan membuat sebuah diagram alir (*flowchart*), struktur dimana tiap node internal merepresentasikan uji atribut, tiap cabang merepresentasikan hasil uji, dan tiap node eksternal merupakan prediksi kelas (Han dan Kamber, 2007; Wu dan Guo, 2011). Karakteristik CART yang menerapkan kondisi *if-then* digunakan untuk melakukan prediksi atau klasifikasi beberapa kasus, baik yang memiliki data yang sangat banyak ataupun sedikit dengan variabel yang bersifat kontinu ataupun kategorikal (Razi dan Athappilly, 2005; Witten dan Frank, 2005). Terlebih lagi, atribut yang tidak tertera pada pohon diasumsikan sebagai atribut yang tidak relevan terhadap analisis (Loh, 2011). Oleh karena itu, sekumpulan atribut yang terdapat pada pohon membentuk sekumpulan atribut yang telah direduksi.

Sebagai algoritma pohon keputusan yang cukup sering digunakan, CART memiliki beberapa kelebihan, antara lain:

- CART tidak membuat asumsi distribusi dalam bentuk apapun, baik pada variabel *dependent* ataupun *independent*.
- Variabel pendukung pada CART dapat berupa kombinasi kategori, interval, dan kontinu.
- CART memiliki algoritma *built-in* untuk mengatasi *missing value* variabel, kecuali ketika kombinasi linear variabel digunakan sebagai aturan pemisah.
- CART tidak dipengaruhi oleh *outliers*, *collinearity*, *heteroscedasticity*, atau bentuk distribusi *error* lainnya yang dapat mempengaruhi prosedur parametrik.
- CART dapat mendeteksi dan mengungkapkan interaksi yang terdapat pada data.
- CART mentransformasi variabel pendukung menjadi logaritma atau kuadrat atau akar kuadrat yang tidak mempengaruhi pohon yang dihasilkan.
- CART dapat mengubah sejumlah besar variabel yang akan dianalisis menjadi hasil bermanfaat yang terdiri dari beberapa variabel penting.

Dari beberapa kelebihan yang dimiliki CART, terdapat satu kelemahan yang sangat penting, yaitu CART dibuat tidak berdasarkan model probabilitas. Tidak ada tingkat probabilitas atau interval kepercayaan yang terkait dengan

prediksi yang berasal dari pohon CART dalam mengklasifikasikan satu *dataset* baru. Keyakinan akan keakuratan dari hasil yang dihasilkan oleh suatu model (pohon), murni berdasarkan akurasi sebelumnya.

Analisis CART terdiri dari empat tahap dasar. Tahap pertama adalah *tree building*, dimana digunakan pemisahan rekursif dalam pembuatannya. Tahap kedua adalah *stopping tree building*, menghentikan proses pembuatan pohon yang menghasilkan pohon yang dianggap sudah “maksimum.” Tahap ketiga adalah *pruning* (pemangkasan), yang menghasilkan urutan pohon sesederhana mungkin. Tahap keempat adalah *optimal tree selection*, pemilihan pohon yang optimal dari sejumlah pohon yang telah dipangkas.

1. *Tree buiding*

Dimulai dengan node utama, yang merepresentasikan sejumlah data dalam *database*, CART memilah variabel yang paling memungkinkan untuk memisahkan node menjadi dua anak node. Untuk menemukan variabel tersebut, CART memeriksa semua variabel pemisah yang memungkinkan dan nilai variabel yang digunakan untuk memisahkan node. Untuk kasus variabel kategorikal, jumlah pemisahan (*split*) yang memungkinkan meningkat seiring dengan jumlah level variabel kategorikal yang digunakan. Tiap node, termasuk node utama, dibagi ke dalam kelas-kelas. Hal ini penting karena tidak ada cara lain untuk mengetahui node terakhir saat proses pembuatan pohon berhenti. Terdapat tiga faktor yang mempengaruhi prediksi kelas, yaitu asumsi probabilitas sebelum dari tiap kelas, matriks *decision loss-cost*, dan pembagian subjek dengan pengaruhnya terhadap data. Pada tiap node, pemisah utama adalah variabel yang paling cocok untuk memisahkan node, memaksimalkan *purity* dari anak node yang dihasilkan. Ketika variabel pemisah utama tidak terdapat pada beberapa data observasi, observasi tersebut tidak dihapus melainkan dicari variabel pemisah pengganti yang memiliki pola seperti yang terdapat di dalam *dataset*, berhubungan dengan variabel hasil, dan sama seperti pemisah utama.

2. *Stopping tree building*

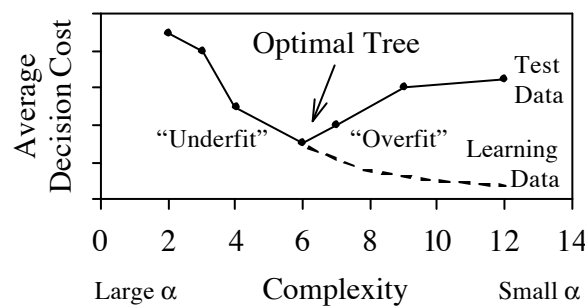
Proses pembuatan pohon akan terus berlangsung hingga proses tersebut tidak mungkin lagi untuk dilanjutkan. Proses pembuatan pohon akan berhenti saat: (i) hanya terdapat satu observasi pada tiap anak node, (ii) semua observasi pada tiap anak node memiliki distribusi variabel prediktor yang identik, sehingga tidak memungkinkan untuk melakukan pemisahan, (iii) batas eksternal jumlah level pohon yang maksimum telah diatur oleh *user*.

3. *Tree pruning*

Untuk menghasilkan urutan dari pohon-pohon yang sederhana, digunakanlah metode *cost-complexity pruning* (pemangkasan kompleksitas biaya). Metode ini bergantung pada parameter kompleksitas, yang dinotasikan dengan α , yang secara bertahap akan meningkat selama proses *pruning* (pemangkasan). Diawali dengan level terakhir (node terminal), anak node akan dipangkas ulang jika perubahan biaya misklasifikasi prediksi yang dihasilkan lebih kecil dari α kali perubahan kompleksitas pohon. Dengan demikian, α adalah ukuran mengenai seberapa banyak akurasi pemisahan tambahan yang harus ditambahkan ke dalam semua bagian pohon untuk menjamin kompleksitas tambahan. Semakin tinggi nilai α , maka semakin banyak node yang harus dipangkas ulang untuk menghasilkan pohon yang lebih sederhana.

4. *Optimal Tree Selection*

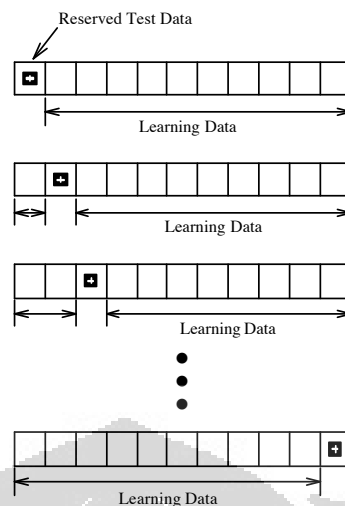
Pohon yang telah maksimum umumnya memiliki *learning data* dengan tingkat akurasi yang lebih tinggi dibanding pohon lainnya. Kinerja pohon yang telah maksimum dengan menggunakan *learning data* atau yang disebut dengan *resubstitution cost*, umumnya melakukan estimasi yang berlebihan terhadap kinerja pohon yang menggunakan *testing data*. Tujuan dari tahap ini adalah mendapatkan parameter kompleksitas α yang tepat sehingga informasi pada *learning data* menghasilkan estimasi yang pas (*fit*) bukan terlalu pas (*overfit*).



Gambar 2.2 *Optimal Tree Selection*

(Sumber: Lewis, 2000)

Gambar 2.2 menunjukkan hubungan antara kompleksitas pohon (yang direfleksikan dengan jumlah node terminal) dan biaya keputusan untuk *learning data* dan *testing data*. Umumnya untuk mendapatkan nilai α , dibutuhkan *testing data*, akan tetapi hal ini bisa dihindari dengan menggunakan *cross validation technique* (teknik validasi silang). Pada validasi silang, *learning data* dibagi secara random menjadi N bagian, yang distratifikasi dengan hasil variabel. Dengan begitu, setiap N bagian data memiliki distribusi hasil yang sama. Cara kerjanya adalah salah satu bagian *learning data* digunakan sebagai *testing data* yang akan diuji, sedangkan N-1 bagian data lainnya dikombinasikan untuk digunakan sebagai *learning data* dalam proses pembuatan model. Dengan menggunakan metode ini, biaya minimum akan dihasilkan ketika pohon menjadi cukup kompleks untuk bisa cocok/pas dengan informasi yang terdapat di dalam *learning data*, tetapi tidak terlalu kompleks untuk cocok dengan *noise* (data pengganggu).




Gambar 2.3 *Cross Validation Technique*

(Sumber: Lewis, 2000)

2.1.5 Klasifikasi *K-Nearest Neighbor Classifiers*

K-Nearest Neighbor melakukan klasifikasi berdasarkan kelas dari tetangga terdekatnya. Klasifikasi ini umumnya menggunakan lebih dari satu tetangga, oleh karena itu teknik ini dinamakan dengan Klasifikasi *k-Nearest Neighbor (k-NN)* dimana k adalah jumlah tetangga yang digunakan untuk menentukan kelas pada *learning data*. Sejak contoh *learning data* dibutuhkan dalam proses data, teknik ini juga sering disebut dengan *Memory-based Classification* (Klasifikasi Berdasarkan Memori). Klasifikasi k -NN terdiri dari dua tahapan, yang pertama adalah menentukan jumlah tetangga terdekat (*nearest neighbors*) dan yang kedua adalah menentukan kelas menggunakan tetangga (*neighbors*) tersebut. Berikut adalah contoh klasifikasi 3-NN.



Gambar 2.4 Contoh Klasifikasi *3-Nearest Neighbor*

(Sumber: Cunningham dan Delany, 2007)

Cara menentukan dan mengklasifikasi kelas menggunakan jumlah tetangga yang telah ditentukan adalah dengan menghitung jarak tiap tetangga (q) terhadap contoh uji (x) menggunakan formula berikut.

$$d(q, x_i) = \sum_{f \in F} w_f \delta(q_f, x_{if}) \quad (2.1)$$

Adapun metrik jarak yang digunakan dalam k-NN adalah sebagai berikut.

$$\delta(q_f, x_{if}) = \begin{cases} 0 & f \text{ discrete and } q_f = x_{if} \\ 1 & f \text{ discrete and } q_f \neq x_{if} \\ |q_f - x_{if}| & f \text{ continuous} \end{cases} \quad (2.2)$$

Setelah menghitung jarak tiap tetangga (*neighbor*), terdapat berbagai cara yang dapat digunakan untuk menentukan kelas dari q . Pendekatan yang cukup sering digunakan adalah dengan membobotkan jarak tiap-tiap tetangga dengan menggunakan formula berikut.

$$Vote(y_j) = \sum_{c=1}^k \frac{1}{d(q, x_c)^n} 1(y_j, y_c) \quad (2.3)$$

atau

$$Vote(y_j) = \sum_{c=1}^k e^{-\frac{d(q, x_c)}{h}} 1(y_j, y_c) \quad (2.4)$$

k-NN merupakan klasifikasi yang sangat sederhana untuk dimengerti dan mudah untuk diimplementasikan. Selain itu, k-NN juga memiliki beberapa kelebihan dibandingkan dengan klasifikasi lainnya, antara lain:

- Mudah untuk diimplementasikan.
- Pada situasi dimana penjelasan output *classifier* sangat berguna, k-NN dapat menjadi sangat efektif jika analisis tetangga (*neighbors*) sangat berguna untuk penjelasannya.
- Terdapat beberapa teknik untuk mereduksi beberapa pengganggu (*noise*) yang hanya dapat bekerja pada k-NN saja dan sangat efektif dalam meningkatkan akurasi *classifier*.
- Terdapat *Case-Retrieval Nets*, bagian dari *Memory-Based Classifier* yang dapat meningkatkan waktu proses untuk kasus dalam jumlah banyak.

Akan tetapi, k-NN juga memiliki beberapa kekurangan yang sebaiknya diperhatikan, kekurangan tersebut antara lain:

- Karena semua pekerjaan dilakukan saat waktu proses, k-NN memiliki kinerja waktu proses yang rendah, terutama untuk *learning data* dalam jumlah besar.
- k-NN sangat sensitif terhadap fitur yang tidak relevan dan ‘tumpang tindih’ karena semua fitur berkontribusi dalam persamaan (2.1) dan klasifikasi. Hal ini dapat diperbaiki dengan berhati-hati dalam menyeleksi atau membobotkan fitur.
- Untuk klasifikasi yang sangat sulit, hasil klasifikasi *Support Vector Machines (SVM)* atau *Neural Networks (NN)* dirasa lebih baik dari k-NN.

2.2 *Wakaito Environment for Knowledge Analysis (WEKA)*

WEKA merupakan suatu *software open-source* yang dikeluarkan oleh GNU General Public License dan ditemukan oleh seorang mahasiswa lulusan tahun 2005 dari *Central Connecticut State University* yang bernama James Steck. James merupakan mahasiswa pertama yang lulus dalam bidang *science of data mining* dan mendapatkan penghargaan pertama *Graduate Academic Award*. WEKA merupakan salah satu alat perhitungan *data mining* yang terdiri dari beberapa *tools*: satu set *data pre-processing routines*, yang digunakan untuk memanipulasi data mentah kemudian mentransformasikannya menjadi bentuk yang sesuai dengan *data mining*; *selection feature tools*, yang berguna untuk mengidentifikasi atribut yang tidak relevan kecuali yang berasal dari *dataset*; *classifiers* dan *algoritma data mining*, untuk menangani *learning tasks* yang bersifat numerik dan kategorikal; *metaclassifiers*, untuk meningkatkan kinerja algoritma klasifikasi pada *data mining*; *experimental support*, untuk memverifikasi perbandingan *robustness* dari beberapa model induksi; dan *benchmarking tools*, untuk membandingkan kinerja relatif dari algoritma pembelajaran yang berbeda untuk beberapa *dataset*.

Secara umum, WEKA terdiri dari 12 implementasi skema pembelajaran. Berikut adalah tipe pembelajaran yang terdapat pada WEKA.

1. *Classifiers*

Output dari skema pembelajaran tipe ini adalah sebuah *classifier* atau kelompok, yang biasanya berbentuk pohon keputusan atau sekumpulan aturan yang dapat digunakan untuk memprediksi klasifikasi contoh data baru. Adapun skema pembelajaran *classifiers* dapat dilihat pada Gambar 2.5.

```
weka.classifiers.ZeroR
weka.classifiers.OneR
weka.classifiers.NaiveBayes
weka.classifiers.DecisionTable
weka.classifiers.Ibk
weka.classifiers.j48.J48
weka.classifiers.j48.PART
weka.classifiers.SMO
weka.classifiers.LinearRegression
weka.classifiers.m5.M5Prime
weka.classifiers.LWR
weka.classifiers.DecisionStump
```

Gambar 2.5 Skema Pembelajaran Dasar pada WEKA

(Sumber: Cunningham et al., 1999)

ZeroR digunakan untuk memprediksi nilai rata-rata kelas untuk masalah prediksi numerik. *OneR* digunakan untuk memprediksi hubungan antar data. *NaiveBayes* mengindikasikan probabilitas tiap *item* untuk tiap kategori kelas. *DecisionTable* digunakan untuk merangkum *dataset* ke dalam *decision table*. *Ibk* mengklasifikasikan data dengan membandingkan data tersebut dengan data yang sebelumnya telah ‘dihafal’ dengan menggunakan jarak metrik dan merupakan implementasi dari *k-nearest neighbor classifier*. *J48* merupakan implementasi dari C4.5. *SMO* (*Sequential Minimal Optimization*) mengimplementasikan algoritma untuk *Support Vector Machines* (SVMs). *LinearRegression* untuk prediksi numerik. *m5.M5Prime* digunakan saat pohon keputusan dirancang untuk menetapkan kategori nominal, representasi ini dapat diperpanjang untuk prediksi numerik dengan memodifikasi node daun dari pohon yang mengandung nilai numerik yang merupakan rata-rata dari semua nilai *dataset* daun yang berlaku. LWR merupakan implementasi skema pembelajaran yang lebih canggih untuk prediksi numerik dengan menggunakan

locally weighted regression. *DecisionStump* digunakan untuk membuat keputusan biner sederhana *stumps* (1-level *decision tress*) untuk masalah klasifikasi numerik dan nominal.

2. *Meta-Classifiers*

Bekerja dengan mengoperasikan output dari *learner* lain dengan mengatur *classifier* pada suatu klasifikasi. Dua metode yang umum digunakan untuk membuat klasifikasi tipe ini adalah *boosting* dan *bagging* (Breiman, 1992). *Bagging* bekerja dengan membangun model terpisah dari *learning data* menggunakan teknik pengambilan sampel yang menghapus beberapa kasus dan ulangan yang lain. Pada *boosting*, masing-masing model baru dipengaruhi oleh kinerja model yang dibangun sebelumnya.

3. *Clustering*

Clustering tidak menghasilkan aturan prediktif untuk kelas tertentu, melainkan mencoba untuk menemukan pengelompokan alami (atau kluster) di dalam *dataset*.

4. *Association Rules*

Untuk tipe analisis ini, data diatur dalam sebuah 'keranjang'. Algoritma MBA (*Market Based Analysis*), yang merupakan implementasi algoritma Apriori pada WEKA, merupakan algoritma yang dapat menemukan *association rules* untuk mengidentifikasi pola pembelian konsumen. Hasil dari algoritma ini dapat digunakan sebagai bahan pertimbangan untuk mengkombinasikan produk (terutama saat sedang promo), merancang tata letak toko yang lebih efektif, dan memberikan wawasan tentang loyalitas merek dan *co-branding*.

2.2.1 M5P

M5P adalah *model tree learner M5'* dalam WEKA. *Model tree* adalah salah satu jenis pohon keputusan dengan fungsi regresi linear pada tiap nodenya, membentuk suatu rumusan dasar dari teknik yang akan digunakan untuk memprediksi nilai numerik yang kontinu. Model ini juga dapat mentransformasikan masalah klasifikasi menjadi suatu pendekatan fungsi. Sedangkan M5' adalah reimplementasi dari *model tree learner M5* buatan Quinlan yang dapat menghasilkan klasifikasi yang lebih akurat dibandingkan dengan

pohon keputusan C5.0. untuk kasus dimana sebagian besar data atributnya terdiri dari data numerik. Jika M5 adalah *model tree* yang dihasilkan oleh Quinlan, maka M5' dihasilkan oleh Wang dan Witten. Sama halnya dengan M5, M5' merupakan salah satu program yang sering digunakan dalam proses induksi pohon regresi. M5' secara efektif membagi data menjadi bagian-bagian/node-node dengan menggunakan pohon keputusan dan terus dilanjutkan hingga *expected mean square error* antara output *model tree* dan nilai target 0 dan 1 pada *learning data* menjadi minimum di tiap bagiannya.

2.2.2 IBk


Lazy learners hanya menyimpan *learning data* dan tidak melakukan pekerjaan apa-apa hingga tiba saatnya proses klasifikasi. IB1 adalah salah satu *instance-based learner* yang bekerja dengan cara menemukan satu contoh *learning data* yang memiliki jarak euclidean terdekat dari contoh yang diuji dan memprediksi contoh uji tersebut dengan kelas yang sama seperti contoh *learning data*-nya. Jika terdapat beberapa contoh yang memiliki jarak terdekat, maka contoh *learning* yang pertama kali ditemukan adalah contoh yang digunakan. IBk adalah *k-nearest neighbor classifier* yang menggunakan metrik jarak serupa, dengan jumlah tetangga terdekat ($k = \text{nearest neighbor}$) yang dapat dispesifikasikan secara eksplisit pada *object editor* atau ditentukan secara otomatis menggunakan *leave-one-out cross-validation*. Prediksi yang berasal lebih dari satu tetangga (*neighbor*) dibobotkan berdasarkan jarak masing-masing tetangga terhadap contoh uji dan mengimplementasikan dua formula yang berbeda untuk mengkonversi jarak menjadi bobot. Penambahan contoh *learning* diizinkan pada jenis *classifier* ini, hanya saja ketika contoh ditambahkan, contoh yang paling lama akan dibuang untuk mempertahankan agar jumlah contoh *learning* tetap sama.

2.3 Dry Docking Kapal

Docking kapal adalah suatu peristiwa pemindahan kapal dari air/laut ke atas dok dengan bantuan fasilitas *docking* (pengedokan) untuk selanjutnya dilakukan pemeliharaan. Terdapat empat tipe dok yang biasa digunakan untuk proses *docking*, yaitu dok kolam (*dry dock*), dok apung (*floating dock*), dok tarik (*slipway*), dan dok angkat (*synchrholift*). Jenis dok yang umum digunakan galangan untuk memelihara dan memperbaiki berbagai jenis kapal adalah *dry dock* dan *floating dock*. Dikarenakan pekerjaan *floating* seringkali dilakukan oleh pihak kapal bukan galangan, maka penelitian ini lebih lanjut difokuskan pada pekerjaan yang dilakukan di atas dok atau yang biasa disebut dengan *dry docking*.

Dry docking adalah *docking* yang dilakukan di dalam suatu kolam besar yang terdapat di pinggir laut, yang konstruksinya terdiri dari material beton dan baja. Secara keseluruhan, proses *docking* diawali dengan penyusunan daftar pekerjaan pemeliharaan (*repair list*) yang merupakan sebuah hasil survey (berupa observasi dan wawancara) dari pihak galangan dan permintaan perbaikan dari pihak *owner* yang dilakukan pada saat kapal beroperasi atau bersandar di pelabuhan selama kurun waktu antrinya (minimal 2 bulan sebelum masuk dok). Setelah daftar pekerjaan tersebut disetujui oleh kedua belah pihak, maka pekerjaan pemeliharaan dapat langsung dikerjakan, sebagian besar diawali dengan *dry docking* lalu dilanjutkan dengan *floating*. Berikut adalah pekerjaan-pekerjaan *dry docking*.

1. Penggantian pelat (*replating*) lambung kapal



Gambar 2.6 *Replating* Lambung Kapal

Sebelum dilakukan *replating*, dilakukan uji ketebalan pelat yang dikenal dengan *ultrasonic test*. Hasil dari *ultrasonic test* berupa titik-titik pada bagian yang bermasalah, jadi *replating* hanya dilakukan pada bagian-bagian lambung kapal yang akan diperbaiki saja. Volume pekerjaan *replating* adalah jumlah titik hasil *ultrasonic test* dan berat total pelat pengganti (ton). Semakin banyak titik yang dihasilkan, maka bagian yang harus diperbaiki menjadi semakin luas dan banyak sehingga berat total pelat pengganti menjadi semakin berat.

2. Pemeliharaan dan perbaikan bagian *rudder* (kemudi)



Gambar 2.7 Pemeliharaan dan Perbaikan *Rudder*

Terdapat tiga jenis sistem kedap air pada kemudi, yaitu *simplex seal*, *nock seal*, dan *reamers packing*. Sistem *simplex seal* dan *nock seal* menggunakan oli sebagai media pelumasannya, sedangkan *reamers packing* menggunakan air laut. Pada umumnya, kemudi terdiri dari dua bagian, yaitu *rudder blade* dan *rudder stock*. Dalam proses perbaikan, *rudder blade* dibersihkan dari *fouling* (organisme laut) dengan menggunakan *scrap* kemudian *diblasting* untuk membersihkan karat yang menempel pada *rudder blade*. Setelah *rudder blade* dibersihkan, dilakukan pengecatan secara merata untuk menghindari karat. Untuk bagian *rudder stock*, cukup dibersihkan dengan gerinda *brush*. Namun, jika *rudder stock* melebihi batas *clearance* (kelonggaran), maka harus dilakukan penggantian bantalan. Jenis perbaikan *rudder stock* lainnya adalah rekondisi atau penggantian *rudder stock* dan penggantian *shaft slip* pada *rudder stock*. Volume pekerjaan pemeliharaan dan perbaikan *rudder* adalah jumlah *seal* yang diganti; luas bagian *rudder blade* yang dibersihkan, *diblasting*, dan dicat; serta jenis perbaikan yang dilakukan pada *rudder stock*.


3. Pemeliharaan dan perbaikan bagian *propeller* (baling-baling)

Pada umumnya kerusakan *propeller* terjadi pada bagian *blade*, yaitu seperti terdapat *fouling* dan keretakan pada baling akibat benturan. Langkah perbaikan baling-baling akibat *fouling* terdiri dari: (i) membersihkan baling-baling dengan gerinda *brush*, (ii) mempolish bagian yang masih terdapat sisa *fouling*, (iii) melakukan *color check*.



Gambar 2.8 *Fouling* pada Daun Baling-baling

Apabila baling-baling bengkok dan bengkokan tersebut tidak begitu parah, maka baling-baling dapat diluruskan kembali dengan cara dipanaskan dan dipukul merata atau *dipress* hingga rata tanpa terjadi perubahan sudut. Jika baling-baling mengalami keretakan, maka perbaikan untuk kerusakan jenis ini adalah dengan menggerinda keretakan hingga membentuk permukaan yang siap untuk dilas/*bevel*. Setelah *bevel* terbentuk, baling-baling dilas dengan elektrode yang sama dengan bahan baling-baling.



Gambar 2.9 Retak pada *Propeller*

Sedangkan jika daun *propeller* patah, maka baling-baling harus direkondisi dengan material yang sama dengan bahan baling-baling dan *dibalancing*. *Balancing* baling-baling merupakan perbaikan terhadap baling-baling apabila baling-baling mengalami ketidakseimbangan. Teori *balancing* tersebut hanya untuk jenis baling-baling FPP (*Fix Pitch Propeller*) dan CPP (*Controllable Pitch Propeller*). *Balancing* baling-baling dilakukan dengan cara melepas semua *blade* kemudian menimbang *blade* tersebut. Pada proses perbaikan, *shaft* baling-baling dibersihkan dengan menggunakan gerinda *brush*, kemudian dilakukan pengecekan dengan menggunakan test MPI (*Magnetif Particular Induction*). Apabila terjadi kerusakan yang cukup parah, maka *shaft* baling-baling akan diperbaiki di bengkel mekanik, seperti ganti bantalan, rekondisi atau ganti baru *seal*, ganti *shaft slip*. Volume pekerjaan pemeliharaan dan perbaikan baling-baling adalah jenis perbaikan yang dilakukan pada baling-baling; luas bagian baling-baling yang dibersihkan, *dipolish*, dan dicat; serta jumlah komponen *propeller* yang diganti.

4. Pemeliharaan dan perbaikan lambung kapal

Pekerjaan pemeliharaan dan perbaikan pelat lambung kapal terdiri dari: (i) penyekrapan, merupakan proses pembersihan badan kapal dari *fouling* yang menempel pada badan kapal yang berada di bawah garis air. Penyekrapan dilakukan secara manual dengan menggunakan alat berupa lempengan besi yang bertepi tajam/sikat baja atau gerinda untuk menghilangkan kotoran-kotoran yang sulit dibersihkan dengan sikat baja. (ii) *Water jet*, merupakan proses yang dilakukan untuk membersihkan lambung kapal dari sisa *fouling* yang telah diskrap. Media yang digunakan dalam *water jet* adalah air tawar yang disemprotkan oleh sebuah kompresor dengan tekanan tertentu. (iii) *Sandblasting*, merupakan proses yang dilakukan untuk membersihkan lambung dari karat dan sisa-sisa cat yang lama dengan menggunakan pasir. Pasir yang digunakan adalah pasir kuarsa, pasir silica, pasir besi *time slack*, pasir besi *coper slack*. (iv) Pengecatan, dilakukan agar pelat tidak mengalami korosi akibat kelembaban udara laut. Selain pemeliharaan dan perbaikan pelat,

terdapat juga pemeliharaan dan perbaikan lainnya, seperti penggantian *zinc anode*. Volume pemeliharaan dan perbaikan lambung kapal adalah luas bagian pelat yang diskrap, di *water jet*, di *sandblast*, dan dicat; serta jumlah *zinc anode* yang diganti.

5. Pemeliharaan dan perbaikan jangkar dan rantai jangkar

Kerusakan yang biasa terjadi pada jangkar adalah kerusakan pada *mooring system* rantai jangkar, seperti mata rantai jangkar karat, aus, bengkok, dan retak; mata rantai jangkar aus dan retak dari sambungan rantai jangkar; mata rantai jangkar aus dan karat dari bak rantai jangkar. Pekerjaan pemeliharaan jangkar dan rantai jangkar terdiri dari membersihkan, mengetok karat, menyikat, serta mengecat jangkar dan rantai jangkar. Volume pemeliharaan dan perbaikan jangkar dan rantai jangkar adalah luas jangkar dan panjang rantai jangkar yang dipelihara dan jenis perbaikan yang dilakukan.

6. Pemeliharaan dan perbaikan kotak masukan, katup isap, katup buang air laut

Pekerjaan pemeliharaannya terdiri dari membersihkan dan memeriksa kondisi kotak masukan, katup isap, dan katup buang air laut. Jika kondisi kotak masukan, katup isap, dan katup buang air laut sudah tidak layak pakai, maka dilakukan penggantian dengan komponen baru. Volume pemeliharaan dan perbaikan kotak masukan, katup isap, dan katup buang air laut adalah jumlah kotak masukan, katup isap, katup buang air laut yang harus dibersihkan dan diganti.

7. Pemeliharaan tangki kapal

Pemeliharaan tangki kapal terdiri dari membuka/memasang *manhole* (termasuk ganti *packing*), membuka/memasang *plug* dasar dan membersihkan tangki. Volume pemeliharaannya adalah jumlah *manhole* dan *plug* dasar yang dibuka/pasang, serta volume tangki yang dibersihkan.

BAB 3

PENGUMPULAN DAN PENGOLAHAN DATA

3.1 PT. Daya Radar Utama

3.1.1 Profil PT. Daya Radar Utama

PT Daya Radar Utama merupakan salah satu galangan kapal di Jakarta yang telah berdiri sejak tahun 1972 dan merupakan salah satu galangan kapal yang aktif membangun berbagai jenis kapal hingga ukuran 1000 DWT dan memperbaiki kapal hingga ukuran 8000 DWT. PT Daya Radar Utama juga sudah berhasil membangun dan memperbaiki kapal-kapal baja, aluminium, dan *fibreglass*. Untuk pembangunan kapal baru (*ship building*), PT Daya Radar Utama telah membangun berbagai ukuran dan tipe kapal seperti Ferry Roro dengan ukuran 750 GRT, *Passenger & Cargo Vessel* sampai 750 DWT, *Harbour Tug*, *FRP Patrol Boat*, *Floating Jetty*, *Bouy*, dan lain-lain. Divisi perbaikan kapal PT Daya Radar Utama berpengalaman dalam memperbaiki kapal-kapal jenis Tanker, Penumpang, *Ferry*, *Dredger*, *Z-Drive Tug Boat*, *Bulk Carrier*, *High Speed Ferry*, dan konversi kapal dari kontainer menjadi akomodasi untuk menunjang kegiatan *offshore*.

PT Daya Radar Utama telah menerapkan Sistem Manajemen Mutu ISO 9001:2000 untuk industri perkapalannya dengan ruang lingkup pekerjaan pembangunan, perbaikan, dan konversi kapal. Manajemen PT Daya Radar Utama mengadopsi pendekatan proses yang menekankan pentingnya:

1. Memahami dan memenuhi persyaratan.
2. Kebutuhan untuk mempertimbangkan proses dalam pengertian nilai tambah.
3. Memperoleh hasil kinerja proses dan efektifitas.
4. Perbaikan berkesinambungan proses berdasarkan pengukuran yang objektif.

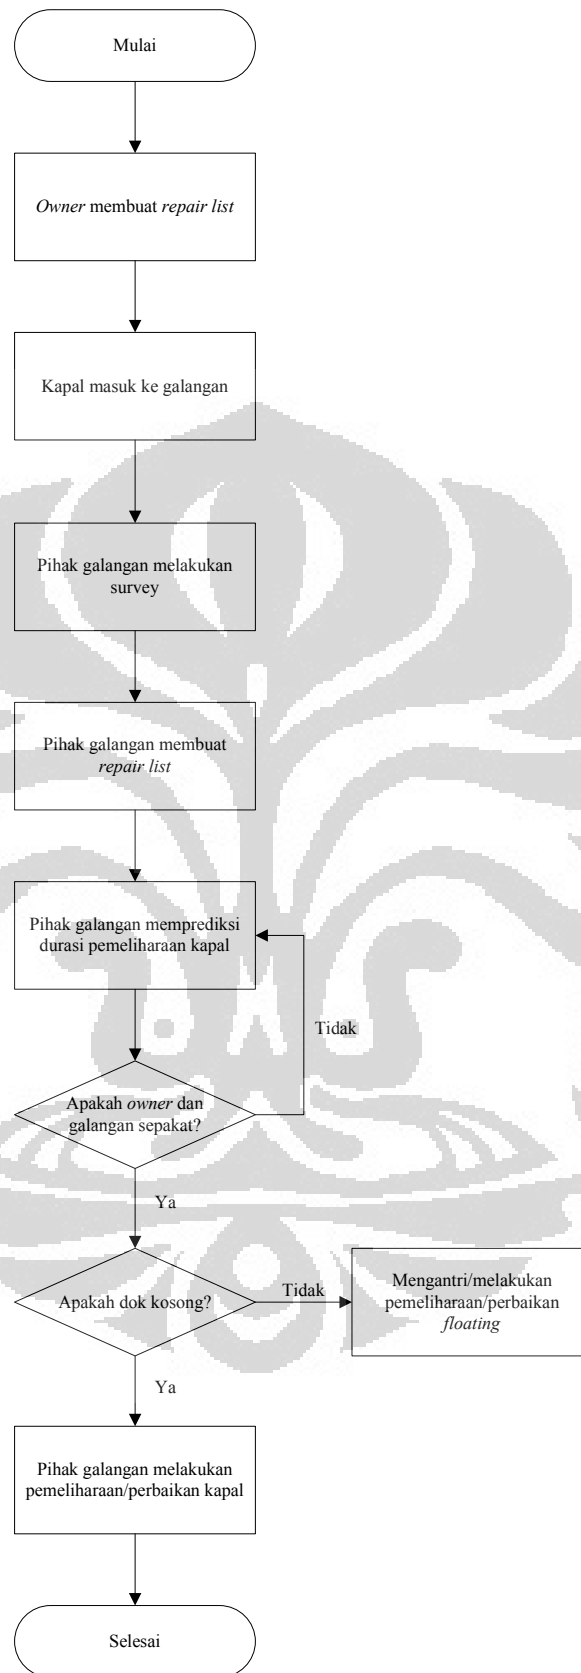
Visi PT Daya Radar Utama adalah menjadi perusahaan galangan kapal yang unggul di segmen kelas menengah dan siap bersaing di pasar global. Sedangkan misinya adalah sebagai berikut:

1. Diakui dan dikenal luas sebagai perusahaan yang handal dalam memenuhi harapan pelanggan.
2. Meningkatkan kemampuan untuk mewujudkan pertumbuhan yang berkesinambungan.
3. Memberi nilai tambah yang optimal bagi para pemegang saham, karyawan, pelanggan, dan mitra usaha.

Ruang lingkup penerapan Sistem Manajemen Mutu ISO 9001: 2000 PT Daya Radar Utama adalah pada aktivitas pembangunan, perbaikan, dan konversi kapal dengan komitmen untuk selalu memberikan dan meningkatkan pelayanan sesuai dengan harapan pelanggan. Sasaran (tujuan) mutu PT Daya Radar Utama ditetapkan secara berkala sesuai dengan target Manajemen dan selaras dengan Kebijakan Mutu perusahaan, dimana pencapaian kebijakan mutu menjadi tanggung jawab seluruh jajaran manajemen karyawan.

3.1.2 Operasional Pemeliharaan Kapal

Untuk mengetahui cara galangan dalam melakukan estimasi durasi pemeliharaan kapal, langkah pertama yang harus dilakukan adalah mengetahui kegiatan operasional pemeliharaan sejak kapal berlabuh di galangan. Adapun kegiatan operasional pemeliharaan kapal pada PT Daya Radar Utama digambarkan pada Gambar 3.1.



Gambar 3.1 Diagram Alir Kegiatan Operasional Pemeliharaan

Kegiatan pemeliharaan kapal dimulai dari *annual docking* kapal yang telah jatuh tempo, kemudian pihak *owner* membuat daftar pekerjaan pemeliharaan dan perbaikan (*repair list*) yang diinginkan pemilik kapal untuk dilakukan oleh pihak galangan saat kapal masuk ke galangan. Jika masih ada kapal terdahulu yang belum selesai dipelihara/perbaiki, maka kapal yang baru datang harus mengantri. Umumnya waktu antri kapal adalah sekitar 2 bulan. Ketika kapal sudah naik dok, *owner* menyerahkan daftar pekerjaan yang telah dibuat. Kemudian daftar pekerjaan tersebut diperiksa ulang oleh pihak galangan, untuk menentukan apakah pekerjaan-pekerjaan yang terdapat di dalam daftar benar-benar harus dilakukan atau tidak sekaligus menentukan besar volume pemeliharaan yang akan dilakukan. Setelah pihak galangan melakukan pemeriksaan, pemilik kapal dan pihak galangan bertemu untuk menyepakati pekerjaan yang akan dilakukan beserta dengan volume pekerjaannya. Kemudian dengan daftar dan volume pekerjaan yang telah disepakati, pihak galangan mengestimasi durasi pemeliharaan kapal.

3.2 Pengumpulan Data

Satisfaction note adalah daftar pekerjaan pemeliharaan kapal yang telah disepakati oleh kedua belah pihak, pihak *owner* dan galangan. *Satisfaction note* ini sangat penting bagi galangan karena mengandung informasi mengenai pekerjaan yang telah dilakukan bukan hanya sekedar direncanakan dan disepakati. Saat ini, data yang terdapat pada *satisfaction note* hanya digunakan untuk membuat perhitungan biaya atas pemeliharaan kapal yang *docking* oleh pihak galangan.

Namun, selain dapat digunakan untuk menentukan biaya pemeliharaan kapal, data pada *satisfaction note* juga dapat digunakan untuk mengestimasi durasi pemeliharaan kapal yang saat ini masih dilakukan berdasarkan pengalaman tenaga ahli. *Satisfaction note* berisi daftar pekerjaan pemeliharaan kapal yang terdiri dari pekerjaan *dry docking* (di atas dok) dan *floating* (terapung/di atas air).

Penelitian ini menekankan pada pekerjaan *dry docking* kapal karena biaya *dry docking* umumnya lebih mahal dibandingkan dengan *floating*. Pemakaian dok, yang dalam hal ini adalah *graving dock*, adalah alasan atas mahalnya biaya *dry docking* karena dok memiliki kapasitas terbatas yang membatasi semua kapal yang datang untuk langsung naik dok, melainkan harus mengantri. Oleh karena itu, penelitian ini hanya menggunakan data-data terkait dengan pekerjaan *dry docking*, yang berupa:

1. Pemeliharaan dan perbaikan lambung kapal: luas bagian lambung kapal yang *discrap*, *disandblast*, *diwater jet*, dan dicat serta jumlah *zinc anode* yang baru dipasang.
2. Penggantian pelat kapal: jumlah titik hasil *ultrasonic test*, luas pelat pengganti, jumlah titik las ulang, dan panjang las ulang.
3. Pemeliharaan dan perbaikan baling-baling: jenis perbaikan yang dilakukan pada daun, bantalan, dan poros baling-baling; jumlah *seal*, *packing*, *chrome liner*, *ring* yang diganti, dan volume *grease* yang diganti.
4. Pemeliharaan dan perbaikan kemudi: jenis perbaikan yang dilakukan pada daun, bantalan, dan poros kemudi; penggantian *shaft seal*; jumlah *seal*, *packing*, dan *ring* yang diganti.
5. Pemeliharaan dan perbaikan kotak masukan, katup isap, katup buang air laut: jumlah kotak masukan, katup isap, katup buang air laut yang diganti.
6. Pemeliharaan tangki kapal: jumlah *manhole* dan *plug* yang dibuka/pasang serta volume tangki yang dibersihkan.
7. Pemeliharaan dan perbaikan jangkar dan rantai jangkar: pilihan antara dilakukan atau tidaknya pemeliharaan jangkar dan volume bak rantai jangkar yang dibersihkan.

3.3 Penentuan Atribut *Dry Docking*

Setiap galangan kapal umumnya memiliki *satisfaction note*, yang berfungsi sebagai laporan pekerjaan pemeliharaan yang telah dilakukan. Namun, data yang terdapat pada *satisfaction note* tidak hanya dapat digunakan untuk

menentukan biaya pemeliharaan tetapi juga dapat digunakan untuk mengestimasi durasi pemeliharaan, yang dalam penelitian ini ditekankan pada pekerjaan *dry docking*. Atribut dan jenis data pekerjaan *dry docking* dapat dilihat pada Tabel 3.1.

Tabel 3.1 Spesifikasi Atribut *Dry Docking*

Atribut	Spesifikasi Data
ukuran, tank, bak	Volume (m ³)
grt	Berat (ton)
scraping, sandblasting, cuci, cat	Luas (m ²)
zinc, sealprop, ringprop, packingprop, chrome, ringkem, packingkem, sealkem, chest, valve, scrupper, manhole, plug	Jumlah (buah)
ut, las	Jumlah (titik)
pelat, grease	Berat (kg)
propeller, porosprop, kemudi, poroskem	A = tidak ada perbaikan, B = rekondisi, C = balancing, D = ganti, E = rekondisi dan balancing, F = ganti dan balancing, G = ganti dan rekondisi, H = ganti, rekondisi, dan balancing
bantalanprop, bantalankem	A = tidak ada perbaikan, B = rekondisi/cor, C = ganti, D = balancing
shaftseal, jangkar	Pilihan (YES, NO)
panjanglas	Panjang (m)

3.4 Reduksi Data dan Eliminasi *Missing Value*

Untuk menghindari adanya pengaruh negatif dari atribut yang tidak relevan, tidak berguna, dan ‘tumpang tindih’ pada data historis yang akan diproses, maka perlu dilakukan proses reduksi data. Reduksi data yang dilakukan merupakan hasil analisis berdasarkan wawancara dengan operator yang ahli di bidangnya, yaitu pemeliharaan kapal. Atribut dikatakan tidak relevan jika atribut

tersebut tidak mempengaruhi durasi *dry docking* kapal secara signifikan, sedangkan atribut yang ‘tumpang tindih’ adalah atribut yang memiliki informasi atau data yang dimiliki oleh atribut lain. Jika atribut memiliki nilai yang sama pada semua atau kebanyakan data, maka atribut tersebut dikatakan sebagai atribut yang tidak berguna karena atribut yang seperti itu hanya memberikan pengaruh yang sangat kecil (Srdoc, 2007). Setelah dilakukan analisis mengenai atribut yang mempengaruhi durasi *dry docking* secara signifikan, maka didapatkan 29 atribut dari 35 atribut yang telah ditentukan sebelumnya. 29 atribut tersebut dapat dilihat pada Tabel 3.2.

Tabel 3.2 Atribut Hasil Reduksi Data

Atribut	Spesifikasi Data
tank	Volume (m ³)
scraping, sandblasting, cuci, cat	Luas (m ²)
zinc, sealprop, ringprop, packingprop, chrome, ringkem, packingkem, sealkem, chest, valve, scrupper	Jumlah (buah)
ut, las	Jumlah (titik)
pelat, grease	Berat (kg)
propeller, porosprop, kemudi, poroskem	A = tidak ada perbaikan, B = rekondisi, C = balancing, D = ganti, E = rekondisi dan balancing, F = ganti dan balancing, G = ganti dan rekondisi, H = ganti, rekondisi, dan balancing
bantalanprop, bantalankem	A = tidak ada perbaikan, B = rekondisi/cor, C = ganti, D = balancing
shaftseal	Pilihan (YES, NO)
panjanglas	Panjang (m)

Setelah menentukan 29 atribut yang signifikan, maka tahap selanjutnya adalah mengeliminasi data yang tidak memiliki nilai atau yang dikenal dengan

istilah *missing value* karena data, baik *learning data* maupun *testing data*, yang memiliki *missing value* akan menghasilkan estimasi atau prediksi yang tidak tepat, sehingga hasil yang didapatkan menjadi tidak *reliable*.

3.5 Perhitungan Waktu *Dry Docking*

Seperti yang telah dipaparkan sebelumnya, setiap galangan kapal memiliki *satisfaction note* sebagai laporan pekerjaan pemeliharaan yang telah dilakukan oleh pihak galangan. Selain berfungsi untuk menentukan besar biaya pemeliharaan yang akan dibebankan kepada *owner*, *satisfaction note* dapat digunakan untuk mengestimasi durasi pemeliharaan kapal yang pada penelitian ini ditekankan pada pekerjaan *dry docking*. Berikut adalah langkah-langkah yang dilakukan untuk mengestimasi durasi *dry docking* dengan menggunakan metode CART (*Classification and Regression Tree*).

1. Memasukan *predictor* dan *target variable learning* dan *testing data* ke dalam excel. *Learning data* merupakan data historis *dry docking* kapal selama 6 tahun (2005 - 2010) yang digunakan untuk ‘mengajari’ CART sehingga dapat mengetahui hubungan antara *predictor variable* (atribut *dry docking*) dengan *target variable* (durasi). *Testing data* merupakan data 2 tahun terakhir yang akan diestimasi (2011 - 2012) dengan *target variable* (durasi) masih berupa ‘?’.
2. Melatih CART dengan menggunakan *learning data*, sehingga menghasilkan beberapa rumusan durasi *dry docking* kapal, yang berupa model linier yang terdiri dari atribut-atribut dengan signifikansi pengaruh yang lebih besar dibanding atribut lainnya dan pohon klasifikasi yang terklasifikasi berdasarkan kriteria pekerjaannya. Adapun *syntax* yang harus ditambahkan untuk menjalankan *software* WEKA adalah sebagai berikut.

```
@relation trial

@attribute scraping numeric
@attribute sandblasting numeric
@attribute cuci numeric
@attribute cat numeric
@attribute zinc numeric
@attribute ut numeric
@attribute pelat numeric
@attribute propeller {A,B,C,D,E,F,G,H}
@attribute bantalanprop {A,B,C,D}
@attribute porosprop {A,B,C,D,E,F,G,H}
@attribute sealprop numeric
@attribute ringprop numeric
@attribute packingprop numeric
@attribute chrome numeric
@attribute grease numeric
@attribute kemudi {A,B,C,D,E,F,G,H}
@attribute poroskem {A,B,C,D,E,F,G,H}
@attribute shaftseal {YES,NO}
@attribute bantalankem {A,B,C,D}
@attribute ringkem numeric
@attribute packingkem numeric
@attribute sealkem numeric
@attribute chest numeric
@attribute valve numeric
@attribute scrupper numeric
@attribute tank numeric
@attribute las numeric
@attribute panjangglas numeric
@attribute durasi numeric

@data
```

Gambar 3.2 *Syntax* Tambahan pada *File WEKA*

3. Mengestimasi durasi *dry docking* pada *testing data* dengan menggunakan pohon klasifikasi dan model linier yang dihasilkan saat melatih CART.

```

@data
275,315,0,315,46,400,1326.39,E,B,A,0,0,1,0,0,A,A,NO,A,0,1,0,0,0,123.06,0,0,15.548618,?
1395,1860,1877,1877,69,2691,5090.07,E,B,A,6,0,0,7,0,A,A,NO,C,0,0,0,0,0,0,1768.3,0,0,16.794804,?
730,730,590,730,0,200,128.93,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,200.26,0,0,8.037218,?
430,430,430,430,6,200,206.69,E,A,A,0,4,0,0,0,A,A,NO,A,0,0,0,2,0,0,89.25,0,0,99.14.953143,?
100,220,100,220,20,435,1880.3,E,C,B,0,3,1,0,0,A,A,NO,A,0,1,0,0,0,0,0,16.25,15.628237,?
1013,1926,0,4975,38,0,7409.8,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,2498.88,0,148.83,10.333512,?
465,2875.4,1877,2892.4,69,450,4083.4,B,A,A,0,1,0,0,0,A,A,NO,A,0,0,0,0,0,1000.6,0,0,10.075892,?
800,1200,0,1600,60,150,0,A,A,A,0,0,0,0,0,A,B,NO,C,2,0,4,0,0,0,303,0,0,11.864659,?
254,1265,0,2531,52,361,1019.73,A,A,A,0,6,0,0,0,A,A,NO,A,0,0,0,0,0,26,10,12.030804,?
2372,2407,2407,2497,74,450,7000,E,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,893.3,0,0,15.396533,?
300,300,300,300,62,400,948.42,E,A,A,0,0,0,0,0,A,A,NO,C,0,0,0,0,0,0,340.05,100,0,15.307124,?
300,300,300,300,62,400,2000,E,A,A,0,0,0,0,0,A,A,NO,C,0,0,0,0,0,0,274.45,0,0,15.51877,?
738,1198,1172,4942,0,300,806.18,A,A,A,0,0,2,0,0,A,A,NO,A,0,0,0,0,0,307,0,0,8.455346,?
465,1860,1877,1877,69,400,9529.88,A,A,A,3,1,3,0,20,A,D,NO,A,0,0,0,1,0,0,452.3,0,0,9.563036,?
2858,2858,2858,2858,71,601,2106.94,A,A,A,0,0,0,0,0,A,A,NO,A,1,0,2,0,0,1349.46,0,0,9.464475,?
373.5,1785,0,3213.75,0,1701,0,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,441.11,765,0,8.039224,?
290,685,0,580,26,70,24000,E,C,C,6,1,0,1,0,A,A,NO,A,0,0,2,0,0,0,83.2,0,0,19.892533,?
1750,1750,1750,1850,50,0,1299.7,E,A,A,0,1,0,0,0,A,A,NO,A,0,0,0,0,0,0,14.312257,?
2500,2800,2500,4000,102,0,16776.64,E,A,A,0,1,3,0,0,A,A,NO,A,0,1,0,0,0,2112.53,0,0,17.013658,?
2250,2250,2250,2250,148,467,4106.92,B,C,D,0,0,0,0,0,A,A,NO,A,0,1,0,0,0,0,0,9.361755,?
2309,3770,10060,17710,169,0,6488.5,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,33,3525,20.9,5.863068,?
477,557,557,557,44,720,18216.85,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,0,18.427268,?
465.16,1860.84,1878.14,1778.34,69,650,8531.89,E,A,A,0,1,0,0,0,A,A,NO,A,0,2,0,0,0,1210.74,0,0,16.129479,?
1526.25,1526.25,1526.25,2066.55,70,326,316.35,A,A,A,0,0,0,0,0,A,A,NO,A,
0,0,0,0,0,27.03,1015,18.69,13.440395,?
366.71,366.71,366.71,2200.26,43,100,3000,A,A,A,0,0,0,0,0,A,A,NO,A,4,0,5,0,0,0,30.07,0,0,12.351108,?
543.92,543.92,543.92,543.92,46,299,796.81,A,A,A,0,1,5,0,0,A,A,NO,A,0,0,0,0,0,144.05,32,0,12.264428,?
1255,1255,1255,1255,88,100,1089.35,H,C,A,4,2,2,0,0,A,A,NO,A,0,0,0,0,0,0,0,14.609374,?
465.16,1860.64,1878.14,1878.14,69,550,5441.58,A,B,A,5,0,0,2,0,A,B,NO,C,4,1,0,0,0,0,1982.63,0,0,9.404162,?
45.6,136.43,0,295.98,12,0,292.38,B,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,0,0,0,9.448031,?
250,575,0,1515,24,0,1851.22,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,0,0,10.131602,?
465,1860,1877,1877,69,500,8693.57,A,A,A,3,1,5,0,0,B,D,NO,C,1,1,0,0,0,0,647.9,0,0,9.577781,?
0,3310,0,3310,62,0,9713.01,E,C,A,0,10,16,0,50,A,A,NO,A,0,0,0,0,0,0,0,0,16.970516,?
465.21,1860.84,1874.64,1874.84,69,513,1920.73,E,A,A,3,1,0,1,0,A,A,NO,C,0,0,0,0,0,0,1275.6,0,29.4,14.709703,?

```

Gambar 3.3 Estimasi Durasi *Dry Docking* Menggunakan M5P

3.6 Uji Validasi Hasil Estimasi

Untuk mengetahui apakah model yang dihasilkan sudah cukup baik dan representatif atau tidak, maka dilakukanlah uji validasi terhadap *learning* dan *testing data* yang sama dengan menggunakan tahapan yang sama namun dengan metode yang berbeda, yaitu metode k-NN dengan menggunakan algoritma IBk. Yang membedakan antara metode CART dan k-NN adalah jumlah atribut yang digunakan dalam melakukan estimasi. CART melakukan generalisasi terhadap semua atribut yang digunakan pada data, sehingga model linier yang dihasilkan hanya terdiri dari beberapa atribut yang memiliki signifikansi pengaruh yang lebih besar dibanding atribut lainnya. Sedangkan k-NN tidak melakukan generalisasi terhadap atribut yang digunakan, sehingga atribut yang digunakan untuk melakukan estimasi durasi adalah semua atribut pada data.

```

@data
275,315,0,315,46,400,1326.39,E,B,A,0,0,1,0,0,A,A,NO,A,0,1,0,0,0,123.06,0,0,15.333333,?
1395,1860,1877,1877,69,2691,5090.07,E,B,A,6,0,0,7,0,A,A,NO,C,0,0,0,0,0,1768.3,0,0,11.333333,?
730,730,590,730,0,200,128.93,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,200.26,0,0,6.666667,?
430,430,430,430,6,200,206.69,E,A,A,0,4,0,0,0,A,A,NO,A,0,0,0,2,0,0,89.25,0,0.99,15.666667,?
100,220,100,220,20,435,1880.3,E,C,B,0,3,1,0,0,A,A,NO,A,0,1,0,0,0,0,0,16.25,20.333333,?
1013,1926,0,4975,38,0,7409.8,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,2498.88,0,148.83,10.333333,?
465,2875.4,1877,2892.4,69,450,4083.4,B,A,A,0,1,0,0,0,A,A,NO,A,0,0,0,0,0,1000.6,0,0,11.666667,?
800,1200,0,1600,60,150,0,A,A,A,0,0,0,0,0,A,B,NO,C,2,0,4,0,0,0,303,0,0,7.666667,?
254,1265,0,2531,52,361,1019.73,A,A,A,0,6,0,0,0,A,A,NO,A,0,0,0,0,0,0,26,10,12,?
2372,2407,2407,2497,74,450,7000,E,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,893.3,0,0,9,?
300,300,300,300,62,400,948.42,E,A,A,0,0,0,0,0,A,A,NO,C,0,0,0,0,0,0,340.05,100,0,13,?
300,300,300,300,62,400,2000,E,A,A,0,0,0,0,0,A,A,NO,C,0,0,0,0,0,0,274.45,0,0,13,?
738,1198,1172,4942,0,300,806.18,A,A,A,0,0,2,0,0,A,A,NO,A,0,0,0,0,0,307,0,0,10.333333,?
465,1860,1877,1877,69,400,9529.88,A,A,A,3,1,3,0,20,A,D,NO,A,0,0,0,1,0,0,452.3,0,0,10.333333,?
2858,2858,2858,2858,71,601,2106.94,A,A,A,0,0,0,0,0,A,A,NO,A,1,0,2,0,0,1349.46,0,0,7.333333,?
373.5,1785,0,3213.75,0,1701,0,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,441.11,765,0,12.333333,?
290,685,0,580,26,70,24000,E,C,C,6,1,0,1,0,A,A,NO,A,0,0,2,0,0,0,83.2,0,0,19.666667,?
1750,1750,1750,1850,50,0,1299.7,E,A,A,0,1,0,0,0,A,A,NO,A,0,0,0,0,0,0,0,0,9,?
2500,2800,2500,4000,102,0,16776.64,E,A,A,0,1,3,0,0,A,A,NO,A,0,1,0,0,0,2112.53,0,0,9.333333,?
2250,2250,2250,2250,148,467,4106.92,B,C,D,0,0,0,0,0,A,A,NO,A,0,1,0,0,0,0,0,15.333333,?
2309,3770,10060,17710,169,0,6488.5,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,33,3525,20.9,8.333333,?
477,557,557,557,44,720,18216.85,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,0,0,0,24,?
465.16,1860.84,1878.14,1778.34,69,650,8531.89,E,A,A,0,1,0,0,0,A,A,NO,A,0,2,0,0,0,1210.74,0,0,9,?
1526.25,1526.25,1526.25,2066.55,70,326,316.35,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,27.03,1015,18.69,7,?
366.71,366.71,366.71,2200.26,43,100,3000,A,A,A,0,0,0,0,0,A,A,NO,A,4,0,5,0,0,30.07,0,0,15,?
543.92,543.92,543.92,46,299,796.81,A,A,A,0,1,5,0,0,A,A,NO,A,0,0,0,0,0,144.05,32,0,10.333333,?
1255,1255,1255,1255,88,100,1089.35,H,C,A,4,2,2,0,0,A,A,NO,A,0,0,0,0,0,0,0,0,10,?
465.16,1860.64,1878.14,1878.14,69,550,5441.58,A,B,A,5,0,0,2,0,A,B,NO,C,4,1,0,0,0,1982.63,0,0,13,?
45.6,136.43,0,295.98,12,0,292.38,B,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,0,0,0,10.666667,?
250,575,0,1515,24,0,1851.22,A,A,A,0,0,0,0,0,A,A,NO,A,0,0,0,0,0,0,0,0,7,?
465,1860,1877,1877,69,500,8693.57,A,A,A,3,1,5,0,0,B,D,NO,C,1,1,0,0,0,647.9,0,0,7.666667,?
0,3310,0,3310,62,0,9713.01,E,C,A,0,10,16,0,50,A,A,NO,A,0,0,0,0,0,0,0,0,18.333333,?
465.21,1860.84,1874.64,1874.84,69,513,1920.73,E,A,A,3,1,0,1,0,A,A,NO,C,0,0,0,0,0,1275.6,0,29.4,20,?

```

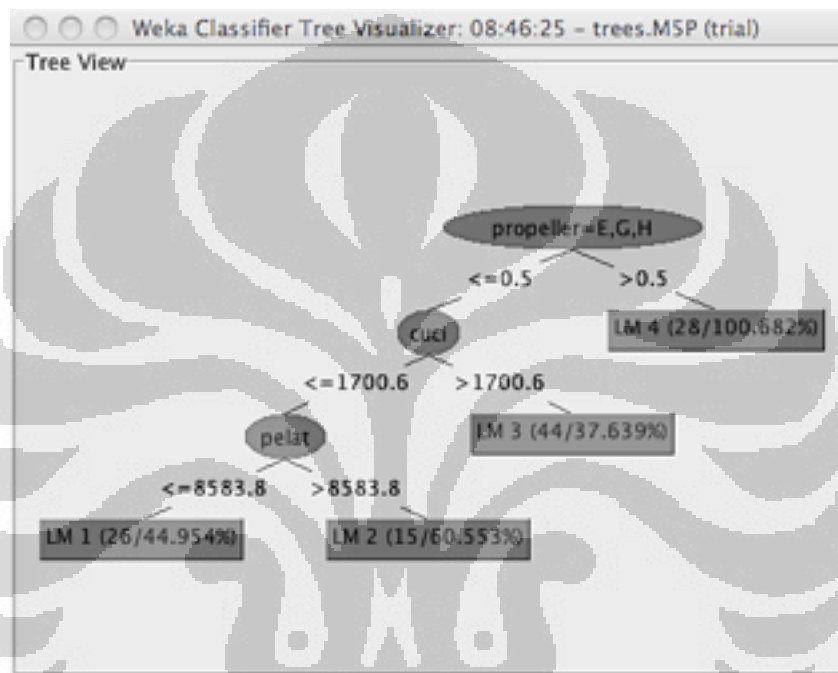
Gambar 3.4 Estimasi Durasi *Dry Docking* Menggunakan IBk

BAB 4

ANALISIS

4.1 Analisis Pohon Klasifikasi CART

Sub bab ini menjabarkan analisis akar, cabang, dan daun pohon klasifikasi CART yang didapat dari pengolahan data. Pohon klasifikasi CART dapat dilihat pada Gambar 4.1.



Gambar 4.1 Hasil Pohon Klasifikasi Durasi *Dry Docking*

Berdasarkan pohon klasifikasi Gambar 4.1, dapat dilihat bahwa durasi *dry docking* terklasifikasi berdasarkan 3 atribut, yaitu propeller, cuci, dan pelat. Klasifikasi pertama adalah berdasarkan pekerjaan propeller. Jika pada data terdapat salah satu pekerjaan propeller E/G/H, maka model linier yang digunakan untuk mengestimasi durasi *dry docking* adalah LM 4 dan jika pada data tersebut tidak terdapat salah satu pekerjaan propeller E/G/H, maka data tersebut akan diklasifikasi lagi berdasarkan luas permukaan yang dicuci. Jika luas permukaan yang dicuci lebih dari 1700,6 m², maka model linier yang digunakan untuk mengestimasi durasi *dry docking* adalah LM 3 dan jika kurang dari sama dengan 1700,6 m², maka data tersebut akan diklasifikasi lagi berdasarkan berat pelat yang diganti. Jika berat pelat yang diganti kurang dari sama dengan 8583,8 ton, maka

model linier yang digunakan untuk menghitung durasi *dry docking* adalah LM 1 dan LM 2 jika berat pelat yang diganti lebih dari 8583,8 ton. Untuk mengetahui rumus durasi *dry docking* tiap model linier, dapat dilihat pada Gambar 4.2.

```

=== Classifier model (full training set) ===

M5 pruned model tree:
(using smoothed linear models)

propeller=E,G,H <= 0.5 :
|  cuci <= 1700.6 :
|  |  pelat <= 8583.8 : LM1 (26/44.954%)
|  |  pelat > 8583.8 : LM2 (15/60.553%)
|  cuci > 1700.6 : LM3 (44/37.639%)
propeller=E,G,H > 0.5 : LM4 (28/100.682%)

LM num: 1
durasi =
-0.001 * scraping
-0.0007 * sandblasting
+0.001 * cuci
+0.082 * zinc
+0.0007 * ut
+0.0002 * pelat
+0.7393 * propeller=E,G,H
+8.5688

LM num: 2
durasi =
-0.0036 * scraping
-0.0004 * sandblasting
-0.0006 * cuci
+0.0499 * zinc
+0.0007 * ut
+0.0002 * pelat
+0.7393 * propeller=E,G,H
+14.6214

LM num: 3
durasi =
0.0008 * sandblasting
-0.0006 * cuci
+0.0007 * ut
+0.0001 * pelat
+0.7393 * propeller=E,G,H
+8.2669

LM num: 4
durasi =
-0.0006 * cuci
+0.0007 * ut
+0.0002 * pelat
+1.7194 * propeller=E,G,H
+13.2962

Number of Rules : 4

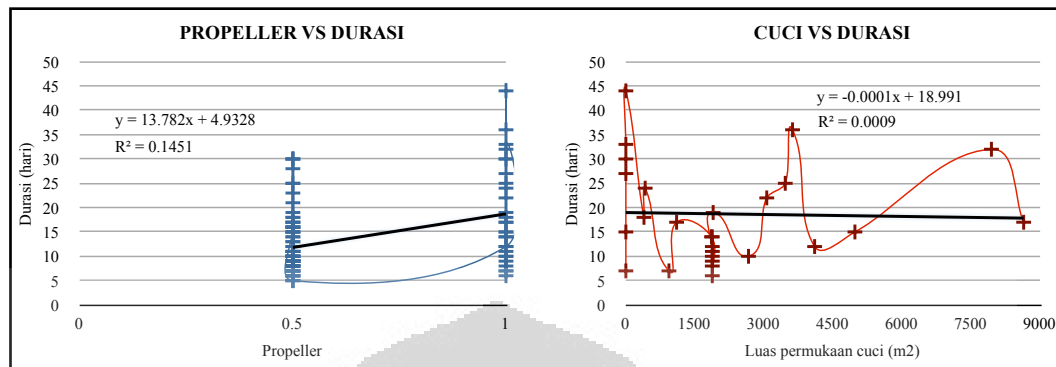
```

Gambar 4.2 Hasil Model Linier *Dry Docking*

Pada Gambar 4.2 terlihat bahwa terdapat 4 model linier berbeda yang digunakan untuk menghitung durasi *dry docking*. Dari total 113 data, 26 data diantaranya menggunakan LM 1, 15 data menggunakan LM 2, 44 data menggunakan LM 3, dan 28 data menggunakan LM 4. Berdasarkan jumlah data yang digunakan, maka LM 3 adalah rumusan *dry docking* yang cukup sering digunakan untuk mengestimasi durasi *dry docking* pada *learning data*.

Seperti yang telah dipaparkan sebelumnya bahwa 4 model linier yang dihasilkan pada pengolahan *learning data* memiliki atribut dan koefisien korelasi yang berbeda. Dimulai dengan LM 4 yang terdiri dari 4 atribut, yaitu cuci, ut, pelat, dan propeller=E,G,H. 3 dari atribut yang tertera pada LM 4 memiliki korelasi positif dengan durasi *dry docking*, yang berarti semakin besar volume pekerjaan atribut, maka semakin lama durasi *dry docking* yang dihasilkan. Sedangkan 1 atribut lainnya, yaitu cuci, memiliki korelasi negatif dengan durasi *dry docking*. Namun, bukan berarti semakin besar volume pekerjaan cuci, maka semakin singkat durasi pekerjaan cuci yang dihasilkan. Hal ini lebih dikarenakan penambahan volume pekerjaan cuci tidak terlalu memberikan pengaruh yang signifikan terhadap penambahan durasi *dry docking*. Pada Gambar 4.3 **CUCI VS DURASI** terlihat bahwa pada luas permukaan yang rendah pun, durasi *dry docking* yang dihasilkan sudah cukup besar sehingga menjadikan penambahan volume pekerjaan cuci tidak terlalu mempengaruhi durasi *dry docking*. Dikarenakan penambahan volume pekerjaan cuci tidak terlalu mempengaruhi durasi *dry docking* dan adanya pekerjaan propeller E/G/H pada LM 4, maka durasi *dry docking* yang dialokasikan untuk pekerjaan cuci dibuat menjadi semakin singkat, yang artinya harus semakin cepat diselesaikan karena pekerjaan propeller E/G/H dianggap membutuhkan waktu yang lebih banyak untuk diselesaikan. Pada Gambar 4.3 **PROPELLER VS DURASI** terlihat bahwa pengaruh pekerjaan propeller E/G/H terhadap durasi *dry docking* cukup besar yang jika dirata-ratakan akan menghasilkan perbedaan 7 hari antara *dry docking* yang memiliki pekerjaan propeller E/G/H di dalamnya dengan *dry docking* tanpa

pekerjaan propeller E/G/H di dalamnya. Oleh karena itu, atribut cuci memiliki koefisien korelasi negatif.

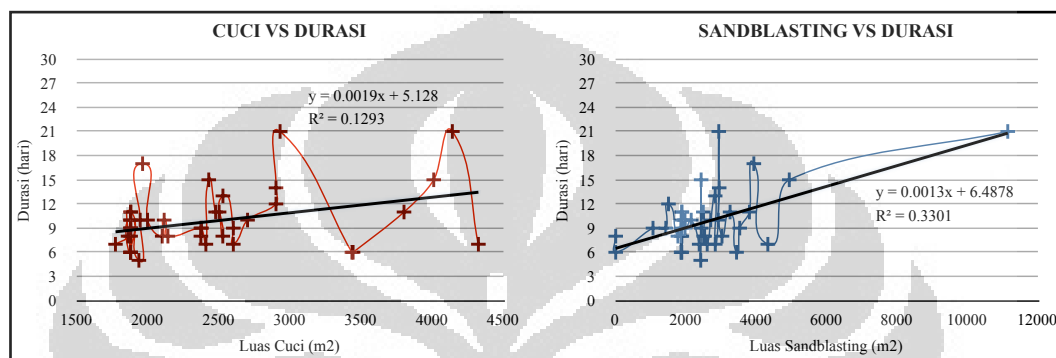


*Grafik biru: korelasi positif; Grafik merah: korelasi negatif

Gambar 4.3 Grafik LM 4

LM 3 adalah model linier yang digunakan untuk menghitung durasi *dry docking* dengan kriteria: tidak memiliki pekerjaan propeller E/G/H dan memiliki pekerjaan cuci dengan luas permukaan diatas 1700,6 m². LM 3 terdiri dari 5 atribut yang signifikan terhadap durasi *dry docking*, yaitu sandblasting, cuci, ut, pelat, dan propeller=E,G,H. 4 atribut diantaranya memiliki korelasi positif dengan durasi *dry docking* dan hanya 1 atribut, yaitu cuci, yang memiliki korelasi negatif. Tidak seperti halnya LM 4 yang mempersingkat durasi pekerjaan cuci karena terdapat pekerjaan propeller E/G/H, pada LM 3 terjadi penambahan atribut sandblasting dengan tingkat signifikansi pengaruh yang lebih besar dibandingkan atribut cuci. Oleh karena itu, durasi *dry docking* yang dialokasikan untuk pekerjaan cuci menjadi semakin singkat, yang artinya harus semakin cepat diselesaikan. Walaupun pada umumnya volume pekerjaan cuci memiliki nilai yang sama dengan volume pekerjaan sandblasting, namun media yang digunakan untuk kedua pekerjaan sangat berbeda, yaitu air dan pasir. Hal inilah yang menjadikan pekerjaan sandblasting lebih sulit dilakukan karena berhubungan dengan persediaan pasir yang digunakan dan akan semakin sulit seiring dengan bertambahnya luas permukaan sandblasting ataupun cuci. Oleh karena itu, untuk luas permukaan cuci di atas 1700,6 m², penyelesaian pekerjaan sandblasting dianggap membutuhkan alokasi waktu yang cukup banyak. Pada Gambar 4.4 terlihat bahwa durasi *dry docking* yang dihasilkan seiring dengan peningkatan

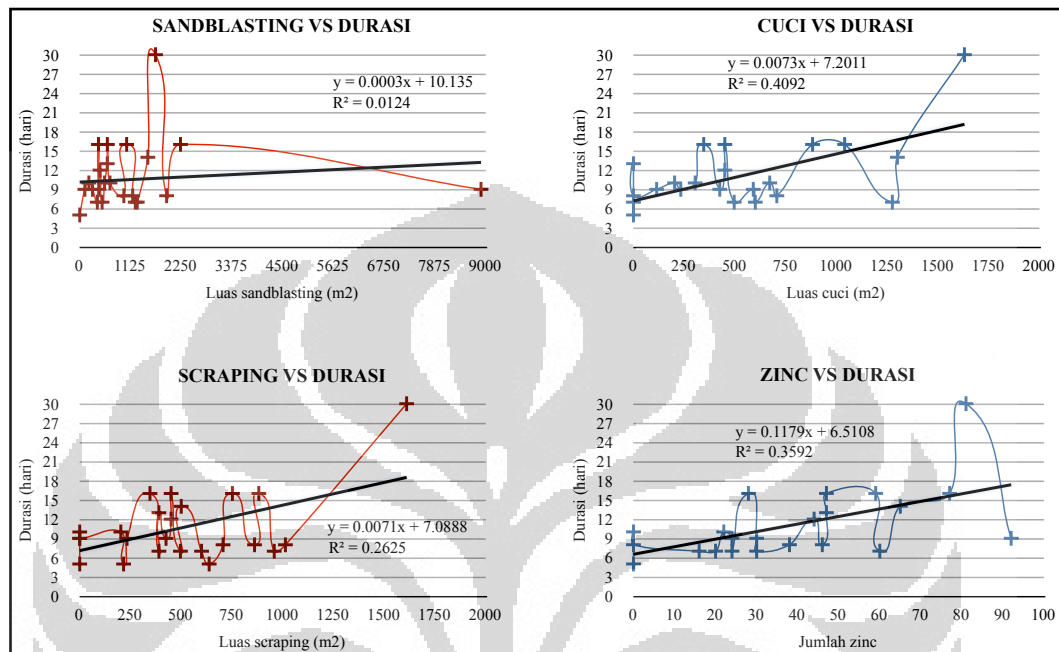
volume pekerjaan cuci cenderung lebih *stagnan* dibandingkan dengan pekerjaan sandblasting yang cenderung meningkat, hal tersebut menandakan bahwa penambahan volume pekerjaan sandblasting lebih mempengaruhi durasi *dry docking*. Dengan durasi *dry docking* yang cenderung lebih *stagnan*, menjadikan alokasi durasi *dry docking* untuk pekerjaan cuci dipersingkat dan dialihkan pada pekerjaan sandblasting yang membutuhkan lebih banyak waktu untuk diselesaikan.



Gambar 4.4 Grafik LM 3

LM 1 merupakan model linier yang digunakan untuk menghitung durasi *dry docking* dengan kriteria pekerjaan: tidak ada pekerjaan propeller E/G/H, pekerjaan cuci dengan luas kurang dari sama dengan 1700,6 m², dan melakukan pekerjaan *replating* dengan berat pelat kurang dari sama dengan 8583,8 ton. LM1 terdiri dari 7 atribut, yaitu scraping, sandblasting, cuci, zinc, ut, pelat, dan propeller=E,G,H. Dari 7 atribut, scraping dan sandblasting merupakan atribut yang memiliki korelasi negatif terhadap durasi *dry docking*. Serupa dengan LM 3, dikarenakan pada LM 2 terjadi penambahan atribut scraping, sandblasting, dan zinc menjadikan adanya pengurangan alokasi waktu untuk beberapa pekerjaan, yang dalam hal ini adalah pekerjaan scraping dan sandblasting. Pada Gambar 4.5 terlihat bahwa durasi *dry docking* yang dihasilkan seiring dengan peningkatan volume pekerjaan sandblasting dan scraping cenderung lebih *stagnan* dibandingkan dengan pekerjaan cuci dan zinc yang lebih menunjukkan peningkatan. Seperti yang telah dipaparkan sebelumnya bahwa atribut yang cenderung memberikan hasil durasi *dry docking* yang lebih *stagnan* memiliki pengaruh yang sangat kecil. Oleh karena itu, alokasi durasi *dry docking* untuk

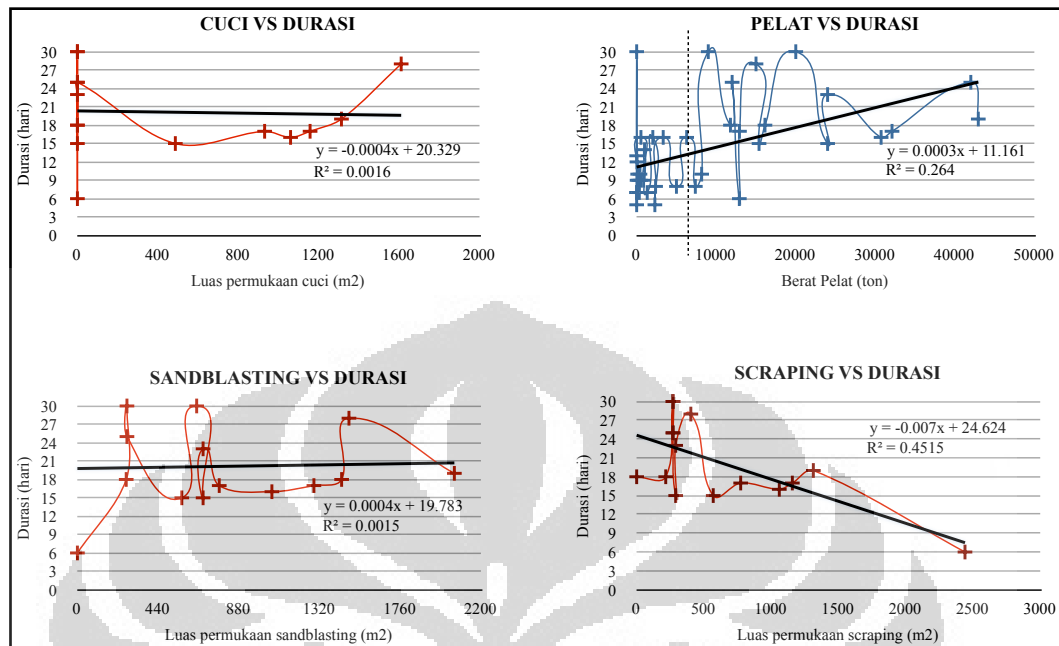
pekerjaan sandblasting serta scraping dipersingkat dan dialihkan kepada pekerjaan yang memiliki pengaruh lebih besar, yang dalam model linier ini berupa pekerjaan cuci dan zinc. Oleh karena itu, atribut sandblasting dan scraping memiliki koefisien korelasi negatif.



Gambar 4.5 Grafik LM 1

Sedangkan LM 2 adalah model linier yang digunakan untuk menghitung durasi *dry docking* dengan kriteria pekerjaan sebagai berikut: tidak ada pekerjaan propeller E/G/H, pekerjaan cuci dengan luas kurang dari sama dengan 1700,6 m², dan melakukan pekerjaan *replating* dengan berat pelat diatas 8583,8 ton. LM 2 terdiri dari 7 atribut yang signifikan terhadap durasi *dry docking*, yaitu scraping, sandblasting, cuci, zinc, ut, pelat, dan propeller=E,G,H. Dari 7 atribut, terdapat 3 atribut yang memiliki korelasi negatif, yaitu scraping, sandblasting, dan cuci. Dikarenakan berat pelat yang diganti memiliki nilai lebih dari 8583,8 ton, maka dibutuhkan pengurangan alokasi durasi *dry docking* yang cukup besar terutama pada pekerjaan yang dapat dipersingkat dan memiliki tingkat signifikansi yang rendah. Seperti yang terlihat pada Gambar 4.6, scraping, sandblasting, dan cuci adalah ketiga atribut tersebut. Oleh karena itu, atribut scraping, sandblasting, dan cuci memiliki koefisien korelasi yang negatif, yang artinya alokasi durasi *dry docking* untuk ketiga pekerjaan tersebut harus dipersingkat dan dialihkan pada

pekerjaan *replating* yang pada Gambar 4.6 terlihat sangat mempengaruhi durasi *dry docking*.



Gambar 4.6 Grafik LM 2

Tabel 4.1 adalah hasil estimasi durasi *dry docking* pada *testing data* dengan berdasarkan pohon klasifikasi CART dan model linier yang sebelumnya telah dihasilkan pada *learning data*.

Tabel 4.1 Hasil Estimasi Menggunakan M5P

ID	Aktual	M5P	ID	Aktual	M5P
11ARJ	18	16	11PAN	7	20
11AWU	13	17	11RE	8	14
11BAR	17	8	11RS	16	17
11BIM	16	15	11SN	10	9
11BKM	26	16	11SJ	21	6
11CP	10	10	11TON	18	18
11SIR	8	10	11TAT	11	16
11TRI	7	12	11TW	10	13
11DK	8	12	11CUC	15	12
11GD	7	15	11KAL(1)	15	12
11JAY	25	15	11MN	26	15
11JAY4	25	16	12BR	11	9
11KAL	10	8	12CTP	5	9
11KEL	10	10	12CP	10	10
11LHO	15	9	12KEL	13	10
11MEL	18	8	12SC	18	17

Dapat dilihat pada Tabel 4.1 bahwa dari 33 *testing data*, hanya terdapat 4 data aktual yang sesuai dengan estimasi.

4.2 Analisis Performance Measurement

Dalam melakukan prediksi numerik terdapat beberapa alternatif ukuran yang biasa digunakan untuk mengevaluasi keberhasilan, 5 diantaranya adalah *Root Mean-Squared Error (RMSE)*, *Mean Absolute Error (MAE)*, *Root Relative Squared Error (RRSE)*, *Relative Absolute Error (RAE)*, dan *Correlation Coefficient (CC)*. Tabel 4.2 memaparkan rumusan dari tiap-tiap ukuran yang digunakan dalam *performance measurement*.

Tabel 4.2 *Performance Measurement* dalam Prediksi Numerik

Performance measure	Formula
mean-squared error	$\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n}$
root mean-squared error	$\sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n}}$
mean absolute error	$\frac{ p_1 - a_1 + \dots + p_n - a_n }{n}$
relative squared error	$\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{(a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2}$, where $\bar{a} = \frac{1}{n} \sum_i a_i$
root relative squared error	$\sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{(a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2}}$
relative absolute error	$\frac{ p_1 - a_1 + \dots + p_n - a_n }{ a_1 - \bar{a} + \dots + a_n - \bar{a} }$
correlation coefficient	$\frac{S_{PA}}{\sqrt{S_P S_A}}$, where $S_{PA} = \frac{\sum_i (p_i - \bar{p})(a_i - \bar{a})}{n-1}$, $S_P = \frac{\sum_i (p_i - \bar{p})^2}{n-1}$, and $S_A = \frac{\sum_i (a_i - \bar{a})^2}{n-1}$

*p adalah nilai prediksi dan a adalah nilai aktual

(Sumber: Witten dan Frank, 2005)

Dari Tabel 4.2 dapat diketahui bahwa semakin rendah nilai RMSE, MAE, RRSE, RAE, maka semakin baik nilai estimasi yang dihasilkan dan semakin tinggi nilai CC, maka semakin baik pula nilai estimasi yang dihasilkan.

Setelah melakukan pengolahan data dengan menggunakan M5P pada *learning data*, maka didapatkanlah hasil *performance measurement* seperti yang tertera pada Gambar 4.7.

=== Cross-validation ===	
=== Summary ===	
Correlation coefficient	0.5804
Mean absolute error	4.799
Root mean squared error	6.3664
Relative absolute error	78.16 %
Root relative squared error	80.8075 %
Total Number of Instances	113

Gambar 4.7 *Performance Measurement* M5P

Terlihat pada Gambar 4.7 bahwa nilai CC yang didapatkan dari hasil pengolahan *learning data* dengan menggunakan M5P adalah sebesar 0,5804. Dengan skala antara 0 hingga 1, nilai 0,5804 sudah menyatakan korelasi positif yang cukup kuat antara nilai prediksi dan aktual walaupun tidak terlalu kuat karena nilai tersebut telah melebihi nilai tengahnya, yaitu 0,5.


Namun, nilai yang cukup tinggi juga didapatkan pada nilai RMSE, MAE, RRSE, dan RAE. Hal ini menunjukkan bahwa tingkat kesalahan atau *error* yang dihasilkan dari model matematis dan pohon klasifikasi juga cukup tinggi yang diyakini diakibatkan oleh tingginya tingkat variasi data. Cuaca, penyediaan material, dan jumlah pekerja adalah faktor-faktor yang menyebabkan tingginya variasi pada data.

Permasalahan pertama adalah cuaca, dikarenakan *graving dock* yang dimiliki PT Daya Radar Utama adalah *graving dock* tanpa atap, maka cuaca sangat berpengaruh terhadap durasi *dry docking*, terutama untuk pekerjaan-pekerjaan yang membutuhkan kondisi kering. Seperti yang diketahui, cuaca adalah faktor alam yang sulit untuk diprediksi, oleh karena itu jika cuaca saat *dry docking* jelek, maka durasi *dry docking* akan mundur beberapa hari (jika pekerjaan tersebut tidak dapat diselesaikan hanya dengan *overtime*). Permasalahan kedua adalah penyediaan material. Sering sekali ditemukan kasus dimana pihak *owner* cenderung ingin membeli sendiri material yang akan digunakan untuk bagian-bagian kapal yang akan diganti karena faktor harga. Kecenderungan pihak *owner* untuk membeli sendiri tanpa memperhatikan faktor waktu sering sekali menjadi hambatan bagi pihak galangan untuk menyelesaikan pekerjaannya. Selain itu, faktor ketidakterersediaan material memungkinkan adanya waktu menganggur selama durasi *dry docking* aktual yang terdapat pada data. Permasalahan terakhir adalah ketersediaan jumlah pekerja. Jika jumlah pekerja tidak berbanding lurus dengan banyaknya pekerjaan ataupun volume pekerjaan, maka durasi *dry docking* menjadi semakin lama dan semakin sulit untuk diprediksi karena berhubungan dengan faktor *human behavior*.

4.3 Analisis Uji Validasi Hasil

Sub bab ini memaparkan analisis mengenai hasil uji validasi terhadap model M5P - CART yang telah dihasilkan dengan menggunakan IBk yang berlandaskan pada prinsip k-NN. Seperti yang telah dipaparkan sebelumnya, perbedaan antara CART dan IBk terletak pada jumlah atribut yang digunakan dalam melakukan estimasi. Jika CART melakukan generalisasi terhadap semua atribut dan hanya menggunakan beberapa atribut yang signifikan untuk melakukan estimasi, k-NN menggunakan semua atribut pada data dalam melakukan estimasi. Untuk mengetahui apakah model yang menggunakan beberapa atribut sudah cukup baik, maka dilakukanlah validasi terhadap model tersebut dengan menggunakan semua atribut. Pada sub bab sebelumnya terlihat bahwa tingkat kesalahan atau *error* yang dihasilkan model CART cukup tinggi, dengan *root relative squared error (RRSE)* mencapai 80,8075%. Dengan melakukan uji validasi, maka dapat diketahui penyebab dari tingginya nilai RRSE tersebut, apakah disebabkan karena kurang bagusnya model yang dihasilkan atau data yang terlalu variatif.

Terlihat pada Gambar 4.8, hasil estimasi dengan menggunakan M5P (CART) cukup berbeda dengan IBk (k-NN). Namun, *trend* yang dihasilkan keduanya memiliki kemiripan dan baik M5P maupun IBk, keduanya jarang sekali terlihat berhimpitan dengan nilai aktual. Untuk lebih jelas mengenai angka yang dihasilkan, dapat dilihat pada Tabel 4.3.



Gambar 4.8 Grafik Perbandingan Durasi *Dry Docking*

Tabel 4.3 Tabel Perbandingan Aktual - Estimasi

ID	Aktual	M5P	IBk (k=3)
11ARJ	18	16	15
11AWU	13	17	11
11BAR	17	8	7
11BIM	16	15	16
11BKM	26	16	20
11CP	10	10	10
11SIR	8	10	12
11TRI	7	12	8
11DK	8	12	12
11GD	7	15	9
11JAY	25	15	13
11JAY4	25	16	13
11KAL	10	8	10
11KEL	10	10	10
11LHO	15	9	7
11MEL	18	8	12
11PAN	7	20	20
11RE	8	14	9
11RS	16	17	9
11SN	10	9	15
11SJ	21	6	8
11TON	18	18	24
11TAT	11	16	9
11TW	10	13	7
11CUC	15	12	15
11KAL(1)	15	12	10
11MN	26	15	10
12BR	11	9	13
12CTP	5	9	11
12CP	10	10	7
12KEL	13	10	8
12SC	18	17	18
12TIL	10	15	20

Terlihat pada Tabel 4.3, dari 33 *testing data* hanya terdapat 4 titik dimana nilai estimasi M5P berhimpitan dengan nilai estimasi IBk dan hanya 8 titik dimana nilai estimasi M5P dan IBk berhimpitan dengan nilai aktual.

```

=== Cross-validation ===
=== Summary ===

Correlation coefficient          0.5804
Mean absolute error             4.799
Root mean squared error        6.3664
Relative absolute error        78.16 %
Root relative squared error    80.8075 %
Total Number of Instances      113

```

Gambar 4.9 Performance Measurement M5P

```

=== Cross-validation ===
=== Summary ===

Correlation coefficient          0.4639
Mean absolute error             5.3009
Root mean squared error        7.2589
Relative absolute error        86.334 %
Root relative squared error    92.1362 %
Total Number of Instances      113

```

Gambar 4.10 Performance Measurement IBk

Dapat terlihat pada Gambar 4.9 dan 4.10 bahwa *correlation coefficient* yang dihasilkan M5P lebih tinggi dibandingkan dengan IBk, hal tersebut menyatakan bahwa model yang dihasilkan sudah memiliki korelasi positif yang cukup kuat antara nilai estimasi dan nilai aktualnya. Sedangkan untuk *mean absolute error*, *root mean squared error*, *relative absolute error*, dan *root relative squared error*, terlihat bahwa kedua model menghasilkan nilai yang cukup tinggi. Hal tersebut menjelaskan bahwa nilai *error* yang tinggi bukan disebabkan oleh model yang dihasilkan M5P jelek, tetapi lebih dikarenakan data yang digunakan untuk membuat model terlalu variatif, sehingga menyebabkan tingkat kesalahan yang cukup besar. Akan tetapi nilai *mean absolute error*, *root mean squared error*, *relative absolute error*, dan *root relative squared error* yang dihasilkan M5P cenderung lebih rendah dibanding IBk. Jadi, walaupun keduanya memiliki nilai *error* yang cukup besar, dikarenakan nilai *error* yang dihasilkan M5P cenderung lebih rendah dari IBk, maka model M5P yang hanya menggunakan beberapa atribut dapat dikatakan lebih baik dibandingkan model IBk yang menggunakan semua atribut. Dari hasil validasi ini dapat diketahui bahwa penggunaan keseluruhan atribut dapat memberikan pengaruh besar terhadap nilai *error* yang dihasilkan karena data yang digunakan pada penelitian ini sangat variatif.

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Pemeliharaan merupakan salah satu kegiatan yang sangat penting dalam industri perkapalan karena dapat menentukan kelaikan kapal. Namun, kegiatan ini tidak didukung dengan fasilitas yang memadai karena jika dibandingkan dengan jumlah transportasi laut nasional yang kian meningkat, kapasitas yang dimiliki galangan nasional untuk kegiatan pemeliharaan masih sangat minim. Hal inilah yang menjadikan estimasi durasi pemeliharaan kapal sebagai suatu hal yang sangat penting. Adapun data yang dibutuhkan dalam melakukan estimasi durasi pemeliharaan, yaitu volume pekerjaan pemeliharaan yang bisa didapatkan pada *satisfaction note*.

Satisfaction note adalah daftar pekerjaan pemeliharaan kapal yang mengandung informasi mengenai pekerjaan yang telah dilakukan. Estimasi durasi pemeliharaan yang dilakukan dengan memperhitungkan volume pekerjaan dapat diakomodir dengan metode *data mining*. *Data mining* adalah metode analisis data dalam jumlah besar untuk mengetahui hubungan yang tidak terduga sebelumnya. Metode ini mengolah data volume pekerjaan pemeliharaan menjadi durasi pemeliharaan dengan model linier yang dihasilkan pohon klasifikasi CART (*Classification and Regression Tree*).

CART adalah salah satu metode dalam *data mining* yang digunakan tidak hanya untuk mengklasifikasi tetapi juga untuk meregresi sejumlah atribut yang dianggap memiliki pengaruh terhadap hasil yang ingin dicapai. Atribut yang digunakan pada penelitian ini adalah jenis pekerjaan pemeliharaan yang dibatasi pada pekerjaan di atas dok saja atau yang lebih dikenal dengan istilah *dry docking* karena pada umumnya setiap galangan memiliki kapasitas dok yang terbatas. Dengan metode CART, 29 atribut yang dianggap memiliki pengaruh cukup besar terhadap durasi *dry docking* diklasifikasi dan diregresi membentuk suatu model linier yang digunakan untuk menghitung durasi pemeliharaan *dry docking*.

Berdasarkan hasil yang didapatkan, diketahui bahwa terdapat 3 jenis pekerjaan pemeliharaan *dry docking* yang dijadikan sebagai dasar dalam mengklasifikasi durasi *dry docking*, yaitu pekerjaan propeller, cuci, serta *replating* dan berdasarkan klasifikasi ketiga jenis pekerjaan tersebut, didapatkanlah 4 kelas durasi *dry docking* dengan kriteria pekerjaan dan model linier yang berbeda-beda. Namun, model yang dihasilkan dengan menggunakan metode CART memiliki nilai *error* yang cukup tinggi (MAE = 4,799; RMSE = 6,3364; RAE = 78,16%; RRSE = 80,8075%). Oleh karena itu, dilakukanlah validasi model dengan metode lain, yaitu k-NN yang menggunakan semua atribut ke dalam perhitungan durasi *dry docking*. Sama halnya seperti CART, metode k-NN juga menghasilkan nilai *error* yang cukup tinggi dengan MAE = 5,3009; RMSE = 7,2589; RAE = 86,334%; RRSE = 92,1362%. Dengan tingginya nilai *error* yang dihasilkan oleh kedua metode, hal ini menunjukkan bahwa kesalahan bukan terdapat pada model yang dihasilkan tetapi pada data yang digunakan yang cenderung sangat variatif, sehingga dapat disimpulkan bahwa model yang digunakan untuk melakukan estimasi durasi *dry docking* sudah cukup baik karena memiliki nilai *error* yang lebih rendah dibandingkan metode lain, yaitu k-NN.

5.2 Saran

Penelitian yang dilakukan masih jauh dari sempurna, masih terdapat banyak hal yang dapat dikembangkan dan diperbaiki lebih lanjut. Berikut adalah saran-saran yang diharapkan dapat memperbaiki dan mengembangkan penelitian ini.

1. Dikarenakan tidak dilakukannya pengelompokkan pekerjaan pemeliharaan (*dry docking* dan *floating*) pada beberapa *satisfaction note*, penelitian ini dapat dilanjutkan dengan melakukan estimasi durasi pemeliharaan kapal secara keseluruhan, tidak sebatas pada pekerjaan *dry docking* saja, sehingga estimasi yang dihasilkan nantinya dapat lebih akurat.

2. Penelitian ini dapat dilanjutkan dengan melakukan simulasi terhadap *lead time* material dan jumlah pekerja, mengingat kedua faktor tersebut yang menyebabkan tingginya variasi pada data durasi *dry docking* aktual.
3. Penelitian ini dapat dilanjutkan dengan optimasi. Durasi *dry docking* kapal dapat dibenturkan dengan kendala-kendala yang dimiliki galangan sehingga nantinya dapat menghasilkan estimasi durasi *dry docking* yang optimal.



DAFTAR REFERENSI

- Cunningham, P. and Delany, S. (2007). *K-Nearest Neighbor Classifiers*, Technical Report UCD-CSI-2007-4.
- Hand, D., Mannila, H., & Smyth, P. (2001). *Principles of Data Mining*. Cambridge, MA: MIT Press.
- Hendriyadi. (2010). *Laporan Kerja Praktek (Shipyard & Engineering)*. Surabaya: Institut Teknik Surabaya (ITS).
- Larose, Daniel T. (2005). *Discovering Knowledge in Data: An Introduction to Data Mining*. New Jersey: John Wiley & Sons, Inc.
- Lewis, Roger J. (2000). *An Introduction to classification and Regression Tree (CART) Analysis*, Annual Meeting for Academic Emergency Medicine in San Fransisco.
- Lin, Shih-Yen, Wei, Jo-Ting, Weng, Chih-Chien, and Wu, Hsin-Hung. (2011). *A Case Study of Using Classification and Regression Tree and LRFM Model in Pediatric Dental Clinic*. International Conference on Innovation, Management and Service. IPEDR vol.14. Singapore: IACSIT Press.
- Ma'arif, Syamsul. (2011). *Laporan Praktek Kerja PT. Dock dan Perkapalan Kodja Bahari (persero) Galangan II - Jakarta*. Semarang: Universitas Diponegoro (Undip).
- Srdoc, A., Bratko, I., Sluga, A. (2007). *Machine Learning Applied to Quality Management - A Study in Ship Repair Domain*, *Computers in Industry* 58, 464-473.
- Witten, I.H., and Frank, E. (2005). *Data Mining: Practical Machine Learning Tools and Techniques - 2nd Edition*. San Fransisco: Elsevier.

LAMPIRAN

Lampiran 1. Learning Data

id	scraping	sandblasting	cuci	cat	zinc	ut	plat	propeller	bantalan prop	poros prop	sealprop	ringprop	packing prop	chrome
05AWU	1860.84	1860.84	1878	1878	69	1268	11591	E	B	C	8	0	0	2
06BSIP	999.92	2427.26	2427	5270.4	34	0	72289	A	A	A	0	0	0	0
06ABU	0	0	0	0	0	0	2287	F	A	B	3	44	2	1
06ANO	496	496	496	496	20	340	331.8	A	A	A	0	0	0	0
06GB	390	390	0	2300	24	0	0	A	A	A	0	0	0	0
06CA	706	1174.61	706	1175	46	176	5000	A	A	A	0	0	0	0
06LHO	1540	3524	2600	9340	88	600	7145	A	A	A	0	2	0	2
06CM	1443.9	2913.8	2114	7248	44	270	19286	A	A	A	0	0	0	0
06GD	2407	1423.6	2372	2442	82	600	15067	A	A	A	0	0	0	0
06JM	4580	5300	7940	21720	442	4555	1E+05	E	A	A	10	4	6	2
06KAL	3220	3620	3620	3620	126	1902	77695	H	A	A	2	0	0	2
06LEM	539.05	539.05	935.6	539.1	38	150	19.82	E	A	A	3	0	0	0
06LAW	1990.19	1059.77	1878	1878	48	395	52305	B	C	A	5	0	0	0
06MAE	1292	4931.6	4009	13827	0	1887	7433	A	A	C	6	7	3	5
06PIO	202.5	202.5	202.5	930	22	100	128.1	B	C	E	4	2	2	0
06GS	390	390	0	2300	16	0	0	A	A	A	0	0	0	0
06SIR	1860.84	1860.84	1878	1878	69	550	0	A	B	C	0	0	0	0
07BAL	2440	0	0	0	78	433	12903	A	A	A	0	0	0	0
07BIN	3321.15	1860.84	1878	1878	69	600	7228	A	A	A	0	22	2	2
07BOK	773	773	931	931	50	0	12920	A	A	A	0	0	0	0
07BSP	1830	2490	2476	2490	76	600	3685	A	A	B	0	0	0	0
07CA	0	550	304	1404	0	0	8168	A	A	A	0	0	0	0
07JAT	0	3434	3434	3434	75	400	932.3	A	A	A	0	0	0	0
07KAR	2900	1500	2900	10100	251	0	28137	A	A	A	0	0	0	0
07KEL	2996.3	1877	1877	1778	69	450	11851	E	A	A	0	1	0	0
07KIR3	500	1510	1300	5200	65	300	990.1	C	C	B	2	0	0	0
07KIR	1936	2431.2	2376	9230	112	417	2080	B	C	A	1	12	0	0
07KLA	2900	3000	4100	22800	73	1524	6406	E	A	A	5	0	0	2
07MAL	0	114.2	114.2	339.4	24	0	52.56	C	C	A	0	8	0	0
07MUF	1962	3925	1962	9564	43	424	528	A	B	B	0	0	0	0
07MUS	1771.2	2829.1	1771	8487	82	400	1114	A	A	A	0	0	0	0
07PAL	2100	3020	2100	2600	45	1785	4090	A	A	A	0	0	0	0
07PS	388	338	0	388	46	220	2000	E	A	A	0	0	0	0
07PAN	1540	2600	2600	5300	62	1991	7784	C	A	F	5	2	0	2
07PSA	1996.76	1967.76	1997	1968	65	2000	159.4	A	A	A	0	0	0	0
07PON	1540	2500	2100	2700	62	2281	10000	A	A	A	0	0	0	0
07SB	956	1102	1102	1102	50	829	47274	E	C	A	7	14	0	2
07SF	1157	1289	1157	1289	62	2001	32097	C	A	D	0	0	0	0
07SIR	930	1861	1878	1878	69	450	394.5	C	A	A	0	0	0	0
07TAT	1488.67	1969.21	1878	1878	77	350	267.2	A	A	A	4	1	3	1
07TIL	1489	1860.84	1878	1878	69	250	2084	A	A	A	0	0	0	0
07TK	0	2826.9	2527	2236	92	300	1920	B	A	A	10	30	4	2
07TON	569	569	487	5569	50	339	15381	A	A	A	0	0	0	0
08AWU	930	1877	1877	1877	69	302	0	B	A	A	5	5	0	4

Lampiran 1. Learning Data (Lanjutan)

id	scraping	sandblasting	cuci	cat	zinc	ut	plat	propeller	bantalan prop	poros prop	sealprop	ringprop	packing prop	chrome
08BIN	1505.5	1878.34	1860	3480	69	1416	8586	A	A	A	0	0	0	0
08CP	1013	1926	0	4975	38	300	7374	A	A	A	0	0	0	0
08GD	2407	1767.5	2372	2604	82	764	10000	A	A	B	0	1	0	0
08IJ	3482	0	0	3166	118	478	94794	E	A	A	6	2	0	2
08IJ(1)	1703.88	4975	4975	6679	0	2035	12866	E	A	A	0	6	4	6
08JAY	390	390	0	1170	58	396	200.2	E	A	A	5	14	0	0
08KIR	200	2145	1945	4479	97	273	2760	B	A	A	0	0	0	0
08KIR (1)	400	2416	1936	6708	149	400	7753	A	C	A	0	0	0	0
08LAW	1878.34	1878.34	1861	1878	69	412	20000	A	A	A	0	0	0	0
08LHO	1540	0	2140	2700	62	2500	5564	A	A	A	0	0	0	0
08TAM	320.4	419.4	419.4	498.8	50	510	2551	E	A	B	0	0	1	0
08TIL	1860.84	1860.84	1878	1878	69	420	898.8	A	A	A	5	6	4	2
09ABU	8143	11140	4140	31120	0	7002	2655	C	A	B	14	8	5	0
09AWU	1860	1860	1877	1877	69	500	5398	E	A	A	4	1	3	0
09BEL	270	270	0	480	26	70	42000	A	A	A	0	0	0	0
09BIM	430	430	0	1720	60	500	749.9	E	A	A	6	10	0	2
09BIN	1505.5	1878.34	1860	1878	69	1734	17788	E	B	A	1	6	0	2
09BR	930.42	1860.84	1896	1878	75	1694	2783	E	B	A	0	0	0	0
09CEL	270	270	0	480	52	70	9000	A	A	A	0	0	0	0
09DK	100	1880	1880	3760	99	428	2601	B	C	A	0	11	0	0
09EGO	1610	1680	1630	2140	81	600	0	B	C	A	8	60	0	4
09GB	390	610	0	610	47	520	0	A	A	A	0	0	0	0
09HP	861	977.67	0	1186	0	431	2378	A	A	A	0	0	0	0
09IAY	300	300	0	900	86	0	0	E	A	A	2	0	0	0
09JAT	2600	4323	4323	4323	75	400	0	A	A	A	0	0	0	0
09JAT (1)	0	0	3442	0	0	0	0	A	A	A	2	2	0	0
09KEL	2531.3	1860	1877	1877	69	518	2110	B	A	A	4	0	0	0
09SD(1)	637.5	0	0	0	0	300	0	A	A	A	0	0	0	0
09SD	0	1440	0	1237	65	10	16127	A	A	A	0	0	0	0
09MEN	0	3463.71	2664	8125	133	580	2594	E	A	A	0	2	0	0
09NL	216	0	0	0	0	80	0	A	A	A	0	0	0	0
09NL(1)	216	266	0	798	20	0	11789	A	A	A	0	0	0	0
09PAN	270	270	0	480	26	70	12000	A	A	A	0	0	0	0
09RD	2500	3250	2500	3250	78	1000	4358	A	A	A	0	0	1	0
09SIR	930	1860	1877	1877	69	600	11.78	E	A	A	0	2	2	2
09TAM	958	1275	1275	1275	30	200	1327	A	A	A	0	0	0	0
09TAT	930.24	1878.34	1878	1878	69	500	5947	E	B	A	3	3	1	1
09TK	0	8894	590	10965	92	345	871.1	B	A	A	0	0	0	0
09TW	2928.65	2928.65	2929	2929	93	1866	0	C	A	A	0	2	0	0
10ADV	393	393	393	393	30	953	65335	G	C	A	0	0	1	0
10ALU	600	1231	600	1200	60	0	0	A	A	A	0	0	0	0
10BEV	2900	2940	2900	2900	62	2889	757.1	D	A	A	0	5	0	0
10BIN	1488	1944	1878	1879	69	650	16306	B	A	A	3	0	0	3
10BOR	233	283	233	283	30	491	494.6	B	A	B	0	0	2	0
10CUN	270	650	0	540	26	70	20500	E	C	E	0	0	2	0
10KEL	1060	1060	1060	1078	8	200	30724	D	C	A	0	9	0	0
10EGO	402.5	1480	1610	1440	82	2294	15000	B	C	G	6	121	0	0

Lampiran 1. Learning Data (Lanjutan)

id	scraping	sandblasting	cuci	cat	zinc	ut	plat	propeller	bantalan prop	poros prop	sealprop	ringprop	packing prop	chrome
10ELI	752	1040	1040	1040	77	1947	3336	A	A	A	1	1	0	0
10TB	1725	4409.34	8640	16755	169	3570	3313	E	C	A	3	2	1	0
10GD	1186	2372	2407	2497	78	2482	15000	A	A	A	0	0	0	0
10JAY	300	300	0	900	64	400	5000	E	A	A	2	0	0	0
10KAP	290	685	0	580	26	70	24000	A	A	A	2	0	0	0
10KEL A	450	612	450	162	47	200	536.9	A	A	A	0	0	1	0
10KELI	930	1860	1877	1877	69	1697	18192	E	B	A	8	3	0	3
10KELI (1)	0	1877	3462	1860	8	400	29648	H	D	A	8	13	4	4
10KUJ	270	650	0	540	26	70	20000	A	A	A	0	0	0	0
10LAW	947	1877	1877	1877	69	1959	9582	A	A	A	0	0	0	0
10LEM	450	450	450	450	44	150	38.48	A	A	A	0	2	1	0
10LEU	558	1860	1877	1877	69	681	5578	E	B	A	5	0	0	5
10MAK	1313	2054.35	1313	2054	0	100	42939	A	A	A	0	2	1	0
10MAN	1540	2700	2700	3860	72	0	27249	A	A	A	0	0	0	0
10MK	3436	2526	2526	6988	92	638	1511	A	B	A	0	0	0	0
10OG	0	671	671	671	0	0	411.4	B	A	A	0	0	0	0
10PR	425	425	425	1700	30	100	264.6	C	A	A	0	0	0	0
10PED	290	685	0	580	26	70	24000	A	A	A	0	0	0	0
10REB	882	2233	882	2233	59	2500	6286	B	A	A	0	0	1	0
10RL	3060	4060	3060	4060	116	1000	22470	E	A	A	0	1	1	0
10RT	2800	3800	3800	3800	106	0	6303	B	C	A	0	0	0	0
10SP	346	414.75	346	414.8	28	451	2031	A	A	A	0	4	0	0

Lampiran 1. *Learning Data* (Lanjutan)


id	grease	kemudi	poros kem	shafts eal	bantalan kem	ringkem	packing kem	sealkem	chest	valve	scrupper	tank	las	panjang las	durasi
05AWU	0	A	A	NO	A	0	0	0	0	0	0	1360.3	0	0	12
06BSIP	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	15
06ABU	15	A	A	NO	A	0	0	0	0	0	0	0	0	0	5
06ANO	0	A	A	NO	A	0	0	0	0	0	0	50	9	0	7
06GB	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	7
06CA	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	8
06LHO	0	A	A	NO	C	4	0	6	0	4	0	1511.2	0	0	9
06CM	0	A	A	NO	A	0	0	0	0	0	0	0	0	63	10
06GD	0	A	B	NO	A	0	10	0	0	0	0	381.71	0	0	9
06JM	0	A	B	NO	A	3	5	0	0	0	0	4103.8	0	116260	32
06KAL	0	A	B	NO	C	0	0	0	0	0	0	3112	0	665.44	36
06LEM	0	D	A	NO	A	0	0	0	0	0	0	169.59	0	6.33	7
06LAW	0	G	B	NO	C	6	0	0	0	0	0	1553.8	0	0	9
06MAE	15	B	A	NO	B	1	2	2	0	0	0	8493.5	0	0	15
06PIO	0	A	B	NO	A	0	2	0	0	0	0	56.5	0	0	10
06GS	0	A	A	NO	A	0	0	0	0	0	0	1.08	0	0	7
06SIR	0	A	E	NO	C	8	1	0	0	0	0	657.2	0	0	6
07BAL	0	A	F	NO	A	1	0	0	0	0	0	1085.6	0	0	6
07BIN	0	A	A	NO	A	0	0	0	0	0	0	2175.1	0	282.92	9
07BOK	0	A	A	NO	A	0	0	0	0	0	0	2071.9	0	0	17
07BSP	0	A	A	NO	A	0	0	0	0	0	0	1527.4	0	74.82	11
07CA	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	10
07JAT	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	6
07KAR	0	A	A	NO	A	0	0	0	0	0	0	10655	0	0	12
07KEL	0	A	A	NO	A	0	0	0	0	0	0	1874.8	0	0	10
07KIR3	0	A	A	NO	A	0	0	0	0	0	0	174.5	0	0	14
07KIR	0	C	A	NO	C	0	1	0	0	0	0	819.47	0	0	9
07KLA	0	B	E	NO	C	1	0	1	0	0	0	410.18	0	200	12
07MAL	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	9
07MUF	0	A	B	NO	C	0	0	0	0	0	0	1420.9	0	0	17
07MUS	0	A	A	NO	A	0	0	0	0	0	0	1063.4	0	0	7
07PAL	0	A	A	NO	C	0	0	0	0	0	0	1111.2	0	0	8
07PS	0	A	A	NO	A	0	2	0	0	0	0	194.11	0	0	7
07PAN	0	C	C	NO	C	43	0	3	0	0	0	1154.5	0	0	7
07PSA	0	A	A	NO	A	0	0	0	0	0	0	3337	0	428.24	10
07PON	0	A	A	NO	A	0	0	0	0	0	0	808.6	0	0	8
07SB	0	A	A	NO	A	0	0	0	0	0	0	1320	0	105.44	17
07SF	0	A	A	NO	A	0	0	0	0	0	0	5323.4	0	0	17
07SIR	0	A	A	NO	A	0	0	0	0	0	2	1515.4	1	0	8
07TAT	0	A	A	NO	A	0	0	0	0	0	0	1032.8	0	0	9
07TIL	0	A	A	NO	A	0	0	0	0	0	0	997.8	0	0	6
07TK	0	A	A	NO	A	0	2	0	0	0	0	386.5	0	37.92	13
07TON	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	15
08AWU	0	A	A	NO	A	0	2	0	0	0	0	420.24	0	0	6
08BIN	0	A	A	NO	A	0	0	0	0	0	0	1352.8	0	150	8
08CP	0	A	A	NO	A	0	0	0	0	0	0	2498.9	0	0	8
08GD	0	A	A	NO	A	0	0	0	0	0	0	838.77	0	0	8
08IJ	0	A	A	NO	A	0	0	0	0	0	0	1385	0	1008.25	44

Lampiran 1. Learning Data (Lanjutan)

id	grease	kemudi	poros kem	shafts eal	bantalan kem	ringkem	packing kem	sealkem	chest	valve	scrupper	tank	las	panjang las	durasi
08IJ(1)	0	A	B	YES	C	2	0	3	1	0	0	2363.2	0	0	15
08JAY	0	A	A	NO	A	0	0	0	0	0	0	28.13	0	0	30
08KIR	0	A	A	NO	C	0	2	0	0	0	0	8049.4	0	0	10
08KIR (1)	0	A	A	NO	A	0	1	0	0	0	0	1237.2	0	0	5
08LAW	0	A	A	NO	A	0	0	0	0	0	0	1871.5	0	0	8
08LHO	0	A	A	NO	C	3	0	10	0	0	0	1278.9	0	0	8
08TAM	0	C	A	NO	A	0	0	0	0	0	0	320.8	27585	28.05	24
08TIL	0	A	A	NO	A	0	0	0	0	0	0	879	0	0	6
09ABU	0	A	A	NO	A	0	2	4	0	0	0	4860	0	28.35	21
09AWU	0	B	B	YES	C	2	0	0	0	0	0	1510.3	0	0	6
09BEL	0	A	A	NO	A	0	2	2	0	0	0	35	0	0	25
09BIM	0	A	A	NO	A	0	0	0	0	0	0	22.04	0	0	33
09BIN	0	B	A	NO	C	10	0	0	0	0	0	2180.6	0	0	14
09BR	0	F	A	NO	C	28	3	0	0	0	0	1925.5	0	0	19
09CEL	0	A	A	NO	A	0	0	0	0	0	0	35	0	0	30
09DK	0	A	A	NO	A	0	0	0	0	4	0	1277.9	0	0	11
09EGO	0	A	A	NO	A	0	0	0	0	0	0	1543.9	0	0	30
09GB	0	A	A	NO	A	0	0	0	0	0	0	0	0	2	13
09HP	0	A	A	NO	A	0	0	0	0	0	0	4632.5	0	625.48	8
09JAY	0	A	A	NO	A	0	0	0	2	2	0	28.65	0	0	15
09JAT	0	A	A	NO	C	0	4	4	0	0	0	1472.2	0	0	7
09JAT(1)	0	A	A	NO	A	2	0	0	0	0	0	0	0	0	6
09KEL	0	B	A	YES	C	0	0	0	0	0	0	1143.4	0	0	10
09SD(1)	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	5
09SD	0	A	A	NO	A	0	0	0	3	0	0	1018.6	7036	7.9	18
09MEN	0	A	A	NO	A	0	0	0	0	0	0	1459.5	0	1.2	10
09NL	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	5
09NL(1)	0	D	A	NO	A	0	0	0	0	0	0	0	0	0	18
09PAN	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	25
09RD	50	A	A	NO	A	0	1	0	0	0	0	1590.5	0	6.4	11
09SIR	0	A	A	NO	A	0	0	0	0	0	0	2509.3	0	0	8
09TAM	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	7
09TAT	0	B	A	NO	C	2	6	0	0	0	0	1437.6	0	0	11
09TK	0	A	A	NO	A	0	1	0	0	0	0	1437.8	0	0	9
09TW	45	A	A	NO	A	0	0	0	0	0	0	408.93	2238	6	21
10ADV	0	A	D	NO	A	0	1	0	1	3	0	7.34	0	16.84	18
10ALU	0	A	A	NO	A	0	0	0	0	0	0	239.29	0	0	7
10BEV	0	A	A	NO	A	0	0	0	0	0	0	1015.5	0	0	14
10BIN	0	A	A	NO	C	1	0	0	0	0	0	1805.9	0	11.7	10
10BOR	0	A	A	NO	A	0	0	0	0	3	0	67.19	0	0	9
10CUN	0	A	A	NO	A	0	0	1	0	0	0	36	0	0	30
10KEL	0	A	A	NO	A	0	0	0	0	0	0	1612.4	0	37.2	16
10EGO	45	A	B	NO	A	2	0	0	0	0	0	989.64	0	0	28
10ELI	0	A	A	NO	A	0	0	0	0	2	0	1753.2	0	0	16
10TB	45	A	A	NO	C	0	5	0	7	0	0	2465.9	0	0	17
10GD	0	A	A	NO	B	0	0	0	0	0	0	1099.5	0	0	7
10JAY	0	A	A	NO	A	0	0	0	2	1	2	28.65	0	0	27

Lampiran 1. Learning Data (Lanjutan)

id	grease	kemudi	poros kem	shafts eal	bantalan kem	ringkem	packing kem	sealkem	chest	valve	scrupper	tank	las	panjang las	durasi
10KAP	0	A	A	NO	A	0	0	2	0	0	0	83.2	0	0	15
10KELA	0	A	A	NO	A	0	0	0	0	0	0	160.26	44	0	16
10KELI	0	B	B	NO	C	10	1	0	0	0	0	1938	0	0	14
10KELI (1)	0	B	A	YES	C	0	0	0	0	0	0	1612.4	0	0	25
10KUJ	0	A	A	NO	A	0	0	0	0	0	0	36	0	0	30
10LAW	0	A	A	NO	A	0	0	0	0	0	0	992.1	0	167.25	11
10LEM	0	A	A	NO	A	0	0	0	0	0	0	1E+05	0	0	12
10LEU	0	A	A	NO	A	0	0	0	0	0	0	1302.7	0	536.68	9
10MAK	0	A	A	NO	A	0	0	0	0	0	0	5137.8	0	4.5	19
10MAN	0	A	A	NO	A	0	0	0	0	0	0	1094.4	0	45.3	10
10MK	0	A	A	NO	C	0	0	0	0	0	0	1087.1	0	0	8
10OG	0	A	A	NO	A	0	0	0	0	0	0	385.76	0	0	10
10PR	0	A	A	NO	A	0	0	0	0	0	0	67453	0	0	9
10PED	0	A	A	NO	A	0	0	2	0	0	0	44.76	0	0	23
10REB	0	A	A	NO	A	0	0	0	0	0	0	1957.1	474	1.5	16
10RL	0	A	A	NO	C	0	1	0	0	0	0	2663.3	215	59.6	22
10RT	0	B	B	NO	A	0	0	0	0	0	0	1617.3	0	0	11
10SP	0	A	A	NO	A	0	0	0	0	0	0	52.5	0	0	16



Lampiran 2. Testing Data

id	scraping	sandblasting	cuci	cat	zinc	ut	pelat	propeller	bantalan prop	poros prop	sealprop	ringprop	packing prop	chrome
11ARJ	275	315	0	315	46	400	1326	E	B	A	0	0	1	0
11AWU	1395	1860	1877	1877	69	2691	5090	E	B	A	6	0	0	7
11BAR	730	730	590	730	0	200	129	A	A	A	0	0	0	0
11BIM	430	430	430	430	6	200	207	E	A	A	0	4	0	0
11BKM	100	220	100	220	20	435	1880	E	C	B	0	3	1	0
11CP	1013	1926	0	4975	38	0	7410	A	A	A	0	0	0	0
11SIR	465	2875.4	1877	2892	69	450	4083	B	A	A	0	1	0	0
11TRI	800	1200	0	1600	60	150	0	A	A	A	0	0	0	0
11DK	254	1265	0	2531	52	361	1020	A	A	A	0	6	0	0
11GD	2372	2407	2407	2497	74	450	7000	E	A	A	0	0	0	0
11JAY	300	300	300	300	62	400	948	E	A	A	0	0	0	0
11JAY4	300	300	300	300	62	400	2000	E	A	A	0	0	0	0
11KAL	738	1198	1172	4942	0	300	806	A	A	A	0	0	2	0
11KEL	465	1860	1877	1877	69	400	9530	A	A	A	3	1	3	0
11LHO	2858	2858	2858	2858	71	601	2107	A	A	A	0	0	0	0
11MEL	373.5	1785	0	3214	0	1701	0	A	A	A	0	0	0	0
11PAN	290	685	0	580	26	70	24000	E	C	C	6	1	0	1
11RE	1750	1750	1750	1850	50	0	1300	E	A	A	0	1	0	0
11RS	2500	2,800	2500	4000	102	0	16777	E	A	A	0	1	3	0
11SN	2250	2250	2250	2250	148	467	4107	B	C	D	0	0	0	0
11SJ	2309	3770	10060	17710	169	0	6489	A	A	A	0	0	0	0
11TON	477	557	557	557	44	720	18217	A	A	A	0	0	0	0
11TAT	465.16	1860.84	1878.1	1778	69	650	8532	E	A	A	0	1	0	0
11TW	1526.25	1526.25	1526.3	2067	70	326	316	A	A	A	0	0	0	0
11CUC	366.71	366.71	366.71	2200	43	100	3000	A	A	A	0	0	0	0
11KAL (1)	543.92	543.92	543.92	543.9	46	299	797	A	A	A	0	1	5	0
11MN	1255	1255	1255	1255	88	100	1089	H	C	A	4	2	2	0
12BR	465.16	1860.64	1878.1	1878	69	550	5442	A	B	A	5	0	0	2
12CTP	45.6	136.43	0	296	12	0	292	B	A	A	0	0	0	0
12CP	250	575	0	1515	24	0	1851	A	A	A	0	0	0	0
12KEL	465	1860	1877	1877	69	500	8694	A	A	A	3	1	5	0
12SC	0	3310	0	3310	62	0	9713	E	C	A	0	10	16	0
12TIL	465.21	1860.84	1874.6	1875	69	513	1921	E	A	A	3	1	0	1

Lampiran 2. *Testing Data* (Lanjutan)

id	grease	kemudi	poros kem	shafts eal	bantalan kem	ringkem	packing kem	sealkem	chest	valve	scrupper	tank	las	panjang las	durasi
11ARJ	0	A	A	NO	A	0	1	0	0	0	0	123.1	0	0	18
11AWU	0	A	A	NO	C	0	0	0	0	0	0	1768	0	0	13
11BAR	0	A	A	NO	A	0	0	0	0	0	0	200.3	0	0	17
11BIM	0	A	A	NO	A	0	0	0	2	0	0	89.25	0	0.99	16
11BKM	0	A	A	NO	A	0	1	0	0	0	0	0	0	16.25	26
11CP	0	A	A	NO	A	0	0	0	0	0	0	2499	0	148.83	10
11SIR	0	A	A	NO	A	0	0	0	0	0	0	1001	0	0	8
11TRI	0	A	B	NO	C	2	0	4	0	0	0	303	0	0	7
11DK	0	A	A	NO	A	0	0	0	0	0	0	0	26	10	8
11GD	0	A	A	NO	A	0	0	0	0	0	0	893.3	0	0	7
11JAY	0	A	A	NO	C	0	0	0	0	0	0	340.1	100	0	25
11JAY4	0	A	A	NO	C	0	0	0	0	0	0	274.5	0	0	25
11KAL	0	A	A	NO	A	0	0	0	0	0	0	307	0	0	10
11KEL	20	A	D	NO	A	0	0	0	1	0	0	452.3	0	0	10
11LHO	0	A	A	NO	A	1	0	2	0	0	0	1349	0	0	15
11MEL	0	A	A	NO	A	0	0	0	0	0	0	441.1	765	0	18
11PAN	0	A	A	NO	A	0	0	2	0	0	0	83.2	0	0	7
11RE	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	8
11RS	0	A	A	NO	A	0	1	0	0	0	0	2113	0	0	16
11SN	0	A	A	NO	A	0	1	0	0	0	0	0	0	0	10
11SJ	0	A	A	NO	A	0	0	0	0	0	0	33	3525	20.9	21
11TON	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	18
11TAT	0	A	A	NO	A	0	2	0	0	0	0	1211	0	0	11
11TW	0	A	A	NO	A	0	0	0	0	0	0	27.03	1,015	18.69	10
11CUC	0	A	A	NO	A	4	0	5	0	0	0	30.07	0	0	15
11KAL (1)	0	A	A	NO	A	0	0	0	0	0	0	144.1	32	0	15
11MN	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	26
12BR	0	A	B	NO	C	4	1	0	0	0	0	1983	0	0	11
12CTP	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	5
12CP	0	A	A	NO	A	0	0	0	0	0	0	0	0	0	10
12KEL	0	B	D	NO	C	1	1	0	0	0	0	647.9	0	0	13
12SC	50	A	A	NO	A	0	0	0	0	0	0	0	0	0	18
12TIL	0	A	A	NO	C	0	0	0	0	0	0	1276	0	29.4	10