

# PREDIKSI WAKTU SANDAR KAPAL DI PELABUHAN BATU AMPAR, KOTA BATAM, PROVINSI KEPULAUAN RIAU

Candra Kurniawan  
Sekolah Teknik Elektro dan  
Informatika  
Institut Teknologi Bandung  
Bandung, Indonesia  
candrak@students.itb.ac.id

Fahrur Rozi  
Sekolah Teknik Elektro dan  
Informatika  
Institut Teknologi Bandung  
Bandung, Indonesia  
fahurrozi@students.itb.ac.id

Saiful Rizal  
Sekolah Teknik Elektro dan  
Informatika  
Institut Teknologi Bandung  
Bandung, Indonesia  
saiful.rizal@students.itb.ac.id

*Abstract - Batu Ampar Port is the largest goods port in Batam City which has the best traffic for export activities and important activities. Waiting times are still a problem in port services. Waiting time is one indicator of port management efficiency. The average waiting time for the Batu Ampar port for unloading activities in the first quarter of 2015 was 7 days, while the loading activity was 5 days. This is what makes Batu Ampar harbor still many complaints, resulting in the number of queue ships. For this reason, an analysis is needed to produce a model that can provide a picture of waiting times at the port and evaluate the built-in analytic model. The secondary data analysis of the Batu Ampar port uses data mining. Data mining methods are performed using supervised learning methods, namely multiple regression and decision trees. The general purpose of multiple regression is to further about the relationship between the independent variable or predictor and the dependent variable or criterion. The decision tree used to extract port data uses this classification. Decision tree classifications can find data containing well-collected object classes, so that classes can be interpreted completely in the context of substantive theory. Two model evaluation methods were carried out for the two modeling results that were built. The Variance Analysis Test (ANOVA) is used for evaluating multiple regression models, while for the decision tree model is evaluated with a confusion matrix. The results of the data analysis showed the length of time the ship unloaded / loaded by three variable types of expedition, flag, and volume. By using multiple regression a predictive model of ship berth time is generated. Evaluation results, the model is made significant. With a 95% confidence level the predictive model created will represent the true value. For the decision tree, the evaluation model created was appropriate, with a precision of 84.50%.*

Keywords—dwelling time, prediction, multiple regression, decision tree, anova, confusion matrix

## I. PENDAHULUAN

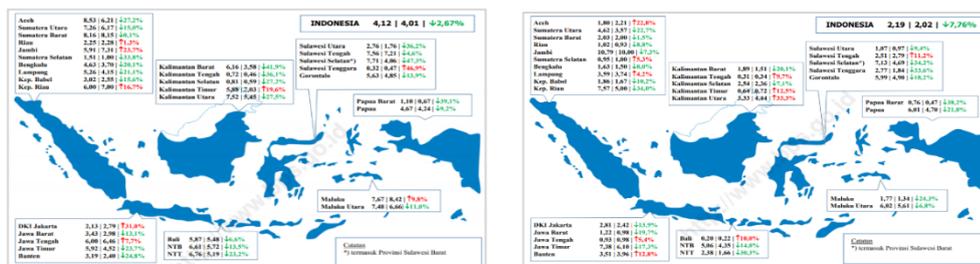
Kota Batam merupakan salah satu dari tujuh Kabupaten/Kota yang terletak di Provinsi Kepulauan Riau. Wilayah perairan Kota Batam lebih luas dibandingkan daratannya, luas wilayah perairannya 2.791,09 km<sup>2</sup> (73%) sedangkan luas wilayah daratannya hanya 1.038,84 km<sup>2</sup> (27%). Luas wilayah laut yang lebih dominan menyebabkan moda transportasi laut lazim digunakan di wilayah Kepulauan Riau dan sekitarnya, tidak terkecuali Kota Batam. Letak Kota Batam sangat strategis, yaitu di jalur pelayaran dunia internasional, hanya berjarak 20 kilometer dari Singapura. Pulau Batam menjadi pintu gerbang dari wilayah Indonesia karena letaknya di wilayah perbatasan. pelabuhan yang dimiliki Kota Batam tidak hanya berskala nasional tetapi juga berskala internasional. Batam memiliki pelabuhan transit untuk kepentingan ekonomi perdagangan, tidak kurang dari 5 pelabuhan di Kota Batam menjadi pintu kegiatan ekspor impor. Nama pelabuhan dan nilai ekspor impor tersebut disebutkan pada Tabel 1.

Tabel 1. Nilai Ekspor Impor melalui Pelabuhan di Batam, 2017 [1]

Pelabuhan	Nilai Ekspor (US\$)	Nilai Impor (US\$)
Batu Ampar	3.438.705.821,29	3.406.578.274
Belakang Padang	1.208.167.529,68	13.200.000
Kabil/Panau	1.772.009.805,19	285.466.889
Pulau Sambu	11.725.110,09	229.997.725
Sekupang	2.095.007.610,65	2.125.489.383

Tabel 1 menunjukkan bahwa Pelabuhan Batu Ampar memiliki lalu lintas tertinggi baik untuk kegiatan ekspor maupun kegiatan impor. Hal ini dikarenakan Pelabuhan Batu Ampar merupakan pelabuhan barang terbesar di Kota Batam. Banyaknya pelabuhan dan besarnya nilai ekspor impor selain menjadi kelebihan juga banyak menimbulkan permasalahan pelayanan pelabuhan di Kota Batam. Waktu sandar masih menjadi masalah dalam layanan pelabuhan secara umum di Indonesia. Waktu sandar adalah waktu tunggu (*dwelling time*) yang dibutuhkan kapal yang masuk pelabuhan untuk melakukan aktivitas bongkar muat barang yang dibawa kapal. Waktu sandar berhubungan dengan arus distribusi barang yang tentu saja berhubungan dengan kegiatan ekonomi. Kelancaran arus distribusi barang sulit dicapai tanpa didukung oleh peningkatan efisiensi tata laksana melalui cara-cara seperti mempersingkat waktu tunggu bongkar muat barang di pelabuhan. *Dwelling time* di pelabuhan yang merupakan salah satu indikator efisiensi pengelolaan pelabuhan. Tentunya semakin singkat waktu tunggu yang dibutuhkan untuk bongkar muat, maka semakin baik layanan pelabuhan yang diberikan. Singkatnya waktu tunggu sangat penting mengingat banyaknya kapal yang keluar masuk di Pelabuhan Batu Ampar.

Proses panjang yang harus dilalui sebuah kapal yang masuk di pelabuhan khususnya Pelabuhan Batu Ampar membuat waktu sandar kapal tidak menentu. Padahal semakin lama kapal bersandar di suatu pelabuhan akan berakibat pada mahalnya biaya logistik dan berimbas pada mahalnya harga barang secara umum. Menurut data *dwelling time* [2] dari survei yang dilakukan Badan Pusat Statistik (BPS) seperti terlihat pada Gambar 1, rata-rata waktu tunggu barang di pelabuhan untuk kegiatan bongkar muat barang di Indonesia pada triwulan IV-2014 adalah 4,12 hari dan turun sebesar 2,7 persen menjadi 4,01 hari pada triwulan I-2015. Rata-rata waktu tunggu barang di pelabuhan untuk kegiatan muat barang pada pelabuhan di Indonesia adalah 2,19 hari pada triwulan IV-2014 dan turun sebesar 7,8 persen menjadi 2,02 hari pada triwulan I-2015. Untuk Provinsi Kepulauan Riau, termasuk Kota Batam dan pelabuhan yang ada di Kota Batam, rata-rata waktu tunggu untuk kegiatan bongkar pada triwulan I-2015 adalah 7 hari, sedangkan kegiatan muatnya adalah 5 hari. Hal ini yang menjadikan kinerja pelabuhan Batu Ampar masih banyak dikeluhkan, sehingga berakibat banyaknya antrian kapal. Untuk itulah, perlu dilakukan analisis guna menghasilkan model yang bisa memberikan gambaran waktu tunggu di pelabuhan untuk kapal yang masuk berdasarkan variabel-variabel yang ada dan melakukan evaluasi terhadap model analitik yang telah dibangun.

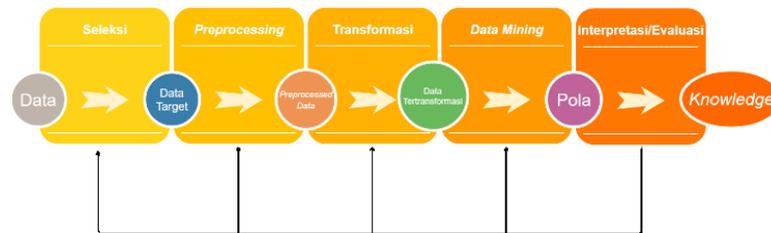


Gambar 1. Rata-Rata *Dwelling Time* untuk Kegiatan Bongkar (kiri) dan Muat (kanan) Barang pada Triwulan IV-2014 dan I-2015 Menurut Provinsi (Hari)

## II. RANCANGAN SOLUSI

Untuk mendapatkan rancangan solusi penelitian, maka diperlukan analisa layanan pelabuhan Batu Ampar di pulau Batam melalui data sekunder. Tentu saja, data tidak akan menghasilkan informasi ataupun pengetahuan apabila tidak melalui pemrosesan data. Vercellis [3] menyatakan bahwa informasi adalah hasil dari kegiatan ekstraksi dan pemrosesan data, dan informasi ditransformasikan menjadi pengetahuan/wawasan ketika digunakan untuk membuat keputusan dan mengembangkan tindakan yang sesuai. Analisis data memanfaatkan metode atau alat analitik untuk memeriksa, mengubah, dan memodelkan data untuk mengekstraksi nilai. Banyak bidang aplikasi memanfaatkan peluang yang disajikan oleh data berlimpah dan metode analisis khusus untuk memperoleh dampak yang diinginkan dengan memanfaatkan *Knowledge Discovery in Databases* (KDD).

KDD atau penemuan pengetahuan/wawasan dalam basis data adalah proses untuk mengidentifikasi kumpulan data sehingga dapat dipahami [4]. Untuk mendapatkan penemuan pengetahuan/wawasan tersebut dibutuhkan proses dengan urutan berulang dan interaktif dari langkah-langkah utamanya, salah satu penerapannya menggunakan *data mining*, dan digambarkan pada Gambar berikut.



Gambar 2. Proses dalam KDD

Penerapan metode analitik yang tepat memungkinkan pimpinan untuk mengandalkan informasi dan pengetahuan yang lebih dapat diandalkan dalam KDD. Sebagai hasilnya, pimpinan dapat membuat keputusan yang lebih baik dan menyusun rencana aksi yang memungkinkan tujuan mereka tercapai dengan cara yang lebih efektif. Analisis layanan pelabuhan Batu Ampar dapat memberikan gambaran mengenai kondisi pelabuhan peti kemas. Dalam analisa data sekunder pelabuhan Batu Ampar menggunakan *data mining*.

Dalam terminologi Layman, data analitik dideskripsikan sebagai kegiatan analisis data, baik besar atau kecil, untuk memahami dan melihat bagaimana menggunakan pengetahuan yang tersembunyi di dalamnya. Model analitik yang digunakan adalah model analitik prediktif. Model analitik prediktif adalah alat yang sangat baik untuk membuat prediksi dan dapat menghasilkan perkiraan tentang apa yang mungkin terjadi. Model analitik prediktif menjawab pertanyaan “apa yang mungkin terjadi”, analisis ini dapat menghasilkan apa saja yang bisa memengaruhi tren dan pola jika suatu data berubah. Lebih jauh lagi arah prediksi bukan hanya sekedar prediksi di masa depan, namun juga dapat diterapkan pada peristiwa yang tidak diketahui di masa lalu, dan masa sekarang.

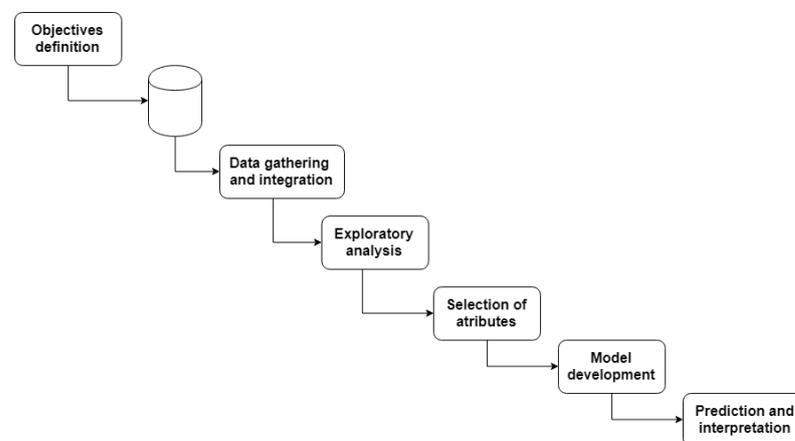
### A. Tahapan Solusi

*Data mining* menunjukkan proses eksplorasi dan analisis pada *dataset*. Kegiatan *data mining* merupakan proses berulang menganalisis basis data besar dengan tujuan mengekstraksi informasi dan pengetahuan yang mungkin terbukti akurat dan berpotensi bermanfaat bagi pekerja berpengalaman yang terlibat dalam pengambilan keputusan dan penyelesaian masalah. Istilah *data mining* mengacu pada keseluruhan proses yang terdiri dari pengumpulan dan analisis data, pengembangan model dan adopsi keputusan praktis dan tindakan konsekuen berdasarkan pengetahuan yang diperoleh. Model yang digunakan pada analisis *data mining* digunakan untuk menghasilkan pengetahuan baru. Proses *data*

*mining* didasarkan pada metode pembelajaran induktif, dimana tujuan utamanya adalah untuk mendapatkan aturan umum dari data yang tersedia yang berasal dari pengamatan masa lalu yang dicatat dalam satu atau lebih basis data. Dengan kata lain, tujuan dari analisis *data mining* adalah untuk menarik beberapa kesimpulan mulai dari sampel pengamatan masa lalu dan untuk menggeneralisasi kesimpulan ini dengan merujuk pada seluruh populasi, sedemikian rupa sehingga hasilnya menjadi seakurat mungkin.

Metode *data mining* yang dilakukan menggunakan algoritma *supervised learning*, yaitu *multiple regression* dan *decision trees*. Tujuan umum dari *multiple regression* [5] [6] adalah untuk mempelajari lebih lanjut tentang hubungan antara beberapa variabel independen atau prediktor dan variabel dependen atau kriteria. Terdapat dua manfaat utama dari *multiple regression* yaitu untuk prediksi dan analisis. Pada studi prediksi, tujuannya adalah untuk mengembangkan formula pada pembuatan prediksi tentang variabel dependen, berdasarkan nilai-nilai yang diamati dari variabel independen. Sedangkan pada analisis, variabel independen dianggap sebagai penyebab variabel dependen.

*Decision trees* [7] telah terbukti menjadi alat analitik untuk berbagai tujuan seperti untuk deskripsi, klasifikasi, dan generalisasi data. *Decision trees* dapat digunakan dalam berbagai disiplin ilmu seperti statistik, *pattern recognition*, *decision theory*, *signal processing*, *machine learning* dan *artificial neural networks*. *Decision trees* adalah cara untuk merepresentasikan aturan yang mendasari data dengan hierarki, struktur sekuensial yang membagi data secara rekursif. *Decision trees* yang digunakan untuk eksplorasi data pelabuhan ini menggunakan klasifikasi. Klasifikasi *decision trees* dapat menemukan apakah data mengandung kelas objek yang dipisahkan dengan baik, sehingga kelas dapat diinterpretasikan secara bermakna dalam konteks teori substantif. *Decision trees* yang secara otomatis dibangun dari data, telah digunakan dengan sukses dalam banyak situasi. Efektivitasnya telah dibandingkan secara luas dengan metode eksplorasi data otomatis lainnya oleh para ahli.



Gambar 3. Tahapan *Data Mining* [3]

Tahapan solusi yang diusulkan menggunakan tahapan *data mining*, seperti terlihat pada Gambar 3, adalah sebagai berikut:

- a. *Objectives definition*: Mendefinisikan tujuan dari melakukan *data mining*.
- b. *Data gathering and integration*: Setelah tujuan diidentifikasi, maka pengumpulan data dimulai. Data dapat berasal dari beberapa tahun sumber dan oleh karena itu mungkin memerlukan integrasi. Integrasi sumber data yang berbeda tahunnya digunakan untuk memperkaya data.
- c. *Exploratory analysis*: Pada fase ketiga dari proses *data mining*, analisis awal data dilakukan dengan tujuan untuk memahami dengan informasi yang tersedia dan melakukan data *cleaning*. Biasanya, data yang disimpan dalam *data warehouse* diproses pada waktu pemuatan sedemikian rupa untuk menghilangkan ketidak

konsistenan. Data *missing* dan *outlier* data dibuang untuk keperluan data *cleaning*. Dalam proses *data mining*, *data cleaning* terjadi pada tingkat semantik. Pertama-tama, distribusi nilai untuk setiap atribut dipelajari, menggunakan histogram untuk atribut kategori dan statistik ringkasan dasar untuk variabel numerik. Dengan cara ini, nilai-nilai abnormal (*outlier*) dan nilai-nilai yang hilang juga dipelajari.

- d. *Selection of attributes*: Pada tahapan ini relevansi atribut yang berbeda dievaluasi dalam kaitannya dengan tujuan analisis. Atribut yang terbukti kurang bermanfaat dihapus, untuk membersihkan informasi yang tidak relevan dari dataset. Selain itu, atribut baru yang diperoleh dari variabel asli melalui transformasi yang sesuai dimasukkan ke dalam dataset. Penambahan variabel baru sangat membantu untuk memperkenalkan atribut baru yang mencerminkan tren yang melekat pada data melalui perhitungan rasio dan perbedaan antara variabel. Analisis eksplorasi dan pemilihan atribut adalah tahap yang penting dari proses *data mining* dan dapat mempengaruhi tingkat keberhasilan pada tahap selanjutnya.
- e. *Model development*: Setelah penambahan atribut pada dataset, pengenalan pola dan model prediksi dapat dikembangkan. Pada pengembangan model, training pada model dilakukan dengan menggunakan *sampel records* yang diambil dari dataset yang belum terdapat atribut tambahan. Kemudian, akurasi prediksi masing-masing model yang dihasilkan dapat dinilai menggunakan sisa data. Lebih tepatnya, dataset yang tersedia dibagi menjadi dua himpunan bagian. Yang pertama merupakan data training set dan digunakan untuk mengidentifikasi model pembelajaran tertentu dalam kelas model yang dipilih. Subset kedua adalah data testing set yang digunakan untuk menilai keakuratan model alternatif yang dihasilkan selama fase *training* untuk mengidentifikasi model terbaik pada prediksi yang dilakukan.
- f. *Prediction and interpretation*: Pada kesimpulan dari proses *data mining*, model yang dihasilkan selama tahapan model development harus diimplementasikan dan digunakan untuk mencapai tujuan awal yang sudah diidentifikasi. Selain itu, model yang dihasilkan harus dimasukkan ke dalam prosedur yang mendukung proses pengambilan keputusan sehingga hasilnya dapat digunakan untuk mendapatkan prediksi dan memperoleh pengetahuan yang lebih mendalam tentang prediksi yang dihasilkan.

## B. Rancangan Evaluasi Solusi

Dua metode evaluasi model dilakukan untuk dua hasil permodelan yang dibangun. Uji *Analysis of Variance* (Anova) digunakan untuk evaluasi model *multiple regression*, sedangkan untuk model *decision tree* dievaluasi dengan *confussion matrix*. Anova merupakan salah satu uji komparatif yang digunakan untuk menguji perbedaan *mean* (rata-rata) data lebih dari dua kelompok, langkahnya ditunjukkan pada Gambar 4. Prinsip Uji Anova adalah melakukan analisis variabilitas data menjadi dua sumber variasi yaitu variasi di dalam kelompok (*within*) dan variasi antar kelompok (*between*). Bila variasi *within* dan *between* sama (nilai perbandingan kedua varian mendekati angka satu), maka berarti tidak ada perbedaan efek dari intervensi yang dilakukan, dengan kata lain nilai *mean* yang dibandingkan tidak ada perbedaan. Sebaliknya bila variasi antar kelompok lebih besar dari variasi didalam kelompok, artinya intervensi tersebut memberikan efek yang berbeda, dengan kata lain nilai *mean* yang dibandingkan menunjukkan adanya perbedaan.



Gambar 4. Langkah-langkah Anova

*Confusion matrix* adalah suatu metode yang biasanya digunakan untuk melakukan perhitungan akurasi pada konsep *data mining* dengan membandingkan nilai yang dihasilkan pada model dengan nilai data sebenarnya [8]. Pada evaluasi menggunakan *confusion matrix* terdapat empat istilah sebagai representasi hasil proses klasifikasi. Keempat istilah tersebut adalah *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN), dapat dilihat pada Tabel 2. Nilai *True Positive* (TP) merepresentasikan benar dalam model dan benar pada data sebenarnya. Nilai *True Negative* (TN) merepresentasikan salah dalam model dan salah pada data sebenarnya. Nilai *False Positive* (FP) merepresentasikan benar dalam model dan salah pada data sebenarnya. Sementara itu, *False Negative* (FN) merepresentasikan salah dalam model dan benar pada data sebenarnya.

Tabel 2.  
*Confusion Matrix*

Kelas	Terklasifikasi Positif	Terklasifikasi Negatif
Positif	TP (True Positive)	FN (False Negative)
Negatif	FP (False Positive)	TN (True Negative)

Berdasarkan nilai TN, FP, FN, dan TP dapat diperoleh nilai akurasi, presisi dan *recall*. Nilai akurasi menggambarkan seberapa akurat sistem dapat mengklasifikasikan data secara benar. Dengan kata lain, nilai akurasi merupakan perbandingan antara data yang terklasifikasi benar dengan keseluruhan data. Nilai akurasi dapat diperoleh persamaan pertama pada daftar persamaan di bawah ini. Nilai presisi menggambarkan jumlah data kategori positif yang diklasifikasikan secara benar dibagi dengan total data yang diklasifikasi positif. Presisi dapat diperoleh dengan persamaan kedua. Sementara itu, *recall* menunjukkan berapa persen data kategori positif yang terklasifikasikan dengan benar oleh sistem. Nilai *recall* diperoleh dengan persamaan ketiga. Berikut daftar persamaan yang dimaksud.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} * 100\% \quad (1)$$

$$\text{Presisi} = \frac{TP}{FP+TP} * 100\% \quad (2)$$

$$\text{Recall} = \frac{TP}{FN+TP} * 100\% \quad (3)$$

Dimana:

- TP adalah *True Positive*, yaitu jumlah data positif yang terklasifikasi dengan benar oleh sistem.
- TN adalah *True Negative*, yaitu jumlah data negatif yang terklasifikasi dengan benar oleh sistem.
- FN adalah *False Negative*, yaitu jumlah data negatif namun terklasifikasi salah oleh sistem.
- FP adalah *False Positive*, yaitu jumlah data positif namun terklasifikasi salah oleh sistem

Sementara itu, pada klasifikasi dengan jumlah keluaran kelas yang lebih dari dua (*multi-class*), cara menghitung akurasi, presisi dan *recall* dapat dilakukan dengan menghitung rata-rata dari nilai akurasi, presisi dan *recall* pada setiap kelas. Persamaan 4, 5, dan 6 merupakan formula untuk menghitung nilai akurasi, presisi dan *recall* dari sistem klasifikasi *multi-class*.

$$Akurasi = \frac{\sum_{i=1}^l \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i}}{l} * 100\% \quad (4)$$

$$Presisi = \frac{\sum_{i=1}^l TP_i}{\sum_{i=1}^l (FP_i + TP_i)} * 100\% \quad (5)$$

$$Recall = \frac{\sum_{i=1}^l TP_i}{\sum_{i=1}^l (TP_i + FN_i)} * 100\% \quad (6)$$

Dimana:

- $TP_i$  adalah *True Positive*, yaitu jumlah data positif yang terklasifikasi dengan benar oleh sistem untuk kelas ke-i.
- $TN_i$  adalah *True Negative*, yaitu jumlah data negatif yang terklasifikasi dengan benar oleh sistem untuk kelas ke-i.
- $FN_i$  adalah *False Negative*, yaitu jumlah data negatif namun terklasifikasi salah oleh sistem untuk kelas ke-i.
- $FP_i$  adalah *False Positive*, yaitu jumlah data positif namun terklasifikasi salah oleh sistem untuk kelas ke-i,  $l$  adalah jumlah kelas.

### III. PENGUMPULAN DATA

#### A. Metode Pengumpulan Data

Metode pengumpulan data dan informasi yang berhubungan dengan masalah yang akan dibahas dalam penelitian ini adalah untuk data utama dengan melakukan permintaan data langsung ke narasumber yaitu BP Batam selaku pengelola pelabuhan Batu Ampar sedangkan data lainnya dengan melakukan pencarian di website BPS, khususnya BPS Kota Batam. Permintaan data ke BP Batam dan pencarian data pada website dilakukan pada minggu ke-empat April 2019.

#### B. Jenis Data

Penelitian ini menggunakan data sekunder. Data utama diperoleh dari BP Batam selaku pengelola pelabuhan Batu Ampar dengan periode Januari 2016 hingga Maret 2019. Data ini merupakan data transaksi pelabuhan bongkar/muat di pelabuhan Batu Ampar Batam, sedangkan data lainnya seperti dwelling time, pertumbuhan ekonomi, dan inflasi diperoleh dari BPS Kota Batam tahun 2015 – 2019 dan website BPS. Atribut data yang digunakan untuk analisis meliputi:

Tabel 3.  
Atribut Data

No	Atribut	Deskripsi	Tipe Data	Keterangan
1	Bendera	Nama negara dengan bendera yang terpasang di kapal	String	
2	Grosstone (GT)	Kapasitas kapal	Integer	
3	Jenis Ekspedisi	Jenis ekspedisi kapal	String	Jenis ekspedisi terdiri dari: Bongkar dalam negeri, Muat dalam negeri, Ekspor, Impor
4	Volume Barang	Volume barang yang diangkut dalam ( <i>container</i> )	Float	-
6	Tanggal Kedatangan	Tanggal kedatangan kapal	Date	-
7	Tanggal Berlayar	Tanggal berlayar kapal	Date	-

### C. Preprocessing Data

Data transaksi bongkar/muat yang berasal dari BP Batam masih berupa data mentah. Data tersebut masih kotor sehingga perlu dilakukan pembersihan data terlebih dahulu. Pentingnya melakukan *data preprocessing* ini dikarenakan data yang tidak berkualitas akan menghasilkan kualitas analisis yang tidak baik juga. Beberapa hal yang menyebabkan dilakukan *preprocessing* data yaitu:

- Data tidak lengkap antara lain, data hilang/kosong, kekurangan atribut tertentu atau atribut yang sesuai dan hanya berisi data agregat.
- Noise*, disebabkan data mengandung kesalahan dan data mengandung *outlier*.
- Tidak konsisten, mengandung perbedaan dalam kode dan nama.

Setelah dilakukan pembersihan data maka diperoleh jumlah record yang layak dilakukan analisis lebih lanjut adalah sebanyak 100.175 record. Jika dirinci pertahun dapat dilihat pada tabel dibawah ini.

Tabel 4.  
Jumlah *Record Raw Data* Hasil *Preprocessing*

Tahun	Sebelum <i>Preprocessing</i> Data	Setelah <i>Preprocessing</i> Data
2016	61 777	43 163
2017	40 333	28 344
2018	35 570	25 513
2019*	7 672	3 155
Total	145 352	100 175

\* sampai 31/03/2019

### D. Analisis Deskriptif

#### 1. Analisis SWOT

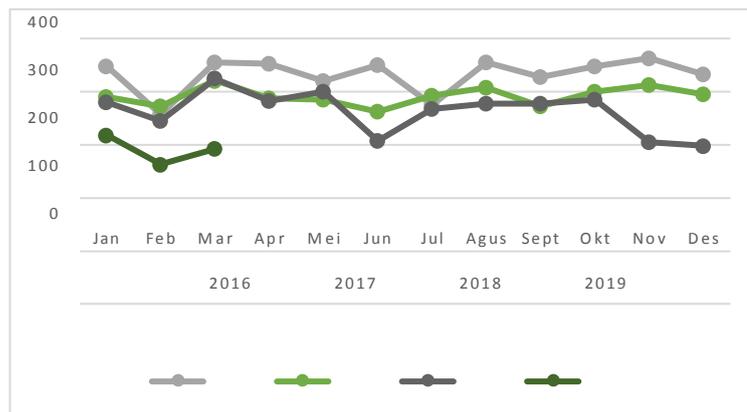
Seiring dengan semakin meningkatnya volume perdagangan dunia lewat laut yang mengakibatkan meningkatnya arus kedatangan kapal dan aktivitas bongkar muat, maka berdasarkan hasil analisis kinerja dan kebutuhan terminal dibuatlah analisis SWOT pelabuhan Batu Ampar untuk mengidentifikasi kekuatan dan kelemahan pelabuhan serta peluang dan ancaman yang dihadapi pelabuhan dalam menghadapi hal tersebut. Untuk menggunakan kekuatan dan meminimalisir kekurangan serta agar mampu memanfaatkan peluang dan menghindari ancaman maka dibuatlah strategi berupa matriks SWOT sebagai berikut:

Tabel 5.  
Matriks SWOT Pelabuhan Batu Ampar

<i>INTERNAL FACTORS</i>	
<i>STRENGTH (+)</i>	<i>WEAKNESSES (-)</i>
<ul style="list-style-type: none"> <li>Mempunyai sumber daya manusia yang berkualitas.</li> <li>Mempunyai kebijakan <i>free port</i> dan <i>free trade zone</i>.</li> <li>Bersertifikat <i>ISPS Code</i>.</li> </ul>	<ul style="list-style-type: none"> <li>Nilai BOR (tingkat pemakaian dermaga) yang telah melebihi persyaratan UNCTAD (standar pelabuhan internasional).</li> <li>Produktivitas peralatan bongkar muat rendah.</li> </ul>
<i>EXTERNAL FACTORS</i>	
<i>OPPORTUNITIES (+)</i>	<i>THREATS (-)</i>
<ul style="list-style-type: none"> <li>Terletak pada posisi yang strategis dekat dengan jalur perdagangan internasional yang ramai.</li> </ul>	<ul style="list-style-type: none"> <li>Fasilitas dan pelayanan di pelabuhan Singapura.</li> <li>Permasalahan lahan bagi investor.</li> </ul>

## 2. Analisis Jumlah Kunjungan Kapal

Jumlah kunjungan kapal di pelabuhan Batu Ampar dari Januari 2016 hingga maret 2019 menunjukkan tren menurun. Penurunan jumlah kunjungan kapal dikarenakan perekonomian lesu dan kenaikan tarif bongkar muat mulai 2017. Pada bulan Januari 2016, jumlah kunjungan kapal sebanyak 448 kapal sedangkan pada bulan Maret 2019 sebanyak 292 kapal. Jumlah kunjungan kapal terbanyak yaitu pada bulan November 2016 sebanyak 463 kapal sedangkan jumlah kunjungan kapal yang paling rendah pada bulan Februari 2019 yaitu sebanyak 263 kapal. Jumlah kunjungan kapal barang di pelabuhan Batu Ampar berdasarkan data pada tahun 2016-2019 dapat dilihat gambar 5.



Gambar 5 Jumlah Kunjungan Kapal di Pelabuhan Batu Ampar per Bulan 2016 – 2019

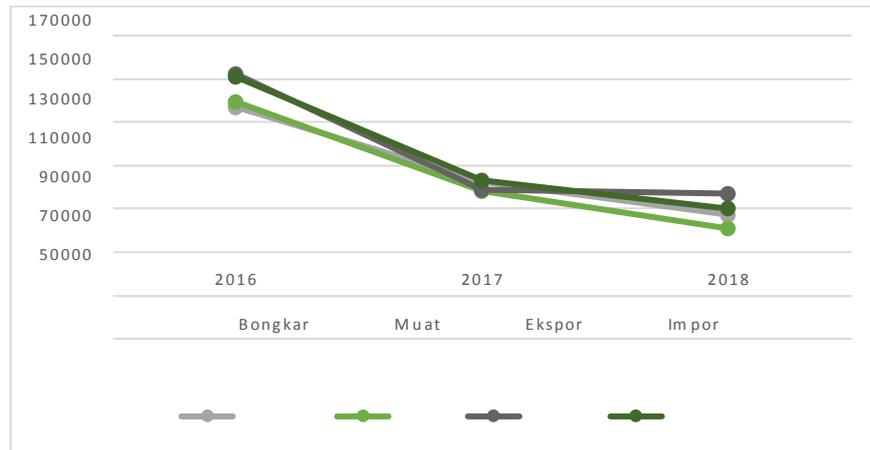
Jumlah kunjungan kapal menurut bendera yaitu Indonesia dan Asing menunjukkan tren yang berbeda. Jumlah kunjungan kapal berbendera Indonesia menunjukkan tren menurun setiap tahunnya sedangkan kapal berbendera asing menunjukkan tren menaik setiap tahunnya. Pada tahun 2016, jumlah kunjungan kapal berbendera Indonesia sebanyak 3.896 kapal menurun pada tahun 2018 sebanyak 2.923 kapal, sedangkan jumlah kunjungan kapal berbendera asing pada tahun 2016 sebanyak 1.283 naik menjadi 1.423 pada tahun 2018. Kunjungan kapal berbendera Indonesia terbanyak pada bulan Januari 2016 sebanyak 345 kapal, sedangkan paling rendah pada bulan februari 2019 sebanyak 154 kapal. Kunjungan kapal berbendera asing terbanyak pada bulan Maret 2018 sebanyak 136 kapal, sedangkan paling rendah pada bulan februari 2016 sebanyak 88 kapal.

Tabel 6.  
Jumlah Kunjungan Kapal menurut Bendera 2016 - 2019

Bulan	2016		2017		2018		2019	
	Indonesia	Asing	Indonesia	Asing	Indonesia	Asing	Indonesia	Asing
Januari	345	103	294	97	262	117	187	131
Februari	269	88	265	108	234	110	154	109
Maret	342	114	305	116	288	136	175	117
April	337	116	282	106	264	119	-	-
Mei	319	100	282	103	283	118	-	-
Juni	334	115	262	100	202	104	-	-
Juli	277	97	272	120	242	124	-	-
Agustus	355	99	298	110	256	122	-	-
September	323	104	260	113	252	125	-	-
Oktober	336	111	285	116	258	127	-	-
November	343	120	287	126	197	108	-	-
Desember	316	116	275	119	185	113	-	-
Total	3 896	1 283	3 367	1 334	2 923	1 423	357	516

### 3. Analisis Volume Bongkar Muat

Jumlah volume bongkar muat peti kemas di Pelabuhan Batu Ampar berdasarkan data tahun 2016-2019 dapat dilihat pada tabel 7. Volume bongkar/muat dari tahun 2016 hingga 2018 menunjukkan tren menurun baik perdagangan dalam negeri maupun perdagangan luar negeri. Hal ini sejalan dengan jumlah kunjungan kapal yang juga menunjukkan tren menurun dari tahun 2016 hingga 2018. Penurunan ini dikarenakan perekonomian lesu dan kenaikan tarif bongkar muat mulai 2017.



Gambar 6. Volume Bongkar Muat Tahun 2016 - 2018

Volume bongkar/muat perdagangan luar negeri lebih besar (ekspor/impor) dibandingkan perdagangan dalam negeri. Volume perdagangan luar negeri tertinggi pada tahun 2016 sebesar ekspor 172.179 unit container dan impor 170.871 unit container, sedangkan perdagangan dalam negeri tertinggi pada tahun 2016 sebesar 156.975 unit container untuk bongkar dan 159.378 unit container untuk muat. Volume perdagangan luar negeri terendah pada tahun 2018 sebesar ekspor 117.036 unit container dan impor 110.026 unit container, sedangkan perdagangan dalam negeri terendah pada tahun 2018 sebesar 107.270 unit container untuk bongkar dan 100.882 unit container untuk muat.

Tabel 7.  
Data Volume Bongkar Muat Peti Kemas di Pelabuhan Batu Ampar

Tahun	Perdagangan Dalam Negeri		Perdagangan Luar Negeri		Total
	Bongkar (Unit)	Muat (Unit)	Ekspor (Unit)	Impor (Unit)	
2016	156 975	159 378	172 179	170 871	659 403
2017	122 743	118 502	119 104	122 954	483 303
2018	107 270	100 882	117 036	110 026	435 214
2019*	12 660	13 480	13 113	11 426	50 679

\* sampai Maret 2019

## IV. EKSPERIMEN DAN HASIL

### A. Analisis Data

Beberapa hal yang dilakukan terhadap data hasil preprocessing sebelum membangun model yaitu pembentukan variabel baru, pengkodean dan transformasi data, dan agregasi data. Hal ini diperlukan agar data dapat dianalisis lebih lanjut.

1. Pembentukan Variabel Baru

Pada raw data awal terdapat dua variabel yaitu tanggal kedatangan dan tanggal berlayar sedangkan variabel yang dibutuhkan dalam analisis yaitu lamanya waktu kapal bersandar. Oleh karena itu, variabel lamanya waktu dibentuk dari selisih tanggal kedatangan dengan tanggal keberangkatan (dalam hari).

2. Pengkodean dan Transformasi Data

Pengkodean data adalah pemberian kode-kode tertentu pada data termasuk memberikan kategori untuk jenis data yang sama. Kode adalah simbol tertentu dalam bentuk huruf atau angka untuk memberikan identitas data. Kode yang diberikan dapat memiliki makna sebagai data kuantitatif (berbentuk skor). Kuantifikasi atau transformasi data menjadi data kuantitatif dapat dilakukan dengan memberikan skor terhadap data dengan mengikuti kaidah-kaidah dalam skala pengukuran. Beberapa variabel data yang dilakukan pengkodean yakni:

Tabel 8.  
Pengkodean Data

No	Variabel	Kode	Tipe Data
1	Bendera	1. Indonesia 2. Asing	Integer
2	Grosstone (GT)	1. <1000 2. 1000 – 1500 3. 1500 – 2000 4. 2000>	Integer
3	Jenis Ekspedisi	1. Bongkar dalam negeri 2. Muat dalam negeri 3. Ekspor 4. Impor	Integer

3. Agregasi Data

Pada data awal, tiap-tiap record terpisah berdasarkan transaksi kapal dan detail barang sehingga volume barang terpisah menurut detail barang, sedangkan record data yang diperlukan terpisah berdasarkan transaksi kapal yang melakukan bongkar/muat saja. Oleh karena itu, dilakukan agregasi volume data berdasarkan transaksi kapal yang melakukan bongkar/muat. Setelah dilakukan agregasi data, jumlah record data semula 100.175 record menjadi 15.583 record.

Tabel 9.  
Jumlah Record Data Setelah Agregasi

Tahun	Sebelum Agregasi Data	Setelah Agregasi Data
2016	43 163	5 152
2017	28 344	4 879
2018	25 513	4 486
2019*	3 155	1 066
Total	100 175	15 583

\* sampai Maret 2019

**B. Pembangunan Model**

**Model Multiple Regression**

Permodelan menggunakan SPSS sebagai tools analisisnya, dengan  $\alpha = 5\%$ , dan confidence interval = 95%. Variabel waktu menjadi dependent variable/variabel terikat/variabel yang diukur. Bendera, grosstone (GT), jenis ekspedisi, dan volume

menjadi independent variable/variabel bebasnya. Apabila dimasukkan dalam persamaan model multiple regression, maka persamaannya akan menjadi:

$$Y = \beta + \alpha_1 X_1 + \alpha_2 X_2 + \alpha_3 X_3 + \alpha_4 X_4, \text{ dimana nilai dari:}$$

Y = waktu

$\beta$  = konstanta

$\alpha_1$  = koefisien jenis ekspedisi

$X_1$  = jenis ekspedisi

$\alpha_2$  = koefisien bendera

$X_2$  = bendera

$\alpha_3$  = koefisien *grosstone* (GT)

$X_3$  = jenis *grosstone* (GT)

$\alpha_4$  = koefisien *volume*

$X_4$  = *volume*

Tabel 10.  
Hasil Permodelan *Multiple Regression* Sebelum Perbandingan Signifikansi

Model		Coefficients <sup>a</sup>									
		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Correlations			Collinearity Statistics	
		B	Std. Error	Beta			Zero-order	Partial	Part	Tolerance	VIF
	(Constant)	2.336	.076		30.737	.000					
	jenis ekspedisi	-.161	.017	-.149	-9.381	.000	-.185	-.131	-.125	.707	1.415
	bendera	.317	.031	.151	10.151	.000	.026	.141	.135	.804	1.244
	grosstone	-.010	.019	-.008	-.511	.609	.154	-.007	-.007	.653	1.532
	volume	.002	.000	.263	15.911	.000	.281	.218	.212	.650	1.538

Berdasarkan output hasil permodelan pada Tabel 12, didapatkan persamaan sebagai berikut:

$$\text{Waktu} = 2,336 - 0,161 \text{ jenis ekspedisi} + 0,317 \text{ bendera} - 0,10 \text{ grosstone (GT)} + 0,002 \text{ volume}$$

Namun setelah perbandingan signifikansinya terhadap  $\alpha$ , didapatkan variabel *grosstone* (GT) tidak signifikan, maka variabel tersebut dihilangkan. Nilai signifikansi dilihat dari Sig. dalam tabel kemudian dibandingkan dengan  $\alpha$ . Apabila Sig. >  $\alpha$  maka variabel bebasnya tidak berpengaruh signifikan terhadap variabel terikat. Adapun model dihitung lagi, dan didapatkan model baru sebagai berikut:

$$\text{Waktu} = 2,313 - 0,160 \text{ jenis ekspedisi} + 0,319 \text{ bendera} + 0,002 \text{ volume}$$

Tabel 11.  
Hasil Permodelan *Multiple Regression* setelah Perbandingan Signifikansi

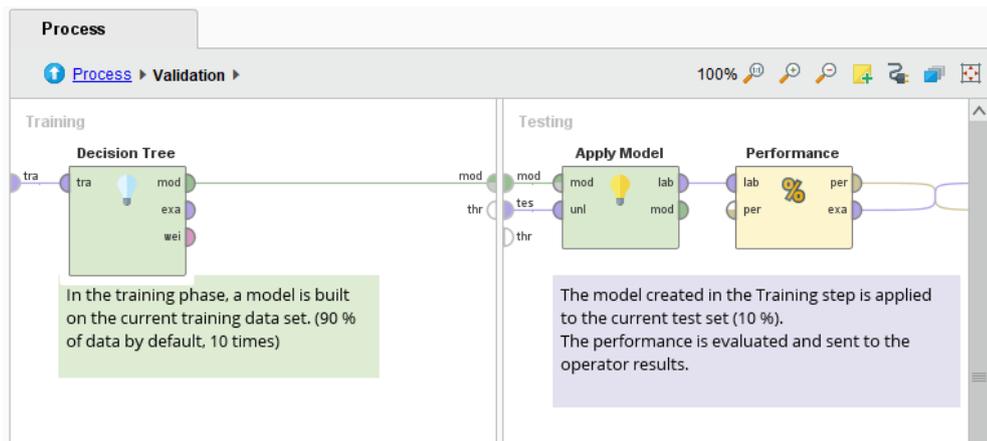
Model		Coefficients <sup>a</sup>									
		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Correlations			Collinearity Statistics	
		B	Std. Error	Beta			Zero-order	Partial	Part	Tolerance	VIF
1	(Constant)	2.313	.062		37.461	.000					
	Jenis ekspedisi	-.160	.017	-.147	-9.426	.000	-.185	-.131	-.126	.726	1.377
	bendera	.319	.031	.152	10.251	.000	.026	.143	.137	.812	1.232
	volume	.002	.000	.259	17.778	.000	.281	.243	.237	.837	1.195

Dengan persamaan model yang didapat, dapat diartikan sebagai berikut:

1. Konstanta bernilai 2,313 mempunyai makna jika semua variabel bebas (jenis ekspedisi, bendera, dan *volume*) bernilai 0, maka waktu yang dibutuhkan kapal untuk sandar di Pelabuhan Batu Ampar adalah 2,313 hari.
2. Koefisien jenis ekspedisi bernilai -0,160 mempunyai makna jika variabel bebas lainnya yaitu bendera dan *volume* bernilai 0, maka waktu yang dibutuhkan kapal untuk sandar di Pelabuhan Batu Ampar adalah 2,153 hari ( $2,313 - 0,160$ ).
3. Koefisien bendera bernilai +0,319 mempunyai makna jika variabel bebas lainnya yaitu jenis ekspedisi dan *volume* bernilai 0, maka waktu yang dibutuhkan kapal untuk sandar di Pelabuhan Batu Ampar adalah 2,63 hari ( $2,313 + 0,319$ ).
4. Koefisien volume bernilai +0,02 mempunyai makna jika variabel bebas lainnya yaitu jenis ekspedisi dan bendera bernilai 0, maka waktu yang dibutuhkan kapal untuk sandar di Pelabuhan Batu Ampar adalah 2,315 hari ( $2,313 + 0,002$ ).

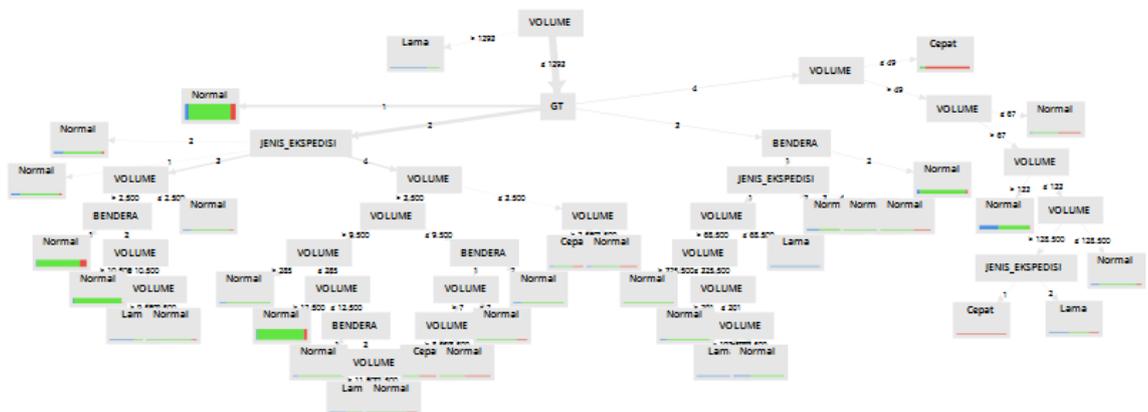
### Model Decision Tree

Permodelan decision tree menggunakan RapidMiner sebagai tools analisisnya. Variabel waktu menjadi dependent variable/variabel terikat/variabel yang diukur. Bendera, grosstone (GT), jenis ekspedisi, dan volume menjadi independent variable/variabel bebasnya. Gambar 9 menunjukkan proses pembuatan model, dimana 90% data sebagai data model, dan 10% sisanya sebagai data testing.



Gambar 7. Proses Pembangunan Model Menggunakan RapidMiner

Berdasarkan hasil permodelan, didapatkan gambar *decision tree* sebagai berikut:



Gambar 8. Model Decision Tree

Dengan deskripsi *tree* sebagai berikut:

### Tree

```

VOLUME > 1293: Lama {Lama=3, Normal=1, Cepat=0}
VOLUME ≤ 1293
| GT = 1: Normal {Lama=356, Normal=4144, Cepat=524}
| GT = 2
| | JENIS_EKSPEDISI = 1: Normal {Lama=59, Normal=237, Cepat=16}
| | JENIS_EKSPEDISI = 2: Normal {Lama=68, Normal=254, Cepat=18}
| | JENIS_EKSPEDISI = 3
| | | VOLUME > 2.500
| | | | BENDERA = 1: Normal {Lama=25, Normal=1745, Cepat=265}
| | | | BENDERA = 2
| | | | | VOLUME > 10.500: Normal {Lama=31, Normal=1396, Cepat=47}
| | | | | VOLUME ≤ 10.500
| | | | | | VOLUME > 9.500: Lama {Lama=2, Normal=2, Cepat=0}
| | | | | | VOLUME ≤ 9.500: Normal {Lama=0, Normal=9, Cepat=1}
| | | | | VOLUME ≤ 2.500: Normal {Lama=2, Normal=9, Cepat=1}
| | | JENIS_EKSPEDISI = 4
| | | | VOLUME > 3.500
| | | | | VOLUME > 9.500
| | | | | | VOLUME > 285: Normal {Lama=1, Normal=6, Cepat=0}
| | | | | | VOLUME ≤ 285
| | | | | | | VOLUME > 12.500: Normal {Lama=51, Normal=3045, Cepat=188}
| | | | | | | VOLUME ≤ 12.500
| | | | | | | | BENDERA = 1: Normal {Lama=2, Normal=16, Cepat=0}
| | | | | | | | BENDERA = 2
| | | | | | | | | VOLUME > 11.500: Lama {Lama=1, Normal=1, Cepat=1}
| | | | | | | | | VOLUME ≤ 11.500: Normal {Lama=0, Normal=8, Cepat=2}
| | | | | | VOLUME ≤ 9.500
| | | | | | | BENDERA = 1
| | | | | | | | VOLUME > 7
| | | | | | | | | VOLUME > 8.500: Cepat {Lama=0, Normal=1, Cepat=2}
| | | | | | | | | VOLUME ≤ 8.500: Normal {Lama=0, Normal=5, Cepat=5}
| | | | | | | | | VOLUME ≤ 7: Normal {Lama=0, Normal=12, Cepat=3}
| | | | | | | BENDERA = 2: Normal {Lama=1, Normal=5, Cepat=0}
| | | | | VOLUME ≤ 3.500
| | | | | | VOLUME > 2.500: Cepat {Lama=1, Normal=5, Cepat=7}
| | | | | | VOLUME ≤ 2.500: Normal {Lama=1, Normal=5, Cepat=3}
| GT = 3
| | BENDERA = 1
| | | JENIS_EKSPEDISI = 1
| | | | VOLUME > 68.500
| | | | | VOLUME > 325.500: Normal {Lama=0, Normal=14, Cepat=0}
| | | | | VOLUME ≤ 325.500
| | | | | | VOLUME > 201: Normal {Lama=9, Normal=57, Cepat=0}
| | | | | | VOLUME ≤ 201
| | | | | | | VOLUME > 193.500: Lama {Lama=3, Normal=1, Cepat=0}
| | | | | | | VOLUME ≤ 193.500: Normal {Lama=20, Normal=38, Cepat=0}
| | | | | | VOLUME ≤ 68.500: Lama {Lama=3, Normal=0, Cepat=0}
| | | | JENIS_EKSPEDISI = 2: Normal {Lama=36, Normal=110, Cepat=0}
| | | | JENIS_EKSPEDISI = 3: Normal {Lama=0, Normal=3, Cepat=1}
| | | | JENIS_EKSPEDISI = 4: Normal {Lama=0, Normal=2, Cepat=1}
| | | BENDERA = 2: Normal {Lama=65, Normal=912, Cepat=31}

```

Gambar 9. Potongan Deskripsi Model *Decision Tree*

### C. Evaluasi Model

Dua metode evaluasi model dilakukan untuk dua hasil permodelan yang dibangun. Uji Anova digunakan untuk evaluasi model *multiple regression*, sedangkan untuk model *decision tree* dievaluasi dengan *confussion matrix*.

Tabel 12.  
Hasil Uji Anova Model *Multiple Regression*

		ANOVA <sup>a</sup>				
	Model	Sum of Squares	df	Mean Square	F	Sig.
1	Regression	574.475	3	191.492	195.207	.000 <sup>b</sup>
	Residual	4954.865	5051	.981		
	Total	5529.340	5054			

a. Dependent Variable: waktu

b. Predictors: (Constant), *volume*, bendera, jenis ekspedisi

Dalam Anova, nilai signifikansi dilihat dari Sig. dalam tabel 14 dibandingkan dengan nilai  $\alpha$ . Nilai  $\alpha$  yang digunakan adalah 5%. Apabila Sig. <  $\alpha$  maka dapat disimpulkan model yang dibuat signifikan. Dengan tingkat kepercayaan 95% model prediktif yang dibuat akan merepresentasikan nilai sebenarnya.

Untuk evaluasi *decision tree* ditunjukkan dengan output dari RapidMiner pada Tabel 15. Nilai presisi untuk model yang dirancang adalah 84,50%. Menunjukkan bahwa model sudah fit.

Tabel 15.  
Confusion Matrix dari RapidMiner untuk Model *Decision Tree*

### PerformanceVector

```
PerformanceVector:
accuracy: 84.50% +/- 0.40% (micro average: 84.50%)
ConfusionMatrix:
True:  Lama   Normal  Cepat
Lama:  31     56      5
Normal: 1130  12716  1147
Cepat:  10     68     420
kappa: 0.238 +/- 0.024 (micro average: 0.238)
ConfusionMatrix:
True:  Lama   Normal  Cepat
Lama:  31     56      5
Normal: 1130  12716  1147
Cepat:  10     68     420
```

accuracy: 84.50% +/- 0.40% (micro average: 84.50%)

	true Lama	true Normal	true Cepat	class precision
pred. Lama	31	56	5	33.70%
pred. Normal	1130	12716	1147	84.81%
pred. Cepat	10	68	420	84.34%
class recall	2.65%	99.03%	26.72%	

## V. KESIMPULAN

### A. Kesimpulan

Berdasarkan hasil analisis, kesimpulan yang dapat diambil adalah sebagai berikut:

1. Lamanya waktu kapal melakukan bongkar/muat dipengaruhi oleh tiga variabel yaitu jenis ekspedisi, bendera, dan *volume*.
2. Hasil analisis menggunakan regresi berganda menghasilkan model seperti berikut:  

$$\text{Waktu} = 2,313 - 0,160 \text{ jenis ekspedisi} + 0,319 \text{ bendera} + 0,002 \text{ volume}$$
3. Evaluasi model menunjukkan bahwa model yang dibuat signifikan. Dengan tingkat kepercayaan 95% model prediktif yang dibuat akan merepresentasikan nilai sebenarnya. Untuk *decision tree*, evaluasi menunjukkan model yang dibuat sudah fit, dengan presisi 84,50%.
4. Dengan model regresi yang dibangun, pengusaha dalam hal ini pemilik kapal dapat memprediksi lamanya waktu yang dibutuhkan untuk bersandar di Pelabuhan Batu Ampar berdasarkan variabel yang sudah disebutkan sebelumnya.

### B. Saran

Adapun saran dalam penulisan laporan ini yang bisa ditingkatkan untuk penelitian berikutnya adalah sebagai berikut:

1. Hasil model hanya dapat menentukan prediksi lamanya kapal bersandar tetapi model belum dapat menentukan bagaimana meningkatkan kinerja layanan pelabuhan dengan mempercepat waktu bongkar/muat barang.
2. Karena keterbatasan data, model belum memperhitungkan maksimal muatan pelabuhan yang dapat menangani jumlah kapal secara bersamaan.

## DAFTAR PUSTAKA

- [1] BPS Kota Batam, Kota Batam Dalam Angka 2018. 2018.
- [2] BPS, *Laporan Survei Dwelling Time 2015*. 2016.
- [3] C. Vercellis, *Business Intelligence: Data mining and Optimization for Decision Making. Methods*. A John Wiley and Sons, Ltd, 2009.
- [4] U. M. Fayyad, G. Piatetsky-Shapiro, and P. Smyth, "From *Data mining* to Knowledge Discovery in Databases," *AI Mag.*, vol. 17, pp. 37–54, 1996.
- [5] P. D. Allison, *Multiple Regression : A Primer (Undergraduate Research Methods & Statistics in the Social Sciences)*, 1st ed. Pine Forge Press, 1998.
- [6] C. Hapter, "Multiple Regression," 2014.
- [7] S. K. Murthy, "Automatic Construction of Decision Trees from Data: A Multi-Disciplinary Survey," *Data Min. Knowl. Discov.*, vol. 2, no. 4, pp. 345–389, Dec. 1998.
- [8] E. Prasetyo, *Data mining : Konsep Dan Aplikasi Menggunakan Matlab*, 1st ed. Yogyakarta: Andi, 2012.