

**PERANCANGAN *FRAMEWORK* PENANGANAN GANGGUAN
BERBASIS *SUPERVISED LEARNING*
Studi Kasus: Penyedia Layanan Jaringan Pita Lebar**

TESIS

**Karya tulis sebagai salah satu syarat
untuk memperoleh gelar Magister dari
Institut Teknologi Bandung**

**Oleh
MOHAMMAD ISA
NIM: 23217118
(Program Studi Magister Teknik Elektro)**



**INSTITUT TEKNOLOGI BANDUNG
Januari 2020**

ABSTRAK

PERANCANGAN *FRAMEWORK* PENANGANAN GANGGUAN BERBASIS *SUPERVISED LEARNING*

Studi Kasus: Penyedia Layanan Jaringan Pita Lebar

Oleh

Mohammad Isa

NIM: 23217118

(Program Studi Magister Teknik Elektro)

Meluasnya adopsi TI dalam proses bisnis organisasi, menyebabkan ketergantungan pada layanan TI semakin tinggi. Gangguan layanan TI berisiko menyebabkan kerugian bisnis bagi organisasi yang besarnya proporsional dengan durasi gangguan. Karena itu, informasi prediksi durasi gangguan yang akurat semakin dibutuhkan untuk merespon gangguan dengan lebih baik. Prediksi durasi gangguan merupakan hal yang sangat kompleks karena dipengaruhi berbagai faktor. Namun, metode prediksi durasi gangguan saat ini masih terlalu sederhana dan subjektif karena sangat bergantung pada kemampuan operator manusia.

Penelitian ini bertujuan mengembangkan *framework* penanganan gangguan yang mampu memberikan informasi prediksi durasi gangguan dengan lebih akurat. Metode *supervised learning* merupakan bagian dari teknologi *machine learning* sehingga mesin belajar dari data pengalaman lampau. Metode *supervised learning* dikombinasikan ke dalam rancangan *framework* untuk meningkatkan akurasi prediksi serta mengurangi beban kerja manusia. Metode *supervised learning* dikombinasikan pada aktivitas kategorisasi dan prediksi durasi gangguan.

Berdasarkan penelitian ini, kombinasi *Bagging-Class Weighting-ETS* merupakan strategi klasifikasi terbaik untuk kategorisasi gangguan dalam kondisi *imbalanced* dengan nilai *F1-score* 0.5526 dan akurasi 97.21%. Sedangkan model *artificial neural network* (ANN) yang digunakan pada prediksi durasi awal gangguan mampu meningkatkan akurasi prediksi 18-19% daripada metode konvensional. Simulasi rancangan *framework* menunjukkan hasil yang baik, dengan *framework* dapat memberikan informasi prediksi durasi gangguan baik pada fase respon maupun fase perbaikan. Dibandingkan dengan proses bisnis penanganan gangguan, rancangan *framework* terbukti mampu meningkatkan efektivitas dan efisiensi proses penanganan gangguan. Sebagai justifikasi akhir, rancangan *framework* yang diusulkan telah dipublikasikan kepada tenaga ahli terkait dibidangnya dan mendapat penilaian yang sangat baik (85.56%).

Kata kunci: ITSM, ITIL, *machine learning*, prediksi durasi, *framework*, *artificial neural network*, jaringan pita lebar

ABSTRACT

DESIGNING SUPERVISED LEARNING BASED INCIDENT MANAGEMENT FRAMEWORK Case Study: Broadband Network Service Provider

By

Mohammad Isa

NIM: 23217118

(Master's Program in Electrical Engineering)

Widespread adoption of IT in the organization's business processes, causing dependence on IT services is increasingly high. Disruption of IT services risks causing business losses for organizations whose magnitude is proportional to the duration of the disruption. Therefore, accurate prediction of incident duration information is increasingly needed to better respond to IT incident. Incident duration prediction is very complex because it is influenced by various factors. However, the current prediction method for incident duration is still too simple and subjective because it is very dependent on the ability of the human operator.

This research aims to develop a incident handling framework that is able to provide more accurate information about incident duration prediction. Supervised learning method is part of machine learning technology so that machine could learn from past experience data. Supervised learning methods are combined into the framework design to improve prediction accuracy and reduce human workload. The supervised learning method is combined in the activity categorization and prediction of the incident duration.

Based on result of this research, the combination of Bagging-Class Weighting-ETS is the best classification strategy for categorizing incident in imbalanced conditions with an F1-score of 0.5526 and an accuracy of 97.21%. While the artificial neural network (ANN) model used in the initial prediction of the incident duration could improve the prediction accuracy of 18.43-19.41% compared to conventional methods. The framework design simulation shows good results, with the framework could provide information on the incident duration prediction both in the response phase and the repair phase. Compared with existing business process for incident handling, the framework design has been proven to be able to increase the effectiveness and efficiency of the incident handling process. As a final justification, the proposed framework design has been published to relevant experts in their field and received a very good rating (85.56%).

Keywords: ITSM, ITIL, machine learning, duration prediction, framework, artificial neural network, broadband network

**PERANCANGAN *FRAMEWORK* PENANGANAN GANGGUAN
BERBASIS *SUPERVISED LEARNING*
Studi Kasus: Penyedia Layanan Jaringan Pita Lebar**

Oleh
Mohammad Isa
NIM: 23217118
(Program Studi Magister Teknik Elektro)

Institut Teknologi Bandung

Menyetujui
Pembimbing

Tanggal

Dosen Pembimbing

(Dr. Ir. Albarda, M.T.)

PEDOMAN PENGGUNAAN TESIS

Tesis Magister yang tidak dipublikasikan terdaftar dan tersedia di Perpustakaan Institut Teknologi Bandung, dan terbuka untuk umum dengan ketentuan bahwa hak cipta ada pada penulis dengan mengikuti aturan HaKI yang berlaku di Institut Teknologi Bandung. Referensi kepustakaan diperkenankan dicatat, tetapi pengutipan atau peringkasan hanya dapat dilakukan seizin penulis dan harus disertai dengan kaidah ilmiah untuk menyebutkan sumbernya.

Sitasi hasil penelitian Tesis ini dapat di tulis dalam bahasa Indonesia sebagai berikut:

Isa, Mohammad. (2020): *Perancangan Framework Penanganan Gangguan Berbasis Supervised Learning*, Tesis Program Magister, Institut Teknologi Bandung.

dan dalam bahasa Inggris sebagai berikut:

Isa, Mohammad. (2020): *Designing Supervised Learning Based Incident Management Framework*, Master's Thesis, Institut Teknologi Bandung.

Memperbanyak atau menerbitkan sebagian atau seluruh tesis haruslah seizin Dekan Sekolah Pascasarjana, Institut Teknologi Bandung.

*Dipersembahkan kepada kedua orang tuaku, istriku Meilina,
kedua putraku Agha & Sakha, kedua mertuaku serta keluarga besarku tercinta
yang senantiasa mendukung lahir dan batin.*

KATA PENGANTAR

Puji dan syukur penulis panjatkan kehadiran Allah SWT, yang atas berkah, rahmat serta karunia-Nya penulis dapat menyelesaikan Tesis ini. Salawat serta salam tercurah kepada Rasulullah SAW beserta keluarga serta sahabatnya.

Penulis ingin mengucapkan rasa terima kasih sebesar-besarnya kepada pihak-pihak yang telah banyak memberikan bantuan serta dukungan selama proses penulisan Tesis ini, yaitu kepada:

1. Dr. Ir. Albarda, M.T., selaku pembimbing yang telah banyak mencurahkan waktu serta perhatian yang demikian banyak dalam memberikan bimbingan serta semangat dalam menyelesaikan Tesis ini.
2. PT. Perusahaan Listrik Negara (PLN) Persero yang telah menyelenggarakan program beasiswa serta memberikan dukungan materiil dalam membiayai perkuliahan serta penelitian sehingga penulis dapat menyelesaikan jenjang pendidikan S2.
3. Istri, anak serta kedua orang tua yang telah banyak memberikan dukungan moril dan semangat dalam menyelesaikan Tesis ini.
4. PT. Indonesia Comnets Plus (ICON+) yang telah menyediakan sumber daya, waktu serta pikirannya dalam membantu menyelesaikan Tesis ini.
5. Rekan-rekan Mahasiswa S2 Layanan Teknologi Informasi 2017 yang telah banyak memberikan bantuan, semangat serta inspirasi dalam menyelesaikan Tesis ini.
6. Serta semua pihak-pihak yang telah membantu, yang penulis tidak dapat sebutkan satu persatu.

Bandung, Januari 2020

Mohammad Isa

DAFTAR ISI

ABSTRAK	i
ABSTRACT	iii
HALAMAN PENGESAHAN	v
PEDOMAN PENGGUNAAN TESIS	vii
HALAMAN PERUNTUKAN	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR LAMPIRAN	xvii
DAFTAR GAMBAR DAN ILUSTRASI	xix
DAFTAR TABEL	xxi
DAFTAR SINGKATAN DAN LAMBANG	xxiii
Bab I Pendahuluan	1
I.1 Latar Belakang	1
I.2 Rumusan Masalah	4
I.3 Tujuan Penelitian	5
I.4 Manfaat Penelitian	5
I.5 Batasan Masalah	5
I.6 Sistematika Penulisan	5
Bab II Tinjauan Pustaka	7
II.1 <i>Incident Management</i> ITIL	7
II.1.1 Identifikasi Gangguan	9
II.1.2 Pencatatan Gangguan	9
II.1.3 Kategorisasi Gangguan	9
II.1.4 Prioritisasi Gangguan	10
II.1.5 Diagnosis Awal	10
II.1.6 Eskalasi Gangguan	10
II.1.7 Investigasi dan Diagnosis	11
II.1.8 Resolusi dan Perbaikan	11
II.1.9 Penyelesaian Gangguan	11
II.2 <i>Supervised Learning</i>	12
II.2.1 <i>Extremely Randomized Trees</i>	13
II.2.2 <i>Artificial Neural Network (ANN)</i>	14
II.2.3 <i>Klasifikasi Imbalanced</i>	16
II.2.4 <i>Supervised Learning</i> pada Kategorisasi Gangguan	17
II.2.5 <i>Supervised Learning</i> pada Prediksi Durasi Gangguan	18
Bab III Metodologi Penelitian	21
III.1 <i>Design Science Research Methodology for Information System (DSRM-IS)</i>	21
III.1.1 Identifikasi Masalah dan Motivasi	21
III.1.2 Tujuan dari Solusi Masalah	22

III.1.3	Desain dan Pengembangan.....	22
III.1.4	Pengujian dan Evaluasi.....	23
III.1.5	Komunikasi.....	23
III.2	<i>Cross-Industry Standard Process for Data Mining (CRISP-DM)</i>	24
III.2.1	Pemahaman Bisnis.....	25
III.2.2	Pemahaman Data	25
III.2.3	Persiapan Data	25
III.2.4	Pemodelan	25
III.2.5	Evaluasi & Implementasi.....	26
Bab IV	Analisis & Perancangan.....	27
IV.1	Fault Management PT. ICON+	27
IV.2	Analisis Proses Bisnis Penanganan Gangguan PT. ICON+	29
IV.3	Analisis Kesenjangan Proses Bisnis Penanganan Gangguan	35
IV.4	Fase Penanganan Gangguan	37
IV.5	Hubungan Antara Aktivitas Penanganan Gangguan dengan Durasi Gangguan.....	38
IV.6	Rancangan <i>Framework</i> Penanganan Gangguan	39
IV.6.1	Kategorisasi Gangguan.....	40
IV.6.2	Prioritisasi Gangguan	40
IV.6.3	Prediksi Durasi Gangguan	42
IV.6.4	Penjadwalan.....	42
IV.6.5	Pembaruan Prediksi Durasi Gangguan	44
IV.7	Model Kategorisasi Gangguan dengan <i>Machine learning</i>	45
IV.7.1	Pemahaman Bisnis.....	45
IV.7.2	Pemahaman Data	45
IV.7.3	Persiapan Data	51
IV.7.4	Pemodelan	52
IV.7.5	Evaluasi Model	56
IV.8	Model Prediksi Durasi Gangguan dengan <i>Machine learning</i>	58
IV.8.1	Pemahaman Bisnis.....	58
IV.8.2	Pemahaman Data	58
IV.8.3	Persiapan Data	65
IV.8.4	Pemodelan	66
IV.8.5	Evaluasi Model	68
Bab V	Implementasi & Evaluasi.....	71
V.1	Simulasi <i>Framework</i> Prediksi Durasi Gangguan	71
V.1.1	Simulasi Aktivitas Kategorisasi Gangguan	71
V.1.2	Simulasi Aktivitas Prioritisasi Gangguan.....	73
V.1.3	Simulasi Aktivitas Prediksi Durasi Gangguan Awal.....	74
V.1.4	Simulasi Aktivitas Penjadwalan	76
V.1.5	Simulasi Aktivitas Update Prediksi Durasi Gangguan.....	78
V.2	Hasil Uji Justifikasi Tenaga Ahli.....	82
V.3	Evaluasi Rancangan dan Hasil Pengujian	87

Bab VI	Kesimpulan dan Saran.....	89
VI.1	Kesimpulan	89
VI.2	Saran.....	89
DAFTAR PUSTAKA		91
LAMPIRAN.....		95

DAFTAR LAMPIRAN

Lampiran A Hasil Model <i>Bagging-Weighting-ETS</i> dengan Data Kategorisasi Gangguan.....	97
A1. <i>Decision Tree</i> ke-1 (Bag #1 - Tree #1).....	97
A2. <i>Decision Tree</i> ke-100 (Bag #5 - Tree #20).....	98
A3. <i>Decision Tree</i> ke-101 (Bag #6 - Tree #1).....	99
A4. <i>Decision Tree</i> ke-200 (Bag #10 - Tree #20).....	100
Lampiran B Hasil Konfigurasi ANN untuk Model Prediksi Durasi Gangguan.	101
B1. Konfigurasi ANN Model Prediksi Durasi Fase Respon	101
B2. Konfigurasi ANN Model Prediksi Durasi Fase Perbaikan	103
Lampiran C Formulir Verifikasi & Validasi Justifikasi Tenaga Ahli.....	111

DAFTAR GAMBAR DAN ILUSTRASI

Gambar I.1 Grafik pertumbuhan jumlah layanan dan jumlah gangguan salah satu operator jaringan pita lebar Indonesia tahun 2015-2018.....	2
Gambar II.2 Proses <i>incident management</i> ITILv3 (Menken et al., 2009)	8
Gambar II.3 Ilustrasi struktur <i>Extremely Randomized Trees</i> (Geurts et al., 2005)13	
Gambar II.4 Ilustrasi struktur <i>Multi Layer Perceptron</i> (Kotu & Deshpande, 2015)	15
Gambar III.1 Tahapan metodologi DSRM-IS (Peffer et al., 2007).....	21
Gambar III.2 Diagram <i>framework</i> CRISP-DM.....	24
Gambar IV.1 Peta wilayah operasional PT. ICON+	27
Gambar IV.2 <i>Stakeholder diagram</i> proses bisnis penanganan gangguan PT. ICON+	28
Gambar IV.3 BPMN <i>As-Is</i> proses bisnis penanganan gangguan PT. ICON+	33
Gambar IV.4 BPMN <i>As-Is</i> sub-proses pre-analisis gangguan	34
Gambar IV.5 BPMN <i>As-Is</i> sub-proses analisis gangguan	34
Gambar IV.6 Garis waktu proses penanganan gangguan	38
Gambar IV.7 Diagram rancangan <i>framework</i> penanganan gangguan	39
Gambar IV.8 Ilustrasi struktur model kategorisasi gangguan.....	56
Gambar IV.9 Grafik tingkat kepentingan variabel bebas model kategorisasi	57
Gambar IV.10 Plot distribusi lognormal terhadap data durasi gangguan	64
Gambar IV.11 Struktur ANN model prediksi durasi gangguan (a) fase respon dan (b) fase perbaikan.....	67

DAFTAR TABEL

Tabel III.1 Detail Tahap Identifikasi Masalah & Motivasi.....	22
Tabel III.2 Detail Tahap Tujuan dari Solusi Masalah.....	22
Tabel III.3 Detail Tahap Desain dan Pengembangan.....	23
Tabel III.4 Detail Tahap Demonstrasi.....	23
Tabel IV.1 Analisis kesenjangan proses bisnis penanganan gangguan PT. ICON+	35
Tabel IV.2 Pemetaan tingkat urgensi gangguan	41
Tabel IV.3 Pemetaan tingkat dampak gangguan	41
Tabel IV.4 Matriks prioritisasi gangguan	42
Tabel IV.5 Ilustrasi penjadwalan berdasarkan prioritas gangguan	44
Tabel IV.6 Deskripsi data model kategorisasi gangguan.....	47
Tabel IV.7 Distribusi frekuensi kategori gangguan setelah <i>filtering</i>	49
Tabel IV.8 Distribusi frekuensi setiap variabel gangguan	49
Tabel IV.9 Hasil uji keterkaitan variabel bebas dan variabel terikat	51
Tabel IV.10 Hasil pengujian strategi klasifikasi untuk kasus <i>imbalanced</i>	54
Tabel IV.11 Konfigurasi parameter model dengan metode <i>grid search</i>	55
Tabel IV.12 <i>Confusion matrix</i> uji model pada data validasi.....	56
Tabel IV.13 Performa hasil uji model pada data validasi	57
Tabel IV.14 Deskripsi data model prediksi durasi gangguan	60
Tabel IV.15 Proses penyaringan data durasi gangguan	62
Tabel IV.16 <i>Quartile range</i> data durasi gangguan (dalam satuan jam).....	63
Tabel IV.17 Analisis statistik data durasi gangguan.....	63
Tabel IV.18 Hasil uji Welch's ANOVA data durasi gangguan	65
Tabel IV.19 Perbandingan evaluasi model prediksi durasi gangguan	69
Tabel V.1 Hasil simulasi model kategorisasi gangguan pada data buatan	72
Tabel V.2 Hasil simulasi model prioritisasi gangguan pada data buatan	73
Tabel V.3 Hasil simulasi model prediksi durasi fase respon pada data buatan	75
Tabel V.4 Hasil simulasi model penjadwalan gangguan pada data buatan	77
Tabel V.5 Hasil simulasi <i>update</i> model penjadwalan akibat gangguan baru pada kelompok ROJB#2	79
Tabel V.6 Hasil simulasi model <i>update</i> prediksi durasi fase perbaikan pada data buatan.....	81
Tabel V.7 Hasil simulasi <i>update</i> model penjadwalan akibat <i>update</i> prediksi durasi	81
Tabel V.8 Pengolahan data justifikasi tenaga ahli menggunakan skala Likert.....	84
Tabel V.9 Analisis perbandingan proses bisnis penanganan gangguan berjalan dengan rancangan <i>framework</i> penanganan gangguan	87
Tabel B1.1 Konfigurasi <i>Weight Input Layer – Hidden Layer</i>	101
Tabel B1.2 Konfigurasi <i>Bias Hidden Layer</i>	101
Tabel B1.3 Konfigurasi <i>Weight Hidden Layer – Output Layer</i>	102
Tabel B1.4 Konfigurasi <i>Bias Output Layer</i>	102
Tabel B2.1 Konfigurasi <i>Weight Input Layer – Hidden Layer</i>	103
Tabel B2.2 Konfigurasi <i>Bias Hidden Layer</i>	108
Tabel B2.3 Konfigurasi <i>Weight Hidden Layer – Output Layer</i>	109
Tabel B2.4 Konfigurasi <i>Bias Output Layer</i>	109

DAFTAR SINGKATAN DAN LAMBANG

SINGKATAN	Nama	Pemakaian pertama kali pada halaman
ANN	<i>Artificial Neural Network</i>	4
BPMN	<i>Business Process Model and Notation</i>	22
CART	<i>Classification and Regression Tree</i>	13
CRISP-DM	<i>Cross-Industry Standard Process for Data Mining</i>	23
CRM	<i>Customer Relationship Management</i>	29
DMAIC	<i>Design, Measure, Analyze, Improve and Control</i>	24
DSRM-IS	<i>Design Science Research Method for Information System</i>	21
ETS	<i>Extremely Randomized Trees</i>	13
FMS	<i>Fault Management System</i>	29
FSM	<i>Field Support Management</i>	29
IP	<i>Internet Protocol</i>	45
IQR	<i>Inter-Quartile Range</i>	62
ITIL	<i>Information Technology Infrastructure Library</i>	3
ITSM	<i>Information Technology Service Management</i>	2
KNN	<i>K-Nearest Neighbor</i>	18
MAE	<i>Mean Absolute Error</i>	68
MAPE	<i>Mean Absolute Percentage Error</i>	19
MLP	<i>Multi Layer Perceptron</i>	14
NMS	<i>Network Monitoring System</i>	9
OLS	<i>Ordinary Least Square</i>	19
RMSE	<i>Root Mean Squared Error</i>	19
ROS	<i>Random Over-Sampling</i>	17
SEMMA	<i>Sample, Explore, Modify, Model and Assess</i>	24
SLA	<i>Service Level Agreement</i>	2
SMOTE	<i>Synthetic Minority Over-sampling Technique</i>	17
SVM	<i>Support Vector Machine</i>	19
LAMBANG		
At	<i>Nilai aktual</i>	68
FN	<i>Jumlah positif terprediksi negatif</i>	53
FP	<i>Jumlah negatif terprediksi positif</i>	53
F_t	<i>Nilai prediksi</i>	68
i	<i>Urutan penanganan gangguan</i>	43
n	<i>Jumlah observasi</i>	68
T_{akhir}	<i>Prediksi durasi akhir</i>	43

LAMBANG	Nama	Pemakaian pertama kali pada halaman
T_{awal}	<i>Prediksi durasi awal</i>	43
T_{tunggu}	<i>Waktu tunggu penanganan gangguan</i>	43
TN	<i>Jumlah negatif terprediksi negatif</i>	53
TP	<i>Jumlah positif terprediksi positif</i>	53


Bab I Pendahuluan

I.1 Latar Belakang

Industri telekomunikasi merupakan salah satu sektor industri yang terus berkembang di Indonesia. Jumlah penduduk yang besar, pertumbuhan ekonomi yang stabil serta tingginya kebutuhan media telekomunikasi menjadi alasan terus berkembangnya industri telekomunikasi nasional. Kebutuhan media telekomunikasi tersebut diprediksi akan terus meningkat seiring dengan meningkatnya adopsi teknologi digital oleh berbagai industri di tanah air. Jaringan pita lebar tetap (*fixed-broadband*) adalah media telekomunikasi yang akan menjadi tulang punggung di masa depan selain jaringan pita lebar bergerak (*mobile-broadband*). Menyadari peran strategis jaringan broadband sebagai salah satu motor penggerak pembangunan tanah air di masa mendatang. Pemerintah telah menetapkan Rencana Jaringan Pita Lebar Indonesia 2014-2019 melalui Perpres No.96 Tahun 2014 (“PERATURAN PRESIDEN REPUBLIK INDONESIA NOMOR 96 TAHUN 2014 TENTANG RENCANA PITALEBAR INDONESIA 2014 – 2019,” 2014). Berdasarkan Perpres tersebut, visi dari Pita lebar Indonesia adalah: “**Mendukung Indonesia menjadi negara maju melalui pengembangan dan pemanfaatan *broadband* sebagai *meta-infrastructure*”**. Dalam Perpres tersebut, pemerintah sekaligus menargetkan pencapaian penetrasi jaringan pita lebar tetap sebesar 30% dari total populasi Indonesia.

Dukungan pemerintah melalui Perpres No.96 Tahun 2014 secara tidak langsung turut dirasakan oleh operator jaringan pita lebar melalui pertumbuhan jumlah pengguna layanan pita lebar dari tahun ke tahun. Peningkatan jumlah pengguna layanan pita lebar tersebut ikut berdampak pada meningkatnya jumlah gangguan yang dialami oleh operator jaringan. Perbandingan jumlah pengguna layanan dengan jumlah laporan tiket gangguan (termasuk keluhan) yang diterima dari salah satu operator jaringan pita lebar tetap ditampilkan pada Gambar I.1. Grafik tersebut menunjukkan bahwa rata-rata pertumbuhan jumlah pengguna layanan antara tahun 2015 hingga 2018 mencapai angka 29%. Namun pertumbuhan

jumlah pengguna layanan tersebut turut diiringi dengan peningkatan jumlah laporan tiket gangguan sebanyak rata-rata 21% pada periode yang sama.



Gambar I.1 Grafik pertumbuhan jumlah layanan dan jumlah gangguan salah satu operator jaringan pita lebar Indonesia tahun 2015-2018

Meningkatnya jumlah laporan gangguan akan berdampak pada meningkatnya beban kerja operator penyedia layanan. Dalam jangka pendek hal ini dapat mempengaruhi kualitas layanan yang diterima oleh pengguna layanan. Terutama dalam hal penanganan laporan gangguan yang berpotensi untuk tidak tertangani dengan baik. Sedangkan dalam jangka menengah, masalah ini dapat mengakibatkan tidak tercapainya *Service Level Agreement* (SLA) terkontrak yang dapat mempengaruhi tingkat retensi pelanggan secara jangka panjang.

Seiring dengan meningkatnya ketergantungan proses bisnis organisasi terhadap layanan TI, sudah sewajarnya bila kestabilan infrastruktur layanan TI menjadi salah satu perhatian utama. *IT Service Management* (ITSM) menjadi strategi yang telah banyak berhasil diadopsi organisasi dalam menjawab tantangan tersebut. Namun menjaga kestabilan infrastruktur layanan TI berbekal ITSM tetap membutuhkan alokasi sumber daya manusia yang tidak sedikit (Kubiak & Rass, 2018). Rata-rata organisasi menggunakan 70% biaya belanja TI untuk operasional serta pemeliharaan infrastruktur layanan TI (Orlov, 2005), termasuk

biaya SDM. Oleh sebab itu, beberapa penelitian mulai mengimplementasikan teknologi ke dalam proses ITSM untuk mengurangi beban kerja SDM, salah satunya yaitu teknologi *machine learning*.

Peranan TI semakin besar dalam setiap organisasi, sehingga TI bertransformasi dari penyedia teknologi menjadi partner strategis organisasi (Bartolini & Sallé, 2004). Besarnya peranan TI dalam organisasi menyebabkan gangguan pada penyediaan layanan TI berdampak besar bagi bisnis organisasi. Namun demikian, gangguan layanan merupakan hal yang tidak dapat dihindari dalam kegiatan penyediaan layanan TI. Berdasarkan *IT Infrastructure Library* (ITIL), gangguan didefinisikan sebagai interupsi atau penurunan kualitas layanan TI yang tidak direncanakan (Jouravlev et al., 2019).

Setiap gangguan memiliki atribut informasi yaitu durasi gangguan yang menyatakan interval waktu yang dibutuhkan sejak gangguan terdeteksi atau dilaporkan hingga gangguan teratasi (Camara, Moshe, Li, Pereira, & Ben-akiva, 2018; Guan, Liu, Yin, & Zhang, 2010; W. Wang, Chen, & Bell, 2005). Beberapa peneliti sebelumnya telah menyatakan bahwa dampak yang diakibatkan dari suatu gangguan proporsional dengan durasi gangguan tersebut (Bartolini & Sallé, 2004; Kieninger et al., 2013; Saarelainen, 2016; Zambon, Etalle, Wieringa, & Hartel, 2011). Dengan kata lain, makin lama gangguan layanan TI tertangani, makin besar pula dampak bisnis yang ditimbulkan kepada organisasi. Bagi pengguna layanan, durasi gangguan berpengaruh terhadap dampak bisnis yang dialami organisasinya. Sedangkan bagi penyedia layanan, durasi gangguan berpengaruh terhadap pencapaian SLA yang disepakati dengan pengguna. Oleh karena itu, prediksi durasi gangguan merupakan informasi penting baik bagi pengguna layanan TI maupun penyedia layanan TI.

Terdapat dua metode untuk memprediksi durasi gangguan yang umum digunakan saat ini. Metode pertama yaitu menggunakan target durasi penyelesaian gangguan berdasarkan kategori atau prioritas gangguan tersebut (Jouravlev et al., 2019). Namun metode ini tidak memperhitungkan berbagai faktor yang dapat

mempengaruhi durasi gangguan. Metode kedua yaitu menggunakan intuisi, skill serta pengalaman petugas gangguan (Valenti, Lelli, & Cucina, 2010). Namun metode ini berpotensi menghasilkan informasi yang tidak akurat dan tidak konsisten karena sangat subjektif pada kemampuan masing-masing individu. Oleh karena itu dibutuhkan alternatif metode prediksi durasi gangguan yang lebih baik dalam suatu *framework* penanganan gangguan layanan TI.

Kategori gangguan merupakan salah satu faktor utama yang mempengaruhi durasi gangguan layanan TI (Caldeira & Brito, 2008). Setiap jenis gangguan membutuhkan penanganan yang berbeda sehingga durasi setiap jenis gangguannya pun akan berbeda. Namun demikian, untuk menentukan kategori gangguan sebelum dapat memprediksi durasi gangguan tersebut merupakan masalah tersendiri. Terlebih pada kondisi dengan frekuensi salah satu jenis gangguan lebih dominan ketimbang jenis gangguan lainnya atau disebut *imbalanced*. Kondisi ini dapat mempengaruhi akurasi prediksi, dimana mesin akan cenderung memprediksi jenis gangguan yang dominan tersebut dan mengabaikan jenis gangguan lainnya. Sehingga dibutuhkan strategi khusus untuk menangani jenis prediksi dengan kondisi *imbalanced* ini.

I.2 Rumusan Masalah

Berdasarkan paparan latar belakang diatas, diperlukan metode alternatif yang dapat memberikan informasi prediksi durasi gangguan dengan lebih akurat dalam konteks penanganan gangguan layanan TI. Dengan demikian, rumusan masalah pada penelitian *framework* penanganan gangguan berbasis *supervised learning* adalah:

1. Strategi klasifikasi apa yang tepat dikombinasikan pada aktivitas kategorisasi gangguan layanan TI?
2. Apakah model *artificial neural network* (ANN) dapat meningkatkan akurasi prediksi durasi awal gangguan layanan TI?
3. Apakah rancangan *framework* penanganan gangguan dapat meningkatkan efektivitas dan efisiensi proses penanganan gangguan?

I.3 Tujuan Penelitian

Tujuan yang ingin dicapai pada penelitian *framework* penanganan gangguan berbasis *supervised learning* adalah:

1. Menganalisis strategi klasifikasi terbaik untuk aktivitas kategorisasi gangguan layanan TI.
2. Menganalisis model ANN sebagai alternatif metode prediksi durasi awal gangguan layanan TI.
3. Merancang *framework* penanganan gangguan yang dapat memberikan informasi prediksi durasi gangguan yang lebih akurat dibandingkan dengan metode konvensional.

I.4 Manfaat Penelitian

Manfaat yang diharapkan dari penelitian *framework* penanganan gangguan berbasis *supervised learning* adalah rancangan *framework* yang diusulkan dapat diadopsi pada proses bisnis penanganan gangguan berjalan sehingga dapat memberikan informasi prediksi durasi gangguan yang sangat dibutuhkan oleh pengguna layanan. Selain itu, adopsi rancangan *framework* ke dalam proses bisnis berjalan diharapkan juga dapat membantu mempermudah proses kerja operator penanganan gangguan.

I.5 Batasan Masalah

Batasan masalah pada penelitian *framework* penanganan gangguan berbasis *supervised learning* adalah pada prediksi durasi penanganan gangguan layanan TI dengan layanan jaringan pita lebar sebagai studi kasus penelitian.

I.6 Sistematika Penulisan

Laporan tesis ini disusun menjadi enam bab sebagai berikut.

1. Bab I PENDAHULUAN memuat latar belakang serta motivasi dari penyusunan tesis ini serta permasalahan penelitian yang ada. Perumusan masalah, tujuan penelitian, batasan masalah serta urutan penyajian juga disampaikan pada bab ini.


2. Bab II DASAR TEORI memuat dasar teori dan pengetahuan yang menjadi landasan dalam penelitian ini.
3. Bab III METODOLOGI PENELITIAN memuat metodologi dan langkah-langkah yang dilakukan dalam melakukan penelitian ini.
4. Bab IV ANALISIS & PERANCANGAN memuat hasil analisis terkait objek penelitian serta rancangan solusi dari masalah penelitian.
5. Bab VI IMPLEMENTASI & EVALUASI memuat simulasi, pengujian serta hasil evaluasi terhadap rancangan solusi yang telah diusulkan.
6. Bab VII KESIMPULAN memuat kesimpulan dari kegiatan yang dilakukan pada penelitian ini.

Bab II Tinjauan Pustaka

II.1 Incident Management ITIL

IT Service Management (ITSM) didefinisikan sebagai sekumpulan kemampuan organisasi untuk menyediakan nilai tambah kepada pelanggan dalam bentuk layanan. ITSM memberi panduan bagaimana mengubah kemampuan dan sumber daya yang dimiliki organisasi menjadi layanan yang memiliki nilai. *IT Infrastructure Library (ITIL)* merupakan *framework* ITSM yang paling banyak dikenal di kalangan eksekutif TI dan bahkan telah banyak menjadi basis acuan *framework* sejenis lainnya (Kubiak & Rass, 2018). Berdasarkan ITILv3, siklus hidup layanan dibagi menjadi lima, yaitu *service strategy*, *service design*, *service transition*, *service operation* dan *continual service improvement*.

Incident management ITIL merupakan salah satu proses yang menjadi bagian dari ITIL *service operation*. *Incident management* adalah proses dari *framework* ITIL yang paling matang dan banyak menjadi fokus untuk diadopsi terlebih dulu karena dampak bisnisnya bagi organisasi dapat dirasakan dengan cepat. Fokus utama dari proses *incident management* adalah menormalkan kembali operasional layanan dalam waktu sesingkat mungkin serta meminimalisir dampaknya terhadap operasional bisnis, dengan demikian tingkat kualitas dan availabilitas layanan dapat selalu terjaga. Berdasarkan ITIL, *incident management* tersusun atas sembilan aktivitas yang ditunjukkan pada Gambar II.2 dan dijelaskan sebagai berikut (Menken, Blokdiik, & Malone, 2009).



Gambar II.1 Proses *incident management* ITILv3 (Menken et al., 2009)

II.1.1 Identifikasi Gangguan

Identifikasi gangguan merupakan proses awal dari *incident management* ITIL yaitu untuk mengidentifikasi potensi gangguan atau kejadian gangguan pada layanan yang diberikan. Setiap komponen pendukung layanan harus dapat dimonitor seluruhnya agar gangguan ataupun potensi gangguan dapat teridentifikasi sedini mungkin sehingga proses *incident management* dapat dimulai secepatnya. Idealnya, gangguan atau potensi gangguan harus dapat diselesaikan sebelum berdampak kepada bisnis. Beberapa sumber dapat digunakan untuk identifikasi gangguan yaitu laporan pengguna layanan kepada *Service Desk*, staf TI, sistem monitoring (NMS) dan penyedia pihak ketiga.

II.1.2 Pencatatan Gangguan

Setelah gangguan teridentifikasi, proses selanjutnya adalah untuk melakukan pencatatan gangguan. Setiap gangguan diberikan nomer identifikasi yang unik serta label waktu yang jelas. Informasi seputar gangguan lainnya ikut disematkan untuk memberikan konteks pada setiap gangguan. Informasi tersebut antara lain adalah kategori gangguan, urgensi gangguan, dampak gangguan, prioritas gangguan, status gangguan, dan lain-lain. Setiap catatan yang dibuat harus mengacu pada spesifik satu gangguan untuk memudahkan proses audit. Catatan gangguan ini selanjutnya akan diperbaharui disetiap proses selanjutnya dari *incident management*. Proses pencatatan gangguan dapat menjadi masukan bagi proses lain dari ITSM, seperti *problem management*, sehingga harus dilakukan secara konsisten.

II.1.3 Kategorisasi Gangguan

Kategori gangguan merupakan salah satu informasi yang disematkan pada proses pencatatan awal gangguan. Umumnya kategori gangguan dapat terdiri dari tiga sampai empat tingkat rincian kategori. Penyusunan kategori gangguan tidak memiliki acuan yang pasti sehingga setiap organisasi menyusunnya berbeda-beda sesuai dengan interpretasi masing-masing. Namun kategori gangguan harus dikaji atau dievaluasi secara berkala untuk memastikan relevansinya.

II.1.4 Prioritisasi Gangguan

Prioritisasi gangguan berdasarkan ITIL, merupakan salah satu aspek penting dalam proses pencatatan awal gangguan. Prioritisasi gangguan menentukan bagaimana setiap gangguan harus ditangani pada proses *incident management* selanjutnya. Prioritisasi gangguan dilakukan dengan mengevaluasi setiap gangguan berdasarkan kriteria urgensi dan kriteria dampak. Urgensi gangguan menunjukkan tingkat sejauh mana penyelesaian gangguan dapat ditunda. Sedangkan dampak menunjukkan tingkat sejauh mana gangguan berdampak terhadap bisnis organisasi. Selanjutnya, hasil evaluasi keduanya dipetakan ke prioritisasi matriks yang telah disepakati oleh semua pihak yang terlibat dalam proses *incident management* organisasi. Target penyelesaian gangguan untuk setiap tingkat prioritas umumnya ikut disepakati bersama dengan matriks prioritisasi tersebut.

II.1.5 Diagnosis Awal

Proses selanjutnya adalah melakukan analisis awal terhadap gangguan yang telah dilakukan pencatatan. Umumnya proses ini dilakukan selagi pengguna layanan masih terhubung dengan operator *Service Desk*. Informasi mengenai gejala gangguan yang dirasakan oleh pengguna serta pengecekan status layanan melalui sistem dikumpulkan. Informasi gangguan sejenis dari historis penanganan gangguan sebelumnya dapat digunakan untuk membantu proses ini. Bila memungkinkan, gangguan akan diselesaikan pada proses diagnosis awal. Namun bila tidak, penyedia layanan perlu menginformasikan nomor referensi gangguan serta langkah-langkah penanganan gangguan selanjutnya kepada pengguna layanan.

II.1.6 Eskalasi Gangguan

Eskalasi merupakan proses menaikkan informasi gangguan ke tingkat penanganan gangguan selanjutnya. Berdasarkan ITIL, eskalasi gangguan dapat dibagi menjadi dua yaitu eskalasi fungsional dan eskalasi hierarki. Bilamana operator *Service Desk* tidak dapat atau dirasa tidak dapat menyelesaikan gangguan sesuai waktu yang disepakati, maka dilakukan eskalasi fungsional yaitu gangguan dialihkan

kepada bagian khusus yang menangani gangguan lebih lanjut. Sedangkan eskalasi hierarki adalah meneruskan informasi gangguan ke struktur organisasi penanganan gangguan yang lebih tinggi tingkatnya. Pada umumnya eskalasi jenis ini dilakukan untuk gangguan-gangguan dengan tingkat urgensi atau tingkat dampak tinggi.

II.1.7 Investigasi dan Diagnosis

Proses ini merupakan tahapan lebih lanjut dan lebih detail dari proses investigasi awal. Pada proses ini penyedia layanan berusaha memahami penyebab, pemicu serta kronologis terjadinya gangguan. Dampak gangguan terhadap layanan diketahui lebih lengkap setelah melalui analisis pada proses ini. Detail hasil investigasi, diagnosis dan analisis pada proses ini wajib diperbaharui pada catatan gangguan yang dibuat sebelumnya. Dokumentasi gangguan yang lengkap memudahkan proses audit serta menyediakan informasi untuk proses penanganan gangguan selanjutnya.

II.1.8 Resolusi dan Perbaikan

Hasil analisis pada proses investigasi dan diagnosis sebelumnya harus mengarah pada langkah resolusi yang diperlukan untuk penyelesaian gangguan. Langkah resolusi yang ditetapkan harus dapat diaplikasikan dan diujicoba dengan terkontrol. Proses ini dapat melibatkan berbagai pihak seperti tim lapangan, kelompok TI khusus, pihak ketiga maupun pengguna layanan sendiri. Setelah resolusi dan perbaikan selesai, pengujian terhadap layanan terganggu wajib dilakukan oleh penyedia layanan untuk memastikan seluruh layanan telah kembali beroperasi normal. Setiap langkah resolusi, perbaikan dan pengujian harus diperbaharui secara berurut dalam catatan gangguan.

II.1.9 Penyelesaian Gangguan

Proses ini merupakan tahap akhir dari proses *incident management* ITIL. Pada proses ini *Service Desk* melakukan konfirmasi status layanan kepada setiap pengguna layanan terdampak baik melalui telepon, pesan singkat maupun surat elektronik. Setelah pengguna layanan terkonfirmasi, sebelum gangguan ditutup,

catatan gangguan harus dipastikan memiliki informasi lengkap terkait gangguan tersebut. Pembaruan kategori gangguan di setiap tingkat kategori termasuk salah satu informasi penting yang harus dipastikan tersedia dan terbaharui. Selain itu, identifikasi permasalahan berulang juga dapat dilakukan pada proses ini. Dengan demikian, keluaran dari proses *incident management* ITIL akan menjadi masukan bagi proses *problem management* ITIL.

II.2 *Supervised Learning*

Tuntutan pengguna agar setiap layanan diberikan dengan lebih cepat, tepat dan efisien menyebabkan perkembangan yang pesat dalam digitalisasi proses bisnis. Perkembangan teknologi mikroelektronik dan mikroprosesor telah menyebabkan komputerisasi berbagai perangkat dalam bentuk sensor dan perangkat pintar. Digitalisasi proses dan komputerisasi tersebut menyebabkan ledakan dalam jumlah data yang berkaitan dengan keseharian aktivitas. Pemanfaatan data yang tersedia dalam jumlah besar dalam menganalisis dan membantu menyelesaikan masalah memancing ketertarikan banyak peneliti pada bidang analisis data dan *machine learning*.


Machine learning dapat didefinisikan sebagai proses mengekstraksi pola dari data secara otomatis yang dilakukan oleh mesin (Kelleher, Namee, & D'Arcy, 2015). Siklus yang dilakukan *machine learning* tidak sekedar belajar dan mengekstraksi pengetahuan dari data tersedia, tetapi juga menggunakan pengetahuan yang telah didapat serta memperbarui pengetahuan tersebut seiring dengan bertambahnya pengalaman (Boutaba et al., 2018). Dengan demikian penyelesaian masalah kompleks yang sebelumnya harus diprogramkan secara eksplisit ke dalam mesin melalui sekumpulan algoritma dan aturan, dapat digantikan dengan proses *machine learning* (Ethem Alpaydin, 2016). Analisis data prediktif merupakan salah satu permasalahan yang dapat diselesaikan menggunakan *machine learning* (Kelleher et al., 2015).

Supervised learning adalah salah satu metode pembelajaran *machine learning* dengan variabel terikat dari data yang digunakan dalam proses pembelajaran telah

memiliki label (Dusia, Member, & Sethi, 2016; Sammut & Webb, 2017). Berbeda dengan *unsupervised learning*, yang mesin belajar dari data *training* yang belum memiliki label (Dusia et al., 2016; Sammut & Webb, 2017). Problem klasifikasi dan regresi merupakan contoh problem yang dapat dipecahkan menggunakan pendekatan *supervised learning* (Boutaba et al., 2018). Pada problem klasifikasi, jenis data pada variabel terikatnya adalah data kategori. Sementara, pada problem regresi jenis data pada variabel terikatnya adalah data kontinu (Abbott, 2014).

II.2.1 *Extremely Randomized Trees*

Extremely randomized trees (ETS) atau *extra trees* merupakan salah satu bentuk algoritma pengembangan dari *decision tree* standar (CART) dalam bentuk *ensemble*. Algoritma ini diperkenalkan pertama kali pada penelitian (Geurts, Ernst, & Wehenkel, 2005) dengan tujuan untuk mengurangi varian dari model CART (*Classification and Regression Tree*) yang diakibatkan dari penentuan nilai *cut-point* saat pembentukan *node*. Sebagaimana diilustrasikan pada Gambar II.3 dibawah, ETS tersusun dari banyak *decision tree*. Masing-masing *decision tree* dibentuk dari subsampel data yang diambil dari seluruh data *training* (sampel). Hasil dari setiap *decision tree* selanjutnya akan digabungkan untuk dilakukan pengambilan keputusan akhir melalui rata-rata (*averaging*).




Gambar II.2 Ilustrasi struktur *Extremely Randomized Trees* (Geurts et al., 2005)

Algoritma ini memiliki kemiripan dengan algoritma *random forest* dalam hal metode *sampling* data yang akan digunakan dalam membentuk model *ensemble* serta struktur *tree* majemuk yang membentuk sekumpulan *tree* (hutan). Perbedaannya dengan *random forest*, algoritma ini menggunakan keseluruhan data pembelajaran untuk membentuk setiap *tree* tanpa metode *bootstrapping*. Selain itu, penentuan *cut-point* saat membentuk *node* dilakukan secara acak (Subramanian, 2015). Dengan pendekatan tersebut, *extremely randomized trees* dapat menghasilkan akurasi yang tinggi namun dengan waktu komputasi yang efisien (Geurts et al., 2005).

II.2.2 Artificial Neural Network (ANN)

Artificial neural network (ANN) atau dikenal dengan jaringan saraf tiruan merupakan salah satu pendekatan yang paling banyak digunakan untuk menyelesaikan problem yang kompleks (Wei & Lee, 2007). ANN dikenal memiliki kemampuan dalam memodelkan hubungan kompleks non-linear. Dengan kemampuan belajar yang dimilikinya, ANN juga dapat dimodifikasi sehingga dapat meminimalisir kesalahan prediksi sesuai kriteria matematis yang diinginkan (W. Wang et al., 2005). ANN merupakan model komputasi matematis yang terinspirasi dari sistem saraf biologis, sehingga istilah yang digunakan pada ANN memiliki kemiripan dengan istilah pada sistem saraf (Kotu & Deshpande, 2015).

ANN memiliki berbagai jenis arsitektur, namun *multi-layer perceptron* (MLP) merupakan jenis yang paling banyak dikenal serta digunakan. MLP merupakan jenis ANN *feed-forward* dengan jaringan neuron yang saling terkoneksi satu dengan lainnya. Struktur MLP paling sederhana setidaknya memiliki tiga lapisan neuron yaitu satu *input layer*, satu atau lebih *hidden layer* dan satu *output layer* dengan masing-masing lapisan tersusun dari satu atau lebih neuron. Contoh struktur ANN *multi-layer perceptron* dapat dilihat pada Gambar II.4 berikut.



Gambar II.3 Ilustrasi struktur *Multi Layer Perceptron* (Kotu & Deshpande, 2015)

Lapisan neuron pertama yang letaknya paling dekat dengan input disebut dengan *input layer*. *Output layer* merupakan lapisan neuron terakhir yang melakukan tiga fungsi sekaligus yaitu fungsi agregasi, fungsi transfer dan fungsi aktivasi. Lapisan yang terletak diantara input dan output *layer* dan memiliki fungsi aktivasi disebut sebagai *hidden layer* (Kotu & Deshpande, 2015). Karakteristik dari sebuah jaringan ANN ditentukan dari fungsi transfer, algoritma pembelajaran serta struktur ANN itu sendiri (Valenti et al., 2010).

Suatu struktur ANN mempelajari hubungan antara variabel input dengan variabel output menggunakan teknik yang disebut *back propagation*. Berdasarkan struktur ANN yang digunakan serta jenis fungsi aktivasinya, ANN berusaha mencari nilai bobot dari setiap jaringan yang menghubungkan antar neuron. Model ANN menggunakan setiap data pembelajaran yang tersedia untuk mengestimasi kesalahan antara hasil prediksi dengan nilai riil. Selanjutnya, model menggunakan estimasi kesalahan tersebut untuk menyesuaikan nilai bobot guna meminimalisir kesalahan pada pembelajaran data berikutnya. Proses ini terus dilakukan secara berulang hingga nilai kesalahan masuk dalam rentang yang dapat diterima (Kotu & Deshpande, 2015).

II.2.3 Klasifikasi *Imbalanced*

Masalah klasifikasi *imbalanced*, atau dikenal dengan *rare class learning*, mengacu pada klasifikasi dengan distribusi data antar kelas yang tidak seimbang (Aggarwal, 2015; Haixiang, Yijing, Shang, Mingyun, & Yuanyue, 2017). Masalah ini merupakan masalah yang sering ditemui, karena hampir setiap dataset memiliki distribusi data yang tidak seimbang. Beberapa contoh kasus dimana masalah ini dapat terjadi yaitu deteksi penyakit, deteksi transaksi *fraud*, deteksi spam ataupun deteksi anomali lainnya. Algoritma klasifikasi umum yang diterapkan pada kasus-kasus tersebut dapat menghasilkan bias.

Salah satu contoh kasus yaitu permasalahan deteksi *fraud* pada sistem perbankan. Pada situasi tersebut dapat dipastikan jika transaksi *fraud* memiliki frekuensi yang jauh lebih kecil dibandingkan transaksi normal. Menerapkan metode klasifikasi secara langsung berpotensi menyebabkan hasil yang *bias* akibat frekuensi transaksi normal yang jauh lebih besar. Pada umumnya algoritma akan cenderung memilih transaksi normal dan tetap menghasilkan akurasi yang tinggi. Namun, jumlah transaksi *fraud* yang berhasil dideteksi akan sangat kecil. Padahal transaksi *fraud* ini yang perlu dideteksi karena berpotensi menimbulkan kerugian finansial.

Beberapa penelitian terdahulu telah banyak mengusulkan strategi atau metode khusus untuk mengatasi masalah klasifikasi *imbalanced*. Secara umum strategi yang diusulkan dapat dikelompokkan sebagai berikut (Haixiang et al., 2017):

1. Pembobotan kelas

Metode pembobotan ini dapat dilakukan dengan memberi bobot yang lebih tinggi untuk kelas minoritas. Metode lain yang lebih terkuantifikasi adalah dengan menghitung biaya kesalahan yang diakibatkan kesalahan melakukan masing-masing kelas. Metode pembobotan kelas umumnya akan memindahkan bias ke arah kelas minoritas, sehingga akurasi kelas minoritas menjadi lebih tinggi (Aggarwal, 2015).

2. *Resampling*

Metode *resampling* dilakukan pada tahap persiapan data, yaitu dengan menghapus data (*undersampling*) dari kelas mayoritas atau menambahkan

data (*oversampling*) dari kelas minoritas. Pada umumnya, metode *oversampling* lebih banyak digunakan, karena metode *undersampling* berpotensi menghilangkan data penting (Spelmen & Porkodi, 2018). Metode *oversampling* yang banyak digunakan antara lain *Random Over-Sampling* (ROS) dan *Synthetic Minority Over-sampling Technique* (SMOTE).

3. *Ensemble*

Ensemble melakukan salah satu pendekatan di level algoritma yang paling banyak digunakan untuk mengatasi klasifikasi imbalanced. Metode *ensemble* merupakan metode yang menggabungkan beberapa model klasifikasi sekaligus dan telah terbukti menghasilkan performa yang lebih baik dari model klasifikasi tunggal. Berdasarkan proses pembentukan modelnya, *ensemble* dapat dikelompokkan menjadi dua yaitu *iterative* (metode *boosting*) dan *parallel* (metode *bagging*). Faktor efisiensi waktu dan kepraktisan penggunaan menyebabkan metode *ensemble bagging* lebih direkomendasikan (Haixiang et al., 2017). Selain itu beberapa penelitian sebelumnya menunjukkan metode *bagging* dikombinasikan dengan metode *resampling* memiliki hasil yang lebih baik dibandingkan metode *boosting* (Haixiang et al., 2017).

II.2.4 *Supervised Learning* pada Kategorisasi Gangguan

Pendekatan *supervised learning* telah banyak digunakan untuk menjawab berbagai masalah penelitian pada berbagai tahap penanganan gangguan. Analisis tiket gangguan merupakan salah satu permasalahan yang telah banyak menjadi objek penelitian beberapa tahun belakangan. Ekstraksi informasi dari teks yang bersumber dari tiket gangguan serta menentukan klasifikasi gangguan berdasarkan informasi pada tiket merupakan dua permasalahan pada analisis tiket gangguan (Lucca, Penta, & Gradara, 2002). Berdasarkan penelitian, sistem pelaporan gangguan dengan analisis tiket otomatis berbasis *supervised learning* mampu meningkatkan efisiensi proses hingga 35% serta mengurangi waktu pelayanan hingga >35% (Shao & Chen, 2008; Xu, He, Zhou, & Li, 2018).

Penelitian (Lucca et al., 2002) menguji beberapa model yaitu ruang vektor, probabilistik, *support vector machine* (SVM), *decision tree* dan *k-nearest neighbor* (KNN) untuk kategorisasi gangguan berdasarkan deskripsi tiket. Historis tiket gangguan selama dua tahun, sebanyak enam ribu tiket, digunakan sebagai data pembelajaran menggunakan metode *k-cross validation*. Berdasarkan penelitian tersebut, SVM memiliki performa yang terbaik dibandingkan model lainnya.

Penelitian (Phomasakha, Sakolnakorn, & Meesad, 2008) membahas mengenai tahapan prosedur persiapan data yang dapat mendukung ekstraksi informasi dari tiket gangguan. Peneliti sekaligus mengkomparasi performa beberapa algoritma berbasis *decision tree* yaitu ID3, *random tree*, J48, *random forest*, NB Tree dan Rep Tree. Historis tiket gangguan selama empat bulan dengan total 14.440 kasus digunakan sebagai data pembelajaran. Berdasarkan penelitian tersebut, model *decision tree* berhasil digunakan untuk problem kategorisasi gangguan dengan algoritma ID3 sebagai algoritma terbaik.

Penelitian (Vedala, 2018) membandingkan model *logistic regression* dengan dua model *ensemble* berbasis *decision tree* yaitu *random forest* dan *extremely randomized trees*. Data tiket selama dua tahun atau sebanyak 114.747 tiket digunakan sebagai data pembelajaran. Berdasarkan pemodelan yang dilakukan pada penelitian ini, kedua model *ensemble* berbasis *decision tree* berhasil mengungguli model *logistic regression* dengan model *random forest* mendapat *F1-score* tertinggi yaitu 0.9. Lebih lanjut, peneliti melakukan ujicoba model klasifikasi *random forest* tersebut pada jalur produksi. Hasilnya, pada jalur produksi model *random forest* berhasil mendapat *F1-score* sebesar 0.86.

II.2.5 Supervised Learning pada Prediksi Durasi Gangguan

Prediksi durasi gangguan merupakan salah satu faktor penting dalam sistem manajemen gangguan (Guan et al., 2010). Durasi gangguan merupakan salah satu faktor yang dapat digunakan untuk menilai kompleksitas sebuah gangguan. Selain itu, informasi prediksi durasi gangguan dapat digunakan oleh pengguna layanan

untuk menentukan langkah mitigasi yang perlu diambil. Durasi gangguan sendiri merupakan interval waktu yang dibutuhkan sejak gangguan terdeteksi atau dilaporkan hingga gangguan teratasi (Camara et al., 2018; Guan et al., 2010; W. Wang et al., 2005). Gambar II.5 menunjukkan garis waktu proses penanganan gangguan hingga didapatkan pengukuran durasi gangguan.

Hingga penulisan ini dilakukan, belum ditemukan referensi penelitian mengenai prediksi durasi gangguan layanan TI. Lingkup penelitian terdekat yang sudah pernah dilakukan peneliti-peneliti sebelumnya adalah mengenai prediksi durasi gangguan atau kecelakaan lalu lintas. Penelitian-penelitian tersebut membahas antara lain mengenai faktor-faktor dominan yang mempengaruhi durasi gangguan, pola distribusi durasi gangguan serta metode yang digunakan untuk melakukan prediksi durasi gangguan.

Metode prediksi durasi gangguan lalu lintas telah banyak diajukan melalui penelitian-penelitian terdahulu. Beberapa metode prediksi durasi gangguan yang umum digunakan adalah regresi, *decision tree*, ANN, hingga *survival analysis*. Penelitian (A. Khattak, Wang, & Zhang, 2012) mengusulkan metode regresi *ordinary least square* (OLS) mendapatkan hasil *mean absolute percentage error* (MAPE) sebesar 37% untuk gangguan dalam rentang waktu 15 menit. Masih menggunakan basis regresi, (A. J. Khattak, Liu, Wali, Li, & Ng, 2016) menggunakan metode regresi quantile hingga didapatkan *root mean square error* (RMSE) sebesar 57.49 menit. Pendekatan berbeda dilakukan menggunakan metode *decision tree*. Penelitian (Zhan, Gan, & Hadi, 2011) mengusulkan penggunaan M5P yang berbasis *decision tree* untuk menghasilkan MAPE sebesar 42.7%. Sementara penelitian (Wynter, He, Kamarianakis, & Jintanakul, 2011) mengkombinasikan metode *decision tree* dengan regresi quantile hingga didapatkan MAPE sebesar 49.1%. Metode non-linear menggunakan ANN juga diadopsi oleh beberapa peneliti untuk memprediksi durasi gangguan lalu lintas. Penelitian (Wei & Lee, 2005) berhasil memperoleh MAPE antara 20-30% menggunakan ANN dengan 1 *hidden layer*. Penelitian (Valenti et al., 2010) mencoba membandingkan ANN dengan *multiple linear regression*, *decision tree*,


SVM, dan *k-nearest neighbor*. Hasilnya meskipun ANN memiliki MAPE terbesar (44%), tetapi untuk durasi gangguan yang panjang (>90 menit) jaringan saraf tiruan memberikan hasil terbaik.

Beberapa penelitian terkait ikut memberi kontribusi dalam menganalisis faktor-faktor yang berpengaruh signifikan terhadap durasi gangguan lalu lintas. Berdasarkan penelitian (S. Wang, Li, & Guo, 2018), menggunakan metode Kruskal-Wallis ditemukan enam dari tiga belas faktor berpengaruh signifikan terhadap durasi gangguan. Penelitian (Weiming Liu, Liping Guan, 2005), menggunakan metode *stepwise regression* menyimpulkan delapan dari enam belas faktor berpengaruh signifikan terhadap durasi gangguan. Selain dua metode tersebut, *decision tree* juga dapat digunakan untuk menganalisis faktor yang signifikan terhadap durasi gangguan (Wynter et al., 2011).

Bab III Metodologi Penelitian

III.1 *Design Science Research Methodology for Information System (DSRM-IS)*

Penelitian ini didesain menggunakan metodologi *Design Science Research Method for Information System Research* (DSRM-IS). Metodologi ini dikembangkan oleh (Peffer, Tuunanen, Rothenberger, & Chatterjee, 2007). Metodologi ini dikembangkan sebagai *framework* bagi penelitian di bidang information system dengan mengadopsi prinsip design science. Metodologi DSRM-IS terdiri atas enam tahapan seperti terlihat pada Gambar III.1, yaitu identifikasi masalah dan motivasi, mendefinisikan tujuan dari solusi, perancangan dan pengembangan, demonstrasi atau uji coba solusi, evaluasi solusi, serta komunikasi solusi sebagai hasil penelitian. Penjelasan lengkap mengenai tahapan metodologi DSRM-IS yang diadopsi pada penelitian adalah sebagai berikut:



Gambar III.1 Tahapan metodologi DSRM-IS (Peffer et al., 2007)

III.1.1 Identifikasi Masalah dan Motivasi

Tahapan ini bertujuan untuk mengidentifikasi secara spesifik masalah yang akan diangkat pada penelitian serta menjustifikasi pentingnya permasalahan tersebut untuk dipecahkan. Identifikasi masalah dilakukan dengan mempelajari proses bisnis berjalan yang terkait dengan prediksi durasi pada proses penanganan gangguan. Justifikasi masalah dilakukan untuk menjelaskan pentingnya penelitian ini untuk dilakukan. Detail langkah yang dilakukan pada tahap identifikasi masalah dan motivasi dijelaskan pada Tabel III.1

Tabel III.1 Detail Tahap Identifikasi Masalah & Motivasi

Data	1) Proses bisnis penanganan gangguan 2) Publikasi ilmiah, jurnal ilmiah
Metode	1) Studi literatur 2) <i>Business Process Model & Notation</i> (BPMN)
Hasil	1) Proses bisnis penanganan gangguan berjalan (BPMN As-Is) 2) Identifikasi permasalahan prediksi durasi gangguan pada proses bisnis penanganan gangguan

III.1.2 Tujuan dari Solusi Masalah

Pada tahapan ini ditentukan tujuan dari solusi untuk menjawab rumusan masalah yang didefinisikan sebelumnya. Tujuan dari penelitian dapat diungkapkan secara kuantitatif, seperti sejauh mana solusi dapat lebih baik dari kondisi saat ini. Maupun secara kualitatif, seperti bagaimana artifak dapat mendukung solusi dari masalah yang dikemukakan. Secara umum tujuan dari penelitian ini adalah untuk merancang *framework* penanganan gangguan berbasis *supervised learning* yang dapat memberikan informasi prediksi durasi gangguan. Detail langkah yang dilakukan pada proses tujuan dari solusi masalah dijelaskan pada Tabel III.2.

Tabel III.2 Detail Tahap Tujuan dari Solusi Masalah

Data	1) Hasil identifikasi permasalahan prediksi durasi gangguan pada proses bisnis penanganan gangguan
Metode	1) Studi literatur
Hasil	1) Tujuan dari solusi masalah

III.1.3 Desain dan Pengembangan

Pada tahapan ini dilakukan perancangan *framework* baik secara konseptual seperti alur aktivitas hingga model untuk setiap aktivitas. Proses yang dilakukan pada tahap ini meliputi merancang alur aktivitas penanganan gangguan usulan sehingga dapat memberikan informasi prediksi durasi gangguan. Rancangan proses dibuat dengan mengacu pada salah satu *framework IT Service Management* (ITSM) yang telah matang. Setelah usulan alur aktivitas penanganan gangguan didapatkan, proses selanjutnya adalah menganalisis dan menentukan teknologi atau metode yang tepat untuk setiap aktivitas pada rancangan proses penanganan gangguan.

Sebagai akhir dari tahapan ini, dilakukan perancangan model aktivitas berdasarkan teknologi atau metode yang telah ditentukan

Tabel III.3 Detail Tahap Desain dan Pengembangan

Data	1) Tujuan dari solusi masalah
Metode	1) ITILv3 2) <i>Business Process Model & Notation</i> (BPMN) 3) CRISP-DM
Hasil	1) Model kategorisasi gangguan 2) Model prioritisasi gangguan 3) Model prediksi durasi gangguan 4) Model penjadwalan penanganan gangguan 5) Rancangan <i>framework</i> penanganan gangguan

III.1.4 Pengujian dan Evaluasi

Setelah artefak solusi dihasilkan, proses selanjutnya adalah mendemonstrasikan artefak tersebut. Pada penelitian ini dilakukan dua jenis pengujian yaitu simulasi menggunakan data buatan serta justifikasi tenaga ahli. Simulasi rancangan *framework* menggunakan data buatan dilakukan untuk menguji fungsionalitas *framework* yang diusulkan. Sementara justifikasi tenaga ahli dilakukan untuk memperoleh validasi terhadap rancangan *framework* berdasarkan pandangan tenaga ahli terkait. Sebagai akhir dilakukan evaluasi akhir terhadap dua hasil pengujian yang telah didapatkan.

Tabel III.4 Detail Tahap Demonstrasi

Data	1) Rancangan <i>Framework</i> Penanganan Gangguan 2) Form justifikasi tenaga ahli
Metode	1) Simulasi rancangan <i>framework</i> dengan data buatan 2) Wawancara untuk justifikasi tenaga ahli 3) Analisis hasil simulasi dan justifikasi tenaga ahli 4) Penarikan kesimpulan dari penelitian
Hasil	1) Evaluasi hasil rancangan <i>framework</i> penanganan gangguan


III.1.5 Komunikasi

Pada tahap ini dilakukan dokumentasi hasil penelitian dalam bentuk buku tesis dan publikasi ilmiah. Di dalam buku tesis memuat secara lengkap proses

penelitian yang dilakukan hingga didapatkan solusi serta kesimpulan penelitian. Publikasi ilmiah memuat hasil penelitian sebagai media komunikasi dan publikasi yang dapat digunakan untuk penelitian dan hal terkait lainnya.

III.2 Cross-Industry Standard Process for Data Mining (CRISP-DM)

Pada tahapan desain dan pengembangan, penelitian ini banyak dilakukan pemodelan *machine learning* menggunakan data. Oleh karena itu pada tahapan ini diadopsi salah satu *framework* pemodelan data, yaitu *Cross-Industry Standard Process for Data Mining* (CRISP-DM). CRISP-DM merupakan salah satu *framework data mining* yang paling banyak dikenal dan digunakan selain SEMMA dan DMAIC. Metode ini dikembangkan oleh konsorsium antara Daimler-Chrysler, NCR dan SPSS. Secara umum CRISP-DM terdiri dari 6 tahapan seperti ditunjukkan pada Gambar III.2, yaitu pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi dan implementasi. Penjelasan metode CRISP-DM yang diadopsi pada penelitian ini adalah sebagai berikut:



Gambar III.2 Diagram *framework* CRISP-DM

III.2.1 Pemahaman Bisnis

Pada tahapan ini diperlukan pemahaman mengenai kebutuhan proses bisnis, untuk menentukan tujuan bisnis dari model yang dirancang. Selain tujuan bisnis, tujuan teknis juga perlu didefinisikan pada tahap ini. Kriteria evaluasi model baik dari sisi bisnis maupun teknis juga ditentukan pada tahap ini untuk menilai keberhasilan model yang dibuat. Proses dilanjutkan dengan pendataan sumber daya yang dibutuhkan untuk membentuk model, yaitu data yang diperlukan serta sumber data tersebut.

III.2.2 Pemahaman Data

Pada tahapan ini, pengumpulan data dari sumber data yang telah didefinisikan sebelumnya dilakukan. Selanjutnya dilakukan analisis deskriptif serta eksplorasi terhadap data yang telah dikumpulkan data. Verifikasi terhadap kualitas data yang telah didapat juga dilakukan pada tahap ini. Proses verifikasi mencakup masalah yang didapati terhadap data yang dikumpulkan seperti kelengkapan data, format data, ataupun data yang hilang. Solusi yang akan dilakukan terhadap permasalahan data juga dijabarkan pada tahap ini.

III.2.3 Persiapan Data

Pada tahapan ini dilakukan pemilihan sampel data yang akan digunakan sebagai dataset. Setelah sampel data ditentukan selanjutnya dilakukan proses cleansing data untuk mengatasi problem kualitas data yang teridentifikasi pada proses sebelumnya. Data bersih tersebut selanjutnya dilakukan pembentukan atribut baru (feature engineering) bila memang diperlukan. Bila data masih terpisah selanjutnya dilakukan integrasi data berdasarkan atribut tertentu. Reformat data sesuai kebutuhan proses model selanjutnya dilakukan pada data yang telah terintegrasi tersebut.

III.2.4 Pemodelan

Tahapan ini terdiri atas pemilihan teknik (algoritma), pembagian dataset pelatihan dan pengujian, pemodelan, pengaturan parameter serta penilaian model. Pemilihan algoritma dilakukan berdasarkan karakteristik data serta referensi dari penelitian

terkait. Setelah algoritma ditentukan selanjutnya dataset dibagi menjadi dua, yaitu data pelatihan (*training*) dan data pengujian (*testing/validasi*). Data pelatihan adalah data yang akan digunakan untuk membentuk model, sedangkan data pengujian adalah data yang digunakan untuk validasi model. Pada proses pembentukan model dengan data pelatihan, dilakukan prosedur *k-fold cross validation* untuk menghindari efek *overfitting*. Pada proses pemodelan dilakukan pengaturan parameter dari algoritma yang digunakan. Pengaturan parameter dan penilaian model adalah proses iteratif untuk mendapatkan model terbaik. Setelah didapatkan parameter model terbaik dari data pelatihan selanjutnya model diujikan pada data validasi.


III.2.5 Evaluasi & Implementasi

Setelah mendapat model terbaik yang telah diujikan pada data validasi, tahap selanjutnya adalah mengevaluasi model akhir tersebut. Evaluasi dilakukan berdasarkan kriteria teknis serta kriteria bisnis yang telah ditentukan pada tahap awal. Apabila model akhir dirasa telah memenuhi kedua kriteria tersebut, maka model tersebut dianggap sebagai model terpilih. Apabila model akhir belum mencukupi, maka proses dapat diulang kembali melalui tahap awal. Model terpilih selanjutnya dapat diimplementasi pada proses bisnis berjalan.

Bab IV Analisis & Perancangan

IV.1 Fault Management PT. ICON+

PT. Indonesia Comnets Plus (ICON+) adalah salah satu anak perusahaan dari PT. PLN (Persero) yang menjalankan bisnis di bidang jasa penyediaan layanan Teknologi Informasi & Komunikasi (TIK). Pada awal berdirinya, perusahaan hanya berfokus untuk melayani kebutuhan PLN Group akan jaringan telekomunikasi. Namun seiring dengan berkembangnya industri TIK di tanah air, perusahaan mulai mengembangkan usahanya dengan melayani perusahaan lain di luar PLN Group dengan memanfaatkan lisensi penyelenggaraan jaringan tertutup. Jasa layanan yang diberikan oleh PT. ICON+ pun ikut berkembang mengikuti kebutuhan industri TIK. Jasa layanan yang tersedia saat ini adalah layanan berbasis jaringan, layanan *contact center*, layanan *cloud & data center* serta layanan solusi berbasis aplikasi dengan cakupan wilayah operasional seluruh Indonesia seperti terlihat pada Gambar IV.1 berikut.



Gambar IV.1 Peta wilayah operasional PT. ICON+

Fault Management merupakan salah satu divisi pada PT. ICON+ dan memiliki peran utama dalam melakukan deteksi, analisis, serta penanganan gangguan terkait layanan jaringan yang disediakan oleh PT. ICON+. Karena masih

mengadopsi konsep *monitoring* terpusat, maka *Fault Management* bertanggung jawab terhadap penanganan gangguan di seluruh wilayah operasional perusahaan yang terbagi atas 11 regional di seluruh Indonesia (Gambar IV.1). Proses penanganan gangguan layanan jaringan di PT. ICON+ secara umum dapat dilihat pada Gambar IV.2. Dari gambar tersebut terlihat *Fault Management* berinteraksi dengan 3 *stakeholder* lainnya yaitu:

1. *Contact Center*


Divisi yang bertugas sebagai helpdesk yang menerima laporan, memberi update informasi serta melakukan konfirmasi selesai kepada pelanggan.

2. *Regional*

Divisi yang bertugas mengelola aset jaringan di areanya termasuk melakukan koordinasi gangguan dengan *Field Support*.

3. *Field Support*

Divisi yang bertugas melakukan perbaikan fisik yang diperlukan di lapangan dan selalu berkoordinasi dengan *Regional* maupun *Fault Management*.



Gambar IV.2 *Stakeholder diagram* proses bisnis penanganan gangguan PT. ICON+

Perusahaan giat menargetkan pertumbuhan, dengan pertumbuhan jumlah pelanggan serta layanan pertahun rata-rata mencapai 29% dalam kurun waktu 4 tahun terakhir. Pertumbuhan jumlah pelanggan ikut meningkatkan pertumbuhan jumlah gangguan pada periode yang sama dengan rata-rata pertahun mencapai 21%. Divisi *Fault Management* sebagai divisi yang bertanggung jawab terhadap penanganan gangguan pelanggan memiliki komposisi personil gabungan dengan pengalaman rata-rata >5 tahun di posisi *Analyst* dan *Manager on Duty*. Sementara untuk posisi *Surveillance*, terdiri dari personil berpengalaman >5 tahun, maupun kurang dari 3 tahun. Jumlah personil *Fault Management* tidak mengalami perubahan yang signifikan dalam kurun waktu 4 tahun terakhir.

Perusahaan telah mengembangkan sistem berbasis TI untuk mendukung proses penanganan gangguan. *Fault Management System* (FMS) merupakan aplikasi utama dalam proses penanganan gangguan. FMS digunakan untuk mencatat setiap gangguan yang terjadi baik proaktif dan reaktif, serta kronologis penanganan gangguan yang dilakukan. FMS didukung oleh 2 aplikasi lainnya yaitu *Customer Relationship Management* (CRM) dan *Field Support Management* (FSM). CRM digunakan untuk mencatat serta melaporkan berkala tiket gangguan yang dilaporkan oleh pelanggan melalui *Contact Center*. Sementara FSM digunakan untuk mengelola personil *Field Support* yang dilakukan oleh Regional. Pengelolaan yang dilakukan termasuk pengaturan alur kerja, pelacakan posisi, serta komunikasi seputar penanganan gangguan di lapangan.

IV.2 Analisis Proses Bisnis Penanganan Gangguan PT. ICON+

Proses bisnis penanganan gangguan berjalan saat ini dilakukan oleh *Fault Management* dengan melibatkan 3 stakeholder utama yaitu *Contact Center*, Regional dan *Field Support*. Proses bisnis penanganan gangguan dimulai dari saat terdeteksinya gangguan baik secara proaktif (*monitoring* alarm) maupun reaktif (laporan pelanggan) hingga perbaikan gangguan selesai dilakukan. Alur proses bisnis berjalan untuk penanganan gangguan digambarkan dalam diagram BPMN pada Gambar IV.3-IV.5. Proses bisnis penanganan gangguan terdiri atas subproses atau aktivitas, yaitu:

1. Identifikasi Gangguan

Tahap ini adalah tahapan saat gangguan telah teridentifikasi oleh *Fault Management*. Sumber deteksi gangguan terbagi menjadi 2 yaitu proaktif dan reaktif. Pada gangguan proaktif, gangguan terdeteksi melalui sistem monitoring alarm pada *Fault Management*. Sedangkan pada gangguan reaktif, gangguan terdeteksi melalui laporan pelanggan yang masuk melalui *Contact Center*.

2. Pencatatan Gangguan

Setelah gangguan terdeteksi, selanjutnya akan dilakukan pencatatan gangguan melalui aplikasi. Pada gangguan proaktif, *Fault Management* akan memasukkan gangguan baru yang terdeteksi melalui sistem monitoring kedalam aplikasi FMS. Selanjutnya aplikasi akan memberikan notifikasi kepada *Contact Center* untuk melakukan konfirmasi status layanan kepada pelanggan. Sedangkan pada gangguan reaktif, *Contact Center* akan memasukkan tiket gangguan baru yang dilaporkan pelanggan ke dalam aplikasi CRM. Selanjutnya aplikasi akan memberikan notifikasi kepada *Fault Management* untuk melakukan pengecekan kondisi layanan pada sistem monitoring jaringan.

3. Pre-Analisis Gangguan

Gangguan yang telah tercatat kedalam aplikasi FMS selanjutnya dilakukan analisis awal terhadap gangguan tersebut. Proses pre-analisis awal saat ini dipegang sepenuhnya oleh personil Surveillance dari *Fault Management*. Analisis dilakukan berdasarkan alarm pada sistem monitoring jaringan serta pengecekan kondisi layanan, yang keduanya dilakukan secara jarak jauh (*remote*).

4. Kategorisasi Gangguan

Hasil pre-analisis diperlukan untuk menentukan status kondisi layanan, letak gangguan serta indikasi awal penyebab gangguan. Selanjutnya personil melakukan pembaruan catatan gangguan pada aplikasi FMS berdasarkan hasil pre-analisis. Informasi hasil pre-analisis di aplikasi FMS kemudian dijadikan sebagai informasi awal yang diberikan *Contact Center* kepada pelanggan.

5. Prioritisasi Gangguan

Prioritisasi gangguan diperlukan apabila terdapat keterbatasan *Field Support* tersedia saat dibutuhkan untuk investigasi dan perbaikan gangguan. Prioritisasi gangguan saat ini ditentukan oleh personil *Manager on Duty* pada *Fault Management*. Prioritisasi gangguan yang berlaku saat ini dinilai berdasarkan tingkat urgensi gangguan. Urutan prioritas gangguan dari yang tertinggi adalah gangguan backbone, gangguan distribusi, gangguan head office pelanggan, dan gangguan akses.

6. Eskalasi Gangguan

Eskalasi gangguan dilakukan pada situasi tertentu dalam proses penanganan gangguan. Eskalasi gangguan terbagi menjadi 2 yaitu eskalasi internal dan eskalasi eksternal. Eskalasi internal dilakukan apabila terjadi kendala yang sifatnya internal serta diajukan ke pihak internal dalam organisasi. Contoh kasusnya seperti saat gangguan sudah melebihi batas toleransi waktu tertentu atau ketika material pengganti tidak tersedia. Sebaliknya, eskalasi eksternal dilakukan apabila terjadi kendala yang terkait dengan pihak eksternal organisasi. Contoh kasus seperti gangguan jaringan oleh pihak ketiga atau kendala pada perangkat dari salah satu vendor. Proses eskalasi dilakukan oleh personil *Manager on Duty* dari *Fault Management*.

7. Investigasi Gangguan

Pada tahap investigasi gangguan, dilakukan analisis yang lebih mendalam berdasarkan hasil pre-analisis sebelumnya. Analisis dilakukan berdasarkan hasil investigasi secara remote ataupun dengan investigasi *Field Support* di lapangan. Sebagian besar proses investigasi dilakukan setelah *Field Support* tiba di lokasi gangguan. Hal ini dikarenakan terbatasnya data yang dapat diambil secara remote pada saat terjadinya gangguan. Berdasarkan hasil analisis pada tahap investigasi, selanjutnya direncanakan tahap-tahap perbaikan gangguan yang diperlukan.


8. Perbaikan Gangguan

Pada tahap perbaikan gangguan mulai dilakukan langkah perbaikan terhadap gangguan. Perbaikan dapat dilakukan baik secara temporer (agar layanan cepat pulih) maupun permanen. Bila memungkinkan perbaikan gangguan


dilakukan secara *remote* oleh personil Analyst dari *Fault Management*. Sedangkan gangguan yang membutuhkan perbaikan fisik, akan dilakukan oleh personil *Field Support* berdasarkan analisis dan arahan dari *Fault Management*.

9. Gangguan Selesai


Aktivitas akhir adalah mengkonfirmasi bahwa gangguan telah terselesaikan. *Fault Management* memvalidasi bahwa layanan sudah berjalan normal kembali, kemudian *Contact Center* mengkonfirmasi kepada pelanggan bahwa layanan sudah dapat digunakan. Setelah tiket gangguan dinyatakan selesai oleh *Contact Center*, *Fault Management* menyatakan gangguan selesai pada aplikasi FMS dengan mengisi penyebab gangguan serta langkah penyelesaian yang dilakukan. Penyelesaian gangguan di aplikasi FMS dilakukan dengan akurat untuk menjamin proses pelaporan kepada manajemen bila dibutuhkan.



Gambar IV.3 BPMN As-Is proses bisnis penanganan gangguan PT. ICON+



Gambar IV.4 BPMN As-Is sub-proses pre-analisis gangguan



Gambar IV.5 BPMN As-Is sub-proses analisis gangguan

IV.3 Analisis Kesenjangan Proses Bisnis Penanganan Gangguan

Analisis kesenjangan (*gap analysis*) dilakukan dengan membandingkan proses bisnis penanganan gangguan berjalan dengan salah satu *framework* ITSM. Proses *incident management* dari *framework* ITIL digunakan sebagai referensi pembanding. Berdasarkan analisis kesenjangan, terdapat beberapa perbedaan antara proses bisnis berjalan dengan *incident management* ITIL. Berdasarkan penamaan organisasi, proses bisnis penanganan gangguan menggunakan nama *Fault Management* dan *Contact Center*, sementara *Service Desk* lebih dikenal pada *incident management* ITIL. Berdasarkan fungsional organisasi, *Fault Management* memiliki peran dominan pada proses bisnis berjalan, sementara *Service Desk* memegang peranan penting pada *incident management* ITIL.

Selain dua hal diatas, perbedaan lainnya terdapat pada aktivitas prioritas gangguan. Pada proses bisnis berjalan, prioritas gangguan baru dilakukan saat tidak tersedianya sumber daya *Field Support* sesuai kebutuhan. Prioritas gangguan juga hanya ditentukan berdasarkan evaluasi terhadap tingkat urgensi gangguan. Sementara berdasarkan ITIL, prioritas gangguan dilakukan pada awal proses pencatatan dan berlaku untuk setiap gangguan. Prioritas gangguan menurut ITIL dievaluasi berdasarkan tingkat urgensi dan tingkat dampak dari gangguan. Karena prioritas gangguan telah diketahui sejak awal maka akan mengurangi terjadinya interupsi dalam proses penanganan gangguan. Tabel IV.1 berikut menyajikan lengkap hasil analisis kesenjangan dari proses bisnis penanganan gangguan terhadap *incident management* ITIL.

Tabel IV.1 Analisis kesenjangan proses bisnis penanganan gangguan PT. ICON+

Aktivitas	Proses Bisnis Penanganan Gangguan	ITIL <i>Incident management</i>
Identifikasi	Identifikasi gangguan dilakukan oleh <i>Fault Management</i> melalui sistem monitoring untuk gangguan proaktif. Gangguan reaktif dilakukan oleh <i>Contact Center</i> melalui telepon, email, dsb.	Identifikasi gangguan secara proaktif dilakukan melalui event management. Sementara identifikasi gangguan reaktif dilakukan oleh <i>Service Desk</i> melalui telepon, email, dsb.


Pencatatan	Laporan gangguan yang masuk diberikan referensi nomor tiket unik oleh sistem CRM untuk kemudian direlasikan ke referensi nomor gangguan unik oleh sistem FMS. Catatan gangguan terus diperbaharui hingga gangguan selesai ditangani.	Setiap gangguan diberikan nomor gangguan unik sebagai referensi tunggal. Selanjutnya catatan gangguan diperbaharui hingga gangguan terselesaikan.
Kategorisasi	Kategorisasi dilakukan oleh <i>Fault Management</i> setelah melalui diagnosis awal. Kategori gangguan mengacu pada penyebab gangguan dan terdiri atas tiga level yang semakin rinci.	Kategorisasi dilakukan pada awal pencatatan gangguan dan berisi klasifikasi penyebab gangguan yang dapat disusun menjadi tiga sampai empat tingkat.
Prioritisasi	Prioritisasi dilakukan saat sumber daya penanganan gangguan tidak tersedia. Prioritisasi dilakukan menggunakan evaluasi tingkat urgensi gangguan berdasarkan hierarki gangguan.	Prioritisasi gangguan dilakukan setelah kategorisasi dan berlaku untuk setiap gangguan. Prioritisasi dilakukan berdasarkan evaluasi tingkat urgensi dan tingkat dampak masing-masing gangguan. Setiap tingkat prioritas memiliki target penyelesaian gangguan tersendiri.
Diagnosis Awal	Diagnosis awal dilakukan oleh <i>Contact Center</i> dengan menerima informasi keluhan dan alarm dari pelanggan. Selanjutnya <i>Fault Management</i> melakukan pengecekan secara remote ke dalam sistem monitoring jaringan.	Diagnosis awal dilakukan oleh <i>Service Desk</i> . <i>Service Desk</i> berusaha menyelesaikan gangguan pada tahap ini. Bila tidak memungkinkan nomor referensi gangguan diberikan kepada pengguna layanan.
Eskalasi	Eskalasi dibagi menjadi dua yaitu eskalasi internal kepada struktur manajemen internal dan eskalasi eksternal kepada pihak diluar organisasi untuk gangguan yang melibatkan pihak ketiga.	Eskalasi dibagi menjadi dua yaitu eskalasi fungsional untuk gangguan yang tidak terselesaikan dalam rentang waktu tertentu dan eskalasi hierarkial untuk informasi gangguan prioritas tinggi.
Investigasi & Diagnosis	Investigasi dan diagnosis lebih lanjut dilakukan oleh <i>Fault Management</i> dibantu oleh <i>Field Support</i> bila diperlukan. Hasil investigasi dan diagnosis didokumentasi pada FMS.	Aktivitas berfokus pada mengetahui penyebab, pemicu serta kronologi gangguan. Setiap hasil analisis diperbaharui pada catatan gangguan.
Resolusi & Perbaikan	Perbaikan dilakukan oleh <i>Field Support</i> setelah mendapat persetujuan dari <i>Fault Management</i> . Progress perbaikan didokumentasi pada FMS.	Langkah resolusi dan perbaikan yang dilakukan harus diaplikasikan dan diujicoba secara terkontrol. Proses perbaikan diperbaharui dan terdokumentasi pada catatan gangguan.

Penyelesaian	Penyelesaian gangguan dilakukan oleh <i>Fault Management</i> setelah <i>Contact Center</i> mendapat konfirmasi dari pelanggan bahwa tiket sudah bisa ditutup. <i>Fault Management</i> melakukan validasi dan verifikasi laporan pada FMS sebelum penyelesaian gangguan.	<i>Service Desk</i> melakukan konfirmasi status gangguan kepada pengguna layanan. Catatan gangguan ditutup setelah melakukan pembaruan informasi dan klasifikasi penyebab gangguan.
--------------	---	---

IV.4 Fase Penanganan Gangguan

Penanganan gangguan merupakan proses bisnis yang terdiri dari rangkaian beberapa aktivitas. Aktivitas-aktivitas tersebut secara berurutan adalah identifikasi, pencatatan, ketgorisasi, prioritisasi, diagnosis awal, investigasi dan diagnosis, resolusi dan perbaikan serta penyelesaian gangguan. Durasi gangguan merupakan total waktu yang dibutuhkan untuk melakukan perbaikan, dimulai saat gangguan teridentifikasi hingga gangguan dinyatakan selesai. Garis waktu proses penanganan gangguan dapat dilihat pada Gambar IV.6 dibawah.

Rangkaian aktivitas tersebut secara garis besar dapat dibagi menjadi dua fase yaitu fase respon dan fase perbaikan. Fase respon yaitu fase di saat penyedia layanan memberikan informasi awal gangguan kepada pelanggan. Pada fase ini umumnya data terkait penanganan gangguan belum tersedia lengkap, sementara informasi dibutuhkan dengan cepat untuk disampaikan kepada pengguna layanan. Fase perbaikan, yaitu fase di saat penyedia layanan melakukan analisis lebih lanjut serta melakukan tindakan perbaikan untuk menormalkan kembali layanan kepada pelanggan. Pada fase ini umumnya data terkait penanganan gangguan sudah tersedia lebih lengkap, sementara informasi diberikan kepada pengguna layanan berupa pembaruan dari informasi yang diberikan sebelumnya.




Gambar IV.6 Garis waktu proses penanganan gangguan

IV.5 Hubungan Antara Aktivitas Penanganan Gangguan dengan Durasi Gangguan

Berdasarkan rangkaian aktivitas pada proses penanganan gangguan sebelumnya, terdapat dua aktivitas yang teridentifikasi memiliki pengaruh terhadap prediksi durasi gangguan dan menjadi fokus dari perancangan *framework*. Berdasarkan salah satu penelitian, jenis atau kategori gangguan dan prioritas gangguan merupakan faktor yang berpengaruh terhadap durasi gangguan selain dampak dan kondisi geografis gangguan (Caldeira & Brito, 2008). Pernyataan ini diperkuat dengan uji statistik Welch's ANOVA terhadap data gangguan pada tahun 2018 yang menunjukkan kategori gangguan secara statistik berpengaruh signifikan terhadap durasi gangguan. Tingkat prioritas menentukan bagaimana gangguan direspon selama proses penanganan gangguan. Bahkan berdasarkan proses penanganan gangguan ITIL, target penyelesaian gangguan ditentukan berdasarkan tingkat prioritasnya. Selain kedua aktivitas tersebut, penjadwalan merupakan aktivitas lain yang berpengaruh terhadap durasi gangguan namun tidak secara khusus disebutkan dalam proses penanganan gangguan ITIL. Penjadwalan menentukan bagaimana urutan penanganan gangguan dilakukan sehingga metode penjadwalan yang digunakan akan berpengaruh terhadap durasi gangguan.

IV.6 Rancangan *Framework* Penanganan Gangguan

Bagian ini menampilkan rancangan *framework* penanganan gangguan yang diusulkan sebagaimana terlihat pada Gambar IV.7. Secara garis besar *framework* dibagi menjadi tiga bagian utama yaitu *layer* data, *layer* proses dan *layer* teknologi. *Layer* data merupakan data atau informasi yang dibutuhkan dalam setiap aktivitas. *Layer* proses merupakan aktivitas yang dilakukan pada *framework* penanganan gangguan. Serta *layer* teknologi, merupakan metode atau teknologi yang dapat membantu setiap aktivitas.



Gambar IV.7 Diagram rancangan *framework* penanganan gangguan

IV.6.1 Kategorisasi Gangguan

Pada aktivitas kategorisasi dilakukan klasifikasi indikasi gangguan menjadi kategori gangguan berdasarkan data-data pendukung yang tersedia antara lain keluhan, gejala, alarm/diagnosis cek, dan lain-lain. Data tersebut umumnya bisa didapatkan dari laporan pelanggan maupun sistem monitoring milik penyedia layanan. Kategori gangguan umumnya dibuat secara bertingkat, dengan kategori yang makin detail pada tingkatan yang lebih dalam. Setiap tingkat gangguan umumnya berisi lebih dari dua kategori gangguan. Aktivitas ini dilakukan pada tahap awal penanganan gangguan, di saat data yang bisa didapatkan umumnya tidak cukup banyak dan detail. Beberapa jenis gangguan pun seringkali memiliki keluhan, gejala dan alarm yang serupa sehingga menimbulkan faktor ketidakpastian.

Keadaan diatas menjadi tantangan tersendiri bagi operator untuk dapat menyimpulkan indikasi gangguan secara pasti dan konsisten. Mengacu pada karakteristik dari aktivitas kategorisasi gangguan, metode *supervised learning* dari *machine learning* dapat diadopsi untuk membantu operator menentukan kategori gangguan dengan lebih baik. Secara lebih spesifik, metode yang cocok digunakan adalah *multi-class classification*. Pada metode ini model secara otomatis menentukan satu dari beberapa (lebih dari dua) kategori gangguan yang ada setelah mempelajari data-data historis gangguan.

IV.6.2 Prioritisasi Gangguan

Tujuan dari aktivitas prioritisasi gangguan adalah untuk menentukan skala prioritas dari suatu gangguan. Prioritisasi dilakukan dengan mengevaluasi tingkat urgensi dan dampak dari setiap gangguan. Urgensi gangguan menunjukkan tingkat sejauh mana kecepatan penanganan gangguan diperlukan (Menken et al., 2009). Pada operator layanan jaringan pita lebar, tingkat urgensi dapat ditentukan berdasarkan hierarki jaringan yang mengalami gangguan serta kelas pelanggan yang terdampak gangguan. Dampak gangguan menunjukkan tingkat sejauh mana pengguna ataupun bisnis terdampak oleh gangguan (Menken et al., 2009). Jumlah

pengguna layanan terganggu dapat digunakan untuk menentukan tingkat dampak gangguan.

Untuk menjamin objektivitas dan konsistensi dari evaluasi yang dilakukan maka diperlukan model pemetaan yang telah disepakati oleh pihak terkait di dalam organisasi penyedia layanan. Tabel IV.2 dan IV.3 masing-masing menunjukkan contoh pemetaan tingkat urgensi dan tingkat dampak gangguan. Tingkat urgensi dan dampak gangguan diklasifikasikan menjadi empat yaitu kritis, tinggi, sedang dan rendah. Setelah tingkat urgensi dan tingkat dampak gangguan ditentukan, selanjutnya dilakukan pemetaan pada prioritas matriks untuk menentukan skala prioritas gangguan seperti pada Tabel IV.4. Skala prioritas gangguan dapat diklasifikasikan menjadi lima yaitu kritis (kode=1), tinggi (kode=2), sedang (kode=3), rendah (kode=4), dan *best effort* (kode=5). Model tersebut selanjutnya dapat direpresentasikan ke dalam sistem rule-based agar aktivitas dapat dilakukan secara otomatis.

Tabel IV.2 Pemetaan tingkat urgensi gangguan

Hierarki Gangguan	Tingkat Urgensi
Backbone	Kritis
Distribusi	Tinggi
Access - VIP	Sedang
Access - Reguler	Rendah

Tabel IV.3 Pemetaan tingkat dampak gangguan

$\sum$ Layanan Terganggu	Tingkat Dampak
>10	Kritis
6-10	Tinggi
1-5	Sedang
0	Rendah

Tabel IV.4 Matriks prioritisasi gangguan

		DAMPAK			
		Kritis	Tinggi	Sedang	Rendah
URGENSI	Kritis	1	1	2	3
	Tinggi	1	2	3	4
	Sedang	2	3	3	4
	Rendah	3	4	4	5

IV.6.3 Prediksi Durasi Gangguan

Tujuan aktivitas ini adalah untuk melakukan prediksi durasi setiap gangguan yang dihitung sejak gangguan teridentifikasi hingga gangguan teratasi (t_{pred}). Aktivitas ini mengasumsikan tidak ada waktu tunggu dalam penanganan gangguan yang diakibatkan tidak tersedianya sumber daya. Prediksi dilakukan dengan mempertimbangkan berbagai variabel yang dianggap dapat mempengaruhi durasi gangguan. Semakin banyaknya variabel yang digunakan untuk memprediksi durasi gangguan berpotensi membuat prediksi yang dihasilkan semakin akurat. Namun disisi lain, hal ini membuat formulasi perhitungan durasi menjadi semakin kompleks karena relasinya sudah melibatkan banyak variabel.

Melihat kompleksitas dalam formulasi prediksi durasi gangguan, maka teknologi *machine learning* dapat diadopsi pada aktivitas ini. Data durasi gangguan yang akan digunakan dalam proses pembelajaran dapat diambil dari historis gangguan sebelumnya. Durasi gangguan digunakan sebagai label atau variabel target, sedangkan faktor-faktor berpengaruh terhadap durasi digunakan sebagai variabel bebas. Durasi gangguan merupakan variabel yang merepresentasikan waktu sehingga dapat dikategorikan sebagai variabel kontinu. Berdasarkan karakteristik tersebut, maka metode regresi menggunakan teknologi *machine learning* cocok digunakan pada aktivitas prediksi durasi gangguan.

IV.6.4 Penjadwalan

Aktivitas penjadwalan bertujuan mengatur urutan pekerjaan (gangguan yang akan ditangani) oleh sumber daya (Analyst dan atau *Field Support*) yang telah

dialokasikan untuk melakukan pekerjaan tersebut. Sebagaimana diketahui, pada alur proses penanganan gangguan, setiap gangguan telah diberikan skala prioritas melalui proses prioritisasi gangguan. Skala prioritas menentukan urutan penanganan gangguan. Gangguan dengan skala prioritas yang lebih tinggi akan dijadwalkan untuk ditangani lebih dulu dibanding gangguan dengan skala lebih rendah. Apabila didapati dua gangguan dengan skala prioritas yang sama, maka gangguan yang teridentifikasi lebih awal akan ditangani lebih dulu. Algoritma ini dikenal dengan penjadwalan *priority-based first-come first-served (FCFS)* (Silberschatz, Galvin, & Gagne, 2012).

Pada proses penanganan gangguan, gangguan yang belum tertangani akan masuk ke dalam antrian sehingga mengalami waktu tunggu (T_{tunggu}). Waktu tunggu tersebut kemudian dipergunakan dalam perhitungan prediksi durasi gangguan akhir (T_{akhir}). Perhitungan waktu tunggu dan prediksi durasi akhir dapat dituliskan dalam formula berikut:

$$T_{tunggu}(i) = T_{akhir}(i-1) \quad (IV.1)$$

$$T_{akhir}(i) = T_{awal}(i) + T_{tunggu}(i) \quad (IV.2)$$

dengan:

i = Urutan penanganan gangguan

T_{akhir} = Prediksi durasi akhir

T_{awal} = Prediksi durasi awal

T_{tunggu} = Waktu tunggu

Informasi prediksi durasi gangguan akhir (T_{akhir}) dihitung dengan mengakumulasi durasi hasil aktivitas prediksi durasi gangguan (T_{awal}) dengan waktu tunggu antrian pada aktivitas penjadwalan (T_{tunggu}). Aktivitas ini juga menjadi akhir dari fase respon penanganan gangguan. Tabel IV.5 menggambarkan ilustrasi proses penjadwalan berbasis prioritas gangguan.

Tabel IV.5 Ilustrasi penjadwalan berdasarkan prioritas gangguan

ID	Waktu Identifikasi	Prediksi Durasi Awal	Prioritas Gangguan	Urutan	Waktu Tunggu	Prediksi Durasi Akhir
XX1	10:20	04:30	2	2	05:00	09:30
XX2	10:20	05:00	1	1	00:00	05:00
XX3	10:21	03:00	2	3	09:30	12:30
XX4	10:21	07:00	3	4	12:30	19:30

IV.6.5 Pembaruan Prediksi Durasi Gangguan

Setelah aktivitas pada fase respon dilalui, maka memasuki fase perbaikan, hal yang perlu dilakukan adalah memberikan pembaruan informasi prediksi durasi gangguan. Aktivitas ini diperlukan karena sangat memungkinkan terjadinya perubahan informasi pada fase perbaikan dari yang diterima pada fase respon. Kondisi yang memicu perlunya pembaruan informasi prediksi durasi dapat dibagi menjadi dua, yaitu perubahan kondisi gangguan dan perubahan prioritas gangguan yang dipicu adanya gangguan baru.

Pada fase perbaikan, penyedia layanan melakukan investigasi secara lebih mendalam, baik dengan menerjunkan tim *Field Support* ke lapangan atau menggunakan metode analisis yang lebih mendalam. Dengan lebih banyaknya data didapat, sangat memungkinkan indikasi gangguan berubah dari saat fase respon. Selain itu, pada fase ini sangat mungkin ditemukan situasi yang dapat menghambat proses penanganan gangguan, seperti faktor cuaca. Situasi tersebut sulit untuk teridentifikasi pada fase respon, namun dapat mempengaruhi durasi gangguan. Oleh karena itu pembaruan informasi durasi gangguan diperlukan pada fase perbaikan ini.

Pada fase perbaikan, gangguan dengan prioritas lebih tinggi akan ditangani lebih dulu dibandingkan gangguan dengan prioritas lebih rendah sesuai dengan jadwal. Jadwal penanganan gangguan bersifat dinamis atau dapat berubah pada situasi tertentu. Apabila pada prosesnya terjadi gangguan baru dengan prioritas yang lebih tinggi, maka urutan pada penjadwalan akan berubah. Perubahan urutan

jadwal ini akan ikut mengubah prediksi durasi gangguan sehingga perlu dilakukan pembaruan informasi.

IV.7 Model Kategorisasi Gangguan dengan *Machine learning*

IV.7.1 Pemahaman Bisnis

Pada tahap pre-analisis gangguan, kategorisasi gangguan merupakan aktivitas klasifikasi indikasi gangguan berdasarkan hasil diagnosis awal. Diagnosis awal dilakukan dengan melakukan tes konektivitas secara jarak jauh (*remote*) dari titik pusat pengecekan ke beberapa titik referensi dalam sistem jaringan berbasis *Internet Protocol* (IP). Tes konektivitas dan titik referensi pengecekan berbeda tergantung pada jenis layanan terganggu. Klasifikasi indikasi gangguan pada tahap pre-analisis dibagi menjadi 5 jenis yaitu *Not incident*, *Transmission media*, *Physical device*, *Device configuration* dan *Power supply*.

IV.7.2 Pemahaman Data

Aplikasi FMS adalah aplikasi inti yang digunakan pada proses bisnis *Fault Management*. Data historis gangguan yang telah tertangani tersimpan dalam *database* aplikasi FMS. Data yang digunakan diambil dari dua tabel dalam *database* FMS, yaitu tabel *incident* (berisi id gangguan, waktu gangguan, kategori gangguan, dll) dan tabel *action request* (berisi hasil id gangguan dan diagnosis ke titik-titik referensi pengecekan). Data yang diambil adalah data gangguan layanan berbasis IP untuk periode Januari – Desember 2018 dengan hasil diagnosis lengkap. Total terdapat sepuluh variabel bebas, satu variabel terikat dan 11.875 observasi gangguan.

Tabel IV.6 dibawah berisi deskripsi variabel dan observasi data yang diambil. Terdapat tiga variabel bebas dengan nilai observasi kosong atau N/A, yaitu VPN_POP_GATEWAY, IX_POP_GATEWAY dan METRO_POP_PSEUDO WIRE. Nilai kosong pada ketiga variabel bebas ini bukan karena kesalahan input tetapi karena pada setiap observasi gangguan hanya salah satu dari ketiga variabel bebas tersebut yang dilakukan pengecekan tergantung pada jenis layanannya. Agar mudah dipahami, selanjutnya nilai kosong pada ketiga variabel tersebut akan

diganti dengan “Not Checked” atau NC. Selain itu, variabel bebas *timestamp* masih dalam format tanggal-waktu. Variabel bebas ini akan digunakan untuk membuat tiga variabel bebas turunan yaitu *month*, *day* dan *shift*.

Tabel IV.6 Deskripsi data model kategorisasi gangguan

Variabel	Tabel Data	Keterangan	Tipe Data	Deskripsi
1. Incident ID	FMS/incident FMS/action request	Nomer ID setiap insiden gangguan	Integer	-
2. Keluhan	FMS/incident	Jenis keluhan yang dilaporkan pelanggan	Polynominal	<i>Link down, Performance issue, Bandwidth issue, Limited access, Change request</i>
3. Service	FMS/action request	Jenis layanan pelanggan	Polynominal	IPVPN, Metronet, Internet/IIX
4. Timestamp	FMS/incident	Tanggal dan waktu terjadinya gangguan	Datetime	-
5. Month	Turunan variabel "Timestamp"	Bulan dilaporkannya gangguan	Polynominal	Jan, Feb, Mar, Apr, May, Jun, Jul, Aug, Sep, Oct, Nov, Des
6. Day	Turunan variabel "Timestamp"	Hari dilaporkannya gangguan	Polynominal	Senin, Selasa, Rabu, Kamis, Jumat, Sabtu, Minggu
7. Shift	Turunan variabel "Timestamp"	Periode shift dilaporkannya gangguan	Polynominal	Pagi, Siang, Malam
8. Regional	FMS/incident	Regional terjadinya gangguan	Polynominal	RSBU, RSBT, RSBS, ROJB, RJBR, RJTY, RJTM, RBNT, RINT, RKAL
9. Status_CPE	FMS/action request	Status perangkat provider di lokasi pelanggan	Polynominal	Managed, Unmanaged
10. POP_LASTMILE_PING_DLL	FMS/action request	Status test PING	Polynominal	OK, NOK

		gateway ke site cabang pelanggan		
11. POP_HO_PING_GW_LM_HO	FMS/action request	Hasil test PING gateway ke site pusat pelanggan	Polynomial	OK, NOK, N/A
12. POP_HO_PING_GW_LM_IIX	FMS/action request	Status test PING gateway ke IX/IIX	Polynomial	OK, NOK, N/A
13. POP_HO_PING_PSEUDOWIRE	FMS/action request	Status test PING pseudowire ke gateway P2P	Polynomial	OK, NOK, N/A
14. LVL-1 KATEGORI (Target)	FMS/incident	Kategori gangguan	Polynomial	<i>Not Incident, Transmission media, Physical device, Device configuration, Power supply</i>

Berdasarkan hasil observasi pada data yang telah diambil, terdapat indikasi anomali yang mungkin terjadi pada proses diagnosis, atau pada proses kategorisasi akhir gangguan. Sebagai contoh, pada gangguan media transmisi didapati hasil diagnosis awal normal. Hal tersebut tidak mungkin terjadi dikarenakan pada saat media transmisi terganggu maka konektifitas layanan dipastikan ikut terganggu. Oleh sebab itu dilakukan filtering terhadap data observasi yang terindikasi anomali tersebut agar tidak mempengaruhi pemodelan. Distribusi kategori gangguan sebelum dan setelah proses filtering anomali ini dapat dilihat pada Tabel IV.7. Sedangkan distribusi setiap variabel gangguan secara lengkap dapat dilihat pada Tabel IV.8.

Tabel IV.7 Distribusi frekuensi kategori gangguan setelah *filtering*

Kategori Gangguan	Sebelum Filtering	Setelah Filtering
Not incident	11.311	10.769
Transmission media	370	324
Physical device	121	90
Device configuration	65	50
Power supply	8	8
Total	11.875	11.241

Tabel IV.8 Distribusi frekuensi setiap variabel gangguan

Variabel	Nominal	Frekuensi
Keluhan	<i>Link down</i>	8.507
	<i>Performance issue</i>	2.017
	<i>Bandwidth issue</i>	435
	<i>Limited access</i>	262
	<i>Change request</i>	20
Service	Metronet	4.564
	IPVPN	4.152
	Internet/IIX	2.525
Month	Jan	675
	Feb	840
	Mar	858
	Apr	997
	May	1.005
	Jun	573
	Jul	822
	Aug	982

	Sep	999
	Oct	1.125
	Nov	1.231
	Des	1.134
Day	Senin	2.084
	Selasa	1.771
	Rabu	1.928
	Kamis	1.878
	Jumat	1.833
	Sabtu	969
	Minggu	778
Shift	Pagi	6.328
	Siang	4.142
	Malam	771
Region	ROJB	3.276
	RJTM	1.224
	RSBS	1.146
	RJTY	1.096
	RJBR	1.017
	RINT	948
	RSBT	759
	RBNT	693
	RSBU	564
	RKAL	518
POP_LASTMILE_CPE_DEVICE	<i>Managed</i>	6.603
	<i>Unmanaged</i>	4.638
POP_LASTMILE_PING_DLL	OK	10.601
	NOK	640
VPN_POP_GATEWAY	OK	4.101
	NOK	51
	N/A	7.089
IX_POP_GATEWAY	OK	2.494
	NOK	31
	N/A	8.715
METRO_POP_PSEUDOWIRE	OK	4.524
	NOK	40
	N/A	6.677
LVL-1 KATEGORI (Target)	<i>Not incident</i>	10.769
	<i>Transmission media</i>	324
	<i>Physical device</i>	90
	<i>Device configuration</i>	50
	<i>Power supply</i>	8

Setelah data dari delapan variabel bebas dan satu variabel terikat didapatkan, selanjutnya perlu dilakukan pengujian untuk mengetahui keterkaitan antara setiap

variabel bebas dengan variabel terikat. Metode analisis statistik Chi-Square dan Fisher's Exact Test dipergunakan untuk mengetahui keterkaitan tersebut. Hipotesis (H_0) dari kedua analisis menyatakan antara kedua variabel tidak memiliki keterkaitan (independen). Sedangkan hipotesis alternatif (H_A) adalah kedua variabel memiliki keterkaitan. Pengujian dilakukan dengan tingkat kepercayaan 95% ($\alpha = 0.05$). Nilai $p > 0.05$ menunjukkan tidak cukup bukti untuk menolak H_0 , sebaliknya nilai $p < 0.05$ menunjukkan cukup bukti untuk menolak H_0 . Berdasarkan pengujian yang telah dilakukan untuk kombinasi setiap variabel bebas dengan variabel terikat, didapatkan hanya variabel bebas Day yang tidak memiliki keterkaitan. Hasil uji lengkap dapat dilihat pada Tabel V.X dibawah.

Tabel IV.9 Hasil uji keterkaitan variabel bebas dan variabel terikat

Variabel Bebas	DF	Chi-Square (X^2)	p-value (Chi-Square)	p-value (Fisher's)
Keluhan	16	88.072	5.658e-12	0.0005
Service	8	18.123	0.02032	0.02399
Month	44	199.64	2.2e-16	0.0005
Day	24	25.01	0.4052	0.4273
Shift	8	17.974	0.0214	0.0170
Region	36	79.761	3.724e-05	0.0005
Upstream	4	3829.5	2.2e-16	0.0005
Downstream	4	7431.4	2.2e-16	0.0005

IV.7.3 Persiapan Data

Setelah pengumpulan dan analisis data yang diambil dari database aplikasi, langkah selanjutnya adalah mempersiapkan data yang akan digunakan untuk pemodelan. Proses pertama yang dilakukan adalah membuat variabel turunan yaitu "Month", "Day" dan "Shift" dari variabel "Timestamp". Variabel bebas turunan "Month" dan "Day" didapat dari tanggal terjadinya gangguan. Variabel bebas turunan Shift didapat dari jam terjadinya gangguan setelah dikonversi ke jam operasional shift *Fault Management*. *Fault Management* memiliki tiga shift masing-masing delapan jam dengan jam 07:00-15:00 WIB shift pagi, 15:00-23:00 WIB shift siang dan 23:00-07:00 WIB shift malam.

Proses kedua adalah menghapus atau mengkonversi observasi yang tidak memiliki nilai (“N/A”). Berdasarkan hasil pengamatan sebelumnya, tiga variabel bebas yang tidak memiliki nilai yaitu “VPN_POP_GATEWAY”, “IX_POP_GATEWAY”, dan “METRO_POP_GATEWAY”. Observasi yang tidak memiliki nilai pada ketiga variabel tersebut akan diganti menjadi “NC” atau “Not Checked”. Ketiga variabel tersebut menunjukkan hasil pengecekan konektivitas kearah gateway untuk masing-masing layanan. Setiap gangguan yang masuk akan memiliki dua hasil diagnosa yaitu konektivitas kearah pelanggan dan konektivitas kearah gateway layanan (salah satu dari tiga variabel diatas). Oleh sebab itu ketiga variabel dapat diagregasi menjadi satu yang selanjutnya disebut “*Upstream*”. Sedangkan hasil diagnosa konektivitas kearah pelanggan diubah nama dari “POP_LASTMILE_PING_DLL” menjadi “*Downstream*”.

Proses ketiga adalah pengkodean variabel kategori menjadi numerik. seperti terlihat pada Tabel IV.6 sebelumnya, bentuk data pada variabel bebas dan terikat adalah kategori atau polinomial. Sementara, mayoritas algoritma klasifikasi menggunakan persamaan matematika yang membutuhkan data input dalam bentuk numerik. Oleh sebab itu, proses pengkodean variabel bebas ini diperlukan.

IV.7.4 Pemodelan

Berdasarkan pemahaman bisnis yang dilakukan sebelumnya, model bertujuan untuk menentukan kategori indikasi gangguan, oleh karena itu jenis algoritma yang pada pemodelan adalah klasifikasi. Jumlah kelas yang akan dikategorisasi sebanyak lima kelas, dengan distribusi masing-masing kelas yaitu 1346:41:11:6:1. Karena jumlah kelas yang lebih dari dua dengan distribusi yang tidak merata menjadikan kategorisasi indikasi gangguan sebagai kasus klasifikasi kelas banyak tidak seimbang (*multiclass imbalanced classification*). Pada kasus klasifikasi kelas banyak tidak seimbang, model cenderung memilih kelas yang mayoritas dan menghiraukan kelas yang minoritas. Strategi khusus dibutuhkan untuk mendapatkan model yang baik dari kasus klasifikasi ini. Beberapa strategi yang akan diujikan pada proses pemodelan klasifikasi indikasi gangguan adalah pembobotan kelas (*class weight*), *resampling* dan *ensemble*.

Proses pertama tahap pemodelan ini adalah membagi data secara acak menjadi dua yaitu data pelatihan dan data validasi. Proporsi pembagian data adalah 85% data pelatihan dan 15% data validasi. Hasil pembagian didapatkan data pelatihan sebanyak 10.116 observasi, sedangkan data validasi sebanyak 1.125 observasi. Selama proses pemodelan data yang digunakan adalah data pelatihan. Data validasi hanya akan digunakan saat evaluasi akhir model, setelah model terbaik didapatkan dari proses pemodelan.

Proses kedua adalah melakukan pemodelan dengan beberapa kombinasi strategi yang sesuai kasus klasifikasi kelas banyak tidak seimbang. Strategi pertama menggunakan basis algoritma klasifikasi saja, kedua dengan melakukan pembobotan kelas, ketiga dengan resampling data, keempat dengan metode *ensemble*, kelima dengan kombinasi *ensemble*-pembobotan kelas, dan keenam dengan kombinasi *ensemble*-resampling data. Algoritma *extremely randomized trees* dipilih sebagai basis algoritma klasifikasi. Setiap strategi dilakukan dengan skenario validasi silang lima tingkat (*5-fold cross-validation*) dan setiap strategi dilakukan sepuluh kali pengujian.

Pada kasus klasifikasi *multiclass imbalanced*, *accuracy* tidak dapat dijadikan sebagai penilaian tunggal. *F1-score* merupakan salah satu metode penilaian lain yang cocok digunakan pada kasus klasifikasi *multiclass imbalanced* (Haixiang et al., 2017). *F1-score* merupakan nilai yang menunjukkan kombinasi harmonik antara *precision* dan *recall* (Subramanian, 2015), dua metode penilaian klasifikasi lainnya yang juga umum digunakan. Pada penelitian ini, *F1-score* dan *accuracy* dipilih sebagai dua metode penilaian yang utama. Formula dari evaluasi *accuracy* dan *F1-score* dituliskan seperti formula IV.3 dan IV.6 sebagai berikut (Raschka & Mirjalili, 2017):

$$Accuracy (Acc) = \frac{TP+TN}{FP+FN+TP+TN} \quad (IV.3)$$

$$Precision (Prec) = \frac{TP}{TP+FP} \quad (IV.4)$$

$$Recall (Rec) = \frac{TP}{FN+TP} \quad (IV.5)$$

$$F1 \text{ score} = 2 \times \frac{Prec \times Rec}{Prec+Rec} \quad (IV.6)$$

dengan:

TP = Jumlah True Positive

TN = Jumlah True Negative

FP = Jumlah False Positive

FN = Jumlah False Negative

Hasil pengujian keenam strategi klasifikasi dapat dilihat pada Tabel IV.10. Hasil pengujian menunjukkan bahwa setiap strategi memiliki nilai rata-rata *accuracy*, *precision*, *recall* dan *F1-score* berbeda. Kombinasi strategi *ensemble*-pembobotan kelas (Bag-Wei-ETS) dengan nilai *accuracy* 0.9721, *recall* 0.5364 dan *F1-score* 0.5526 merupakan strategi terbaik dibandingkan lima strategi lainnya. Sementara nilai *precision* terbaik yaitu 0.6023 dihasilkan oleh strategi *ensemble* (Bag-ETS). Dilihat dari waktu pemrosesan, terlihat bahwa strategi *ensemble* memakan waktu pemrosesan yang lebih lama daripada pembobotan kelas dan *resampling*. Sehingga strategi kombinasi *ensemble-resampling* memakan waktu yang paling lama dibanding lima strategi lainnya. Berdasarkan hasil diatas, maka strategi kombinasi *ensemble*-pembobotan kelas (Bag-Wei-ETS) dipilih sebagai metode klasifikasi indikasi gangguan pada penelitian ini.

Tabel IV.10 Hasil pengujian strategi klasifikasi untuk kasus *imbalanced*

Strategy	Fit Time	Accuracy	Precision	Recall	F1-Score
[1] ETS	0.0546	0.9716	0.5727	0.5273	0.5418
[2] Wei-ETS	0.0589	0.9710	0.5684	0.5329	0.5439
[3] ROS-ETS	0.3052	0.9712	0.5655	0.5335	0.5426
[4] Bag-ETS	0.3370	0.9721	0.6023	0.5286	0.5506
[5] Bag-Wei-ETS	0.3659	0.9721	0.5959	0.5364	0.5526
[6] Bag-ROS-ETS	2.1698	0.9717	0.5928	0.5334	0.5491

Proses ketiga adalah melakukan konfigurasi parameter dari strategi klasifikasi terbaik yang dipilih. Proses ini dilakukan untuk mendapatkan model dengan hasil terbaik. Konfigurasi parameter dilakukan menggunakan metode *grid search* yaitu dengan mencari kombinasi nilai dari setiap parameter model yang ditetapkan. Parameter model beserta kombinasinya dapat dilihat pada Tabel IV.11 dibawah. Dari nilai parameter model didapati 810 kombinasi parameter model


yang menghasilkan nilai *F1-score* terbaik. Berdasarkan metode grid search, konfigurasi parameter dengan hasil terbaik yaitu *F1-score* 0.5716 dan *accuracy* 0.9690 adalah kombinasi berikut:

N_estimators = 20
 Criterion = gini
 Max_features = None
 Max_depth = 10
 Min_samples_split = 2
 Min_samples_leaf = 2

Tabel IV.11 Konfigurasi parameter model dengan metode *grid search*

Parameter Model	Deskripsi	Nilai
N_estimators	Jumlah <i>tree</i> yang dibentuk dalam setiap kumpulan <i>tree</i> (<i>forest</i>)	20, 40, 60, 80, 100
Criterion	Fungsi yang digunakan untuk menilai percabangan pada setiap <i>tree</i>	'gini'
Max_features	Jumlah variabel bebas maksimum yang digunakan untuk menilai percabangan pada setiap <i>tree</i>	'sqrt', 'log2', None
Max_depth	Jumlah cabang maksimum yang dapat dibentuk pada setiap <i>tree</i>	5, 10, 15, 20, 25, None
Min_samples_split	Jumlah data minimum yang digunakan untuk membentuk percabangan pada setiap <i>tree</i>	2, 4, 6
Min_samples_leaf	Jumlah data minimum pada setiap <i>leaf</i> pada setiap <i>tree</i>	1, 2, 3

Berdasarkan hasil konfigurasi parameter dengan metode grid search diatas, maka struktur model kategorisasi gangguan akan terdiri dari sepuluh kelompok (konfigurasi standar *ensemble bagging*) yang masing-masing kelompok terdiri atas dua puluh *decision tree*. Setiap kelompok akan menghasilkan label kategori gangguan yang merupakan hasil voting dari setiap *decision tree*. Hasil voting masing-masing kelompok kemudian akan divotingkan kembali untuk didapatkan kategori final. Ilustrasi dari proses tersebut dapat dilihat pada Gambar IV.8 berikut. Sementara contoh sampel model *decision tree* untuk kategorisasi gangguan dapat dilihat pada Lampiran A1-A4.



Gambar IV.8 Ilustrasi struktur model kategorisasi gangguan

IV.7.5 Evaluasi Model

Setelah didapatkan model klasifikasi dengan strategi dan konfigurasi parameter terbaik. Selanjutnya dilakukan evaluasi akhir dengan mengujikan model ke data validasi. Hasil pengujian data validasi yang terdiri dari 1.125 observasi dapat dilihat dalam bentuk *confusion matrix* pada Tabel IV.12 dan tabel evaluasi pada Tabel IV.13 dibawah. Berdasarkan hasil pengujian model pada data validasi didapatkan nilai rata-rata *F1-score* 0.514 dan rata-rata *accuracy* 0.9724. Dengan mengamati tabel *confusion matrix*, terlihat jika setiap kategori gangguan terklasifikasi dengan baik, kecuali pada kategori gangguan *Power Supply*. Hal ini dapat disebabkan kurangnya variabel bebas yang dapat menjadi indikator terjadinya gangguan *Power Supply*.


Tabel IV.12 *Confusion matrix* uji model pada data validasi

		Prediksi				
		DC	NI	PD	PS	TM
Aktual	DC	3	0	2	0	0
	NI	4	1060	3	1	10
	PD	0	0	4	1	4
	PS	0	0	0	0	1
	TM	0	0	5	0	27

Tabel IV.13 Performa hasil uji model pada data validasi

	Accuracy	Precision	Recall	F1-Score	Support
Device Configuration (DC)		0.429	0.600	0.500	5
Not Incident (NI)		1.000	0.983	0.992	1078
Physical Device (PD)		0.286	0.444	0.348	9
Power Supply (PS)		0.000	0.000	0.000	1
Transmission Media (TM)		0.643	0.844	0.730	32
Micro Average	0.9724	0.972	0.972	0.972	1125
Macro Average		0.471	0.574	0.514	1125
Weighted Average		0.981	0.972	0.976	1125

Melalui model kategorisasi yang telah terbentuk, dapat diketahui variabel bebas yang dianggap penting dalam pembentukan model. Nilai setiap variabel bebas terhadap model dapat dilihat pada Gambar IV.9 dibawah. Berdasarkan grafik tersebut maka tiga variabel bebas yang memiliki tingkat kepentingan tertinggi terhadap model kategorisasi adalah “Upstream” (0.276), “Downstream” (0.216) dan “Day” (0.124). Sedangkan variabel bebas “Keluhan” (0.030) memiliki tingkat kepentingan yang paling rendah.



Gambar IV.9 Grafik tingkat kepentingan variabel bebas model kategorisasi

IV.8 Model Prediksi Durasi Gangguan dengan *Machine learning*

IV.8.1 Pemahaman Bisnis

Prediksi durasi gangguan merupakan aktivitas memprediksi durasi dari setiap gangguan yang terjadi. Durasi gangguan dalam konteks penanganan gangguan merupakan waktu yang dibutuhkan oleh penyedia layanan untuk menormalkan kembali layanan kepada pelanggan. Durasi dihitung sejak gangguan teridentifikasi hingga gangguan terselesaikan. Secara bisnis, informasi ini penting baik bagi pengguna maupun penyedia layanan. Bagi keduanya, dengan informasi prediksi durasi gangguan maka strategi yang lebih baik dapat diterapkan dalam merespon gangguan. Prediksi durasi gangguan saat ini dilakukan sesuai target waktu penyelesaian masing-masing gangguan yang telah ditentukan organisasi berdasarkan kategori setiap gangguan. Untuk meningkatkan akurasi prediksi durasi gangguan, maka prediksi perlu mempertimbangkan faktor-faktor lain yang berpengaruh terhadap durasi gangguan.

Model prediksi durasi gangguan yang dikembangkan dibagi menjadi dua model. Model pertama (Model Durasi A) dikembangkan untuk memprediksi durasi gangguan pada fase respon, di saat informasi terkait gangguan yang diperoleh relatif lebih sedikit. Sementara, model kedua (Model Durasi B) dikembangkan untuk memprediksi durasi gangguan pada fase respon, di saat informasi terkait gangguan sudah lebih banyak diperoleh. Menggunakan dua model prediksi durasi tersebut, penyedia layanan dapat memberikan update informasi prediksi durasi gangguan yang lebih akurat seiring dengan berjalannya proses penanganan gangguan.

IV.8.2 Pemahaman Data

Data yang digunakan dalam proses pemodelan prediksi durasi gangguan diambil dari database dua aplikasi yang digunakan dalam proses bisnis penanganan gangguan. Kedua aplikasi tersebut adalah aplikasi FMS dan aplikasi FSM. Data pada aplikasi FMS berisi karakteristik gangguan seperti kategori, regional, waktu, dsb. Sementara data pada aplikasi FSM berisi karakteristik penanganan gangguan team *Field Support*, durasi persiapan, durasi perjalanan, penghambat penanganan,

dsb). Kedua data yang terpisah tersebut disatukan berdasarkan ID gangguan sehingga didapatkan data lengkap. Masing-masing model prediksi durasi gangguan memiliki enam variabel bebas untuk Model Durasi A, sepuluh variabel bebas untuk Model Durasi B, dan satu variabel terikat untuk Model Durasi A dan Model Durasi B. Deskripsi lengkap variabel yang digunakan untuk model prediksi durasi gangguan dapat dilihat pada Tabel IV.14 berikut.

Tabel IV.14 Deskripsi data model prediksi durasi gangguan

Variabel	Input Model	Sumber Data	Deskripsi	Tipe Data	Keterangan
1. Kategori Level-1	A	FMS	Kategori atau jenis gangguan di level 1	Polynominal	<i>Transmission Media, Device Configuration, Physical Device, Power Supply</i>
2. Kategori Level-2	B	FMS	Kategori atau jenis gangguan di level 2	Polynominal	<i>Cable-ADSS, Cable-Fig.8, Cable-Fiber Armour, Cable-Patchcord, Cable-Connector, dll</i>
3. Region	A/B	FMS	Regional lokasi terjadinya gangguan	Polynominal	RSBU, RSBT, RSBS, ROJB, RJBR, RJTY, RJTM, RBNT, RINT, RKAL
4. Hari	A/B	FMS	Tipe hari saat gangguan dilaporkan	Polynominal	<i>Workday, Non-Workday</i>
5. Jam	A/B	FMS	Tipe jam saat gangguan dilaporkan	Polynominal	<i>Workhour, Non-Workhour</i>
6. NOC_Load	A/B	FMS	Jumlah gangguan yang ditangani NOC dalam 24 jam terakhir	Integer	75 - 695
7. REG_Load	A/B	FMS	Jumlah gangguan yang ditangani Regional terkait	Integer	1 - 230

			dalam 24 jam terakhir		
8. OB_Access	B	FSM	Kendala akses masuk ke lokasi gangguan	Binominal	<i>Yes/No</i>
9. OB_Weather	B	FSM	Kendala cuaca saat progress penanganan gangguan	Binominal	<i>Yes/No</i>
10. OB_Security	B	FSM	Kendala keamanan saat progress penanganan gangguan	Binominal	<i>Yes/No</i>
11. OB_Others	B	FSM	Kendala-kendala lain dalam proses penanganan gangguan	Binominal	<i>Yes/No</i>
12. Durasi (Target)	A/B	FMS	Durasi atau waktu penyelesaian gangguan tercatat	Continous	0.52 – 55.88

Data yang digunakan untuk proses pemodelan prediksi durasi gangguan merupakan data gangguan layanan berbasis IP periode Januari-Desember 2018 yang telah tervalidasi sebagai gangguan. Terdapat sebanyak 16.979 observasi data tervalidasi sebagai gangguan pada periode waktu tersebut. Dari data tersebut, selanjutnya dilakukan seleksi data untuk membersihkan dataset dari data yang dianggap anomali serta data bernilai ekstrem. Penyaringan data diperlukan untuk memperoleh hasil pemodelan yang baik, karena data yang buruk akan mempersulit mesin untuk membuat model.

Penyaringan pertama dilakukan dengan menghilangkan gangguan dengan durasi kurang dari setengah jam. Setengah jam merupakan waktu minimal yang dibutuhkan untuk merespon gangguan, sehingga gangguan kurang dari setengah jam dapat dianggap sebagai anomali. Total terdapat 799 observasi gangguan dengan durasi kurang dari setengah jam. Penyaringan kedua dilakukan dengan menghilangkan gangguan yang membutuhkan pengiriman *Field Support* dengan durasi kurang dari satu jam. Total terdapat 185 observasi gangguan dengan pengiriman team yang berdurasi kurang dari satu jam. Serupa dengan alasan sebelumnya, satu jam merupakan waktu minimal yang dibutuhkan penyedia layanan untuk mengirimkan *Field Support* ke lokasi gangguan. Penyaringan terakhir dilakukan dengan metode *Interquartile Range* (IQR) untuk setiap kategori gangguan. Metode IQR adalah metode umum pada statistik yang bertujuan untuk menghilangkan nilai ekstrem dari sekumpulan data. Total terdapat 1.410 observasi gangguan yang terdeteksi sebagai nilai ekstrem melalui metode IQR. Setelah melalui ketiga proses penyaringan, didapatkan 14.585 observasi gangguan akhir yang akan digunakan untuk proses pemodelan. Detail proses penyaringan data gangguan dapat dilihat pada Tabel IV.15 berikut.

Tabel IV.15 Proses penyaringan data durasi gangguan

Kriteria	Jumlah Tersaring	Jumlah Akhir
Data durasi awal	-	16.979
Durasi gangguan <0.5 jam	799	16.180
Durasi gangguan dengan	185	15.995

Pengiriman Team <1 jam		
Inter-Quartile Range	1.410	14.585


Tabel IV.16 *Quartile range* data durasi gangguan (dalam satuan jam)

	Min	Q1	Q2	Q3	Max	IQR	Batas Bawah	Batas Atas
<i>Transmission Media</i>	0,52	4,71	8,49	20,21	1558,27	15,50	-18,54	43,46
<i>Physical Device</i>	1,01	2,84	5,71	20,06	746,85	17,21	-22,98	45,88
<i>Device Configuration</i>	0,53	3,64	8,86	24,74	818,35	21,10	-28,01	56,39
<i>Power Supply</i>	1,01	2,63	4,15	7,88	117,21	5,25	-5,24	15,76

Hasil analisis statistik terhadap data durasi gangguan , sebagaimana ditampilkan pada Tabel IV.17, menunjukkan bahwa rata-rata durasi gangguan adalah 10,846 jam dengan standar deviasi 9,418 jam. Analisis statistik juga menunjukkan bahwa distribusi durasi gangguan tidak simetris sebagaimana distribusi normal, tetapi miring kearah kanan dengan nilai kemiringan (*skew*) 1,346 dan kurtosis 1,147. Uji Anderson-Darling dilakukan untuk memastikan apakah distribusi durasi gangguan mengikuti pola distribusi normal atau distribusi lognormal. Hasil uji menunjukkan nilai AD untuk distribusi lognormal lebih kecil (AD=47,766) dibandingkan dengan nilai AD untuk distribusi normal (AD=815,138). Hasil ini menunjukkan bahwa distribusi durasi gangguan cenderung mengikuti distribusi lognormal daripada distribusi normal. Grafik histogram data distribusi gangguan pada Gambar IV.10 mengkonfirmasi hal ini.

Tabel IV.17 Analisis statistik data durasi gangguan

Rata-rata	10,846	Minimal	0,520
Standar deviasi	9,418	Kuartil-1	3,990
Varian	88,695	Median	7,220
Kemiringan	1,346	Kuartil-3	15,240
Kurtosis	1,147	Maksimal	55,880
Jumlah Data (n)		14.585	



Gambar IV.10 Plot distribusi lognormal terhadap data durasi gangguan

Tahapan selanjutnya adalah menguji apakah variabel bebas yang digunakan untuk pemodelan memiliki pengaruh terhadap variabel terikat. Metode uji statistik Welch's ANOVA digunakan untuk menguji pengaruh setiap kategori variabel terhadap durasi gangguan. Metode Welch's ANOVA digunakan karena pada metode ini tidak diasumsikan data yang homogen atau memiliki varian yang sama, seperti pada metode ANOVA biasa. Metode ini menguji hipotesis apakah terdapat perbedaan rata-rata nilai variabel terikat yang signifikan terhadap salah satu perlakuan pada variabel bebas. Hipotesis (H_0) pada metode ini adalah tidak terdapat perbedaan rata-rata nilai variabel terikat yang signifikan pada salah satu perlakuan variabel bebas. Apabila nilai p (p -value) hasil uji lebih kecil daripada 0.05 ($p < 0.05$), maka hipotesis ditolak.

Data durasi gangguan periode 2018 digunakan sebagai sampel untuk pengujian Welch's ANOVA dengan total sebanyak 14.585 observasi gangguan. Berdasarkan hasil pengujian Welch's ANOVA menggunakan data sampel disimpulkan jika faktor yang secara signifikan mempengaruhi durasi gangguan layanan pita lebar

adalah kategori gangguan, regional, jam, kendala akses, kendala cuaca, kendala keamanan dan kendala lain-lain. Sementara faktor hari dianggap tidak secara signifikan mempengaruhi durasi gangguan pita lebar. Hasil uji Welch's ANOVA terhadap data durasi gangguan dapat dilihat pada Tabel IV.18 berikut.

Tabel IV.18 Hasil uji Welch's ANOVA data durasi gangguan

Faktor	Nilai p Sampel
Kategori Gangguan	0.000
Regional	0.000
Hari	0.174
Jam	0.000
Kendala Akses	0.000
Kendala Cuaca	0.000
Kendala Keamanan	0.000
Kendala Lainnya	0.039

IV.8.3 Persiapan Data

Setelah data bersih yang akan digunakan untuk pemodelan ditentukan, langkah selanjutnya adalah transformasi data. Transformasi data dilakukan baik pada variabel bebas maupun variabel terikat. Pada variabel bebas yang terdiri atas data bilangan, transformasi data dilakukan dengan melakukan normalisasi data. Normalisasi data merupakan teknik *pre-processing* yang umum dilakukan sebelum melakukan pemodelan ANN. Pada data yang telah ternormalisasi, setiap variabel berada pada skala yang sama sehingga model neural network lebih stabil. Sedangkan pada variabel bebas yang terdiri atas data *polynomial*, transformasi data dilakukan menggunakan metode *dummy coding (one-hot-encoding)*. Pada metode ini setiap kategori pada variabel bebas dipecah menjadi kolom-kolom baru dengan nilai 1 atau 0. Metode ini digunakan karena pada data berjenis *polynomial*, setiap data pada variabel tidak memiliki makna matematis.

Selain pada variabel bebas, transformasi data juga perlu dilakukan pada variabel terikat. Teknik *machine learning* pada umumnya mengasumsikan data mengikuti pola distribusi normal. Sebagaimana telah dijelaskan pada bagian IV.8.2 sebelumnya, distribusi data durasi gangguan lebih mengikuti pola distribusi

lognormal. Oleh karena itu diperlukan transformasi logaritmik terhadap data durasi gangguan, sehingga pola distribusinya mendekati distribusi normal. Beberapa penelitian sebelumnya telah menerapkan metode transformasi logaritmik ini dan mendapatkan hasil yang lebih baik dibandingkan data tanpa transformasi.


IV.8.4 Pemodelan

Setelah melalui proses *pre-processing*, data siap dipergunakan untuk pemodelan. Metode ANN digunakan untuk melakukan pemodelan prediksi durasi gangguan. ANN dipilih karena metode ini mampu menggambarkan hubungan non-linier yang rumit antara input dengan output suatu problem (Valenti et al., 2010) sehingga telah banyak digunakan untuk memecahkan problem kompleks (Wei & Lee, 2007). Berdasarkan karakteristik tersebut, beberapa peneliti (Guan et al., 2010; Valenti et al., 2010; Wei & Lee, 2005, 2007) telah mengadopsi pendekatan ANN untuk memprediksi durasi gangguan jalan raya dengan hasil yang cukup baik.

Pemodelan prediksi durasi ANN dilakukan menggunakan metode *5-folds cross-validation*. Pada metode ini, dataset durasi gangguan akan dibagi menjadi lima bagian (*folds*). Selanjutnya empat dari lima bagian dataset tersebut akan digunakan sebagai data *training* yang kemudian akan divalidasi pada seperlima bagian dataset tersisa. Proses *cross-validation* dilakukan sebanyak lima kali hingga setiap kombinasi bagian digunakan sebagai data *training* dan data validasi.

Digunakan dua struktur ANN yang berbeda untuk prediksi durasi di masing-masing fase penanganan gangguan. Model Durasi A digunakan untuk prediksi durasi fase respon, sedangkan Model Durasi B digunakan untuk prediksi durasi fase perbaikan. Struktur ANN yang digunakan pada Model Durasi A, sebagaimana terlihat pada Gambar IV.11a, terdiri atas delapan belas input *layer*, satu hidden *layer* dengan sembilan neuron dan satu output *layer*. Sedangkan pada Model Durasi B, sebagaimana terlihat pada Gambar IV.11b, struktur yang digunakan adalah empat puluh satu input *layer*, satu hidden *layer* dengan dua

puluh satu neuron dan satu output *layer*. Kedua model menggunakan fungsi sigmoid sebagai fungsi aktivasi. Sementara hasil akhir konfigurasi masing-masing model ANN secara detail dapat dilihat pada Lampiran B1 untuk ANN Model Durasi A dan Lambiran B2 untuk ANN Model Durasi B.



Gambar IV.11 Struktur ANN model prediksi durasi gangguan (a) fase respon dan (b) fase perbaikan

IV.8.5 Evaluasi Model

Evaluasi model dilakukan menggunakan beberapa metode penilaian regresi yaitu *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). MAE dan RMSE keduanya menunjukkan besaran deviasi antara nilai prediksi dengan nilai aktual, tetapi RMSE memberi bobot lebih untuk deviasi yang lebih besar. Sementara, MAPE menunjukkan rata-rata persentase deviasi prediksi tersebut terhadap nilai aktual. Pada penelitian ini, MAPE menjadi acuan evaluasi utama, karena MAPE merupakan formula yang paling umum digunakan dalam mengevaluasi akurasi prediksi (Camara et al., 2018). Formula MAE, RMSE dan MAPE dapat dilihat pada formula IV.6-IV.8 berikut.

$$MAE = \frac{1}{n} \sum_{t=1}^n |A_t - F_t| \quad (IV.6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2} \quad (IV.7)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100\% \quad (IV.8)$$

dengan:

A_t = Nilai aktual

F_t = Nilai prediksi

n = Jumlah observasi

Sebagai pembanding, kedua hasil prediksi model ANN akan dibandingkan dengan hasil prediksi durasi metode konvensional. Pada metode konvensional prediksi durasi gangguan ditentukan berdasarkan target penyelesaian gangguan. Target penyelesaian gangguan berdasarkan kategori gangguan pada metode konvensional adalah delapan jam untuk gangguan *Transmission Media*, empat jam untuk gangguan *Physical Device*, empat jam untuk gangguan *Device Configuration*, dan dua jam untuk gangguan *Power Supply*.

Berdasarkan model prediksi durasi gangguan awal menggunakan ANN, didapatkan nilai untuk Model Durasi A yang digunakan pada fase respon masing-

masing adalah 64,0327% MAPE, 6,7633 MAE dan 10,5173 RMSE. Sedangkan untuk Model Durasi B yang digunakan pada fase perbaikan nilai yang didapatkan adalah 63,0483% MAPE, 6,5553 MAE dan 10,2086 RMSE. Nampak bahwa Model Durasi B memiliki performa yang sedikit lebih baik dibandingkan Model Durasi A. Hal ini menunjukkan bahwa model prediksi durasi gangguan akan semakin akurat seiring dengan bertambahnya informasi terkait yang diterima. Kedua model prediksi durasi dengan ANN memiliki nilai MAPE dan MAE yang lebih baik dibandingkan dengan model konvensional. Sementara model konvensional masih memiliki nilai RMSE yang sedikit lebih baik dibandingkan dengan model prediksi durasi dengan ANN. Hasil penilaian lengkap untuk ketiga model dapat dilihat pada Tabel IV.19.

Tabel IV.19 Perbandingan evaluasi model prediksi durasi gangguan

Penilaian	Model Konvensional	ANN Model Durasi A	ANN Model Durasi B
MAPE	82.4641%	64.0327%	63.0483%
MAE	6.7778	6.7633	6.5553
RMSE	10.1336	10.5173	10.2086

Bab V Implementasi & Evaluasi

V.1 Simulasi *Framework* Prediksi Durasi Gangguan

Pada tahapan ini dilakukan simulasi untuk menguji setiap model aktivitas pada *framework* penanganan gangguan yang telah dirancang sebelumnya. Simulasi dilakukan menggunakan data buatan dengan skenario proses penanganan gangguan pada periode waktu tertentu. Digunakan data buatan sebanyak sepuluh data (Problem ID SIM0001-SIM0010) yang disimulasikan ke dalam *framework* prediksi durasi gangguan. Proses simulasi dilakukan dengan konfigurasi perangkat keras dan perangkat lunak sebagai berikut:

Komputer	: Lenovo Thinkpad X230
Prosesor	: Intel® i5-3320M 2.60 Ghz
RAM	: 8 GB
Sistem Operasi	: Windows 7 Professional SP1
Platform Pemodelan	: Anaconda3-2018.12 (Python 3.6, Scikit 0.20.3, Keras 2.2.4, Tensorflow 1.13.1), Microsoft Excel 2010

V.1.1 Simulasi Aktivitas Kategorisasi Gangguan

Simulasi dilakukan menggunakan model *machine learning Bagging-Class Weighting-Extremely Randomized Trees* (Bag-Wei-ETS). Data pelatihan kategorisasi gangguan yang digunakan pada tahap perancangan digunakan untuk membentuk model. Selanjutnya, dilakukan prediksi terhadap sepuluh data simulasi menggunakan model yang telah terbentuk. Berdasarkan hasil simulasi kategorisasi gangguan, tiga Problem ID diprediksi sebagai keluhan (SIM0002, SIM0006 dan SIM0008), tiga Problem ID diprediksi sebagai gangguan transmisi (SIM0003, SIM0005 dan SIM0010), dua gangguan diprediksi sebagai gangguan konfigurasi (SIM0002 dan SIM0007) dan dua gangguan diprediksi sebagai kerusakan perangkat (SIM0004 dan SIM0009). Data dan hasil simulasi aktivitas kategorisasi selengkapnya dapat dilihat pada Tabel V.1 dibawah.

Tabel V.1 Hasil simulasi model kategorisasi gangguan pada data buatan

ID		INPUT									OUTPUT
PROB_ID	WAKTU	KELUHAN	SERVICE	BLN	HARI	SHIFT	REG	STATUS CPE	DOWN STREAM	UP STREAM	LVL-1 KATEGORI
SIM0001	08-01-19 09:30:00	Unavailable	IPVPN	Jan	Selasa	Pagi	ROJB	Managed	OK	NOK	Device Configuration
SIM0002	08-01-19 09:30:15	Unavailable	Internet/IIX	Jan	Selasa	Pagi	RJBR	Managed	OK	OK	Not Incident
SIM0003	08-01-19 09:30:30	Unavailable	Internet/IIX	Jan	Selasa	Pagi	ROJB	Unmanaged	NOK	OK	Transmission Media
SIM0004	08-01-19 09:30:45	Unavailable	Metronet	Jan	Selasa	Pagi	RJBR	Managed	NOK	OK	Physical Device
SIM0005	08-01-19 09:31:00	Performance	Metronet	Jan	Selasa	Pagi	ROJB	Unmanaged	NOK	OK	Transmission Media
SIM0006	08-01-19 09:31:15	Unavailable	IPVPN	Jan	Selasa	Pagi	RJBR	Managed	OK	OK	Not Incident
SIM0007	08-01-19 09:31:30	Performance	Internet/IIX	Jan	Selasa	Pagi	ROJB	Managed	OK	NOK	Device Configuration
SIM0008	08-01-19 09:31:45	Performance	Metronet	Jan	Selasa	Pagi	ROJB	Unmanaged	OK	OK	Not Incident
SIM0009	08-01-19 09:32:00	Unavailable	Metronet	Jan	Selasa	Pagi	RJBR	Managed	NOK	OK	Physical Device
SIM0010	08-01-19 10:00:00	Unavailable	Internet/IIX	Jan	Selasa	Pagi	ROJB	Managed	NOK	OK	Transmission Media

V.1.2 Simulasi Aktivitas Prioritisasi Gangguan

Simulasi prioritisasi gangguan dilakukan dengan melakukan pemetaan tingkat urgensi dan pemetaan tingkat dampak gangguan pada data simulasi. Selanjutnya hasil pemetaan tersebut dipetakan kembali sesuai dengan matriks prioritisasi gangguan yang telah dirancang sebelumnya. Berdasarkan hasil simulasi prioritisasi gangguan, didapatkan dua gangguan dengan prioritas kritis (SIM0001 dan SIM0004), satu gangguan dengan prioritas sedang (SIM0010), empat gangguan dengan prioritas rendah (SIM0003, SIM0005, SIM0007 dan SIM0009) dan tiga gangguan dengan prioritas best effort (SIM0002, SIM0006, dan SIM0008). Data dan hasil simulasi aktivitas prioritisasi gangguan selengkapnya dapat dilihat pada Tabel V.2 dibawah.

Tabel V.2 Hasil simulasi model prioritisasi gangguan pada data buatan

ID		INPUT				OUTPUT
PROB_ID	WAKTU	URGENSI	KODE	DAMPAK	KODE	PRIORITAS
SIM0001	08-01-19 09:30:00	Backbone	4	20	4	1
SIM0002	08-01-19 09:30:15	Access - Reguler	1	0	1	5
SIM0003	08-01-19 09:30:30	Access - Reguler	1	1	2	4
SIM0004	08-01-19 09:30:45	Access - Reguler	1	1	2	4
SIM0005	08-01-19 09:31:00	Access - Reguler	1	1	2	4
SIM0006	08-01-19 09:31:15	Access - Reguler	1	0	1	5
SIM0007	08-01-19 09:31:30	Access - Reguler	1	2	2	4
SIM0008	08-01-19 09:31:45	Access - Reguler	1	0	1	5
SIM0009	08-01-19 09:32:00	Distribusi	3	12	4	1
SIM0010	08-01-19 10:00:00	Access - VIP	2	8	3	3

V.1.3 Simulasi Aktivitas Prediksi Durasi Gangguan Awal

Pada aktivitas prediksi durasi gangguan dan seterusnya, hanya gangguan yang terkategori sebagai gangguan valid saja yang akan diproses lebih lanjut. Dengan demikian tiga gangguan yang terkategori sebagai keluhan (SIM0002, SIM0006 dan SIM0008) tidak digunakan pada simulasi lanjutan. Model A prediksi durasi, yaitu model prediksi durasi gangguan fase respon digunakan pada simulasi aktivitas ini. Serupa dengan kategorisasi gangguan, data pelatihan yang digunakan pada tahap perancangan digunakan untuk membentuk model neural network. Selanjutnya, dilakukan prediksi terhadap tujuh data simulasi menggunakan model yang telah terbentuk. Data dan hasil simulasi aktivitas prioritas gangguan selengkapnya dapat dilihat pada Tabel V.3 dibawah.

Tabel V.3 Hasil simulasi model prediksi durasi fase respon pada data buatan

ID		INPUT						OUTPUT
PROB_ID	WAKTU	LVL-1 KATEGORI	DAY_STAT	HOURL_STAT	REGION	LOAD REG	LOAD NOC	PREDIKSI DURASI AWAL (JAM)
SIM0001	08-01-19 09:30:00	Device Configuration	Workday	Workhour	ROJB	105	150	4,54
SIM0003	08-01-19 09:30:30	Transmission Media	Workday	Workhour	ROJB	106	153	6,92
SIM0004	08-01-19 09:30:45	Physical Device	Workday	Workhour	RJBR	24	155	3,25
SIM0005	08-01-19 09:31:00	Transmission Media	Workday	Workhour	ROJB	107	158	6,94
SIM0007	08-01-19 09:31:30	Device Configuration	Workday	Workhour	ROJB	108	160	4,48
SIM0009	08-01-19 09:32:00	Physical Device	Workday	Workhour	RJBR	26	165	3,28
SIM0010	08-01-19 10:00:00	Transmission Media	Workday	Workhour	ROJB	110	166	6,97

V.1.4 Simulasi Aktivitas Penjadwalan

Pada simulasi aktivitas penjadwalan gangguan dikelompokkan berdasarkan sumber daya penanganan gangguan yang dialokasikan. Selanjutnya pada setiap kelompok digunakan metode penjadwalan *first-come first-served* berbasis prioritas. Pada kelompok ROJB#2, gangguan SIM0003 dan SIM0005 memiliki prioritas yang sama. Tetapi karena gangguan SIM0003 dilaporkan lebih dulu, maka proses penanganannya dijadwalkan lebih dulu. Sementara pada kelompok RJBR#1, gangguan SIM0004 dilaporkan lebih dulu daripada gangguan SIM0009. Namun gangguan SIM0009 dijadwalkan ditangani lebih dulu karena memiliki prioritas yang lebih tinggi. Berdasarkan simulasi yang dilakukan, gangguan SIM0004, SIM0005 dan SIM0007 memiliki waktu tunggu yaitu selama prediksi durasi gangguan yang ditangani lebih dulu pada masing-masing kelompok. Sehingga prediksi durasi akhir untuk masing-masing gangguan adalah 4,54 jam untuk SIM0001, 6,92 jam untuk SIM0003, 6,53 jam untuk SIM0004, 13,86 jam untuk SIM0005, 9,02 jam untuk SIM0007 dan 3,28 jam untuk SIM0009. Data dan hasil simulasi aktivitas penjadwalan selengkapnya dapat dilihat pada Tabel V.4 dibawah.

Tabel V.4 Hasil simulasi model penjadwalan gangguan pada data buatan

ID		INPUT			OUTPUT		
PROB_ID	WAKTU	TEAM	PRIORITAS	PREDIKSI DURASI AWAL	URUTAN KERJA	WAKTU TUNGGU	PREDIKSI DURASI AKHIR
SIM0003	08-01-19 09:30:30	ROJB #2	4	6,92	1	0	6,92
SIM0005	08-01-19 09:31:00	ROJB #2	4	6,94	2	6,92	13,86
SIM0001	08-01-19 09:30:00	ROJB #1	1	4,54	1	0	4,54
SIM0007	08-01-19 09:31:30	ROJB #1	4	4,48	2	4,54	9,02
SIM0004	08-01-19 09:30:45	RJBR #1	4	3,25	2	3,28	6,53
SIM0009	08-01-19 09:32:00	RJBR #1	1	3,28	1	0	3,28

V.1.5 Simulasi Aktivitas Update Prediksi Durasi Gangguan

Pada tahap ini dilakukan dua skenario simulasi update prediksi durasi gangguan. Skenario pertama adalah munculnya gangguan baru yang memiliki prioritas lebih tinggi. Sementara skenario kedua adalah perubahan kondisi gangguan selama fase perbaikan. Kedua skenario ini merupakan skenario yang umum terjadi pada proses penanganan gangguan dan dapat mempengaruhi prediksi durasi gangguan.

Pada skenario pertama, gangguan SIM0010 muncul pada pukul 10:00 dan dialokasikan ke kelompok ROJB#2 yang sebelumnya sedang menangani gangguan SIM0003 dan SIM0005. Gangguan SIM0010 tersebut memiliki prioritas yang lebih tinggi dari dua gangguan lainnya, yaitu prioritas kritis. Hal ini mengubah urutan penanganan gangguan dari sebelumnya SIM0003 disusul SIM0005, menjadi SIM0010, SIM0003 disusul SIM0005. Perubahan urutan tersebut mengubah prediksi durasi gangguan SIM0003 dari sebelumnya 6,92 jam menjadi 13,89 jam. Sementara prediksi durasi gangguan SIM0005 berubah dari sebelumnya 13,86 jam menjadi 20,83 jam. Data dan hasil simulasi update model penjadwalan yang dipicu gangguan baru tersebut secara lengkap dapat dilihat pada Tabel V.5 dibawah.

Tabel V.5 Hasil simulasi *update* model penjadwalan akibat gangguan baru pada kelompok ROJB#2

ID		INPUT			OUTPUT		
PROB_ID	WAKTU	TEAM	PRIORITAS	PREDIKSI DURASI AWAL	URUTAN KERJA	WAKTU TUNGGU	PREDIKSI DURASI AKHIR
SIM0003	08-01-19 09:30:30	ROJB #2	4	6,92	2	6,97	13,89
SIM0005	08-01-19 09:31:00	ROJB #2	4	6,94	3	13,89	20,83
SIM0010	08-01-19 10:00:00	ROJB #2	1	6,97	1	0	6,97

Pada skenario kedua, perubahan kondisi gangguan dapat memicu perubahan prediksi durasi gangguan. Model B prediksi durasi, yaitu model prediksi durasi pada fase perbaikan gangguan, digunakan untuk memprediksi durasi pada skenario ini. Gangguan yang berada dalam urutan pertama penanganan gangguan di setiap kelompok digunakan untuk simulasi ini yaitu SIM0001, SIM0009 dan SIM0010. Hasil prediksi model B menunjukkan perubahan prediksi durasi dari hasil prediksi model A untuk ketiga gangguan tersebut. Prediksi durasi gangguan SIM0001 berubah dari 4,54 jam menjadi 4,81 jam. Prediksi durasi gangguan SIM0009 berubah dari 3,28 jam menjadi 7,77 jam. Sementara prediksi durasi gangguan SIM0010 berubah dari 6,97 jam menjadi 15,65 jam. Data dan hasil simulasi untuk model prediksi durasi gangguan fase respon dapat dilihat pada Tabel V.6.

Perubahan prediksi durasi pada gangguan urutan pertama di setiap kelompok menyebabkan perubahan penjadwalan di setiap kelompok. Pada kelompok ROJB#2, prediksi durasi gangguan SIM0003 berubah dari 13,89 jam menjadi 22,57 jam. Sementara prediksi durasi gangguan SIM0005 berubah dari 20,83 jam menjadi 29,51 jam. Pada kelompok ROJB#1, prediksi durasi gangguan SIM0007 berubah dari 9,02 jam menjadi 9,29 jam. Pada kelompok RJBR#1, prediksi durasi SIM0004 berubah dari 6,53 jam menjadi 11,02 jam. Data dan hasil simulasi penjadwalan setelah perubahan prediksi durasi fase perbaikan selengkapnya dapat dilihat pada Tabel V.7.

Tabel V.6 Hasil simulasi model *update* prediksi durasi fase perbaikan pada data buatan

ID		INPUT										OUTPUT
PROB_ID	WAKTU	LVL-2 KATEGORI	DAY_ STAT	HOURLY STAT	REG	LOAD REG	LOAD NOC	KP*	KC*	KK*	KL*	PREDIKSI DURASI AWAL
SIM0001	08-01-19 09:30:00	EGP/IGP Routing	Workday	Workhour	ROJB	105	150	N	N	N	N	4,81
SIM0009	08-01-19 09:32:00	Catalyst/Router Broken	Workday	Workhour	RJBR	26	165	N	N	N	Y	7,77
SIM0010	08-01-19 10:00:00	Cable - FA	Workday	Workhour	ROJB	110	166	Y	N	N	N	15,65

*) Keterangan: KP = Kendala Perijinan, KC = Kendala Cuaca, KK = Kendala Keamanan, KL = Kendala Lain-Lain

Tabel V.7 Hasil simulasi *update* model penjadwalan akibat *update* prediksi durasi

ID		INPUT			OUTPUT		
PROB_ID	WAKTU	TEAM	PRIORITAS	PREDIKSI DURASI AWAL	URUTAN KERJA	WAKTU TUNGGU	PREDIKSI DURASI AKHIR
SIM0003	08-01-19 09:30:30	ROJB #2	4	6,92	2	15,65	22,57
SIM0005	08-01-19 09:31:00	ROJB #2	4	6,94	3	22,57	29,51
SIM0010	08-01-19 10:00:00	ROJB #2	1	15,65	1	0	15,65
SIM0001	08-01-19 09:30:00	ROJB #1	1	4,81	1	0	4,81
SIM0007	08-01-19 09:31:30	ROJB #1	4	4,48	2	4,81	9,29
SIM0004	08-01-19 09:30:45	RJBR #1	4	3,25	2	7,77	11,02
SIM0009	08-01-19 09:32:00	RJBR #1	1	7,77	1	0	7,77

V.2 Hasil Uji Justifikasi Tenaga Ahli

Sebagai pendukung hasil penelitian, justifikasi tenaga ahli dilakukan guna memvalidasi rancangan *framework* penanganan gangguan yang diusulkan. Justifikasi tenaga ahli dilakukan oleh tiga pihak tenaga ahli yaitu perwakilan manajemen sebagai pemilik proses bisnis, tenaga operasional sebagai pelaku proses bisnis serta tenaga TI sebagai perancang dan pengelola sistem TI. Setiap pihak tenaga ahli tersebut masing-masing diwakili oleh tiga responden untuk diminta justifikasinya. Metode yang dilakukan adalah dengan melakukan sosialisasi rancangan *framework* melalui presentasi, yang dilanjutkan dengan wawancara dengan pernyataan yang disusun berdasarkan skala Likert.

Tahapan selanjutnya, dilakukan kuantifikasi penilaian terhadap masing-masing pernyataan yang telah disusun berdasarkan skala Likert. Setiap responden tenaga ahli akan diberi nilai lima untuk pernyataan “Sangat Setuju”, empat untuk pernyataan “Setuju”, tiga untuk pernyataan “Ragu-Ragu”, dua untuk pernyataan “Tidak Setuju” dan satu untuk “Sangat Tidak Setuju”. Nilai setiap pernyataan didapatkan dengan memprosentase antara total nilai dengan maksimum nilai yang mungkin didapatkan. Nilai untuk setiap pernyataan kemudian diinterpretasikan sesuai jangkauan yaitu 0.00-19.99% (Sangat Tidak Setuju), 20.00-39.99% (Tidak Setuju), 40.00-59.99% (Ragu-Ragu), 60-79.99% (Setuju) dan 80-100% (Sangat Setuju).

Berdasarkan evaluasi yang dilakukan menggunakan justifikasi tenaga ahli didapatkan beberapa hal, yaitu:

1. Ketiga pihak tenaga ahli sangat setuju (manajemen 93.33%, operasional 86.67% dan TI 80%) bahwa rancangan *framework* mudah untuk dipahami serta dipelajari.
2. Pihak manajemen (100%) dan pihak operasional (86.67%) menyatakan sangat setuju bahwa rancangan *framework* memiliki kesesuaian atau relevansi dengan proses bisnis yang berjalan saat ini.

3. Pihak manajemen menyatakan setuju (73.33%) bahwa rancangan *framework* dapat membantu memberikan kepastian informasi yang dibutuhkan oleh pengguna layanan.
4. Pihak manajemen menyatakan sangat setuju (93.33%) bahwa rancangan *framework* dapat membantu meningkatkan kualitas pelayanan yang diberikan oleh penyedia layanan.
5. Pihak operasional menyatakan sangat setuju (93.33%) bahwa rancangan *framework* dapat membantu pengambilan keputusan dalam proses penanganan gangguan.
6. Pihak operasional menyatakan sangat setuju (86.67%) bahwa rancangan *framework* dapat mendukung pekerjaan mereka dalam proses penanganan gangguan.
7. Pihak TI menyatakan setuju (73.33%) bahwa kebutuhan data yang dibutuhkan dalam rancangan *framework* dapat dipenuhi oleh sistem informasi yang berjalan saat ini.
8. Pihak TI menyatakan setuju (86.67%) bahwa metode dan teknologi yang diadopsi pada rancangan *framework* sudah sesuai dengan kebutuhan disetiap aktivitas penanganan gangguan.
9. Pihak TI menyatakan setuju (73.33%) bahwa rancangan *framework* memungkinkan untuk diimplementasikan pada sistem informasi yang berjalan saat ini.
10. Secara umum, rancangan *framework* penanganan gangguan yang diusulkan mendapatkan penilaian yang sangat baik (85.56%).

Pengolahan data lengkap hasil justifikasi tenaga ahli menggunakan pernyataan yang disusun berdasarkan skala Likert dapat dilihat pada Tabel V.8. Sementara dokumen pendukung berupa formulir evaluasi justifikasi tenaga ahli dapat dilihat pada bagian Lampiran C.

Tabel V.8 Pengolahan data justifikasi tenaga ahli menggunakan skala Likert

Tingkat	No.	Pernyataan	Respon					Total	Nilai	Interpretasi
			STS	TS	RR	S	SS			
Manajemen	1	Menurut Bapak/Ibu, <i>framework</i> penanganan gangguan yang diusulkan dapat dipelajari dan dipahami dengan mudah	0	0	0	1	2	14	93.33%	Sangat Setuju
	2	Menurut Bapak/Ibu, <i>framework</i> penanganan gangguan yang diusulkan memiliki kesesuaian dengan proses bisnis penanganan gangguan yang berjalan saat ini	0	0	0	0	3	15	100.00%	Sangat Setuju
	3	Menurut Bapak/Ibu, <i>framework</i> penanganan gangguan yang diusulkan dapat lebih memberikan kepastian informasi gangguan yang dibutuhkan oleh pengguna layanan	0	0	1	2	0	11	73.33%	Setuju
	4	Menurut Bapak/Ibu, <i>framework</i> penanganan gangguan yang diusulkan dapat membantu meningkatkan kualitas layanan yang diberikan kepada pengguna layanan	0	0	0	1	2	14	93.33%	Sangat Setuju
Operasional	1	Menurut Bapak/Ibu, <i>framework</i> penanganan gangguan yang diusulkan dapat dipelajari dan dipahami dengan mudah	0	0	0	2	1	13	86.67%	Sangat Setuju

	2	Menurut Bapak/Ibu, <i>framework</i> penanganan gangguan yang diusulkan memiliki kesesuaian dengan proses bisnis penanganan gangguan yang berjalan saat ini	0	0	0	2	1	13	86.67%	Sangat Setuju
	3	Menurut Bapak/Ibu, <i>framework</i> penanganan gangguan yang diusulkan dapat membantu pengambilan keputusan dalam proses penanganan gangguan	0	0	0	1	2	14	93.33%	Sangat Setuju
	4	Menurut Bapak/Ibu, <i>framework</i> penanganan gangguan yang diusulkan dapat mendukung pekerjaan Bapak/Ibu dalam proses penanganan gangguan sehingga lebih efektif dan efisien	0	0	0	2	1	13	86.67%	Sangat Setuju
Teknologi Informasi	1	Menurut Bapak/Ibu, <i>framework</i> penanganan gangguan yang diusulkan dapat dipelajari dan dipahami dengan mudah	0	0	0	3	0	12	80.00%	Sangat Setuju
	2	Menurut Bapak/Ibu, kebutuhan data untuk <i>framework</i> penanganan gangguan yang diusulkan dapat dipenuhi oleh sistem informasi penanganan gangguan yang digunakan saat ini	0	0	2	0	1	11	73.33%	Setuju
	3	Menurut Bapak/Ibu, metode atau teknologi yang diadopsi pada usulan	0	0	0	2	1	13	86.67%	Sangat Setuju

		<i>framework</i> penanganan gangguan sudah sesuai dengan karakteristik setiap aktivitas pada proses penanganan gangguan								
	4	Menurut Bapak/Ibu, <i>framework</i> penanganan gangguan yang diusulkan memungkinkan untuk diimplementasikan pada sistem informasi penanganan gangguan yang digunakan saat ini	0	0	1	2	0	11	73.33%	Setuju
Total			0	0	4	18	14	154	85.56%	Sangat Baik

V.3 Evaluasi Rancangan dan Hasil Pengujian

Pada tahap ini dilakukan evaluasi terhadap rancangan *framework* penanganan gangguan berdasarkan hasil uji simulasi dan uji justifikasi tenaga ahli. Rangkaian aktivitas dalam bentuk *framework* telah membantu mengidentifikasi kebutuhan serta masalah di setiap aktivitas yang berkaitan dengan prediksi durasi gangguan. Pendekatan membagi proses penanganan gangguan menjadi dua fase, memungkinkan prediksi durasi dilakukan sesuai dengan karakteristik informasi di setiap fase. Sementara metode *supervised learning* yang dikombinasikan dalam aktivitas pada *framework* berperan meningkatkan akurasi prediksi di aktivitas terkait.

Selain informasi prediksi durasi, rancangan *framework* juga mampu memberikan informasi kategori, prioritas dan penjadwalan dengan lebih konsisten dibandingkan proses bisnis berjalan. Keempat informasi tersebut dapat dihasilkan dengan meminimalisir campur tangan operator manusia karena dilakukan oleh mesin. Dengan demikian, rancangan *framework* penanganan gangguan yang diusulkan lebih efektif dan efisien dibandingkan proses bisnis berjalan. Perbandingan lengkap antara proses bisnis berjalan dengan rancangan *framework* penanganan gangguan dapat dilihat pada Tabel V.9 dibawah.

Tabel V.9 Analisis perbandingan proses bisnis penanganan gangguan berjalan dengan rancangan *framework* penanganan gangguan

Jenis Informasi	Proses Bisnis Penanganan Gangguan Berjalan	Rancangan <i>Framework</i> Penanganan Gangguan
Kategori gangguan	Subjektif diberikan oleh operator <i>Fault Management</i> berdasarkan kemampuan analisis individu operator	Analisis dilakukan oleh mesin dengan konsisten
Prioritas gangguan	Evaluasi dilakukan berdasarkan tingkat urgensi gangguan dan dilakukan oleh operator <i>Fault Management</i> pada kondisi tertentu saja	Evaluasi dilakukan berdasarkan tingkat urgensi dan tingkat dampak gangguan serta dilakukan secara konsisten oleh mesin terhadap setiap gangguan
Penjadwalan penanganan	Dilakukan oleh operator <i>Fault Management</i> dengan berkoordinasi dengan <i>Contact</i>	Secara konsisten dilakukan oleh mesin sesuai dengan skema penjadwalan yang telah

	<i>Center dan Regional</i>	ditentukan
Prediksi durasi gangguan	Ditentukan oleh <i>Fault Management</i> berdasarkan jenis gangguan, namun tidak secara konsisten dilakukan	Analisis dilakukan oleh mesin dengan lebih akurat dan konsisten

Berdasarkan hasil uji simulasi rancangan *framework* penanganan gangguan menggunakan data buatan, nampak bahwa secara fungsional *framework* dapat bekerja sesuai dengan yang diharapkan. Rancangan *framework* dapat memberikan informasi prediksi durasi gangguan pada fase respon penanganan gangguan. Rancangan *framework* juga mampu merespon perubahan situasi pada proses penanganan gangguan dengan memberikan *update* prediksi durasi gangguan pada fase perbaikan. *Update* informasi dapat diberikan baik pada saat terjadi perubahan urutan penanganan akibat munculnya gangguan baru dengan prioritas yang lebih tinggi, maupun saat terjadi perubahan informasi terkait penanganan gangguan tersebut.

Berdasarkan hasil uji justifikasi oleh tenaga ahli, nampak bahwa secara umum rancangan *framework* telah mendapatkan respon yang sangat baik (85.56%). Secara konseptual, pihak manajemen meyakini bahwa rancangan *framework* dapat membantu meningkatkan kualitas layanan dengan memberikan kepastian informasi yang dibutuhkan pelanggan. Di sisi operasional, pihak operator meyakini bahwa rancangan *framework* akan memudahkan pekerjaan mereka dalam proses penanganan gangguan yang pada akhirnya dapat meningkatkan efektivitas dan efisiensi kerja. Sementara secara relevansi konsep, *framework* yang dirancang dianggap telah memiliki kesesuaian dengan proses bisnis penanganan gangguan berjalan serta dapat diimplementasikan pada sistem informasi penanganan gangguan yang digunakan saat ini.

Bab VI Kesimpulan dan Saran

VI.1 Kesimpulan

Penelitian yang dilakukan telah menjawab rumusan masalah penelitian yang diangkat terkait prediksi durasi gangguan layanan TI. Penelitian ini menghasilkan rancangan *framework* penanganan gangguan yang mampu menghasilkan informasi prediksi durasi gangguan dengan mengadopsi teknologi *machine learning*. Berdasarkan hasil penelitian ini, strategi kombinasi *ensemble*-pembobotan kelas (Bag-Wei-ETS) merupakan strategi klasifikasi terbaik untuk diterapkan pada aktivitas kategorisasi gangguan layanan TI dengan *F1-score* 0.5526 dan akurasi 97.21%. Sementara, model *artificial neural network* (ANN) yang dikombinasikan pada aktivitas prediksi durasi gangguan layanan TI menghasilkan akurasi prediksi durasi awal *mean absolute percentage error* (MAPE) lebih baik dibandingkan metode prediksi durasi konvensional. Akurasi prediksi durasi awal model ANN pada fase respon 18.43% lebih baik sementara model ANN pada fase perbaikan 19.41% lebih baik, bila keduanya dibandingkan dengan metode prediksi durasi konvensional.

Secara umum, rancangan *framework* hasil penelitian mendapatkan penilaian sangat baik (85.56%) dari tenaga ahli. Pihak manajemen sangat setuju bahwa rancangan *framework* yang diusulkan memiliki kesesuaian dengan proses bisnis berjalan (100%) serta mampu meningkatkan kualitas pelayanan yang diberikan penyedia layanan (93.33%). Di sisi operasional, pihak operator sangat setuju bahwa rancangan *framework* dapat membantu pengambilan keputusan dalam proses penanganan gangguan (93.33%) sehingga dapat meningkatkan efektivitas dan efisiensi kerja (86.67%). Sementara di sisi implementasi, pihak tenaga TI menyatakan setuju bahwa rancangan *framework* yang diusulkan dapat direalisasikan pada sistem informasi yang berjalan saat ini (73.33%).

VI.2 Saran

Mengacu pada pentingnya informasi prediksi durasi gangguan dalam proses penanganan gangguan layanan TI serta masih sedikitnya literatur penelitian yang

membahas topik ini. Penelitian ini diharapkan dapat menjadi referensi awal untuk pengembangan topik lebih lanjut. Beberapa arah penelitian yang dianggap penting adalah peningkatan akurasi prediksi *machine learning* baik dalam aktivitas kategorisasi maupun prediksi durasi gangguan layanan TI. Penambahan variabel-variabel yang dianggap relevan terhadap aktivitas prediksi merupakan salah satu cara yang dapat ditempuh. Penelitian juga dapat diarahkan terkait pemanfaatan informasi prediksi durasi gangguan di pihak operator penyedia layanan. Salah satunya dengan merancang algoritma penjadwalan yang meminimalisir pelanggaran SLA kepada pelanggan sehingga meminimalisir dampak keuangan dari gangguan layanan TI.

DAFTAR PUSTAKA

- Abbott, D. (2014). *Applied Predictive Analytics*. Wiley.
- Aggarwal, C. (2015). *Data Mining: The Textbook*. Cham: Springer.
- Bartolini, C., & Sallé, M. (2004). Business Driven Prioritization of Service Incidents. *International Workshop on Distributed Systems: Operations and Management*, 64–75.
- Boutaba, R., Salahuddin, M. A., Limam, N., Ayoubi, S., Shahriar, N., Estrada-solano, F., & Caicedo, O. M. (2018). Comprehensive survey Machine Learning. <https://doi.org/10.1186/s13174-018-0087-2>
- Caldeira, J., & Brito, F. (2008). Influential Factors on Incident Management : Lessons Learned from a Large Sample of Products in. *International Conference on Product Focused Software Process Improvement*, 330–344.
- Camara, F., Moshe, E., Li, R., Pereira, F. C., & Ben-akiva, M. E. (2018). Overview of traffic incident duration analysis and prediction. <https://doi.org/10.1186/s12544-018-0300-1>
- Dusia, A., Member, S., & Sethi, A. S. (2016). Recent Advances in Fault Localization in Computer Networks. *IEEE Communications Surveys & Tutorials*, 18(4), 3030–3051. <https://doi.org/10.1109/COMST.2016.2570599>
- Ethem Alpaydin. (2016). *Machine Learning The New AI*. MIT Press.
- Geurts, P., Ernst, D., & Wehenkel, L. (2005). Extremely randomized trees. *Machine Learning*, 63(November 2005). <https://doi.org/10.1007/s10994-006-6226-1>
- Guan, L., Liu, W., Yin, X., & Zhang, L. (2010). Traffic Incident Duration Prediction Based on Artificial Neural Network, (1997), 1–4. <https://doi.org/10.1109/ICICTA.2010.418>
- Haixiang, G., Yijing, L., Shang, J., Mingyun, G., & Yuanyue, H. (2017). Learning from class-imbalanced data : Review of methods and applications. *Expert Systems With Applications*, 73, 220–239. <https://doi.org/10.1016/j.eswa.2016.12.035>
- Jouravlev, R., Anand, A., Orbezo, J. C., Casteel, E., Corona, M., DuMoulin, T., ... Yagi, T. (2019). *ITIL Foundation (Fourth)*. The Stationery Office.

- Kelleher, J. D., Namee, B. Mac, & D'Arcy, A. (2015). *Fundamentals of Machine Learning for Predictive Data Analytics*. MIT Press.
- Khattak, A. J., Liu, J., Wali, B., Li, X., & Ng, M. (2016). Modeling Traffic Incident Duration Using Quantile Regression. *Transportation Research Record Journal of the Transportation Research Board*, (2554), 139–148. <https://doi.org/10.3141/2554-15>
- Khattak, A., Wang, X., & Zhang, H. (2012). Incident management integration tool : dynamically predicting incident durations , secondary incident occurrence and incident delays. *IET Intelligent Transport Systems*, 6(May 2011), 204–214. <https://doi.org/10.1049/iet-its.2011.0013>
- Kieninger, A., Berghoff, F., Fromm, H., Satzger, G., Kieninger, A., Berghoff, F., ... Satzger, G. (2013). Simulation-Based Quantification of Business Impacts Caused by Service Incidents, 170–185.
- Kotu, V., & Deshpande, B. (2015). *Predictive analytics and data mining*. Massachusetts: Morgan Kaufmann. <https://doi.org/10.4018/978-1-4666-9562-7.ch019>
- Kubiak, P., & Rass, S. (2018). An Overview of Data-Driven Techniques for IT-Service-Management. *IEEE Access*, 6, 63664–63688. <https://doi.org/10.1109/ACCESS.2018.2875975>
- Lucca, G. A. Di, Penta, M. Di, & Gradara, S. (2002). An Approach to Classify Software Maintenance Requests. *Proceedings of the International Conference on Software Maintenance (ICSM'02)*.
- Menken, I., Blokdijk, G., & Malone, T. (2009). *ITIL V3 MALC - Managing Across the Lifecycle of IT Services Best Practices Study and Implementation Guide*. London, UK: Emereo Pty Ltd.
- Orlov, L. M. (2005). *Make IT Better for Business Innovation*. Massachusetts.
- Peffer, K., Tuunanen, T., Rothenberger, M. A., & Chatterjee, S. (2007). A Design Science Research Methodology for Information Systems Research. *Journal of Management Information Systems*, 24(3), 45–77. <https://doi.org/10.2753/MIS0742-1222240302>
- PERATURAN PRESIDEN REPUBLIK INDONESIA NOMOR 96 TAHUN 2014 TENTANG RENCANA PITALEBAR INDONESIA 2014 – 2019.

(2014).


- Phomasakha, P., Sakolnakorn, N., & Meesad, P. (2008). Decision Tree-Based Model for Automatic Assignment of IT Service Desk Outsourcing in Banking Business. *9th ACIS International Conference on Software Engineering, Artificial Intelligence, Networking, and Parallel/Distributed Computing*, 387–392. <https://doi.org/10.1109/SNPD.2008.71>
- Raschka, S., & Mirjalili, V. (2017). *Python Machine Learning* (Second). Mumbai: Packt Publishing.
- Saarelainen, K. (2016). The Anatomy of IT Service Incidents, (c), 55–61.
- Sammut, C., & Webb, G. I. (Eds.). (2017). *Encyclopedia of Machine Learning and Data Mining* (Second Edi). New York: Springer.
- Shao, Q., & Chen, Y. (2008). EasyTicket : A Ticket Routing Recommendation Engine for Enterprise Problem Resolution. *VLDB Endowment*, 1(2), 1436–1439.
- Silberschatz, A., Galvin, P. B., & Gagne, G. (2012). *Operating System Concept* (9th ed.). Massachusetts: Wiley.
- Spelmen, V. S., & Porkodi, R. (2018). A Review on Handling Imbalanced Data. *Proceedings of the 2018 International Conference on Current Trends towards Converging Technologies, ICCTCT 2018*, 1–11. <https://doi.org/10.1109/ICCTCT.2018.8551020>
- Subramanian, G. (2015). *Python Data Science Cookbook*. Packt Publishing.
- Valenti, G., Lelli, M., & Cucina, D. (2010). A comparative study of models for the incident duration prediction, 103–111. <https://doi.org/10.1007/s12544-010-0031-4>
- Vedala, D. (2018). *Building a classification engine for ticket routing in IT support systems*. Aalto University.
- Wang, S., Li, R., & Guo, M. (2018). APPLICATION OF NONPARAMETRIC REGRESSION IN PREDICTING TRAFFIC INCIDENT DURATION, 33(1), 22–31. <https://doi.org/10.3846/16484142.2015.1004104>
- Wang, W., Chen, H., & Bell, M. C. (2005). Vehicle Breakdown Duration Modeling. *JOURNAL OF TRANSPORTATION AND STATISTICS*, 8(1).
- Wei, C., & Lee, Y. (2005). Applying data fusion techniques to traveler

- information services in highway network. *Transportation*, 6, 2457–2472.
- Wei, C., & Lee, Y. (2007). Sequential forecast of incident duration using Artificial Neural Network models, 39, 944–954.
<https://doi.org/10.1016/j.aap.2006.12.017>
- Weiming Liu, Liping Guan, X. Y. (2005). The Prediction of Freeway Incident Duration Based on Decision Tree. *China Journal of Highway and Transport*, 18.
- Wynter, L., He, Q., Kamarianakis, Y., & Jintanakul, K. (2011). A Hybrid Tree and Quantile Regression Method for Incident Duration Prediction. *Accepted at 91th TRB Annual Meeting, January 2010, Washington, D.C.*, 9(914), 1–945.
- Xu, J., He, R., Zhou, W., & Li, T. (2018). Trouble Ticket Routing Models and Their Applications. *IEEE Transactions on Network and Service Management*, 15(2). <https://doi.org/10.1109/TNSM.2018.2790956>
- Zambon, E., Etalle, S., Wieringa, R. J., & Hartel, P. (2011). Model-based qualitative risk assessment for availability of IT infrastructures, 553–580.
<https://doi.org/10.1007/s10270-010-0166-8>
- Zhan, C., Gan, A., & Hadi, M. (2011). Prediction of Lane Clearance Time of Freeway Incidents Using the M5P Tree Algorithm. *IEEE Transactions on Intelligent Transportation Systems*, 12(4), 1549–1557.

LAMPIRAN


Lampiran A Hasil Model *Bagging-Weighting-ETS* dengan Data Kategorisasi Gangguan

A1. Decision Tree ke-1 (Bag #1 - Tree #1)




Lampiran A Hasil Model *Bagging-Weighting-ETS* dengan Data Kategorisasi Gangguan (lanjutan)

A2. Decision Tree ke-100 (Bag #5 - Tree #20)




Lampiran A Hasil Model *Bagging-Weighting-ETS* dengan Data Kategorisasi Gangguan (lanjutan)

A3. Decision Tree ke-101 (Bag #6 - Tree #1)



Lampiran A Hasil Model *Bagging-Weighting-ETS* dengan Data Kategorisasi Gangguan (lanjutan)

A4. Decision Tree ke-200 (Bag #10 - Tree #20)



Lampiran B Hasil Konfigurasi ANN untuk Model Prediksi Durasi Gangguan

B1. Konfigurasi ANN Model Prediksi Durasi Fase Respon

Tabel B1.1 Konfigurasi *Weight Input Layer – Hidden Layer*

		Hidden Layer								
		<i>n1</i>	<i>n2</i>	<i>n3</i>	<i>n4</i>	<i>n5</i>	<i>n6</i>	<i>n7</i>	<i>n8</i>	<i>n9</i>
Input Layer	<i>In1</i>	-0.47	-4.31	-1.65	-3.32	-0.57	-0.71	0.40	-0.89	1.86
	<i>In2</i>	-0.10	-1.46	-0.35	0.71	-1.18	-0.45	0.09	-0.52	-1.03
	<i>In3</i>	-0.84	-0.81	0.59	-5.81	-0.09	-2.49	-0.51	1.35	0.59
	<i>In4</i>	0.36	0.52	0.29	-0.44	0.88	-0.14	-0.23	1.08	0.57
	<i>In5</i>	0.26	-1.50	0.11	-0.81	0.66	-1.13	0.28	1.41	-0.01
	<i>In6</i>	-1.01	1.18	0.19	1.30	-0.65	1.74	-1.12	-1.22	1.30
	<i>In7</i>	0.21	-0.18	-0.60	0.79	0.52	-1.88	0.03	0.01	-0.70
	<i>In8</i>	0.67	-0.82	-0.62	-1.03	-0.59	-0.87	0.37	-0.45	0.31
	<i>In9</i>	0.04	-0.57	0.08	-0.86	0.71	0.05	-0.06	1.32	0.19
	<i>In10</i>	0.96	-0.62	-0.11	-0.52	2.08	-2.29	0.24	1.22	-0.26
	<i>In11</i>	0.05	-0.41	0.16	-0.35	1.09	0.30	0.43	1.25	2.06
	<i>In12</i>	0.06	0.82	-1.29	-1.27	-0.87	-1.39	0.07	-1.03	0.79
	<i>In13</i>	0.57	0.41	0.28	-5.89	-0.15	-0.27	0.50	0.94	0.39
	<i>In14</i>	-0.31	-0.08	0.71	0.69	-0.86	1.05	-0.22	0.51	-0.36
	<i>In15</i>	0.27	0.15	-0.49	1.19	-0.65	-0.89	0.13	-0.69	-0.54
	<i>In16</i>	-0.35	0.20	-0.90	0.19	0.03	-0.08	1.00	-0.36	1.72
	<i>In17</i>	0.14	-0.58	-0.67	-0.02	-1.29	0.09	-0.04	-0.06	0.53
	<i>In18</i>	-0.18	-0.23	-0.61	-1.74	0.58	-2.27	0.27	0.32	1.29

Tabel B1.2 Konfigurasi *Bias Hidden Layer*

	Hidden Layer								
	<i>n1</i>	<i>n2</i>	<i>n3</i>	<i>n4</i>	<i>n5</i>	<i>n6</i>	<i>n7</i>	<i>n8</i>	<i>n9</i>
Bias	0.07	-0.39	-0.18	-0.59	0.09	-0.52	0.05	0.53	0.45

B1. Konfigurasi ANN Model Prediksi Durasi Fase Respon (lanjutan)

Tabel B1.3 Konfigurasi *Weight Hidden Layer – Output Layer*

	Hidden Layer								
	<i>n1</i>	<i>n2</i>	<i>n3</i>	<i>n4</i>	<i>n5</i>	<i>n6</i>	<i>n7</i>	<i>n8</i>	<i>n9</i>
Output Layer	0.63	0.35	-0.58	0.68	0.34	0.63	0.27	0.71	0.48

Tabel B1.4 Konfigurasi *Bias Output Layer*

Output Layer	
Bias	0.03

B2. Konfigurasi ANN Model Prediksi Durasi Fase Perbaikan

Tabel B2.1 Konfigurasi *Weight Input Layer – Hidden Layer*

		Hidden Layer										
		<i>n1</i>	<i>n2</i>	<i>n3</i>	<i>n4</i>	<i>n5</i>	<i>n6</i>	<i>n7</i>	<i>n8</i>	<i>n9</i>	<i>n10</i>	<i>n11</i>
Input Layer	<i>In1</i>	-2.74	0.99	-0.60	-0.36	-1.83	-2.52	-0.43	-3.99	-0.27	-0.02	0.14
	<i>In2</i>	0.82	-0.88	0.18	0.05	-0.26	-0.34	0.35	0.06	1.10	-1.12	-0.23
	<i>In3</i>	-1.14	-0.45	0.99	1.09	1.34	0.95	1.29	0.96	2.02	-1.47	1.74
	<i>In4</i>	-0.67	-2.38	0.15	0.85	-0.30	-0.77	-0.48	-1.04	-0.53	-0.73	0.20
	<i>In5</i>	-1.08	0.19	0.53	0.60	-0.60	-0.23	0.77	-0.31	1.01	-0.25	-0.34
	<i>In6</i>	0.12	-0.48	0.26	0.11	0.76	0.10	0.90	-0.99	2.00	-0.09	1.33
	<i>In7</i>	1.08	-1.07	-0.47	-0.21	-0.41	-0.48	-0.10	-0.76	-0.57	0.40	0.01
	<i>In8</i>	0.20	-0.48	-0.02	-0.11	0.03	0.79	1.15	0.22	0.40	0.28	-0.16
	<i>In9</i>	0.12	0.20	0.22	-0.12	-0.36	-0.12	-0.35	0.67	-0.76	0.78	0.13
	<i>In10</i>	1.37	-1.26	0.00	-0.21	-1.36	-0.24	0.37	-1.84	-0.21	0.86	0.58
	<i>In11</i>	-0.27	-0.42	-0.50	-0.12	-2.90	-2.55	-0.59	-2.98	-1.08	0.11	0.08
	<i>In12</i>	0.28	-0.58	0.06	0.06	0.03	0.04	0.81	-0.61	1.05	0.55	0.28
	<i>In13</i>	-0.36	-0.65	0.06	-0.04	-1.86	-2.00	0.29	-2.12	-0.26	0.63	0.02
	<i>In14</i>	-0.59	-0.63	0.60	0.58	-0.55	-0.61	0.59	-0.60	0.51	0.60	0.61
	<i>In15</i>	0.28	-0.76	0.37	0.34	0.82	0.01	0.29	0.15	1.97	-2.14	0.37
	<i>In16</i>	0.02	-1.38	0.31	0.09	0.22	0.00	1.13	-0.12	-0.78	0.04	-0.38
	<i>In17</i>	1.10	-1.64	-0.04	-0.14	-0.63	-0.19	2.29	-1.76	2.05	1.56	-0.59
	<i>In18</i>	-4.03	0.16	0.13	1.97	0.53	0.27	-0.81	0.75	-0.46	0.07	0.85

B2. Konfigurasi ANN Model Prediksi Durasi Fase Perbaikan (lanjutan)

		Hidden Layer									
		<i>n12</i>	<i>n13</i>	<i>n14</i>	<i>n15</i>	<i>n16</i>	<i>n17</i>	<i>n18</i>	<i>n19</i>	<i>n20</i>	<i>n21</i>
Input Layer	<i>In1</i>	0.70	0.34	0.15	-9.36	1.23	0.65	0.86	0.12	-0.47	0.06
	<i>In2</i>	0.34	0.65	-0.20	1.00	0.18	-1.05	-0.29	-0.29	1.78	-0.47
	<i>In3</i>	-1.10	0.11	0.93	1.10	-1.47	-1.40	-1.57	-0.31	-1.83	0.47
	<i>In4</i>	-2.17	0.42	0.61	-0.89	-0.81	-0.92	-1.10	-1.26	0.59	-0.58
	<i>In5</i>	-0.20	-1.10	0.05	0.36	-0.30	-0.51	-0.51	-0.19	1.54	-0.27
	<i>In6</i>	-0.16	-0.54	0.35	-0.43	-1.03	-1.13	0.27	-0.46	-0.70	-0.33
	<i>In7</i>	0.27	-0.45	-0.54	0.36	-0.35	-0.60	-0.32	-0.08	1.12	0.70
	<i>In8</i>	-0.04	0.10	0.39	-0.20	-1.33	-0.40	0.05	-0.16	-0.89	-0.28
	<i>In9</i>	-0.02	0.10	0.55	-0.35	-0.89	0.39	-0.11	-0.15	0.40	0.59
	<i>In10</i>	0.54	-3.44	0.19	0.10	-0.23	-0.75	0.34	0.08	3.03	0.66
	<i>In11</i>	0.02	-0.49	0.41	-2.85	0.67	-0.30	0.28	-0.18	0.11	0.47
	<i>In12</i>	-0.11	-4.73	0.36	-0.35	-0.14	-0.17	-0.08	-0.09	-0.62	-0.35
	<i>In13</i>	-0.18	-0.72	0.30	-2.24	0.49	-0.46	-0.15	-0.86	2.18	0.70
	<i>In14</i>	-0.65	-0.57	0.58	-0.49	-0.77	-0.61	-0.70	-0.69	0.50	0.49
	<i>In15</i>	-0.39	-2.03	0.78	0.01	-0.86	-0.72	-0.42	-0.14	0.76	-0.01
	<i>In16</i>	-0.31	-0.60	-0.59	0.06	-0.92	-2.12	-0.28	-0.57	-0.28	-0.82
	<i>In17</i>	0.56	1.41	0.13	0.25	0.68	-0.74	0.43	-0.03	3.10	0.10
	<i>In18</i>	-4.37	0.17	0.44	0.05	-3.86	0.37	-3.38	-0.24	-2.19	-0.39

B2. Konfigurasi ANN Model Prediksi Durasi Fase Perbaikan (lanjutan)

		Hidden Layer										
		<i>n1</i>	<i>n2</i>	<i>n3</i>	<i>n4</i>	<i>n5</i>	<i>n6</i>	<i>n7</i>	<i>n8</i>	<i>n9</i>	<i>n10</i>	<i>n11</i>
Input Layer	<i>In19</i>	-0.25	-0.22	0.17	0.15	0.13	0.00	0.32	-0.02	0.77	-0.54	0.51
	<i>In20</i>	-2.11	0.29	1.06	0.01	-2.81	-2.02	-0.47	0.28	0.62	-0.07	-0.22
	<i>In21</i>	0.29	-1.22	-0.19	-0.24	-0.37	-0.43	0.95	-0.18	0.43	-0.65	-0.18
	<i>In22</i>	-0.35	-0.37	0.11	0.07	-0.93	-1.77	-0.07	-0.25	-1.08	-4.14	-0.29
	<i>In23</i>	-1.03	0.33	0.35	0.48	0.39	0.34	-0.43	1.44	0.83	-1.18	0.06
	<i>In24</i>	-0.23	0.17	0.63	0.10	-0.35	-0.22	0.48	-0.50	1.58	-0.48	-0.11
	<i>In25</i>	-1.73	0.85	0.01	-0.05	0.18	-0.30	-0.49	0.15	0.01	0.61	0.03
	<i>In26</i>	0.24	0.00	0.95	0.25	-1.55	-0.86	0.04	0.45	1.12	0.17	0.37
	<i>In27</i>	-0.77	-0.04	0.07	0.51	-1.72	-0.46	0.25	-0.39	-0.45	-1.28	-0.39
	<i>In28</i>	-0.16	-0.20	-0.19	0.13	0.72	0.77	1.50	0.03	0.19	0.05	0.48
	<i>In29</i>	-2.14	0.27	0.36	-0.10	0.22	-0.20	0.64	0.13	2.20	1.12	0.32
	<i>In30</i>	0.08	-0.38	0.17	0.21	-0.20	-0.54	0.84	-0.63	0.93	-0.20	0.10
	<i>In31</i>	-0.63	-0.27	0.08	0.17	-1.91	-1.27	-0.39	-0.74	-1.30	-0.77	-0.47
	<i>In32</i>	-0.70	-1.12	-0.07	0.85	0.09	-0.08	0.13	0.02	-0.34	-0.40	0.10
	<i>In33</i>	0.42	-1.30	-0.24	-0.07	0.12	0.66	0.36	-0.29	0.26	0.26	0.19
	<i>In34</i>	-0.14	0.58	0.11	0.35	0.28	-0.28	-0.10	0.10	-0.58	0.84	-0.75
	<i>In35</i>	0.48	-0.52	0.30	-0.03	-0.68	-0.66	0.07	-0.43	-0.30	0.52	-0.16
	<i>In36</i>	-0.46	-0.18	-0.25	0.14	-0.62	-0.51	0.08	-0.43	-0.67	-0.91	-0.81

B2. Konfigurasi ANN Model Prediksi Durasi Fase Perbaikan (lanjutan)

		Hidden Layer									
		<i>n12</i>	<i>n13</i>	<i>n14</i>	<i>n15</i>	<i>n16</i>	<i>n17</i>	<i>n18</i>	<i>n19</i>	<i>n20</i>	<i>n21</i>
Input Layer	<i>In19</i>	-0.48	0.21	0.01	1.49	0.67	-0.34	-0.25	-0.48	1.81	0.52
	<i>In20</i>	-0.51	-0.25	0.23	-4.52	1.43	0.59	-0.72	-0.48	2.56	-0.09
	<i>In21</i>	-0.13	-0.67	-0.56	-0.78	-1.33	-0.24	-0.51	0.14	0.62	-0.33
	<i>In22</i>	-0.35	1.46	-2.28	-1.19	0.69	-0.29	-0.13	-0.83	1.34	-0.52
	<i>In23</i>	-0.96	-0.95	0.41	0.93	0.35	0.33	-0.29	-0.32	0.64	0.96
	<i>In24</i>	0.42	-2.72	-0.53	-0.09	-0.69	-0.50	0.07	0.13	-0.53	-0.40
	<i>In25</i>	-0.93	-2.80	-0.45	-1.77	0.01	0.48	-0.36	-0.16	0.86	0.08
	<i>In26</i>	0.13	-0.16	0.48	0.54	0.96	-0.22	0.05	-0.40	3.47	-0.81
	<i>In27</i>	-0.37	-1.30	-0.53	-0.44	-1.15	0.09	-1.05	-0.05	1.63	-1.50
	<i>In28</i>	0.00	-0.13	0.60	-0.42	-0.91	-0.63	0.02	-0.09	1.94	0.16
	<i>In29</i>	-0.43	0.82	0.23	-0.21	-0.14	-0.10	-0.58	0.05	-0.85	0.62
	<i>In30</i>	0.07	-0.05	-0.02	-0.14	0.08	-1.00	-0.12	-0.42	0.91	0.27
	<i>In31</i>	-0.44	0.46	0.21	-1.27	-0.60	0.22	-0.14	-0.56	-1.09	0.34
	<i>In32</i>	-1.70	0.04	1.14	1.32	-0.37	-1.02	-0.90	-0.89	-0.41	1.28
	<i>In33</i>	-0.48	-4.05	-0.41	0.60	-1.78	-0.99	-0.51	-0.07	1.53	0.22
	<i>In34</i>	0.04	0.18	0.42	-0.24	0.40	-0.20	0.02	-0.06	-0.54	0.26
	<i>In35</i>	0.41	0.23	0.19	-0.61	1.05	-0.14	0.28	-0.20	1.22	0.79
	<i>In36</i>	-0.16	-0.70	-0.45	-0.41	-0.88	-0.53	-0.51	-0.08	0.03	-0.48

B2. Konfigurasi ANN Model Prediksi Durasi Fase Perbaikan (lanjutan)

		Hidden Layer										
		<i>n1</i>	<i>n2</i>	<i>n3</i>	<i>n4</i>	<i>n5</i>	<i>n6</i>	<i>n7</i>	<i>n8</i>	<i>n9</i>	<i>n10</i>	<i>n11</i>
Input Layer	<i>In37</i>	0.08	-0.14	-0.50	-0.78	0.01	0.24	0.19	-1.19	0.08	-0.70	-0.88
	<i>In38</i>	-1.28	1.16	0.92	0.41	-0.29	0.95	3.08	2.39	3.77	-0.20	0.10
	<i>In39</i>	-2.46	0.10	0.90	0.69	0.91	-0.66	0.24	0.08	0.48	-1.53	0.50
	<i>In40</i>	1.18	-1.13	0.37	-0.09	1.29	0.27	0.77	0.43	2.07	2.27	1.19
	<i>In41</i>	0.53	0.22	2.56	0.30	-1.79	-1.18	-0.40	1.14	1.35	1.17	-0.25

		Hidden Layer									
		<i>n12</i>	<i>n13</i>	<i>n14</i>	<i>n15</i>	<i>n16</i>	<i>n17</i>	<i>n18</i>	<i>n19</i>	<i>n20</i>	<i>n21</i>
Input Layer	<i>In37</i>	0.20	-1.66	-0.70	-1.38	0.40	0.11	0.71	0.12	1.40	-0.83
	<i>In38</i>	0.44	-1.80	-0.32	-5.08	-1.01	-0.09	-0.16	0.36	4.36	1.20
	<i>In39</i>	-0.33	-2.52	0.95	0.17	-0.32	-0.54	-0.20	-0.42	6.53	-0.47
	<i>In40</i>	0.08	0.18	0.87	1.13	-1.39	-0.43	-1.60	0.14	2.55	1.84
	<i>In41</i>	0.49	1.29	0.81	0.09	0.51	0.16	0.14	-0.73	0.60	1.08

Lampiran B2 Konfigurasi ANN Model Prediksi Durasi Fase Perbaikan (lanjutan)

Tabel B2.2 Konfigurasi *Bias Hidden Layer*

Hidden Layer		Bias
	<i>n1</i>	-0.60
	<i>n2</i>	-0.42
	<i>n3</i>	0.28
	<i>n4</i>	0.38
	<i>n5</i>	-0.76
	<i>n6</i>	-0.53
	<i>n7</i>	0.52
	<i>n8</i>	-0.25
	<i>n9</i>	0.40
	<i>n10</i>	-0.46
	<i>n11</i>	-0.10
	<i>n12</i>	-0.44
	<i>n13</i>	-0.60
	<i>n14</i>	0.12
	<i>n15</i>	0.09
	<i>n16</i>	-0.53
	<i>n17</i>	-0.73
	<i>n18</i>	-0.63
	<i>n19</i>	-0.53
	<i>n20</i>	0.83
	<i>n21</i>	0.09

Lampiran B2 Konfigurasi ANN Model Prediksi Durasi Fase Perbaikan (lanjutan)

Tabel B2.3 Konfigurasi *Weight Hidden Layer – Output Layer*

		Output Layer
Hidden Layer	<i>n1</i>	-0.65
	<i>n2</i>	-0.41
	<i>n3</i>	0.51
	<i>n4</i>	0.65
	<i>n5</i>	-0.46
	<i>n6</i>	-0.35
	<i>n7</i>	0.33
	<i>n8</i>	-0.66
	<i>n9</i>	0.89
	<i>n10</i>	0.75
	<i>n11</i>	0.56
	<i>n12</i>	-0.27
	<i>n13</i>	-1.21
	<i>n14</i>	0.61
	<i>n15</i>	-0.84
	<i>n16</i>	-0.79
	<i>n17</i>	-0.23
	<i>n18</i>	-0.26
	<i>n19</i>	-0.12
	<i>n20</i>	0.65
	<i>n21</i>	0.60

Tabel B2.4 Konfigurasi *Bias Output Layer*

	Output Layer
Bias	0.18

Lampiran C Formulir Verifikasi & Validasi Justifikasi Tenaga Ahli

Nama Responden :.....
Jabatan :.....
Divisi :.....
Organisasi/Institusi :.....
Tanggal & Waktu :.....

PETUNJUK PENGISIAN FORMULIR

1. Berilah tanda ceklist (√) pada kolom yang tersedia untuk setiap pernyataan, sesuai dengan pendapat Bapak/Ibu
2. Pada masing-masing pernyataan terdapat lima pilihan tanggapan yang mengacu pada teknik skala Likert, yaitu:
 - SS = Sangat Setuju
 - S = Setuju
 - R = Ragu-Ragu
 - TS = Tidak Setuju
 - STS = Sangat Tidak Setuju

KUESIONER PENELITIAN

Saya adalah mahasiswa Sekolah Teknik Elektro & Informatika Institut Teknologi Bandung yang sedang menyelesaikan tesis saya yang berjudul “Perancangan Framework Penanganan Gangguan Berbasis Supervised-Learning. Studi Kasus : Penyedia Layanan Jaringan Pita Lebar”. Prediksi durasi gangguan merupakan salah satu informasi penting yang dibutuhkan baik bagi pengguna layanan maupun penyedia layanan. Namun demikian, prediksi durasi gangguan merupakan hal yang kompleks karena dipengaruhi oleh berbagai macam faktor. Tesis ini mengusulkan suatu framework penanganan gangguan yang dapat menghasilkan informasi prediksi durasi gangguan. Machine learning adalah salah satu bentuk kecerdasan buatan yang memungkinkan mesin untuk belajar mengambil keputusan menggunakan data historis yang tersedia. Adopsi machine learning pada framework ini memungkinkan informasi prediksi durasi gangguan dihasilkan secara otomatis serta lebih akurat. Namun demikian, diperlukan penilaian Bapak/Ibu untuk memvalidasi dan memverifikasi usulan framework tersebut.

No.	Pernyataan (Level Manajemen)	Tanggapan				
		STS	TS	RR	S	SS
1	Menurut Bapak/Ibu, framework penanganan gangguan yang diusulkan dapat dipelajari dan dipahami dengan mudah					
2	Menurut Bapak/Ibu, framework penanganan gangguan yang diusulkan memiliki kesesuaian dengan proses bisnis penanganan gangguan yang berjalan saat ini					
3	Menurut Bapak/Ibu, framework penanganan gangguan yang diusulkan dapat lebih memberikan kepastian informasi gangguan yang dibutuhkan oleh pengguna layanan					
4	Menurut Bapak/Ibu, framework penanganan gangguan yang diusulkan dapat membantu meningkatkan kualitas layanan yang diberikan kepada pengguna layanan					

KRITIK & SARAN :

.....,

Tertanda

()

No.	Pernyataan (Level Operasional)	Tanggapan				
		STS	TS	RR	S	SS
1	Menurut Bapak/Ibu, framework penanganan gangguan yang diusulkan dapat dipelajari dan dipahami dengan mudah					
2	Menurut Bapak/Ibu, framework penanganan gangguan yang diusulkan memiliki kesesuaian dengan proses bisnis penanganan gangguan yang berjalan saat ini					
3	Menurut Bapak/Ibu, framework penanganan gangguan yang diusulkan dapat membantu pengambilan keputusan dalam proses penanganan gangguan					
4	Menurut Bapak/Ibu, framework penanganan gangguan yang diusulkan dapat mendukung pekerjaan Bapak/Ibu dalam proses penanganan gangguan sehingga lebih efektif dan efisien					

KRITIK & SARAN :

.....,

Tertanda

()

No.	Pernyataan (Level Teknologi Informasi)	Tanggapan				
		STS	TS	RR	S	SS
1	Menurut Bapak/Ibu, framework penanganan gangguan yang diusulkan dapat dipelajari dan dipahami dengan mudah					
2	Menurut Bapak/Ibu, kebutuhan data untuk framework penanganan gangguan yang diusulkan dapat dipenuhi oleh sistem informasi penanganan gangguan yang digunakan saat ini					
3	Menurut Bapak/Ibu, metode atau teknologi yang diadopsi pada usulan framework penanganan gangguan sudah sesuai dengan karakteristik setiap aktifitas pada proses penanganan gangguan					
4	Menurut Bapak/Ibu, framework penanganan gangguan yang diusulkan memungkinkan untuk diimplementasikan pada sistem informasi penanganan gangguan yang digunakan saat ini					

KRITIK & SARAN :

.....,

Tertanda

()