



TESIS - BM185407

**ANALISIS FAKTOR-FAKTOR YANG MEMPENGARUHI  
PENGUNAAN MODULASI 64QAM PADA JARINGAN  
LONG-TERM EVOLUTION DENGAN MENGGUNAKAN  
METODE RANDOM FOREST**

**MOCHAMMAD JAINUL  
09211950055009**

**Dosen Pembimbing:  
R. Mohamad Atok, S.Si., M.Si., Ph.D.**

**Departemen Manajemen Teknologi  
Fakultas Desain Kreatif Dan Bisnis Digital  
Institut Teknologi Sepuluh Nopember  
2020**

**[ Halaman ini sengaja dikosongkan ]**

# LEMBAR PENGESAHAN

## LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar

**Magister Manajemen Teknologi (M.MT)**

di

**Institut Teknologi Sepuluh Nopember**

Oleh:

**Mochammad Jainul**

**NRP: 09211950055009**

**Tanggal Ujian: 29 Desember 2020**

**Periode Wisuda: Maret 2021**

Disetujui oleh:

**Pembimbing:**

1. **R. Mohamad Atok, S.Si., M.Si., Ph.D.**  
**NIP: 197109151997021001**



**Penguji:**

1. **Dr. Ahmad Saikhu, S.Si., MT.**  
**NIP: 197107182006041001**
2. **Jerry Dwi Trijoyo Purnomo, S.Si., M.Si., Ph.D.**  
**NIP: 198102232008121003**



**Kepala Departemen Manajemen Teknologi**  
**Fakultas Desain Kreatif Dan Bisnis Digital**



**Prof. Ir. I Nyoman Pujawan, M.Eng, Ph.D, CSCP**  
**NIP: 196912311994121076**

**[ Halaman ini sengaja dikosongkan ]**

# ANALISIS FAKTOR-FAKTOR YANG MEMPENGARUHI PENGGUNAAN MODULASI 64QAM PADA JARINGAN LONG-TERM EVOLUTION DENGAN MENGGUNAKAN METODE RANDOM FOREST

Mahasiswa : Mochammad Jainul  
NRP : 09211950055009  
Pembimbing : R. Mohamad Atok, S.Si., M.Si., Ph.D.

## ABSTRAK

Saat ini pengguna internet/data jaringan telekomunikasi seluler meningkat dengan sangat pesat. Performansi jaringan seluler LTE (Long-Term Evolution) yang bagus merupakan hal yang sangat penting bagi setiap operator telekomunikasi untuk menjaga kepuasan pelanggannya. Performansi jaringan yang buruk juga dapat mengakibatkan pelanggan berpindah ke operator lain. Salah satu variabel indikator dalam mengamati kualitas radio jaringan seluler 4G/LTE adalah Penetrasi penggunaan Modulasi 64QAM. Modulasi 64QAM dapat mengirimkan bitrate yang lebih tinggi dengan penggunaan daya yang lebih rendah. Modulasi 64QAM akan digunakan jika kondisi Channel Quality Index (CQI) sangat bagus yakni nilai  $CQI \geq 10$ . Peningkatan kualitas jaringan dapat dilakukan dengan menambah BTS baru atau mengoptimalkan BTS yang sudah ada. Penambahan BTS baru akan meningkatkan *coverage*, *quality*, dan *capacity*, akan tetapi CAPEX dan OPEX yang dikeluarkan cukup besar dan dibutuhkan waktu yang lama dalam membangun BTS. Peningkatan kualitas jaringan dengan cara mengoptimalkan BTS bisa dilakukan dengan melakukan pembelian fitur-fitur LTE dan biaya yang dikeluarkan masih tergolong rendah.

Peningkatan penetrasi penggunaan modulasi 64QAM membutuhkan analisis terhadap variabel-variabel jaringan *Long-Term Evolution* (LTE). Prosedur yang digunakan saat ini masih menggunakan cara yang kurang efisien dari segi waktu, tenaga dan juga membutuhkan seorang yang ahli dan profesional dalam bidangnya akan tetapi sering kali tidak akurat. Untuk mengatasi masalah ini, digunakan metode machine learning *random forest* untuk menganalisis hubungan antara variabel-variabel KPI. Dengan mengetahui variabel-variabel yang berpengaruh secara signifikan terhadap kualitas jaringan, maka biaya modal yang dikeluarkan operator seluler untuk peningkatan kualitas jaringan akan menjadi lebih efektif dan efisien karena biaya modal yang diinvestasikan hanya berfokus terhadap variabel-variabel yang berpengaruh. Dari hasil penelitian didapatkan ketepatan klasifikasi yang sangat baik yaitu nilai akurasi 92,23% dan nilai AUC 0,981. Pengujian performansi berdasarkan *k-fold stratified sampling* didapatkan nilai rata-rata akurasi 91,28% dan nilai rata-rata AUC 0,976. Pada penelitian ini disusun rekomendasi untuk meningkatkan penetrasi pengguna modulasi 64QAM yaitu dibuat diagram alir peningkatan nilai CQI berdasarkan delapan variabel yang mempunyai nilai *gini importance* tertinggi. Delapan variabel yang mempunyai nilai *gini importance* tertinggi yaitu MIMO, PDCCH\_CCE\_Agg\_8, SE\_3, sinr\_pusch, sinr\_pucch, \_125\_\_PL\_\_130\_, \_130\_\_PL\_\_135\_, DL\_PRB\_Utilization.

**Kata kunci:** LTE, *machine learning*, *Channel Quality Index*, CQI, *Random forest*, *Base Transceiver Station*, BTS, Modulasi, QPSK, 16QAM, 64QAM, AUC

**[ Halaman ini sengaja dikosongkan ]**

# **ANALYSIS OF FACTORS AFFECTING THE USE OF THE 64QAM MODULATION ON THE LONG-TERM EVOLUTION NETWORK BY USING RANDOM FOREST METHOD**

Student's Name : Mochammad Jainul  
Student ID : 09211950055009  
Supervisor : R. Mohamad Atok, S.Si., M.Si., Ph.D.

## **ABSTRACT**

Nowadays internet traffic using cellular telecommunication network is increasing very rapidly. Good LTE (Long-Term Evolution) cellular network performance is very important for any telecommunication operator to maintain customer satisfaction. Poor network performance can also cause customers to switch to other operators. One of the indicator variables in observing the radio quality of the 4G / LTE cellular network is Penetration using 64QAM Modulation. The 64QAM modulation can transmit higher bitrates with lower power usage. 64QAM modulation will be used if the Channel Quality Index (CQI) condition is very good. Network quality improvement can be done by adding new BTS or optimizing existing BTS. The addition of new BTS will increase coverage, quality, and capacity but CAPEX and OPEX are high and the time required to build BTS is also long, while improving network quality by optimizing BTS can be done by purchasing LTE features and costs incurred still relatively low.

Increasing the penetration of using 64QAM modulation requires analysis of Long-Term Evolution (LTE) network variables. The traditional method to improve this Key Performance Indicator (KPI) requires an expert and professional but is often inaccurate and spends a lot of time finding the factors that cause it. To solve this problem, Random forest method is proposed. By knowing the variables that have a significant effect on network quality, the capital costs incurred by cellular operators for improving network quality will be more effective and efficient because the capital costs invested only focus on influencing variables. From the research results, it was found that the classification accuracy is very good (accuracy = 92.23% and AUC=0.981). Performance testing based on k-fold stratified sampling obtained an average accuracy value is 91.28% and an average AUC value is 0.976. In this study, CQI improvement flow was made based on the eight variables that had the highest gini importance value. The eight variables that have the highest gini importance value are MIMO, PDCCH\_CCE\_Agg\_8, SE\_3, sinr\_pusch, sinr\_pucch, \_125\_\_PL\_\_130\_, \_130\_\_PL\_\_135\_, DL\_PRB\_Utilization.

**Keywords:** LTE, machine learning, Channel Quality Index, CQI, Random forest, Base Transceiver Station, BTS, Modulasi, QPSK, 16QAM, 64QAM, AUC

**[ Halaman ini sengaja dikosongkan ]**



## KATA PENGANTAR

Syukur Alhamdulillah penulis panjatkan kehadiran Allah *Subhanahu Wa Ta'ala* yang telah melimpahkan rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan Tesis dengan judul “Analisis Faktor-Faktor yang Mempengaruhi Penggunaan Modulasi 64QAM pada Jaringan Long-Term Evolution dengan Menggunakan Metode Random forest”. Tesis ini disusun sebagai salah satu syarat menyelesaikan studi magister di Program Studi Magister Manajemen Teknologi, Konsentrasi Manajemen Teknologi Informasi, Institut Teknologi Sepuluh Nopember Surabaya.

Penulis menyadari dalam penyelesaian penyusunan laporan Tesis ini tidak lepas dari bimbingan, kerjasama, dukungan maupun doa dari berbagai pihak. Oleh karena itu penulis ingin menyampaikan terima kasih kepada:

1. Bapak Prof. Ir. I Nyoman Pujawan, M.Eng., Ph.D. selaku Kepala Departemen Magister Manajemen Teknologi
2. Bapak R. Mohamad Atok, S.Si., M.Si., Ph.D. selaku dosen pembimbing tesis yang telah meluangkan waktu, tenaga, dan pikiran untuk memberikan bimbingan dan pengarahan kepada penulis dalam menyelesaikan tesis ini.
3. Bapak Jerry Dwi Trijoyo Purnomo, S.Si., M.Si., Ph.D. dan Bapak Dr. Ahmad Saikhu, S.Si., MT. selaku dosen penguji yang telah memberikan banyak tambahan ilmu selama proses perbaikan laporan Tesis.
4. Bapak Muhammad Harpro Rimeka selaku *solution architect* jaringan seluler PT Ericsson Indonesia yang sangat membantu dan mendukung penelitian ini dan telang meluangkan waktunya untuk berdiskusi sehingga penulis sering mendapatkan ide-ide segar sesudahnya.
5. Ibu saya ibu Suwarni, istri dr Fatimah Bibi dan anak tercinta kaila dan hazna yang sselalu memberikan dorongan semangat dan mendoakan dengan penuh ketulusan sehingga penulis dapat menyelesaikan penyusunan Tesis ini.
6. Seluruh teman-teman S2 Manajemen Teknologi Informasi Angkatan 2019 yang selalu memberikan motivasi, mengingatkan, memberi masukan, dan selalu memberi suntikan semangat kepada penulis dalam penyusunan Tesis ini.
7. Semua pihak yang tidak dapat disebutkan satu persatu, yang telah banyak memberikan berbagai macam bantuan dalam penyusunan Tesis ini.

Penulis menyadari bahwa penyusunan Tesis ini masih jauh dari sempurna, maka kritik dan saran yang membangun akan senantiasa penulis harapkan demi kesempurnaan di masa mendatang. Semoga laporan ini dapat memberikan sumbangan yang bermanfaat bagi semua pihak.

Surabaya, 31 Desember 2020

Penulis

## DAFTAR ISI

LEMBAR PENGESAHAN .....	iii
ABSTRAK.....	v
ABSTRACT.....	vii
KATA PENGANTAR .....	ix
DAFTAR ISI.....	xi
DAFTAR TABEL.....	xiii
DAFTAR GAMBAR .....	xv
BAB 1 PENDAHULUAN .....	1
1.1 Latar Belakang .....	1
1.2 Perumusan Masalah.....	8
1.3 Tujuan Penelitian.....	9
1.4 Manfaat Penelitian.....	9
1.5 Batasan Masalah.....	10
1.6 Sistematika Penulisan.....	10
BAB 2 TINJAUAN PUSTAKA .....	11
2.1 Long-Term Evolution (LTE).....	11
<b>2.1.1 Arsitektur Jaringan LTE</b> .....	12
<b>2.1.2 Modulasi dan <i>Channel Quality Index</i> (CQI)</b> .....	15
2.2 Algoritma Random forest.....	18
2.3 Evaluasi Kinerja Metode Klasifikasi.....	20
2.4 Penelitian yang relevan .....	22
BAB 3 METODOLOGI PENELITIAN .....	31
3.1 Perumusan Masalah dan Tujuan Penelitian .....	31
3.2 Studi Pustaka .....	32

3.3.	Pengumpulan Data .....	32
3.4.	Pengolahan Data.....	33
3.5.	Rekomendasi dan Penyusunan Laporan Penelitian.....	37
BAB 4 HASIL DAN PEMBAHASAN .....		39
4.1	Karakteristik Data CQI dan Modulasi.....	39
4.2	Analisis Klasifikasi Modulasi dengan Metode <i>Random forest</i> .....	39
4.3	Rekomendasi Peningkatan CQI ( <i>CQI Improvement Flow</i> ) .....	47
4.4	Perbandingan Kinerja Klasifikasi dengan Penelitian Relevan .....	50
BAB 5 KESIMPULAN DAN SARAN .....		51
5.1	Kesimpulan.....	51
5.2	Saran.....	51
DAFTAR PUSTAKA .....		53
LAMPIRAN.....		57
Lampiran 1. Data Variabel Prediktor Sebelum <i>Preprocessing</i> .....		57
Lampiran 2. Python Syntax Random forest.....		60
Lampiran 3. Koefisien Relasi Variabel Prediktor terhadap Modulasi .....		66
Lampiran 4. Deskripsi Variabel Prediktor .....		68

## DAFTAR TABEL

Tabel 2.1 CQI 4-bit CQI Table. Sumber (3GPP, 2019).....	16
Tabel 2.2 Perbandingan Kinerja Metode <i>Machine Learning</i> .....	19
Tabel 2.3 <i>Confussion Matrix</i> .....	20
Tabel 2.4 Klasifikasi AUC. Sumber (Jain, 2019) .....	22
Tabel 2.5 KPI yang berpengaruh signifikan terhadap kualitas jaringan .....	23
Tabel 2.6 Hasil klasifikasi <i>PCI confusion</i> . Sumber (Veríssimo, 2018).....	25
Tabel 2.7 Hasil klasifikasi <i>RSI Collision</i> . Sumber (Veríssimo, 2018).....	25
Tabel 2.8 Penelitian yang digunakan sebagai referensi .....	26
Tabel 2.8 Penelitian yang digunakan sebagai referensi (lanjutan) .....	27
Tabel 2.8 Penelitian yang digunakan sebagai referensi (lanjutan) .....	28
Tabel 2.8 Penelitian yang digunakan sebagai referensi (lanjutan) .....	29
Tabel 3.1 Jumlah Variabel Prediktor Setelah Dilakukan Seleksi Fitur .....	34
Tabel 3.2 Variabel Penelitian Setelah dilakukan seleksi fitur .....	34
Tabel 3.2 Variabel Penelitian Setelah dilakukan seleksi fitur (lanjutan).....	35
Tabel 3.2 Variabel Penelitian Setelah dilakukan seleksi fitur (lanjutan).....	36
Tabel 4.1 <i>Confussion Matrix</i> Klasifikasi <i>Random Forest</i> .....	40
Tabel 4.2 Performansi Klasifikasi <i>Random Forest</i> .....	40
Tabel 4.3 Hasil Prosentase Uji Performa <i>Stratified Sampling</i> .....	40
Tabel 4.4 Nilai <i>Gini Importance</i> Variabel Prediktor .....	41
Tabel 4.5 Nilai korelasi Pearson dan p-value .....	44
Tabel 4.6 Penjelasan <i>Features Importance</i> .....	47
Tabel 4.7 Contoh Optimasi Jaringan LTE dan LTE <i>Features</i> .....	48
Tabel 4.8 Perbandingan Kinerja Klasifikasi dengan Penelitian Lain .....	50

**[ Halaman ini sengaja dikosongkan ]**

## DAFTAR GAMBAR

Gambar 1.1 Penetrasi Pengguna Internet Indonesia Tahun 2018 .....	1
Gambar 1.2 Penetrasi Pengguna Internet Berdasar Pekerjaan .....	2
Gambar 1.3 Penetrasi Jaringan Seluler Asia-Pasifik .....	2
Gambar 1.4 Jumlah Pelanggan Data PT XL Axiata .....	3
Gambar 1.5 Jumlah BTS PT XL Axiata Tbk.....	4
Gambar 1.6 Pendapatan Data PT Telkomsel tahun 2018 .....	4
Gambar 1.7 Traffik Data/Internet, Jumlah BTS PT Telkomsel.....	5
Gambar 1.8 Evolusi teknologi LTE by Qualcomm .....	6
Gambar 1.9 perbandingan CQI vs Modulasi vs Throughput.....	6
Gambar 1.10 <i>Porter Five Forces Analysis on Operator Seluler</i> .....	7
Gambar 2.1 Atribut <i>air-interface</i> Sistem LTE/4G.....	12
Gambar 2.2 Evolusi Sistem LTE .....	12
Gambar 2.3 Arsitektur jaringa LTE.....	13
Gambar 2.4 korelasi CQI, SNR dan BLER .....	17
Gambar 2.5 <i>Throughput (Mbps) vs CQI(SNR)</i> . .....	17
Gambar 2.6 penggambaran algoritma <i>Random forest</i> . .....	18
Gambar 2.7 Kurva ROC ( <i>Receiver Operating Characteristic</i> ) .....	21
Gambar 2.8 Sistem Model Penelitian .....	23
Gambar 2.9 Sistem jaringan fiber optik.....	24
Gambar 2.10 Hasil penggunaan AI dalam jaringan fiber optik.....	24
Gambar 3.1 Tahapan Penelitian.....	31
Gambar 3.2 <i>Network Analytics Process Step</i> .....	33
Gambar 3.3 Flowchart Tahapan Pengolahan Data .....	33
Gambar 4.1 Data CQI dan Modulasi operator X .....	39
Gambar 4.2 <i>Feature Important</i> yang berpengaruh terhadap modulasi.....	43
Gambar 4.3 Konfigurasi MIMO $2 \times 2$ .....	44
Gambar 4.4 Konfigurasi MIMO $4 \times 2$ .....	45
Gambar 4.5 Nilai SNR tiap Antena MIMO $4 \times 2$ .....	46
Gambar 4.6 <i>CQI Improvement Flow</i> .....	48
Gambar 4.7 Prioritas Pembelian LTE <i>Features</i> .....	49

**[ Halaman ini sengaja dikosongkan ]**



# BAB 1

## PENDAHULUAN

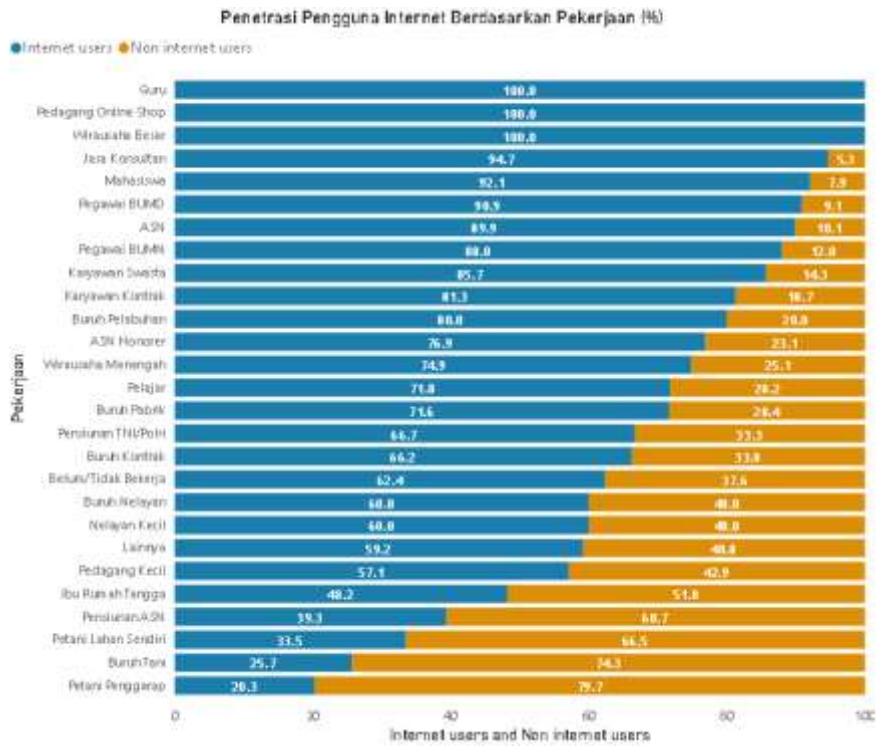
Pada bab ini akan dijelaskan beberapa hal dasar dalam pembuatan proposal penelitian yang meliputi: latar belakang, perumusan masalah, tujuan, manfaat, kontribusi penelitian, dan batasan masalah.

### 1.1 Latar Belakang

Dalam era digital ini perkembangan teknologi informasi sangat pesat dan internet menjadi salah satu kebutuhan yang sangat penting bagi masyarakat. Revolusi industri 4.0 kian berkembang dalam beberapa tahun terakhir seperti adanya *internet of things* (IoT), *block chains*, dan lain-lain yang berakibat munculnya berbagai model bisnis baru dan di kelola dengan cara-cara baru. Menurut hasil survei yang dilakukan Asosiasi Penyelenggara Jasa Internet Indonesia (APJII) pengguna internet di Indonesia pada tahun 2018 mencapai 171,17 juta jiwa (Gambar 1.1). Dalam survei ini juga mayoritas profesi dan atau jenis pekerjaan di Indonesia telah menggunakan layanan internet ditunjukkan seperti pada Gambar 1.2.




Gambar 1.1 Penetrasi Pengguna Internet Indonesia Tahun 2018  
Sumber (APJII, 2018)



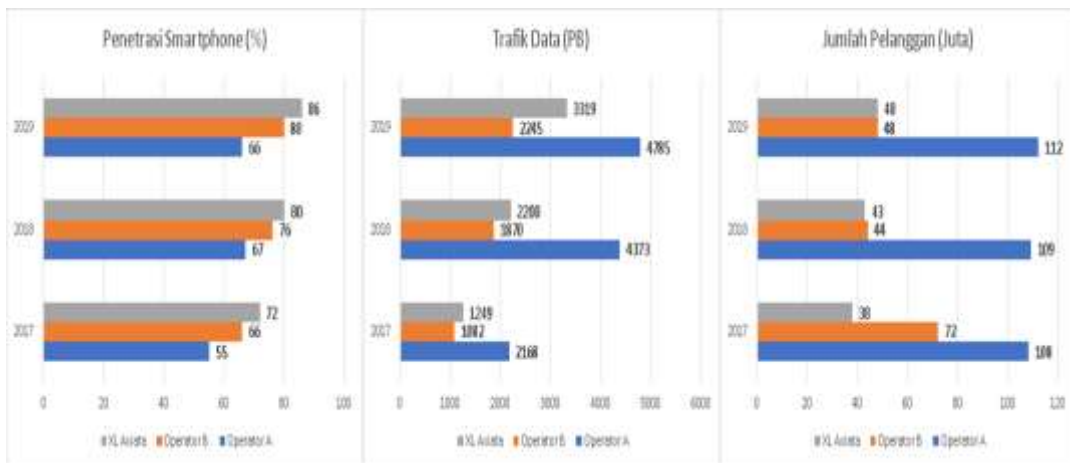
Gambar 1.2 Penetrasi Pengguna Internet Berdasar Pekerjaan  
Sumber (APJII, 2018)

Dalam riset yang dilakukan oleh GSMA (2019) untuk area Asia-Pasifik tahun 2019 terdapat 2,8 milyar koneksi yang menggunakan jaringan seluler dan sekitar 1,7 milyar koneksi internet menggunakan *smartphone*. Pembangunan jaringan radio didominasi dengan teknologi 4G/LTE yang mendukung koneksi data/internet yang lebih cepat.




Gambar 1.3 Penetrasi Jaringan Seluler Asia-Pasifik  
Sumber (GSMA, 2019)

Di Indonesia ada lima operator besar telekomunikasi seluler yaitu PT Telkomsel, PT XL Axiata Tbk, PT Indosat Tbk, H3I Indonesia dan Smartfren. Dalam laporan tahunan XL Axiata (2019), pendapatan data/internet mencapai 89% terhadap pendapatan jasa secara keseluruhan, trafik data mencapai 3.319,9 PB pada tahun 2019 naik 51% dibandingkan tahun 2018. Jumlah pelanggan XL Axiata tercatat sebanyak 56,7 juta pada akhir tahun 2019, dimana pangsa pasar pengguna *smartphone* adalah sebesar 86% atau 48,8 juta. Pembangunan BTS juga didominasi pembangunan 4G/LTE untuk mendukung koneksi internet yang cepat dan stabil. Pembangunan BTS 4G/LTE XL Axiata meningkat 40,2% (YoY). Pada tahun 2018 pelanggan PT Telkomsel tercatat sebanyak 163 juta dimana pelanggan data tercatat sebesar 65% yaitu sebesar 106,6 juta, kontribusi pendapatan data/internet sebesar 53% dan data trafik sebesar 4,373 PB naik sebesar 101,7% dibandingkan tahun 2017. Pembangunan BTS juga didominasi pembangunan 3G/4G untuk mendukung kecepatan internet yang stabil.



Gambar 1.4 Jumlah Pelanggan Data PT XL Axiata

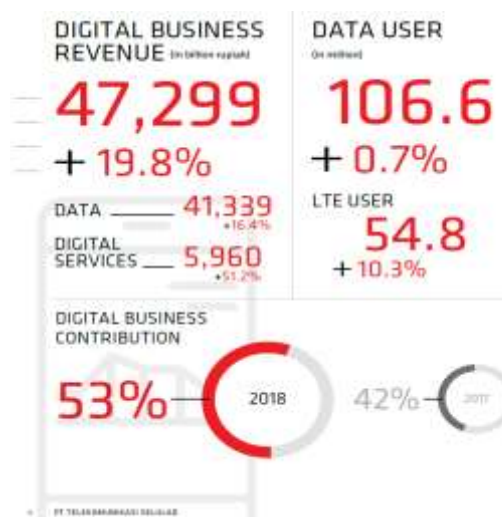
Sumber (Axiata, XL, 2019)



BTS	2015	2016	2017	2018	9M18	9M19	Δ YOY	Δ YTD
4G	3,134	8,204	17,428	29,772	28,028	40,264	40.20%	31.99%
3G	18,239	38,731	45,864	51,398	50,476	53,911	6.81%	4.89%
2G	37,506	37,549	37,802	37,426	37,630	35,926	-4.19%	-3.67%
<b>TOTAL</b>	<b>58,879</b>	<b>84,484</b>	<b>101,094</b>	<b>118,596</b>	<b>116,134</b>	<b>129,261</b>	<b>11.30%</b>	<b>8.99%</b>

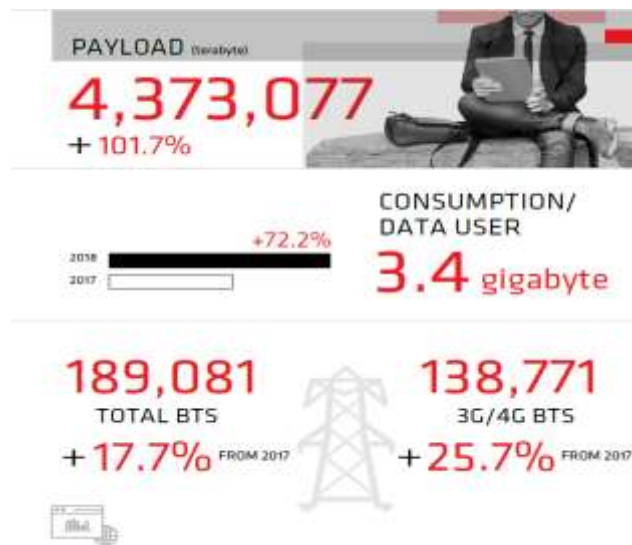
Gambar 1.5 Jumlah BTS PT XL Axiata Tbk

Sumber (Axiata, XL, 2019)




Gambar 1.6 Pendapatan Data PT Telkomsel tahun 2018

Sumber (Telkomsel, 2018)



Gambar 1.7 Traffik Data/Internet, Jumlah BTS PT Telkomsel  
 Sumber (Telkomsel, 2018)

LTE/4G Merupakan evolusi teknologi seluler yang bisa memberikan peningkatan kecepatan akses internet yang jauh lebih dari teknologi sebelumnya yaitu 3G (HSDPA) dan 2G. Secara teori teknologi 4G bisa mencapai kecepatan/ *Throughput* akses data sebesar 1 Gbps. Evolusi kecepatan 4G digambarkan seperti pada Gambar 1.8. Teknologi ini sebagai solusi atas kebutuhan akan komunikasi data yang semakin meningkat. Dalam teknologi 4G/ LTE , sistem modulasi yang digunakan adalah QPSK, 16QAM, dan 64QAM pada arah *downlink* dan *uplink*. Modulasi 64QAM dapat mengirimkan *bitrate* yang lebih tinggi dengan penggunaan daya yang lebih rendah seperti ditunjukkan pada Gambar 1.9. Modulasi akan berubah secara dinamis tergantung kondisi kualitas jaringan, yaitu kondisi *Channel Quality Index (CQI)*. Modulasi 64QAM akan digunakan jika kualitas jaringan sangat bagus yaitu nilai  $CQI \geq 10$ .



Gambar 1.8 Evolusi teknologi LTE by Qualcomm

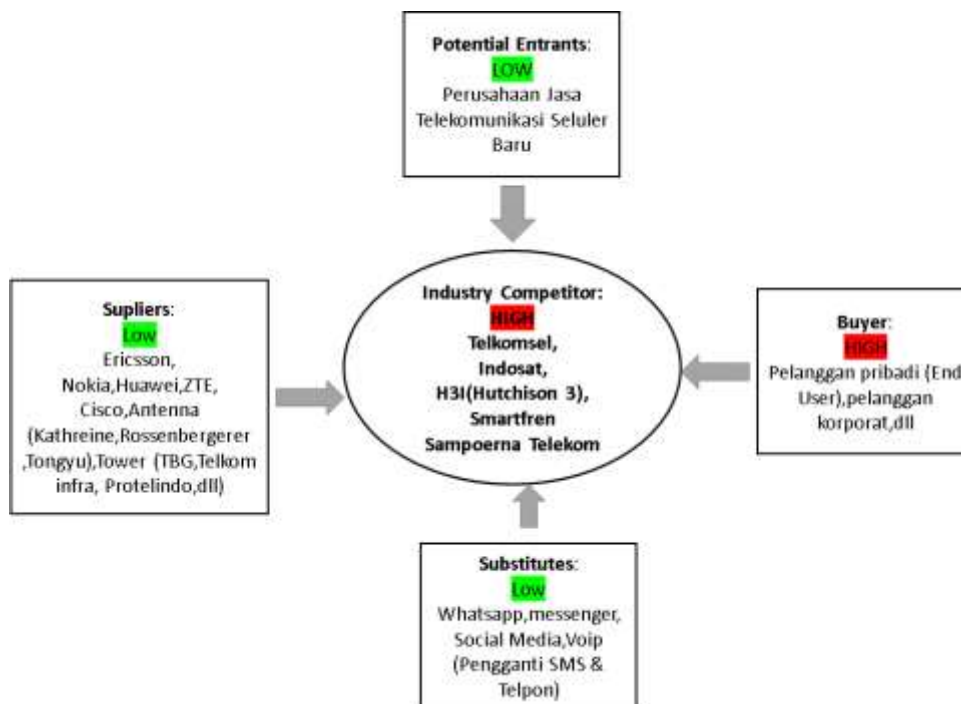


Gambar 1.9 perbandingan CQI vs Modulasi vs Throughput

Kualitas jaringan seluler LTE akan sangat berpengaruh dalam mempertahankan pelanggan atau mendapatkan pelanggan baru bagi operator telekomunikasi. Kualitas jaringan yang buruk seperti susah akses internet, kecepatan internet yang rendah akan memicu terjadinya komplain dari pelanggan dan ketika masalah ini dibiarkan terlalu lama maka akan mengakibatkan pelanggan akan berpindah ke operator telekomunikasi lain. Dalam penelitian yang dilakukan oleh Arvian (2015) *Porter Five Forces Analysis* pada operator seluler bahwa faktor *industry competitor* dan *buyer* mempunyai kategori *high* seperti ditunjukkan pada Gambar 1.10. Hal ini berarti dua faktor tersebut sangat mempengaruhi perusahaan untuk mencapai kesuksesan.

Menurut penelitian ini, faktor *buyer power* sangat tinggi, hal ini karena mudahnya berganti layanan operator dan didukung banyaknya *handphone dual sim card*, sensitif terhadap harga, kebutuhan akan data dengan kualitas layanan yang

baik, dan juga karena pelanggan bisa mengakses informasi mengenai produk layanan operator dengan mudah.



Gambar 1.10 Porter Five Forces Analysis on Operator Seluler  
 Sumber (Arvian, 2015) dan (Cahyanto, 2018)

Peningkatan kualitas jaringan dapat dilakukan dengan menambah BTS baru atau mengoptimalkan BTS yang sudah ada. Penambahan BTS baru akan meningkatkan *coverage*, *quality*, dan *capacity* akan tetapi CAPEX dan OPEX yang dikeluarkan tinggi dan juga waktu yang diperlukan untuk membangun BTS juga lama sedangkan peningkatan kualitas jaringan dengan cara mengoptimalkan BTS bisa dilakukan dengan melakukan pembelian fitur-fitur LTE dan biaya yang dikeluarkan masih tergolong rendah yaitu 10-30 kali lebih rendah dibandingkan membangun BTS baru. Perbandingan ini dapat dilihat pada Tabel 1.1. Penambahan BTS secara besar-besaran dan tidak sesuai kebutuhan akan mengakibatkan biaya modal (CAPEX) yang dikeluarkan operator sangat besar yang berakibat akan menurunnya *Net Profit Margin (NPM)* dan menjadikan harga produknya menjadi mahal dan tidak kompetitif, oleh karena itu diperlukan metode yang cukup akurat dalam meningkatkan kualitas jaringan dan rekomendasi pembangunan BTS yang

dilakukan memang benar-benar diperlukan dalam meningkatkan kualitas jaringan 4G.

Tabel 1.1 Perbandingan Biaya Pembangunan BTS Baru dan *Optimizing* BTS

	<i>Coverage</i>	<i>Quality</i>	<i>Capacity</i>	<i>Time</i>	<i>CAPEX/OPEX</i>
<i>New BTS</i>	<i>Improve</i>	<i>improve</i>	<i>improve</i>	<i>Long</i>	<i>High</i>
<i>Optimizing BTS</i>	<i>May improve</i>	<i>May improve</i>	<i>May improve</i>	<i>Prompt</i>	<i>Low</i>

Dalam meningkatkan penetrasi penggunaan modulasi 64QAM dibutuhkan analisis terhadap variabel-variabel yang lain. Prosedur yang digunakan saat ini masih menggunakan cara yang kurang efisien dari segi waktu, tenaga dan juga membutuhkan seorang yang ahli dan profesional dalam bidangnya akan tetapi sering kali tidak akurat dalam menemukan faktor yang menyebabkan kualitas jaringan LTE memburuk. Untuk mengatasi masalah ini, pada penelitian ini peneliti mencoba menganalisis data kualitas Jaringan dalam hal ini melalui indikator penggunaan modulasi 64QAM dan variable-variabel lain yang berpengaruh dengan menggunakan metode klasifikasi *random forest*.

Dengan mengetahui variabel-variabel yang berpengaruh secara signifikan terhadap kualitas jaringan, maka biaya modal yang dikeluarkan operator seluler untuk peningkatan kualitas jaringan akan menjadi lebih efektif dan efisien karena biaya modal yang diinvestasikan hanya berfokus terhadap variabel-variabel yang berpengaruh seperti pembelian *feature-feature*, optimasi jaringan LTE hanya dilakukan untuk yang berhubungan dengan variabel-variabel tersebut.

## 1.2 Perumusan Masalah

Rumusan masalah yang diangkat dalam penelitian ini dapat dipaparkan sebagai berikut:

1. Bagaimana prosedur proses optimisasi jaringan LTE dalam meningkatkan penetrasi penggunaan 64QAM dengan memanfaatkan algoritma *random forest*.



2. Bagaimana ketepatan klasifikasi/tingkat akurasi yang dihasilkan dari metode *random forest*.

### 1.3 Tujuan Penelitian

Penelitian ini dilakukan dengan tujuan sebagai berikut:

1. Mengidentifikasi variabel signifikan/*importance variable* yang mempengaruhi penetrasi penggunaan modulasi 64QAM.
2. Untuk membuat prosedur optimasi jaringan LTE dalam mengidentifikasi faktor-faktor yang mempengaruhi kualitas jaringan LTE melalui indikator penggunaan modulasi 64QAM dengan menggunakan metode klasifikasi *random forest*.
3. Mengetahui ketepatan klasifikasi dari metode *random forest*.

### 1.4 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Bagi *Internal* Perusahaan  
Prosedur optimasi jaringan LTE yang dihasilkan dapat memberikan pemahaman yang lebih mendalam terkait faktor-faktor yang mempengaruhi kualitas jaringan LTE melalui indikator penetrasi modulasi 64QAM ( $CQI \geq 10$ ) sehingga dapat menjadi referensi dalam melakukan optimasi performansi jaringan LTE.
2. Bagi Operator Telekomunikasi Seluler  
Membantu operator dengan memberikan rekomendasi yang cukup akurat untuk meningkatkan kualitas jaringan apakah aktivitas yang dilakukan menambah BTS, *upgrade* kapasitas atau hanya melakukan optimasi sehingga *cost* yang dikeluarkan oleh operator dalam membangun jaringan 4G sudah efektif dan efisien.
3. Menambah kajian ilmiah mengenai faktor-faktor yang berpengaruh pada penetrasi penggunaan modulasi 64QAM pada jaringan telekomunikasi seluler LTE dengan menggunakan klasifikasi metode *random forest*.

## **1.5 Batasan Masalah**

Untuk memfokuskan permasalahan pada penelitian ini, batasan masalah yang ditentukan adalah sebagai berikut:

1. Data penelitian yang akan digunakan didapatkan dari operator seluler X (salah satu operator telekomunikasi terbesar di Indonesia)
2. Data Analisis yang digunakan hanya pada teknologi *LTE FDD* (*Frequency Division Duplexing*)

## **1.6 Sistematika Penulisan**

Berikut ini adalah sistematika penulisan yang akan diterapkan pada proses penelitian ini:

Bab 1: Pendahuluan

Bab ini menjelaskan tentang latar belakang, rumusan masalah, tujuan, manfaat, batasan masalah, dan sistematika penulisan.

Bab 2: Kajian Pustaka.

Bab ini menjelaskan tentang teori-teori yang berkaitan dengan penelitian ini. Selain itu juga menyajikan penelitian-penelitian terdahulu yang berkaitan dengan penelitian ini. Sumber untuk tinjauan pustakan pada penelitian ini meliputi buku, jurnal, dokumen salah satu vendor telekomunikasi

Bab 3: Bab metodologi penelitian

Bab ini menyajikan alur penelitian secara detail dan sistematis mulai dari tahap awal penelitian, pelaksanaan penelitian, hingga akhirnya diperoleh hasil dari penelitian. Metodologi penelitian disajikan dalam bentuk diagram alir penelitian yang sistematis.

Bab 4: Hasil Penelitian dan Pembahasan.

Bab ini menjelaskan tentang pengumpulan dan pengolahan data, berdasarkan data tersebut, dilakukan Analisis variabel yang secara signifikan mempengaruhi Penetrasi penggunaan modulasi 64QAM.

Bab 5: Kesimpulan dan Saran.

Bab ini menjelaskan tentang kesimpulan yang diperoleh pada penelitian ini serta saran bagi penelitian di masa mendatang.

## **BAB 2**

### **TINJAUAN PUSTAKA**

Dalam penelitian ini dilakukan beberapa kajian Pustaka yaitu dari buku, dokumen mengenai *counter*, *Key performance indicator* yang berkaitan dengan kualitas jaringan seluler dari salah satu vendor telekomunikasi, internet dan jurnal yang berkaitan dengan penelitian ini.

#### **2.1 Long-Term Evolution (LTE)**

Teknologi LTE dibangun dan dikembangkan dengan tujuan untuk menyediakan akses radio yang berkecepatan tinggi, *low latency*, dan mendukung *bandwidth* yang fleksibel. Arsitektur teknologi ini dirancang dengan tujuan untuk mendukung trafik *packet switched* dengan mobilitas tanpa batas, kualitas layanan yang bagus. *Throughput*/Kecepatan akses data/internet yang didukung oleh teknologi LTE berkisar antara 100 Mbps - 1 Gbps.

Atribut *air-interface* dari sistem LTE dapat dilihat pada Gambar 2.1. Sistem ini mendukung bandwidth yang fleksibel berkat skema akses OFDMA (*Orthogonal Frequency Division Multiple Access*) dan SC-FDMA (*Single-carrier FDMA*). Teknologi LTE mempunyai dua cara pengantaran yang dikenal dengan istilah FDD (*Frequency Division Duplexing*) dan TDD (*Time Division Duplexing*). FDD mempunyai cara pengantaran dengan menggunakan dua kanal/frekuensi yang terpisah antara *downlink* dan *uplink* sedangkan TDD data diantarkan dan diterima dalam satu kanal frekuensi yang sama, hanya dengan pemisahan jeda waktu yang singkat. Akses *uplink* pada LTE menggunakan SC-FDMA sedangkan *downlink* menggunakan OFDMA. Selain peningkatan kecepatan akses data yang signifikan dibandingkan dengan 3G/HSDPA, sistem LTE memberikan efisiensi spektral dua hingga empat kali lebih tinggi relative terhadap sistem HSDPA *release 6*. Perbaikan serupa juga dapat diobservasi dalam area yang jauh *cell-edge throughput* untuk lokasi yang sama kecepatan LTE jauh lebih besar dari HSDPA. Dalam hal latensi, jaringan LTE mempunyai kemampuan untuk menghantarkan trafik data dari jaringan ke UE (*User Equipment*) kurang dari 10 ms.

Bandwidth	1.25–20 MHz
Duplexing	FDD, TDD, half-duplex FDD
Mobility	350 km/h
Multiple access	Downlink OFDMA
	Uplink SC-FDMA
MIMO	Downlink $2 \times 2, 4 \times 2, 4 \times 4$
	Uplink $1 \times 2, 1 \times 4$
Peak data rate in 20 MHz	Downlink 173 and 326 Mb/s for $2 \times 2$ and $4 \times 4$ MIMO, respectively
	Uplink 86 Mb/s with $1 \times 2$ antenna configuration
Modulation	QPSK, 16-QAM and 64-QAM
Channel coding	Turbo code
Other techniques	Channel sensitive scheduling, link adaptation, power control, ICIC and hybrid ARQ

Gambar 2.1 Atribut *air-interface* Sistem LTE/4G

Sumber (Khan, 2009)

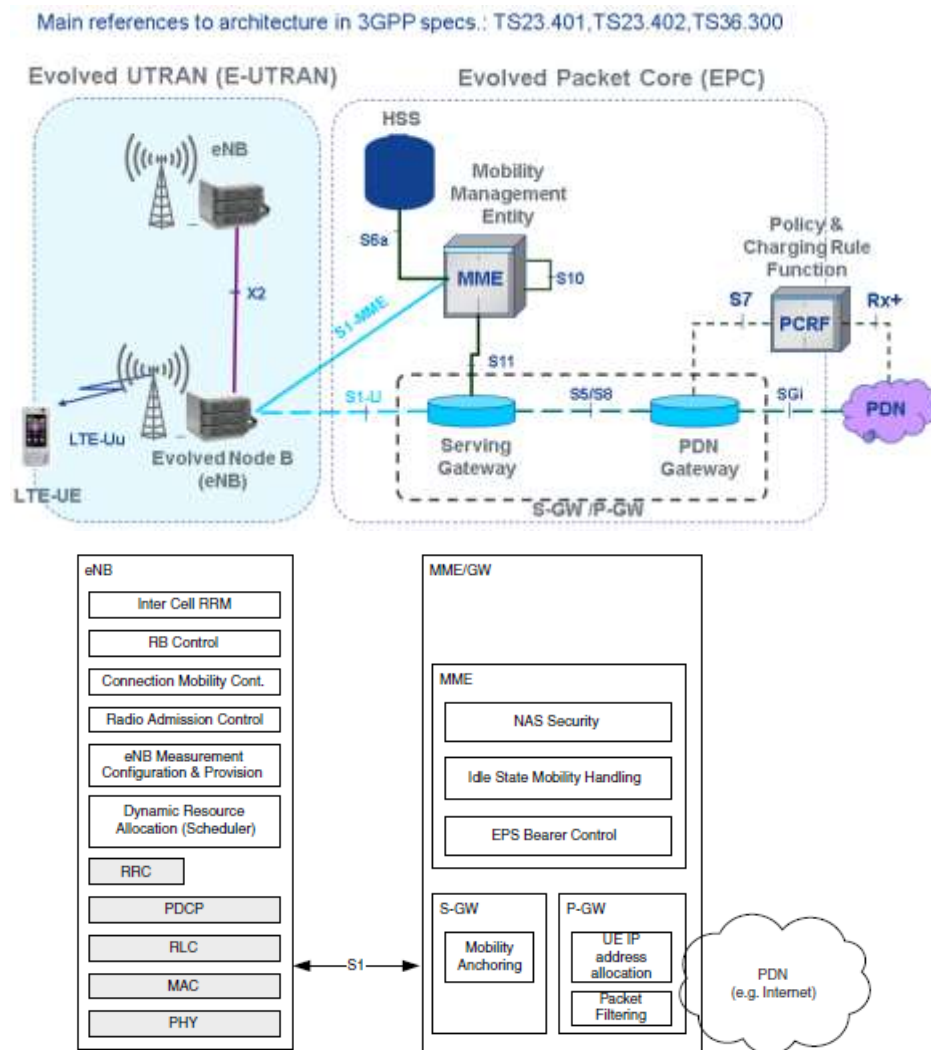


Gambar 2.2 Evolusi Sistem LTE

Sumber (Nokia Solution Network, 2014)

### 2.1.1 Arsitektur Jaringan LTE

Dalam teknologi LTE/4G, semua antarmuka jaringan didasarkan pada protokol IP yang dapat mengintegrasikan jaringan dan sistem yang ada. Arsitektur LTE dapat dilihat pada Gambar 2.3. Ada dua komponen besar dalam arsitektur LTE yaitu komponen radio/BTS *Evolved UTRAN* (E-UTRAN) dan komponen *Evolved Packet Core* (EPC). Inter koneksi antara *Evolved NodeB* (eNB) melalui antar muka X2 sedangkan antara eNB dan MME (*Mobility Management Entity*) dihubungkan melalui antar muka S1.



Gambar 2.3 Arsitektur jaringan LTE

Sumber (Nokia Solution Network, 2014) dan (Khan, 2009)

*Evolved UTRAN (Evolved UMTS Terrestrial Radio Access Network)* terdiri dari dua komponen yaitu eNB dan UE (*User equipment*). UE adalah perangkat yang digunakan agar dapat berkomunikasi dengan jaringan LTE melalui komponen eNB, contoh dari UE adalah *smartphone/handphone*, tablet, modem, dan perangkat lain yang dilengkapi dengan *network adapter* LTE sedangkan eNB merupakan *base station* yang diletakkan pada tower atau ditempatkan diatas Gedung. E-NodeB(eNB) mempunyai dua fungsi diantaranya:

1. Mengirim transmisi radio ke UE baik arah *uplink* maupun *downlink*.

2. mengontrol operasi level rendah semua user *equipment* (UE), dengan mengirimkan pesan sinyal seperti perintah handover yang berhubungan dengan transmisi radio.

EPC (*Evolved Packet Core*) merupakan bagian *core network* dalam sistem komunikasi seluler yang berbasis *all-IP*. Pada sistem *core network* generasi sebelumnya yaitu 2G dan 3G memiliki arsitektur yang terpisah antara *circuit switch* (CS) untuk komunikasi suara dan *packet switch* (PS) untuk komunikasi data. EPC berperan dalam layanan pengiriman IP secara *end to end* pada LTE. EPC terdiri dari beberapa komponen, diantaranya:

1. MME (*Mobility Management Entity*)

MME merupakan elemen kontrol utama yang terdapat pada EPC. MME memiliki fungsi diantaranya *NAS signaling and security, authentication and authorization, idle mode mobility management* dan *Inter CN node signaling for mobility*.

2. SGW (*Serving Gateway*)

Pada arsitektur jaringan LTE, level fungsi tertinggi S-GW adalah jembatan antara manajemen dan switching user plane. S-GW merupakan bagian dari infrastruktur jaringan sebagai pusat operasional dan maintenance. Peranan S-GW sangat sedikit pada fungsi pengontrolan. Hanya bertanggungjawab pada sumbernya sendiri dan mengalokasikannya berdasarkan permintaan MME. Fungsi S-GW diantaranya *Local Mobility gateway for inter-eNB handover, Packet routing and forwarding, Local Mobility gateway for 3GPP accesses*.

3. PGW (*Packet Data Network Gateway*)

PGW bertujuan dalam mengatur hubungan jaringan data antara jaringan 3GPP dan jaringan *non 3GPP* seperti WIMAX, WLAN, dan EVDO. PGW berfungsi menyediakan konektifitas UE ke jaringan eksternal, menjadi titik masuknya koneksi lalu lintas pada UE. PGW juga dapat berfungsi sebagai *packet-filtering*, menentukan jenis layanan, *packet screening* dan *Charging Support*.

4. PCRF (*Policy and Charging Rules Function*)

PCRF merupakan bagian dari arsitektur jaringan yang mengumpulkan informasi dari dan ke jaringan, sistem pendukung operasional, dan sumber lainnya seperti portal secara real time, yang mendukung pembentukan aturan dan kemudian secara otomatis membuat keputusan kebijakan untuk setiap pelanggan aktif di jaringan. Jaringan seperti ini mungkin menawarkan beberapa layanan, kualitas layanan (Quality of services), dan aturan pengisian. PCRF dapat menyediakan jaringan solusi *wireline* dan *wireless* dan juga dapat mengaktifkan pendekatan multidimensi yang membantu dalam menciptakan hal yang menguntungkan dan platform inovatif untuk operator. PCRF juga dapat diintegrasikan dengan platform yang berbeda seperti penagihan, *rating*, pengisian, dan basis pelanggan atau juga dapat digunakan sebagai entitas mandiri.

#### 5. HSS (*Home Subscription Server*)

HSS merupakan tempat penyimpanan data pelanggan untuk semua data permanen *user* seperti informasi langganan data, nomor pelanggan. HSS juga menyimpan lokasi user pada level yang dikunjungi node pengontrol jaringan.

### 2.1.2 Modulasi dan *Channel Quality Index* (CQI)

Modulasi merupakan proses penumpangan sinyal informasi terhadap sinyal pembawa. Pada jaringan LTE modulasi yang digunakan adalah QPSK, 16QAM, dan 64QAM. Modulasi 64QAM dapat mengirimkan *bitrate* yang lebih tinggi dengan penggunaan daya yang lebih rendah. Pada modulasi 64-*Quadrature Amplitude Modulation* (64-QAM) termasuk kategori *high order* modulasi karena 64QAM terdiri dari 64 simbol dimana setiap simbol terdiri dari 6 bit. Modulasi 64QAM digunakan pada saat kondisi kanal antara pengirim dan penerima sangat baik yaitu nilai  $CQI \geq 10$ .

*Channel Quality Index* (CQI) merupakan salah satu variabel dalam mengukur kualitas jaringan LTE/4G disisi radio. Pengguna dengan keadaan *poor channel quality* akan mengalami kualitas layanan (*quality of service*) yang buruk diantaranya kecepatan akses data/internet menjadi rendah, susah dalam


menggunakan internet, panggilan suara putus-putus, dll. CQI digunakan untuk menghitung kualitas saluran downlink saat digunakan untuk *dynamic scheduling*. CQI digunakan oleh scheduler jaringan untuk mendapatkan modulasi yang terbaik dan coding scheme (MCS) mencapai tingkat blok error (BLER) kurang dari 10%. Indeks CQI dan interpretasinya diberikan pada Tabel 2.1. Dari Tabel 2.1 untuk mendapatkan modulasi 64QAM, CQI harus lebih besar sama dengan 10 ( $CQI \geq 10$ ).

Tabel 2.1 CQI 4-bit CQI Table. Sumber (3GPP, 2019)

CQI index	modulation	code rate x 1024	efficiency
0	out of range		
1	QPSK	78	0.1523
2	QPSK	120	0.2344
3	QPSK	193	0.3770
4	QPSK	308	0.6016
5	QPSK	449	0.8770
6	QPSK	602	1.1758
7	16QAM	378	1.4766
8	16QAM	490	1.9141
9	16QAM	616	2.4063
10	64QAM	466	2.7305
11	64QAM	567	3.3223
12	64QAM	666	3.9023
13	64QAM	772	4.5234
14	64QAM	873	5.1152
15	64QAM	948	5.5547

*Channel Quality Index* berhubungan linier dengan SNR (*signal noise to ratio*), dalam jurnal (Li, 2011) formula  $CQI = 0.5223 * SNR + 4,6176$ . *Signal to noise ratio* (SNR) merupakan variabel *downlink* yang diukur oleh UE (*user equipment*) seperti *mobile phone*, modem, *smartphone*, dll. Semakin tinggi nilai SNR maka semakin tinggi nilai CQI.

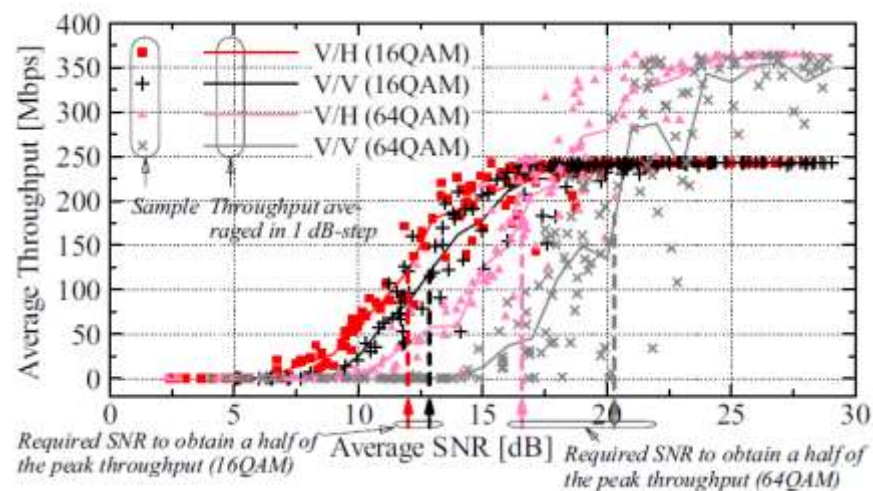




Gambar 2.4 korelasi CQI, SNR dan BLER

Sumber (Li, 2011)

Dalam hal *user experienced*, kecepatan akses data/*throughput* akan lebih baik jika UE mendapatkan modulasi 64 QAM (*Quadrature amplitude modulation*) dibandingkan modulasi 16QAM dan QPSK (*Quadrature Phase Shift Keying*). Perbandingan *throughput* dan modulasi dapat dilihat pada Gambar 2.5. CQI akan dilaporkan UE terhadap eNB secara periodic melalui kanal uplink yaitu PUCCH (*physical uplink control channel*) dan PUSCH (*physical uplink shared channel*).

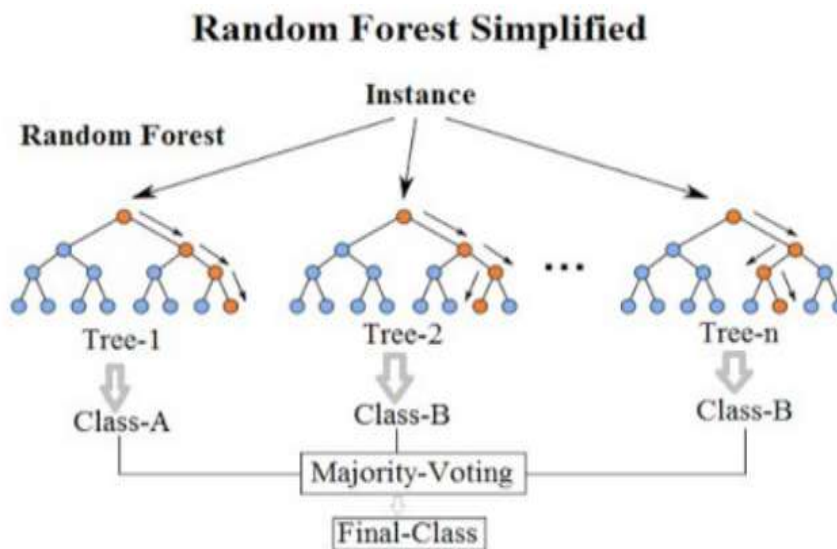


Gambar 2.5 *Throughput (Mbps) vs CQI(SNR)*.

Sumber (Miyazaki, 2010)

## 2.2 Algoritma Random forest

Algoritma *Random forest* merupakan salah satu metode *supervised machine learning*. Algoritma ini dikembangkan dan diperkenalkan pertama kali oleh Leo Breiman pada tahun 2001. Metode ini merupakan pengembangan dari metode *classification and Reggresion Tree* dan menerapkan metode *Bagging (Bootstrap Aggregating)* dan *random feature selection*. Pada dasarnya algoritma *Random forest* merupakan sekumpulan *decision tree* yang hasilnya akan dirata-ratakan menjadi sebuah hasil prediksi. Dalam hal melakukan klasifikasi, hasil akhir dari suatu klasifikasi yang terbentuk dari beberapa pohon tersebut kemudian dipilih berdasarkan *Majority-Voting*.



Gambar 2.6 penggambaran algoritma *Random forest*.

Sumber (Liu, 2019)

Di dalam algoritma *Random forest*, pohon/*tree* yang dihasilkan akan banyak sehingga terbentuklah sebuah hutan (*forest*) kumpulan banyak pohon yang dihasilkan tersebut, kemudian dilakukan analisis terhadap kumpulan pohon tersebut. Dalam kelompok data yang terdiri atas  $n$  amatan dan  $p$  peubah penjelas, algoritma *Random forest* bekerja dengan cara:

1. Melakukan penarikan sample / data secara acak berukuran  $n$  dengan kemungkinan pengambilan data yang sama, tahap ini disebut tahapan bootstrap.

2. Dengan menggunakan contoh bootstrap. Pohon dibangun hingga mencapai ukuran maksimum (tanpa pruning). Pada setiap node, pemilihan node dilakukan dengan memilih  $m$  variabel penjelas secara acak, dimana  $m \ll p$ , lalu pemilah terbaik dipilih berdasarkan  $m$  variabel penjelas tersebut dimana tahapan ini disebut dengan tahapan random feature selection
3. *Repeat* langkah 1 dan 2 sebanyak  $k$  kali, sehingga terbentuklah sebuah hutan atas dari  $k$  pohon.

*Splitting* dalam algoritma *Random forest* menggunakan perhitungan *Gini Index*. Berikut ini formula perhitungan *Gini index* terhadap *classification*:

$$\text{Gini} = N_L \sum_{k=1, \dots, k} p_{kL}(1-p_{kL}) + N_R \sum_{k=1, \dots, k} p_{kR}(1-p_{kR})$$

dimana:  $p_{kL}$  merupakan proporsi dari kelas  $k$  yang ada di node kiri dan  $p_{kR}$  merupakan proporsi dari kelas  $k$  yang ada di node kanan.

Pada Penelitian ini digunakan metode klasifikasi *random forest* karena dari beberapa jurnal yang dijadikan referensi dalam penelitian ini, kinerja metode *machine learning random forest* lebih baik dalam hal akurasi dan nilai AUC yang ditunjukkan seperti pada Tabel 2.2.

Tabel 2.2 Perbandingan Kinerja Metode *Machine Learning*

Penulis	Judul Jurnal	Metode	Kinerja akurasi
(Couronné, 2018)	<i>Random forest versus logistic regression: a large-scale benchmark experiment</i>	<i>Random forest</i> dan <i>logistic regression</i>	Kinerja akurasi dan AUC <i>random forest</i> lebih baik
(Veríssimo, 2018)	<i>PCI and RSI Conflict Detection in a Real LTE Network Using Supervised Learning</i>	RF, SVM, dan AB	Kinerja akurasi RF ( <i>random forest</i> ) lebih baik
(Liu, 2019)	<i>Predicting malfunction of mobile network base station using machine learning approach</i>	<i>Neural Network</i> , <i>Random forest</i> , dan SVM	Kinerja akurasi dan AUC <i>random forest</i> lebih baik
(Chen, 2017)	<i>The Exploration of Machine Learning for Abnormal Prediction Model of Telecom Business Support System</i>	<i>Naïve Bayes</i> , SVM, <i>Random forest</i>	Kinerja akurasi RF ( <i>random forest</i> ) lebih baik

### 2.3 Evaluasi Kinerja Metode Klasifikasi

Data aktual dan data hasil prediksi dari model klasifikasi disajikan dengan menggunakan tabulasi silang (*Confusion matrix*), yang mengandung informasi tentang kelas data yang actual direpresentasikan pada baris matriks dan kelas data hasil prediksi pada kolom (Han & Kamber, 2006).

Tabel 2.3 *Confusion Matrix*

	<i>Predictive Positive Class</i>	<i>Predictive Negative Class</i>
<i>Real Positive Class</i>	<i>True Positive (TP)</i>	<i>False Negative (FN)</i>
<i>Real Negative Class</i>	<i>False Positive (FP)</i>	<i>True Negative (TN)</i>

1. *True Positive (TP)* menunjukkan bahwa kelas yang dihasilkan prediksi klasifikasi positif dan kelas sebenarnya adalah positif
2. *True Negative (TN)* menunjukkan bahwa kelas yang dihasilkan dari prediksi klasifikasi adalah negatif dan kelas sebenarnya adalah negatif.
3. *False Positif (FP)* menunjukkan bahwa kelas yang dihasilkan dari prediksi klasifikasi adalah positif dan kelas sebenarnya adalah negatif.
4. *False Negatif (FN)* menunjukkan bahwa kelas yang dihasilkan dari prediksi klasifikasi adalah negatif dan kelas sebenarnya adalah positif.

Evaluasi klasifikasi terdiri meliputi *accuracy*, *sensitivity*, *specificity*, dan *precision*.

$$Accuracy = \frac{TP}{TP+TN+FP+FN} \quad (2.1)$$

$$Precision = \frac{TP}{TP+FP} \quad (2.2)$$

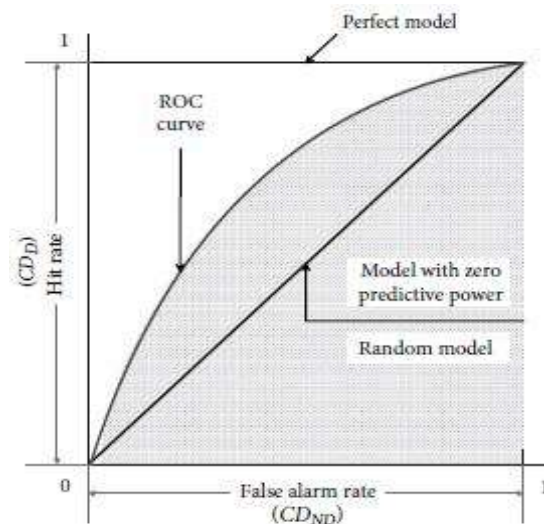
$$Recall/Sensitivity = \frac{TP}{TP+FN} \quad (2.3)$$

$$Specificity = \frac{TN}{TN+FP} \quad (2.4)$$

Untuk kasus imbalance, akurasi klasifikasi tidak cukup sebagai ukuran kriteria standar. *Area Under Curve* (AUC) dan metrik seperti *precision*, *recall* telah digunakan untuk memahami kinerja algoritma learning pada kelas minoritas. *Area Under Curve* (AUC) menyediakan ukuran tunggal kinerja *classifier* untuk evaluasi model mana yang lebih baik secara rata-rata. Ukuran AUC diperoleh dengan menghitung nilai *true positive rate* (TPR) yaitu jumlah objek pada kelas positif yang diklasifikasikan dengan benar dan *false positive rate* (FPR) yaitu jumlah objek pada kelas positif yang salah diklasifikasikan.

$$TPR = \frac{TP}{TP+FN} \quad (2.5)$$

$$FPR = 1 - \frac{TN}{TN+FP} \quad (2.6)$$



Gambar 2.7 Kurva ROC (*Receiver Operating Characteristic*)

Sumber (Jain, 2019)

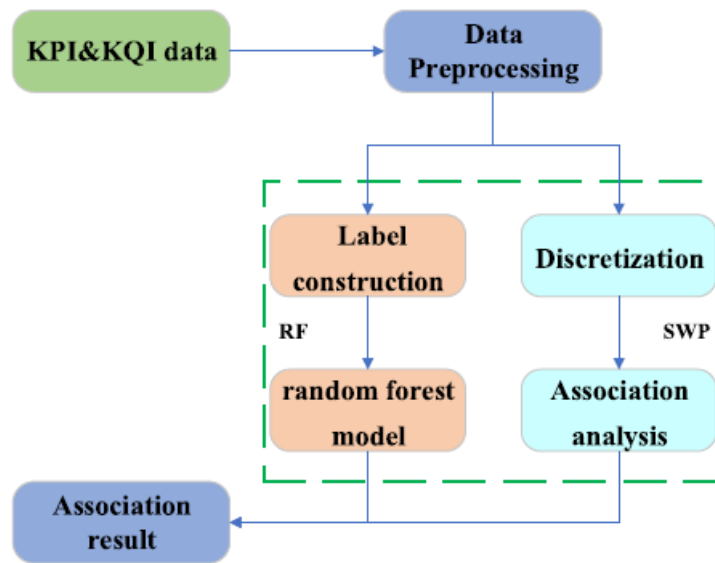
Daerah dibawah kurva ROC disebut sebagai ukuran *Area Under Curve* (AUC). Ukuran AUC digunakan untuk merangkum kurva ROC kedalam suatu nilai, semakin besar nilai AUC maka model dapat dikatakan semakin baik.

Tabel 2.4 Klasifikasi AUC. Sumber (Jain, 2019)

Nilai AUC	Kategori
0,9 – 1	<i>Excellent classification</i>
0,8 – 0,9	<i>Good classification</i>
0,7 – 0,8	<i>Fair classification</i>
0,6 – 0,7	<i>Poor classification</i>
< 0,6	<i>Failure</i>

## 2.4 Penelitian yang relevan

Ada beberapa penelitian/jurnal di IEEE Access dan Science Direct yang dijadikan bahan kajian dalam penyusunan penelitian ini yang membahas penggunaan metode *machine learning* dalam bidang telekomunikasi seluler. Jurnal pertama yang dijadikan referensi adalah penelitian oleh Fan (2019) *Machine Learning Based Quantitative Association Rule Mining Method for Evaluating Cellular Network Performance*. Penelitian ini menggunakan metode *machine learning* SWP (*slidingwindow partitioning*) dan *Random forest* untuk meningkatkan kualitas jaringan seluler. Dalam penelitian ini bertujuan dalam menganalisis hubungan KPI (*Key Performance Indicator*) dan KQI (*Key Quality Indicator*) jaringan seluler 5G. Sistem model yang digunakan dapat dilihat pada Gambar 2.10.



Gambar 2.8 Sistem Model Penelitian

Sumber (Fan, 2019)


Hasil yang didapatkan dalam penelitian ini adalah ada beberapa KPI yang sangat berpengaruh terhadap kualitas jaringan 5G. Hasil eksperimen juga membuktikan kelayakan dan keakuratan metode yang diusulkan.

Tabel 2.5 KPI yang berpengaruh signifikan terhadap kualitas jaringan

<b><i>KPI</i></b>	<b><i>Attribution</i></b>	<b><i>Threshold</i></b>
<i>Uplink PRB Utilization Rate</i>	<i>Negative</i>	0,5
<i>Downlink PRB Utilization Rate</i>	<i>Negative</i>	0,5
<i>RRC Connection Reconstruction Rate</i>	<i>Negative</i>	0,05
<i>User Plane Downlink Average Delay</i>	<i>Negative</i>	100 (ms)
<i>Downlink 64QAM Coding Rate</i>	<i>Negative</i>	0,12
<i>MAC Layer Downlink Error Block Rate</i>	<i>Positive</i>	0,003

Penelitian yang kedua adalah penerapan metode *machine learning neural network* untuk mengoptimalkan biaya operasional jaringan fiber optik di operator telekomunikasi (Rahouma, 2019). Penelitian ini bertujuan untuk memaksimalkan *Return of Investment* (ROI) pada operator seluler. Dalam penelitian ini diusulkan *Intelligent Universal Platform* (IUF) untuk mengelola dan mengoptimalkan tugas operasional di jaringan optik. *Platform* yang diusulkan mendorong pengawasan

jaringan ke otomatisasi, dan dibentuk oleh integrasi antara empat model, yang pertama adalah model energi dan dibangun sesuai dengan variasi konsumsi daya dan mengusulkan tindakan yang disarankan untuk mengoptimalkan konsumsi energi dengan menukar sistem pendingin antara dua jenis sistem (AC dan unit kipas) sesuai dengan tingkat suhu, sistem model juga belajar dari variasi keadaan modul perangkat apakah lagi digunakan saat *busy* atau *idle* dan ketika modul tidak digunakan perangkat berubah ke-*sleeping mode*. Model ke-2 adalah lokalisasi kesalahan dan dibangun oleh eksperimen praktis dari pemulihan kesalahan dan membentuk sistem pakar (*expert system*) untuk memprediksi *mean time to repair* (MTTR). Model ke-3 adalah kinerja jaringan dan dibangun dengan memonitor KPI *optical signal to noise ratio* (OSNR) dan memberikan tindakan korektif yang direkomendasikan untuk menjaga tingkat kinerja yang sama. Model ke-4 adalah manajemen konfigurasi dan menyarankan rute terbaik di jaringan. Hasil dari penelitian variabel *fault location time* berkurang dari 40 menit ke 3 menit, upaya untuk membuat satu sirkuit berkurang 30,87%, jumlah keluhan berkurang 30 % per tahun, dan waktu respons terhadap keluhan berkurang dari 55 menit menjadi 5 menit.



Gambar 2.9 Sistem jaringan fiber optik

Sumber (Rahouma, 2019)

	Fault location time	MTTR	# of lines / year	# of complaints / year	Completed projects in 2019
As-Is	40 min	120 min	234	3559	55 min
To-Be	3 min	83 min	339	2491	5 min

Gambar 2.10 Hasil penggunaan AI dalam jaringan fiber optik

Sumber (Rahouma, 2019)



Penelitian yang ketiga adalah jurnal yang berjudul *PCI and RSI Conflict Detection in a Real LTE Network Using Supervised Learning*. Penelitian ini menguji dua hipotesis mengenai seberapa baik dua masalah jaringan Jangka Panjang Evolusi (LTE) yang berbeda dapat dideteksi melalui *supervised techniques* dengan kinerja mendekati waktu nyata. Masalah jaringan yang diuji adalah *PCI Conflict* dan *root-sequence-index (RSI) collisions*. Hasil yang diperoleh menunjukkan bahwa kedua masalah paling baik dideteksi dengan menggunakan pengukuran *Key Performance Indicator (KPI)* sebagai fitur individual. Ketika terjadi masalah *PCI Conflict* dan *RSI collision*, performansi jaringan seperti *handover success rate* dan *channel interference* akan mengalami degradasi sehingga menyebabkan kualitas jaringan menjadi memburuk. Metode *machine learning* yang digunakan antara, *Extremely Randomized Trees (ERT)*, *Random forest (RF)*, *Adaptive Boosting (AB)*, *Support Vector Machines (SVM)* sedangkan KPI yang digunakan untuk mendeteksi problem ini adalah *UL PUCCH Interference*, *Random Success Rate*, *Handover Success Rate*, dan *Service Drop Rate*.

Tabel 2.6 Hasil klasifikasi *PCI confusion*. Sumber (Verissimo, 2018)

Metode	Accuracy	
	800 Mhz Band	1800 Mhz Band
ERT	85,37%	93,57%
RF	85,63%	93,60%
SVM	85,63%	93,54%
AB	85,73%	93,54%

Tabel 2.7 Hasil klasifikasi *RSI Collision*. Sumber (Verissimo, 2018)

Metode	Accuracy	
	800 Mhz Band	1800 Mhz Band
ERT	59,49%	59,83%
RF	61,70%	65,55%
SVM	60,07%	59,25%
AB	64,73%	69,99%

Pada Tabel 2.8 merupakan jurnal dan penelitian lain yang dijadikan kajian dalam penyusunan penelitian ini:

Tabel 2.8 Penelitian yang digunakan sebagai referensi

No	Penulis	Judul Jurnal	Tahun	Deskripsi	Metode <i>Machine Learning</i>
1	(Jain, 2019)	<i>Churn Prediction in Telecommunication using Logistic Regression and Logit Boost</i>	2019	Dalam penelitian ini penulis memprediksi <i>churn rate</i> pelanggan pada pelanggan operator <i>American Orange</i>	<i>Logistic Regression and Logit Boost</i>
2	(Rozenblit, 2018)	<i>Machine learning methods for SIR prediction in cellular networks</i>	2018	Bagaimana memprediksi SIR ( <i>signal interference ratio</i> ) dan menghasilkan <i>coverage map</i> . model ini dapat dianggap kandidat yang menjanjikan untuk mempelajari peta cakupan/ <i>coverage map</i> , dan dapat digunakan untuk manajemen spektrum yang efisien dalam kerangka jaringan seluler 5G	<i>Multi-Layer Perceptron ANN and K-Nearest</i>
3	(Zhang, 2019)	<i>Machine Learning Based Alarm Analysis and Failure Forecast in Optical Networks</i>	2019	Dalam Penelitian ini penulis mengusulkan skema analisis alarm dan prediksi <i>failure device</i> menggunakan algoritma <i>machine learning</i>	<i>use the combined K-means and Back propagation neural network</i>

Tabel 2.9 Penelitian yang digunakan sebagai referensi (lanjutan)

4	(Liu, 2019)	<i>Predicting malfunction of mobile network base station using machine learning approach</i>	2019	Penelitian ini menggunakan <i>machine learning</i> untuk memprediksi terjadinya kerusakan <i>Base stasion</i> dengan menggunakan data <i>alarm</i> dari BTS. Penelitian ini bertujuan agar segera dilakukan penanganan segera mungkin jika terjadi indikasi kerusakan pada BTS	DNN, <i>Random forest</i> , GDBT, dan SVM
5	(Singh, 2015)	<i>Performance Analysis of Unsupervised Machine Learning Techniques for network Traffic Classification</i>	2015	Penelitian ini menggunakan <i>unsupervised Machine Learning</i> untuk mengklasifikasikan trafik jaringan.	K-Mean dan EM
6	(Chen, 2017)	<i>The Exploration of Machine Learning for Abnormal Prediction Model of Telecom Business Support System</i>	2017	Penelitian ini memberikan metode alternatif yaitu menggunakan <i>machine learning</i> dalam memonitor kinerja BSS ( <i>Business Support System</i> ) <i>telecom operator</i> . BSS digunakan untuk proses <i>billing</i> dan <i>charging</i> dalam industri telekomunikasi	ANN, SVM, <i>Random forest</i> , RBF

Tabel 2.10 Penelitian yang digunakan sebagai referensi (lanjutan)

7	(Kwon, 2018)	<i>Machine Learning-Based Beamforming in Two-User MISO Interference Channels</i>	2018	Peneliti mengusulkan <i>machine learning</i> mengambil daya pancar dan vektor saluran sebagai input dan kemudian merekomendasikan dua pilihan pengguna antara MRT dan ZF.	<i>deep neural network</i> (DNN)
8	(Cheng, 2019)	<i>Machine Learning for Regenerator Placement Based on the Features of the Optical Network</i>	2019	Penelitian ini menggunakan metode <i>machine learning</i> untuk memprediksi alokasi generator secara akurat dalam <i>Elastic Optical Networks (EONs)</i>	ANN
9	(Wu, 2018)	<i>Link Congestion Prediction using Machine Learning for Software-Defined-Network Data Plane</i>	2018	Penelitian ini menyajikan metode <i>machine learning</i> untuk mengurangi <i>link congestion</i> pada <i>Software-Defined Network (SDN)</i> . Data <i>switch</i> dan <i>link</i> dari sistem SDN digunakan sebagai data <i>training</i> .	ANN, SVM, k-Nearest Neighbor (k-NN)

Tabel 2.11 Penelitian yang digunakan sebagai referensi (lanjutan)

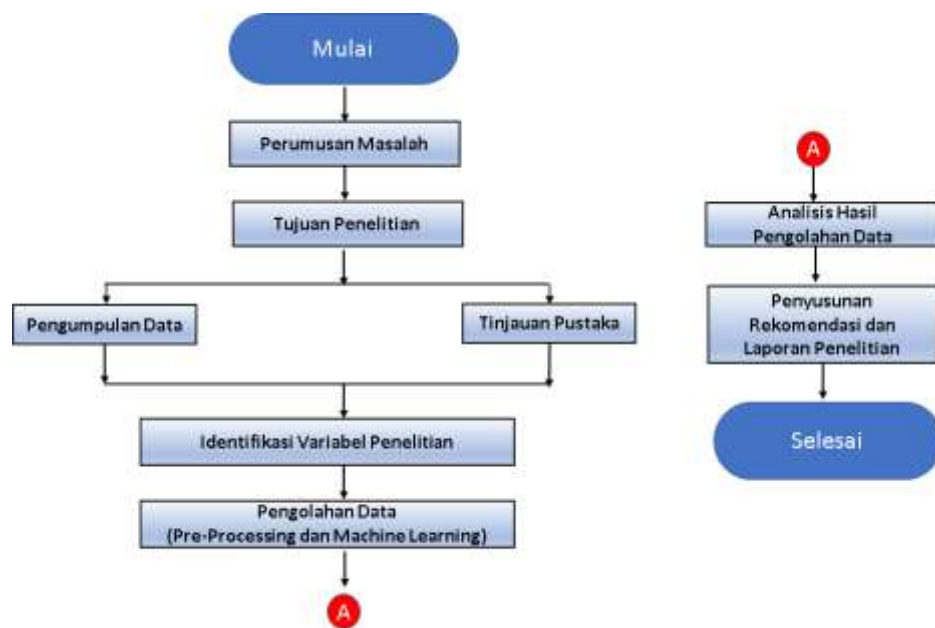
10	(Kumar, 2018)	<i>QoS Aware Load Balancing in Cognitive Wireless Sensor Networks using Machine Learning Concepts</i>	2018	Dalam Penelitian ini metode <i>machine learning</i> digunakan untuk meningkatkan <i>end-to-end throughput</i> dalam Cognitive Wireless Sensor Network	<i>Naive Bayes</i>
11	(Lu, 2019)	<i>Semi-supervised Machine Learning Aided Anomaly Detection Method in Cellular Networks</i>	2019	Dalam Penelitian ini, metode <i>machine learning</i> digunakan untuk mendeteksi <i>quality of experienced (QoE)</i> dalam jaringan seluler. metode yang diusulkan adalah <i>Key Quality Indicator (KQI)-based-QoE</i>	<i>one-class support vector machine (OCSVM)</i>

**[ Halaman ini sengaja dikosongkan ]**

## BAB 3

### METODOLOGI PENELITIAN

Dalam bab ini akan dibahas langkah dan prosedur yang dilakukan untuk mencapai tujuan dan mendapatkan jawaban atas perumusan masalah dalam penelitian. Tahap yang dilakukan dalam metodologi penelitian ini ditunjukkan pada Gambar 3.1.



Gambar 3.1 Tahapan Penelitian

#### 3.1 Perumusan Masalah dan Tujuan Penelitian

Pada tahap ini, penulis merumuskan masalah yang menjadi latar belakang penelitian ini. Permasalahan yang diangkat dalam penelitian ini adalah mengidentifikasi faktor-faktor yang mempengaruhi penetrasi penggunaan modulasi 64QAM pada jaringan LTE, kemudian membuat prosedur optimasi jaringan LTE (*CQI Improvement Flow diagram*) yang dapat digunakan untuk referensi operator atau internal perusahaan.

Telah dijelaskan pada bab 1 bahwa penelitian ini bertujuan mengoptimalkan biaya investasi yang dikeluarkan oleh operator telekomunikasi dalam meningkatkan kualitas jaringan LTE sehingga bisa memaksimalkan *Return of*

*investment* (ROI). Penambahan BTS yang memerlukan *capital expenditure* (CAPEX) yang sangat besar akan dilakukan ketika proses optimasi jaringan sudah maksimal dan tidak ada peningkatan dalam hal kualitas jaringan. Pembelian *features* LTE juga diprioritaskan hanya terhadap variabel-variabel yang berpengaruh secara signifikan sehingga biaya yang dikeluarkan oleh operator telekomunikasi menjadi lebih efektif dan efisien.

### **3.2. Studi Pustaka**

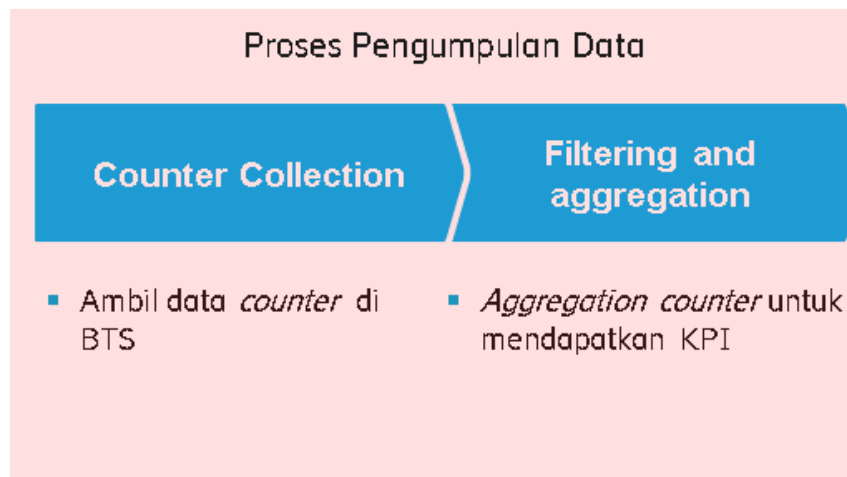
Pada tahap ini setelah merumuskan masalah dan tujuan penelitian, penulis melakukan kajian yang berkaitan dengan topik penelitian. Studi literatur mengenai kepustakaan terkait dengan penelitian bersumber dari jurnal internasional, buku, dokumen *Counter/Key Performance Indicator* Jaringan 4G/LTE salah satu vendor telekomunikasi di Indonesia serta penelitian-penelitian sebelumnya yang relevan dengan penelitian yang dilakukan.

Penulis juga melakukan studi Pustaka dengan melakukan pemahaman lebih lanjut terhadap klasifikasi dalam data *mining* (*machine learning*). Metode *machine learning* klasifikasi yang dipelajari dan digunakan dalam penelitian ini adalah *Random forest*.

### **3.3. Pengumpulan Data**

Sumber data yang digunakan dalam penelitian ini adalah data primer. Sumber data penelitian ini diambil melalui *Operating Support System* (OSS), proses yang dilakukan adalah pengambilan *counter* dari BTS kemudian melakukan proses perhitungan atau *counter aggregation* yang diolah menggunakan *query mysql* dengan memasukan formula - formula yang dibutuhkan sehingga menjadi nilai KPI. Proses pengumpulan data sampai proses rekomendasi dapat dilihat pada Gambar 3.2.

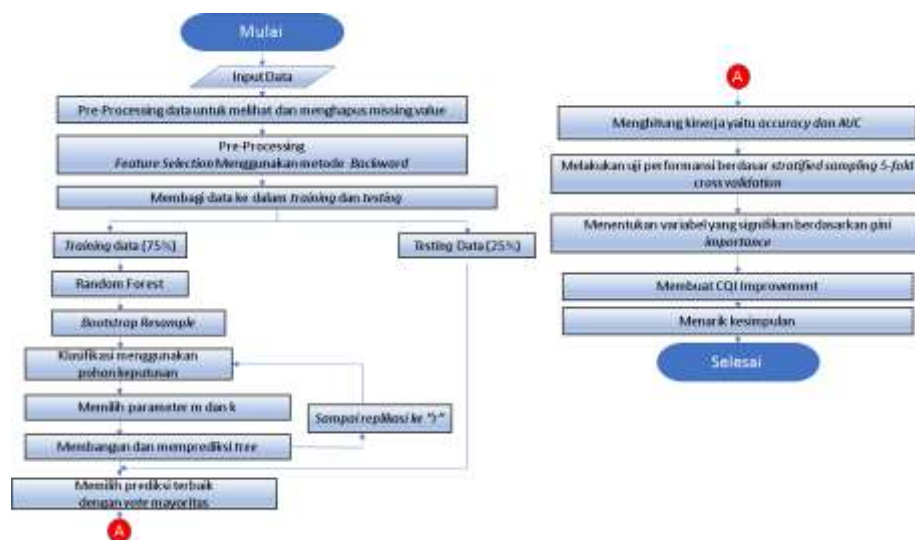




Gambar 3.2 *Network Analytics Process Step*

### 3.4. Pengolahan Data

Setelah didapatkan data untuk kebutuhan penelitian, ada beberapa tahapan dalam pengolahan data yang ditunjukkan pada Gambar 3.3.



Gambar 3.3 Flowchart Tahapan Pengolahan Data

Dalam Teknik *data mining*, yang pertama kali dilakukan sebelum mengolah data adalah melakukan *pre-processing* data. Tahapan pertama yang dilakukan adalah menangani *missing value*. Dalam penelitian ini, untuk variabel dengan *missing value* akan dihapus dari penelitian. Jumlah variabel prediktor yang ada pada

data ini adalah 106. Tahapan yang selanjutnya adalah melakukan seleksi fitur (*feature selection*) untuk memilih variabel prediktor (X) yang digunakan. *Feature selection* dilakukan dengan tujuan untuk mengetahui apakah antara variabel independen terjadi multikolinieritas. Metode yang digunakan dalam memilih variabel prediktor (*Feature Selection*) adalah menggunakan *Backward Elimination*. Metode *backward* merupakan langkah mundur, semua variabel X diregresikan dengan variabel CQI. Pengeliminasian variabel X didasarkan pada nilai  $F_{(parsial)}$  terkecil dan turut tidaknya variabel X pada model juga ditentukan oleh nilai  $F_{(tabel)}$ .

Tabel 3.1 Jumlah Variabel Prediktor Setelah Dilakukan Seleksi Fitur

<b><i>Feature Selection</i></b>		
	Jumlah variabel prediktor (X) sebelum seleksi fitur	Jumlah variabel prediktor (X) sesudah seleksi fitur
Variabel Prediktor (X)	106	77

Jumlah variabel prediktor setelah dilakukan *feature selection* turun dari 106 variabel menjadi 77 variabel seperti ditunjukkan pada Tabel 3.1. Pada Tabel 3.2 ditunjukkan variabel y dan variabel prediktor X yang akan digunakan pada penelitian ini.

Tabel 3.2 Variabel Penelitian Setelah dilakukan seleksi fitur

No	KPI	Variabel	Tipe Data	Keterangan
1	Modulasi	y	Ordinal	DiGunakan untuk klasifikasi: 1=QPSK 2=16QAM 3=64QAM
2	SE_3	X1	Scale/interval	
3	Max_RRC_Connected_User	X2	Scale/interval	
4	Max_RRC_Connected_User_Mhz	X3	Scale/interval	
5	Average_RRC_Connected_User_Mhz	X4	Scale/interval	
6	Max_Active_User	X5	Scale/interval	
7	Average_Active_User_Mhz	X6	Scale/interval	
8	MIMO	X7	Scale/interval	
9	_80_PL_85_	X8	Scale/interval	
10	_85_PL_90_	X9	Scale/interval	

Tabel 3.3 Variabel Penelitian Setelah dilakukan seleksi fitur (lanjutan)

11	_90_PL_95_	X10	Scale/interval	
12	_95_PL_100_	X11	Scale/interval	
13	_100_PL_105_	X12	Scale/interval	
14	_105_PL_110_	X13	Scale/interval	
15	_110_PL_115_	X14	Scale/interval	
16	_115_PL_120_	X15	Scale/interval	
17	_120_PL_125_	X16	Scale/interval	
18	_125_PL_130_	X17	Scale/interval	
19	_130_PL_135_	X18	Scale/interval	
20	_135_PL_140_	X19	Scale/interval	
21	_140_PL_145_	X20	Scale/interval	
22	_145_PL_	X21	Scale/interval	
23	PDCCH_CCE_Aggregation_8_	X22	Scale/interval	
24	cell_availability	X23	Scale/interval	
25	sssr	X24	Scale/interval	
26	s1_conn_est_success_rate	X25	Scale/interval	
27	sarr	X26	Scale/interval	
28	ul_packet_loss_rate	X27	Scale/interval	
29	dl_uu_latency	X28	Scale/interval	
30	ul_prb_utilization	X29	Scale/interval	
31	pmrrconmax	X30	Scale/interval	
32	rrc_connected_users	X31	Scale/interval	
33	dl_volume_gb	X32	Scale/interval	
34	ul_volume_gb	X33	Scale/interval	
35	cbra_success_rate	X34	Scale/interval	
36	cfra_success_rate	X35	Scale/interval	
37	rrc_setup_success_rate	X36	Scale/interval	
38	erab_setup_success_rate	X37	Scale/interval	
39	lte_csfb_activity	X38	Scale/interval	
40	lte_csfb_volume	X39	Scale/interval	
41	lte_csfb_act_rate	X40	Scale/interval	
42	csfb_sr	X41	Scale/interval	
43	lte_active_user_dl	X42	Scale/interval	
44	lte_active_user_ul	X43	Scale/interval	
45	pmrrconnectabsucc	X44	Scale/interval	
46	pmrrconnectabattreatt	X45	Scale/interval	
47	pmslsgconnectabsucc	X46	Scale/interval	
48	pmerabestabattinit	X47	Scale/interval	
49	pmerabrelabnormalenbact	X48	Scale/interval	
50	pmerabrelabnormalenb	X49	Scale/interval	
51	pmerabrelnormalenb	X50	Scale/interval	
52	pmerabrelmme	X51	Scale/interval	
53	pmpdcppktdiscldlpeleuu	X52	Scale/interval	
54	pmpdcppkttransdl	X53	Scale/interval	
55	pmpdcplattimedl	X54	Scale/interval	
56	pmpdcplatpkttransdl	X55	Scale/interval	
57	pmprbuseduldtch	X56	Scale/interval	
58	pmpdcpvoldlrb	X57	Scale/interval	
59	pmuethptimedl	X58	Scale/interval	
60	pmuethpvolut	X59	Scale/interval	

Tabel 3.4 Variabel Penelitian Setelah dilakukan seleksi fitur (lanjutan)

61	pmrrconnlevsum	X60	Scale/interval	
62	pmrrconnlevsmp	X61	Scale/interval	
63	pmpdcpvoluldrb	X62	Scale/interval	
64	pmschedactivitycellul	X63	Scale/interval	
65	pmpdcpvoldlsrb	X64	Scale/interval	
66	pmrasucccbra	X65	Scale/interval	
67	pmrasucccfra	X66	Scale/interval	
68	pmraattcfra	X67	Scale/interval	
69	pmpdcpvoldlrbca	X68	Scale/interval	
70	pmpdcpvoldlrbblasttica	X69	Scale/interval	
71	pmradiothpvoldlscellext	X70	Scale/interval	
72	pmuethptimeulca	X71	Scale/interval	
73	pmuextxtrelscwcdma	X72	Scale/interval	
74	pmcriticalborderevalreport	X73	Scale/interval	
75	pmactiveueulsum	X74	Scale/interval	
76	sinr_pusch	X75	Scale/interval	
77	sinr_pucch	X76	Scale/interval	
78	hosr_intraf	X77	Scale/interval	

Adapun tahap setelah dilakukan *pre-processing* adalah sebagai berikut:

1. Menerapkan algoritma *random forest* pada data penelitian. Klasifikasi yang digunakan pada penelitian ini ada tiga kelas yaitu 1=QPSK, 2=16QAM, 3=64QAM dengan jumlah proporsi yang digunakan adalah 75% untuk data *training*, 25% data *testing*. Proporsi *splitting dataset training* dan *dataset testing* berdasarkan (Dolev, et al., 2020), (Lesmeister, 2015), (Reitermanova, 2010), dan (Esfandyari, et al., 2016). Jumlah k yaitu jumlah pohon yang digunakan dalam penelitian ini adalah 100.
2. Membentuk *confussion matrix* dan menghitung kinerja metode klasifikasi berdasarkan nilai *accuracy* dan AUC.
3. Melakukan uji performansi berdasar *stratified sampling 5-fold cross validation*.
4. Menentukan variabel yang signifikan berdasarkan *gini importance*.
5. Membuat *CQI Improvement Flow* berdasarkan hasil variabel didapatkan dari klasifikasi *random forest*.
6. Menarik kesimpulan.

### **3.5. Rekomendasi dan Penyusunan Laporan Penelitian**

Dalam tahap ini akan dilakukan analisis terhadap hasil prediksi dari klasifikasi *random forest*. Hasil analisis akan menunjukkan variabel-variabel/*feature* yang mempengaruhi penetrasi penggunaan modulasi 64QAM dan akan digunakan sebagai landasan dalam pembuatan rekomendasi yaitu berupa prosedur optimasi jaringan LTE dan kesimpulan dari penelitian yang dilakukan. Simpulan ini akan menjawab rumusan-rumusan masalah yang telah ditentukan pada awal penelitian.

Penyusunan laporan dilakukan agar semua langkah yang telah dilakukan dapat terdokumentasi dengan baik sehingga dapat memberikan informasi yang bermanfaat bagi pembacanya dan akan juga akan disampaikan hal-hal apa saja yang disarankan oleh penulis untuk pengembangan terhadap penelitian ini di masa datang.

**[ Halaman ini sengaja dikosongkan ]**

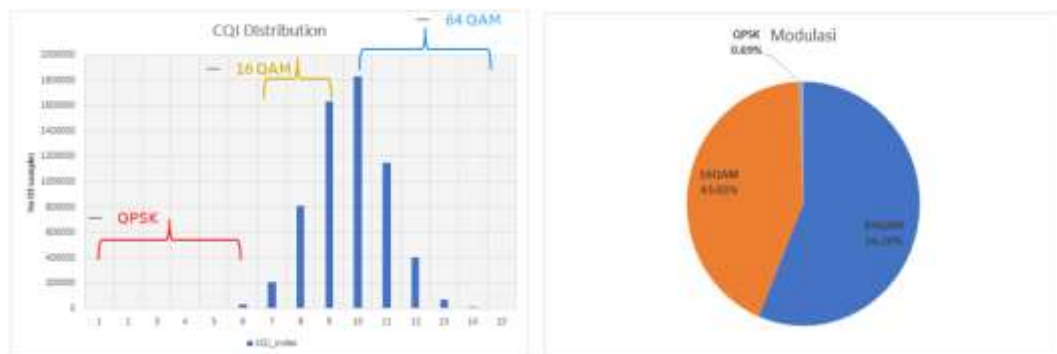
## BAB 4

### HASIL DAN PEMBAHASAN

Pada Bab ini dijelaskan mengenai hasil dan pembahasan berdasarkan dari rumusan masalah dan tujuan penelitian yang telah dibahas pada bab 1 meliputi hasil analisis variabel-variabel yang mempengaruhi penetrasi penggunaan modulasi 64QAM berdasarkan metode *random forest*. Data yang digunakan dalam penelitian ini merupakan data dengan *large* observasi yaitu sebanyak 647,580.

#### 4.1 Karakteristik Data CQI dan Modulasi

Berdasarkan Gambar 4.1 terlihat bawah penetrasi penggunaan modulasi pada operator seluler X untuk modulasi QPSK sebesar 0.69%, modulasi 16QAM sebesar 43.05% dan 64QAM sebesar 56.26% sedangkan nilai CQI didominasi nilai 9 dan 10. Hal ini menunjukkan bawah kualitas jaringan radio LTE/4G pada operator ini cukup bagus.



Gambar 4.1 Data CQI dan Modulasi operator X

#### 4.2 Analisis Klasifikasi Modulasi dengan Metode *Random forest*

Seperti yang telah dijelaskan pada bab 3.4, Pembentukan model dilakukan dengan membagi data menjadi data *training* dan data *testing* dengan jumlah proporsi yang digunakan adalah 75% untuk data *training*, 25% data *testing*. Berikut adalah hasil *confusion matrix* menggunakan *random forest*.

Tabel 4.1 *Confussion Matrix* Klasifikasi *Random Forest*

	Prediction Class			Total
	1(QPSK)	2(16QAM)	3(64QAM)	
Actual Class				
1(QPSK)	949	929	3	1881
2(16QAM)	39	72502	5834	78375
3(64QAM)	0	5768	75871	81639
Total	988	79199	81708	

Tabel 4.1 menyajikan *confusion matrix* untuk metode *Random forest*, dari tabel tersebut dapat dihitung nilai kinerja akurasi, presisi dan *recall* seperti ditunjukkan pada Tabel 4.2. Nilai AUC didapatkan tiap kelas dan AUC *micro average*.

Tabel 4.2 Performansi Klasifikasi *Random Forest*

Accuracy	92,23%			
Class	Precision	Recall	F-Value	AUC
1(QPSK)	96,05%	50,45%	66,16%	0,994
2(16QAM)	91,54%	92,51%	92,02%	0,979
3(64QAM)	92,86%	92,86%	92,86%	0,982
Micro Avg	92,23%	92,23%	92,23%	0,981

Dalam penelitian ini melibatkan pengujian performansi berdasar *stratified sampling* yaitu *sampling* dengan cara membangun himpunan bagian acak dan memastikan bahwa distribusi kelas di subset sama dengan keseluruhan dataset. Sehingga setiap subset mengandung kira-kira proporsi yang sama dari dua nilai label kelas. Sesuai jumlah *k-fold* yang diinputkan dalam penelitian ini menggunakan *5-fold* tes. Berikut ini hasil yang sudah dilakukan.

Tabel 4.3 Hasil Prosentase Uji Performa *Stratified Sampling*

Fold-ke	Accuracy	AUC (micro)
1	92,29%	0,981
2	92,18%	0,981
3	91,91%	0,979
4	92,03%	0,98
5	87,97%	0,957
Rata-rata	91,28%	0,976



Berdasarkan Tabel 4.3 dapat diketahui nilai rata-rata akurasi adalah 91,28% dan AUC 0,976. Model yang dihasilkan sangat bagus karena nilai  $AUC \geq 0,9$ .


Dalam penelitian ini diperlukan untuk mengetahui variabel yang berpengaruh secara signifikan terhadap penetrasi penggunaan modulasi 64QAM. Berikut ini *feature importance* yang didapatkan berdasarkan hasil klasifikasi *random forest*.

Tabel 4.4 Nilai *Gini Importance* Variabel Prediktor

No	Variabel	Gini Importance
1	MIMO	0.1831
2	PDCCH_CCE_Aggregation_8_	0.1106
3	SE_3	0.0775
4	sinr_pusch	0.0629
5	sinr_pucch	0.0375
6	_125__PL__130_	0.0265
7	_130__PL__135_	0.0250
8	DL_PRB_Utilization_	0.0200
9	_135__PL__140_	0.0132
10	lte_active_user_dl	0.0107
11	pmrasucccfra	0.0106
12	Average_Active_User	0.0105
13	dl_uu_latency	0.0104
14	pmrrcconnestabattreatt	0.0103
15	_145__PL_	0.0101
16	pmraattcfra	0.0098
17	ul_packet_loss_rate	0.0097
18	pmprbusedulditch	0.0092
19	pmactiveueulsum	0.0091
20	dl_packet_loss_rate	0.0089
21	pmschedactivitycellul	0.0089
22	lte_active_user_ul	0.0089
23	pmerabrelabnormalenb	0.0086
24	pmerabrelabnormalenbact	0.0082
25	_95__PL__100_	0.0081
26	pmpdcpvoldlrbblasttica	0.0081
27	pmuethptimedlca	0.0080
28	Average_RRC_Connected_User_Mhz	0.0079
29	_115__PL__120_	0.0077
30	pmpdcpvoldlrb	0.0077
31	_100__PL__105_	0.0070
32	pmpdcpktrandsdl	0.0069
33	_140__PL__145_	0.0068
34	_105__PL__110_	0.0066
35	Pmrasucccbra	0.0064

Tabel 4.4 Nilai *Gini Importance* Variabel Prediktor (lanjutan)

36	_90_PL_95_	0.0064
37	_120_PL_125_	0.0064
38	pmpdcplattimedl	0.0064
39	_110_PL_115_	0.0063
40	Max_Active_User_Mhz	0.0063
41	cfra_success_rate	0.0063
42	pmraattcbra	0.0062
43	pmcriticalborderevalreport	0.0062
44	pmrrconnlevsum	0.0062
45	rrc_connected_users	0.0060
46	pmrrconnestabatt	0.0060
47	rrc_setup_success_rate	0.0060
48	ul_prb_utilization	0.0060
49	pmpdcpvoluldrb	0.0058
50	lte_csfb_volume	0.0058
51	pmpdcpptreceivedul	0.0058
52	_85_PL_90_	0.0057
53	cbra_success_rate	0.0057
54	pmslsigconnestabatt	0.0057
55	_80_PL_85_	0.0056
56	sarr	0.0055
57	Max_RRC_Connected_User_Mhz	0.0055
58	lte_csfb_activity	0.0055
59	lte_csfb_act_rate	0.0055
60	pmerabestabattinit	0.0054
61	pmrrconnestabsucc	0.0054
62	pmpdcpvoldlrbca	0.0054
63	pmerabrelmme	0.0053
64	erab_setup_success_rate	0.0052
65	hosr_intraf	0.0052
66	ul_volume_gb	0.0052
67	pmpdcpktdiscldlpruu	0.0050
68	sssr	0.0046
69	Max_Active_User	0.0044
70	pmuethpvolul	0.0043
71	pmuextxtrelscwcdma	0.0042
72	Max_RRC_Connected_User	0.0040
73	pmrrconnmax	0.0038
74	s1_conn_est_success_rate	0.0031
75	cell_availability	0.0021
76	pmrrconnlevsamp	0.0020
77	csfb_sr	0.0016



Gambar 4.2 *Feature Important* yang berpengaruh terhadap modulasi

Berdasarkan Tabel 4.4 dan Gambar 4.2, ada dua variabel yang berpengaruh secara signifikan yaitu variabel MIMO (*Multiple Input Multiple Output*) dan PDCCH\_CCE\_Aggregation\_8. Dalam penelitian ini akan diprioritaskan 8 variabel yang mempunyai nilai *Gini Importance* tertinggi. Hal ini disebabkan:


1. Delapan variabel yang mempunyai *gini importance* tertinggi secara teori LTE juga sangat mendukung.
2. Dalam praktiknya, untuk mengimplementasi fitur LTE dibutuhkan beberapa orang *engineer* dan juga membutuhkan *lock* BTS selama 5-8 menit sehingga akan mempunyai resiko sangat besar jika BTS menjadi *down* akibat perubahan banyak variabel/fitur.
3. Monitor performansi perlu dilakukan secara bertahap untuk mengetahui fitur yang diimplementasikan benar-benar terbukti meningkatkan kualitas jaringan.

KPI/Variabel yang mempunyai nilai *gini importance* tertinggi adalah MIMO. KPI ini mempunyai korelasi positif terhadap CQI seperti yang ditunjukkan pada Tabel 4.5. *Multiple Input Multiple Output* (MIMO) merupakan sistem yang memiliki banyak terminal (antenna) pengirim dan penerima. Pada Gambar 4.3 ditunjukkan skema sederhana suatu sistem komunikasi MIMO. *Fading* antara antena pemancar dan penerima dapat dianggap independent, sehingga probabilitas terdeteksinya informasi yang akurat akan lebih tinggi. *Fading* sinyal dapat

dikurangi dengan teknik *diversity* yang berbeda, dimana sinyal ditransmisikan melalui beberapa jalur *fading* yang independent dalam waktu, frekuensi atau ruang yang dikombinasikan secara konstruktif pada penerima. Pada lingkungan *multi path* dengan *fading* yang independent antara tiap pasangan antenna pemancar dan penerima, sistem MIMO memperoleh peningkatan kapasitas yang signifikan sehingga kinerja sistem menjadi lebih baik dibandingkan dengan sistem konvensional *Single Input Single Output* (SISO) dimana informasi yang sama dapat dikirim dan diterima dari beberapa antenna secara bersamaan.

Tabel 4.5 Nilai korelasi Pearson dan p-value

Variabel	p-value	Korelasi <i>Pearson</i>
MIMO	0,000	0,780
PDCCH_CCE_Aggregation_8_	0,000	-0,429
SE_3	0,000	0,148
sinr_pusch	0,000	0,562
sinr_pucch	0,000	0,339
_125_PL_130_	0,000	-0,404
_130_PL_135_	0,000	-0,446
DL_PRB_Utilization_	0,000	-0,322



Gambar 4.3 Konfigurasi MIMO 2 × 2

Konfigurasi MIMO 2 × 2 yang berarti ada 2 TX antenna pada BTS dan 2 RX antenna pada sisi UE (*User Equipment*) seperti digambarkan pada Gambar 4.3. Dari Gambar 4.3 didapatkan Persamaan *output* MIMO 2 × 2 sebagai berikut:

$$y_1 = h_{11}x_1 + h_{12}x_2 \quad (4.1)$$

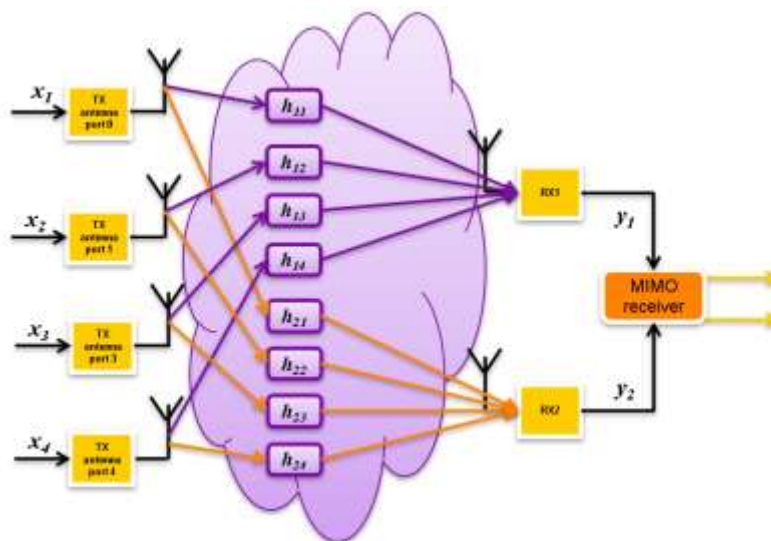
$$y_2 = h_{21}x_1 + h_{22}x_2 \quad (4.2)$$

dimana:  $h_{ij}$  adalah *wireless channel coefficients*

$x_i$  adalah *input data/sinyal* dari antenna 1 dan antenna 2 BTS

$y_i$  adalah *output* dari antenna 1 dan antenna 2 UE

Salah satu fitur dalam LTE yang bisa diuji coba dan diimplementasikan adalah MIMO  $4 \times 2$ , konfigurasi MIMO ini terdiri dari 4 TX antenna pada BTS dan 2 RX antenna pada UE seperti digambarkan pada Gambar 4.5. Konfigurasi ini membutuhkan pergantian antenna dan *radio unit* yang mendukung.



Gambar 4.4 Konfigurasi MIMO  $4 \times 2$

Dari Gambar 4.4 didapatkan Persamaan *output* MIMO  $4 \times 2$  sebagai berikut:

$$y_1 = h_{11}x_1 + h_{12}x_2 + h_{13}x_3 + h_{14}x_4 \quad (4.3)$$

$$y_2 = h_{21}x_1 + h_{22}x_2 + h_{23}x_3 + h_{24}x_4 \quad (4.4)$$

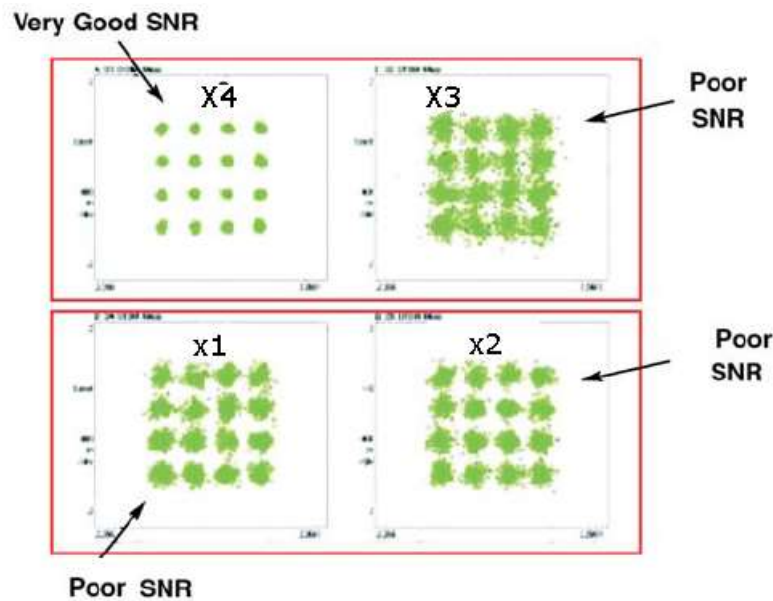
dimana:  $h_{ij}$  adalah *wireless channel coefficients*

$x_i$  adalah *input data/sinyal* dari antenna 1,2,3,4 dari BTS

$y_i$  adalah *output* dari antenna 1 dan antenna 2 UE

Pada Gambar 4.5, ketika fitur MIMO  $2 \times 2$  yang digunakan, maka semua SNR tiap antenna yaitu  $x_1$  dan  $x_2$  sangat buruk maka mengakibatkan CQI juga memburuk dan modulasi yang didapatkan adalah QPSK atau bahkan karena terlalu

buruk nilai SNR mengakibatkan terjadinya *packet drop/packet loss*. Ketika fitur MIMO  $4 \times 2$  digunakan, maka BTS akan memilih SNR yang terbaik yaitu antenna x4 (*diversity mode*) sehingga mengakibatkan CQI juga menjadi bagus dan modulasi 64QAM akan digunakan oleh UE.



Gambar 4.5 Nilai SNR tiap Antena MIMO  $4 \times 2$

Variabel yang kedua adalah PDCCH\_CCE\_Aggregation\_8. Variabel ini memiliki korelasi negatif terhadap CQI, semakin besar nilai KPI ini maka kualitas jaringan LTE akan memburuk. *Channel PDCCH* pada LTE digunakan membawa informasi *resource assignment* untuk kanal *uplink* dan *downlink*. Jika terjadi *PDCCH missed* maka *User Equipment* (UE) tidak dapat mengetahui apakah telah dijadwalkan oleh BTS dalam hal alokasi waktu dan frekuensi. Jika BTS menggunakan CCE\_8 (*Control Channel Element*) yang berarti BTS menggunakan sumber daya REG (*Resource Element Group*) yang besar. Hal ini mengindikasikan adanya interferensi pada PDCCH atau bisa juga mengindikasikan jarak BTS dan UE terlalu jauh (*Overshooting cell*) sehingga level sinyal yang diterima UE sangat rendah.

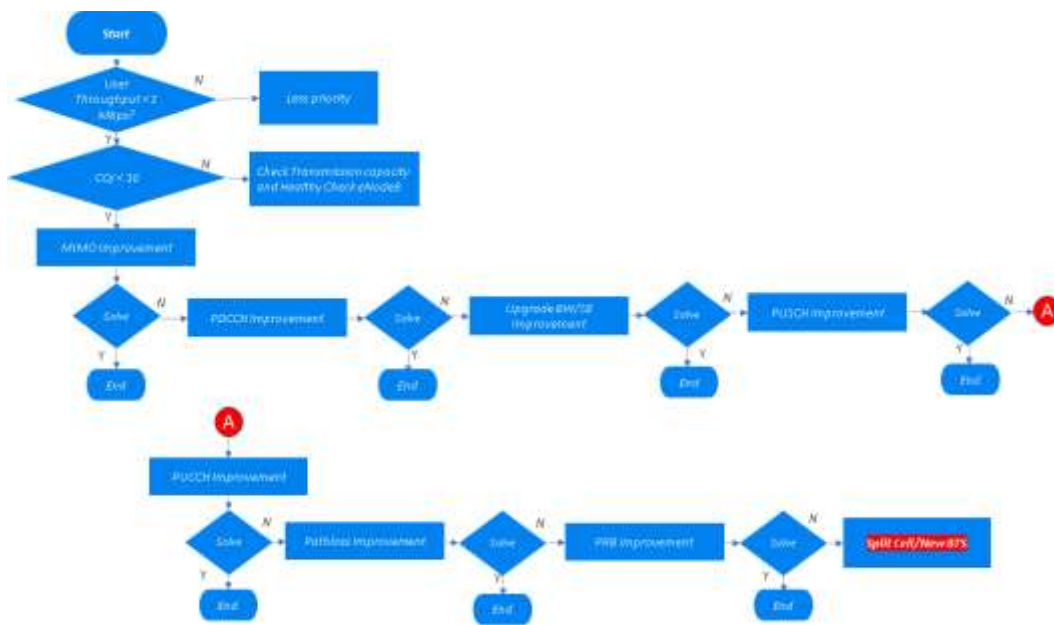
Penjelasan *importance* variabel yang lain dapat dilihat pada Tabel 4.6. Delapan variabel yang mempunyai nilai *gini importance* terbesar berdasarkan metode *random forest*, secara teori LTE juga bisa mempengaruhi nilai SNR/CQI (kualitas jaringan LTE).

Tabel 4.6 Penjelasan *Features Importance*

Variabel	Keterangan
SE_3	Spectral Efficiency berhubungan dengan penggunaan spektrum frekuensi dari operator. KPI ini berkolerasi positif terhadap CQI dan penggunaan Modulasi 64 QAM
sinr_pusch	KPI yang menunjukkan level kualitas jaringan di Kanal <i>Uplink</i> . <i>PUSCH</i> merupakan <i>uplink channel</i> yang akan membawa informasi CQI ke BTS jika UE melakukan aktivitas <i>download</i> dan <i>upload</i> secara bersamaan. KPI ini berkolerasi positif terhadap CQI dan penggunaan Modulasi 64 QAM
sinr_pucch	KPI yang menunjukkan level kualitas jaringan di Kanal <i>Uplink</i> . <i>PUSCH</i> merupakan <i>uplink channel</i> yang akan membawa informasi CQI ke BTS jika UE hanya melakukan aktivitas <i>download</i> . KPI ini berkolerasi positif terhadap CQI dan penggunaan Modulasi 64 QAM
_125__PL__130_	KPI ini menunjukkan <i>range pathloss</i> antara 125 dB-130 dB yang diukur dari BTS ke UE. KPI ini berkolerasi negatif terhadap CQI dan penggunaan Modulasi 64 QAM
_130__PL__135_	KPI ini menunjukkan <i>range pathloss</i> antara 130 dB - 135 dB yang diukur dari BTS ke UE. KPI ini berkolerasi negatif terhadap CQI dan penggunaan Modulasi 64 QAM
DL_PRB_Utilization_	KPI yang menunjukkan kapasitas <i>downlink Physical Resource Block</i> Dari BTS LTE. Semakin tinggi nilainya mengindikasikan penggunaan PRB di BTS sangat tinggi dan berkolerasi negatif terhadap CQI dan penggunaan Modulasi 64 QAM

### 4.3 Rekomendasi Peningkatan CQI (*CQI Improvement Flow*)

Untuk meningkatkan penetrasi penggunaan modulasi 64QAM perlu meningkatkan nilai CQI  $\geq 10$ . Peningkatan CQI dapat dilakukan melalui *regular optimization* dan pembelian fitur-fitur LTE akan tetapi dalam implementasinya peningkatan secara signifikan biasanya didapatkan setelah implementasi fitur-fitur LTE. Rekomendasi peningkatan CQI didapatkan dari hasil *feature importance* menggunakan *random forest* yang ditunjukkan pada Gambar 4.6.



Gambar 4.6 CQI Improvement Flow

Pada Tabel 4.7 ditunjukkan contoh rekomendasi *regular optimization* dan *LTE features* yang berhubungan dengan peningkatan variabel CQI.

Tabel 4.7 Contoh Optimasi Jaringan LTE dan LTE Features

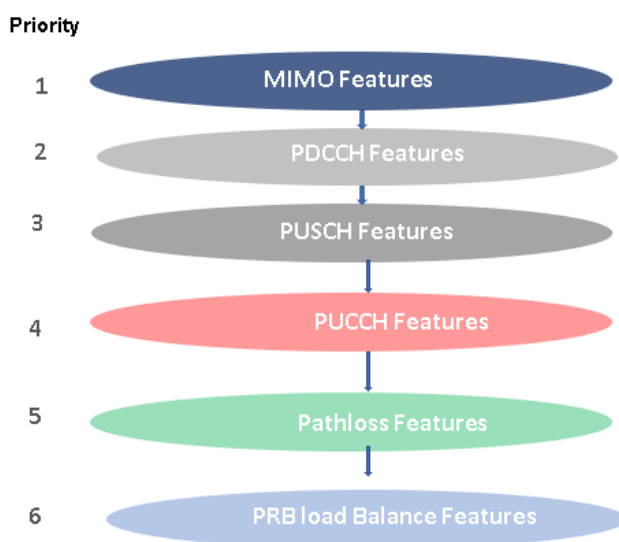
No	Variabel	Regular Optimization	LTE Features
1	MIMO	<ul style="list-style-type: none"> <li>- Check unbalance power</li> <li>- Physical Antenna Adjustment</li> <li>- Cross Partial Feeder Correction</li> <li>- parameter BTS yang berhubungan dengan MIMO</li> </ul>	<ul style="list-style-type: none"> <li>- Adaptive Closed MIMO</li> <li>- Fast MIMO Switching</li> <li>- MIMO 4 × 2, MIMO 4 × 4</li> </ul>
2	PDCCH_CCE_Aggregation_8_	<ul style="list-style-type: none"> <li>- Tuning PDCCH BTS Parameter Max Code PDDCH Rate, Initial Power PDCCH, dll</li> <li>- Physical Antenna Adjustment</li> </ul>	<ul style="list-style-type: none"> <li>- Adaptive PDCCH</li> <li>- PDCCH Link Adaptation</li> <li>- PDCCH Power Boosting,</li> </ul>
3	SE_3	Upgrade frequency Bandwidth (BW)	
4/5	sinr_pusch/sinr_pusch	<ul style="list-style-type: none"> <li>- Tuning Open Loop Power Control Parameter BTS</li> <li>- Physical Antenna Adjusment</li> </ul>	<ul style="list-style-type: none"> <li>- Closed Loop Uplink Power Control</li> <li>- Uplink selective Scheduling</li> <li>- IRC (Interference Rejection Combining)</li> <li>- 2T2R, 2T4R, dll</li> </ul>



Tabel 4.7 Contoh Optimasi Jaringan LTE dan LTE *Features* (lanjutan)

6/7	_125__PL__130_/_130__PL__135_	- <i>Physical Antenna Adjustment</i> - <i>VSWR Checking</i>	- <i>2T2R, 2T4R</i> - <i>TMA (A Tower Mounted Amplifier), dll</i>
8	DL_PRB_Utilization_	<i>Tuning Parameter yang berhubungan dengan penggunaan PRB seperti RGB Allocation, initial MCS, dll</i>	- <i>IFLB Extension Load Sharing</i> - <i>AMLE Load Balancing, dll</i>

Dua variabel yaitu MIMO dan PDCCH\_CCE\_Aggregation\_8 sebaiknya dijadikan prioritas pada operator X dalam melakukan optimasi jaringan dan pembelian LTE *features*. Prioritas fitur-fitur LTE yang dibeli oleh operator X baik untuk *software* BTS yang lama ataupun *software* BTS yang terbaru sebaiknya berdasarkan prioritas yang digambarkan seperti pada Gambar 4.7. Dalam implementasi fitur-fitur LTE diperlukan *resource* yaitu *engineer* untuk *performance monitoring* dan *engineer* untuk implementasi fitur sehingga perlu dilakukan bertahap dalam implementasinya.



Gambar 4.7 Prioritas Pembelian LTE *Features*

#### 4.4 Perbandingan Kinerja Klasifikasi dengan Penelitian Relevan

Pada Tabel 4.8 ditunjukkan perbandingan kinerja klasifikasi penelitian ini dengan penelitian yang lain/relevan. Hasil penelitian ini didapatkan kinerja klasifikasi yang baik yaitu didapatkan nilai akurasi 92,23% dan AUC 0,981.

Tabel 4.8 Perbandingan Kinerja Klasifikasi dengan Penelitian Lain

Penulis/Penelitian	Klasifikasi Data	Akurasi	AUC
Penelitian pada Tesis ini	Penetrasi Modulasi 64QAM	92,23%	0,981
(Verissimo, 2018)	<i>PCI confusion</i>	93,60% (1800 Mhz Band) 85,63% (800 Mhz Band)	
(Verissimo, 2018)	<i>RSI Collision</i>	65,55% (1800 Mhz Band) 61,70% (800 Mhz Band)	
(Liu, 2019)	<i>Malfunction of mobile network</i>	87,23%	0,843
(Jain, 2019)	<i>Churn Prediction</i>	85,24%	0,718
(Zhang, 2019)	<i>Failure Forecast in Optical Networks</i>	94%	
(Kwon, 2018)	<i>Two-User MISO Interference Channels</i>	89%	
(Wu, 2018)	<i>Link Congestion</i>	91,12%	0,971
(Kwon, 2018)	<i>Two-User MISO Interference Channels</i>	89%	

## **BAB 5**

### **KESIMPULAN DAN SARAN**

Dalam bab ini akan dijelaskan mengenai kesimpulan yang didapatkan dari hasil pembahasan serta saran yang diperlukan untuk pengembangan penelitian selanjutnya.

#### **5.1 Kesimpulan**

Kesimpulan yang didapatkan dari hasil analisis dan pembahasan yang telah dilakukan adalah sebagai berikut:

1. Model klasifikasi *Random forest* yang dihasilkan dan diuji menggunakan *Cross Validation* sangat baik karena memiliki nilai akurasi rata-rata 92,23 % dan nilai AUC rata-rata 0,981.
2. Dari hasil klasifikasi pada operator X didapatkan delapan variabel yang signifikan yaitu MIMO, PDCCH\_CCE\_Agg\_8, SE\_3, sinr\_pusch, sinr\_pucch, \_125\_\_PL\_\_130\_, \_130\_\_PL\_\_135\_, DL\_PRB\_Utilization dan dua variabel yaitu MIMO dan PDCCH\_CCE\_Agg\_8 mempunyai nilai *Gini Importance* tertinggi.
3. Tahap Penambahan BTS Baru/*Split Cell* untuk peningkatan kualitas jaringan LTE dilakukan setelah langkah-langkah proses optimasi jaringan dalam diagram *CQI improvement* sudah dilakukan dan tidak ada *improvement* dalam kualitas jaringan seluler.

#### **5.2 Saran**

Berdasarkan hasil penelitian yang telah dilakukan, saran yang diberikan untuk penelitian selanjutnya adalah sebagai berikut:

1. Teknologi LTE generasi sekarang ini hanya mendukung komunikasi data. Pada generasi yang akan datang, LTE akan mendukung koneksi data dan suara (*voice*), oleh karena itu perlu diteliti lagi faktor-faktor yang mempengaruhi penetrasi modulasi jaringan LTE (*quality*) akibat

adanya layanan data dan suara yang bisa digunakan secara bersamaan pada jaringan LTE.

2. Operator X disarankan membuat *regular optimization procedure system* yang bisa melakukan *discrepancy check* dan mengimplementasikan perubahan parameter secara *real time* terutama yang berhubungan dengan 8 variabel yang berpengaruh secara signifikan terhadap kualitas jaringan LTE.

## DAFTAR PUSTAKA

- 3GPP, 2019. UE procedure for reporting Channel State Information (CSI). In: 3GPP, ed. *3GPP TS36.213 V15.9.0 (2019-12)*. Sophia Antipolis Cedex: 3rd Generation Partnership Project (3GPP), p. 214.
- APJII, 2018. *Penetrasi & Profil Perilaku Pengguna Internet Indonesia*, Jakarta: APJII.
- Arvian, E., 2015. How Can The Indonesian Telecommunication Giant Persist Amid The Competition?. p. 24.
- Axiata, XL, 2019. *EXCL\_Annual\_Report\_2019*, Jakarta: XL Axiata.
- Berry, M. & Gordon, L., 2004. *Data Mining Techniques for Marketing, Sales, Customer, Relationship Management*. 2nd Edition ed. s.l.:Wiley Publishing Inc.
- Breiman, L., 2001. *Random forests*. California: University of California.
- Cheng, S., 2019. Machine Learning for Regenerator Placement Based on the Features of the Optical Network. *IEEE Access*, p. 2.
- Chen, J., 2017. The Exploration of Machine Learning for Abnormal Prediction Model of Telecom Business Support System. *IEEE Access*, p. 3.
- Couronné, R., 2018. Random forest versus logistic regression: a large-scale benchmark experiment. *BMC Bioinformatics*, p. 1.
- eríssimo, Vieira, Rodrigues & Queluz1, n.d. PCI and RSI Conflict Detection in a Real LTE Network Using Supervised Learning.
- Esfandyari, A., Zignani, M. & Gaito, S., 2016. User identification across online social networks in practice: Pitfalls and solutions. *SAGE Journals*, Volume 44, p. 11.
- Fan, G., 2019. Machine Learning Based Quantitative Association. *IEEE Access*, Volume 7, p. 6.
- Felix, J., 2019. Aplikasi Pohon pada Statistik dan Machine Learning.
- Gorunescu, 2011. *Data Mining Concept Model and Techniques*. Berlin: Springer. ISBN 978-3-642-19720-8.

- GSMA, 2019. *Asia Pacific, Q4 2019 5G adoption, service diversification and inter-governmental cooperation*, Los Angeles: GSMA.
- Han, J. & Kamber, M., 2006. *Data Mining: Concepts and Techniques*. 2nd ed. USA: Kaufman.
- Han & Kamber, 2006. *Data Mining Concept and Tehniques*. San Fransisco: Morgan.
- Jain, H., 2019. Churn Prediction in Telecommunication using Logistic Regression and Logit Boost. *IEEE Access*, p. 10.
- Jong, J., 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Yogyakarta: Penerbit ANDI.
- Khan, F., 2009. *LTE for 4G Mobile Broadband Air Interface Technologies and Performance*. 1st ed. New York: Cambridge University Press.
- Kumar, A., 2018. QoS Aware Load Balancing in Cognitive Wireless Sensor Networks using Machine Learning Concepts. *IEEE Access*, p. 3.
- Kwon, H., 2018. Machine Learning-Based Beamforming in Two-User MISO Interference Channels. *IEEE Access*, p. 3.
- Larose, 2005. *Discovering Knowledge in Data*. New Jersey: John Willey & Sons, Inc. ISBN 0-471-66657-2..
- Liu, Y., 2019. Predicting malfunction of mobile network base station using machine learning approach. *IEEE Access*, p. 3.
- Li, X., 2011. A Effective SINR Link to System Mapping Method for CQI Feedback in TD-LTE System. *IEEE Access*, p. 3.
- Lu, Y., 2019. Semi-supervised Machine Learning Aided Anomaly Detection Method in Cellular Networks. *IEEE Access*, p. 4.
- McCoy & Auret, n.d. Machine learning applications in minerals processing: A review.
- Miyazaki, N., 2010. MIMO-OFDM Throughput Performances on MIMO Antenna Configurations Using LTE-based Testbed with 100 MHz Bandwidth. *IEEE Access*, p. 4.
- Nokia Solution Network, 2014. *LTE Functionalities and Features Overview*, Helsinki: Nokia Solution Network.

- Purnomo & Kurniawan, 2006. *Supervised Neural Network dan Aplikasinya*. Yogyakarta: Graha Ilmu.
- Rahouma, K., 2019. Applying Machine Learning Technology to Optimize the Operational Cost of the Egyptian Optical Network. *IEEE Access*, p. 12.
- Reitermanova, 2010. Data Splitting. *Proceedings of Contributed Papers*, p. 35.
- Rifai, B., 2013. ALGORITMA NEURAL NETWORK UNTUK PREDIKSI PENYAKIT JANTUNG.
- Rokach, L. & Maimon, O., 2005. Decision Trees.
- Rozenblit, O., 2018. Machine learning methods for SIR prediction in cellular networks. *IEEE Access*, p. 5.
- Santoso, 2007. *Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis*. Yogyakarta: Graha Ilmu.
- Singh, H., 2015. Performance Analysis of Unsupervised Machine Learning Techniques for network Traffic Classification. *IEEE Access*, p. 3.
- Telkomsel, 2018. *Final-Telkomsel 2018 web-ver*, Jakarta: Telkomsel.
- Tufano, A., Accorsi, R. & Manzini, R., n.d. Machine learning methods to improve the operations of 3PL logistics.
- Varkentin, N., 2019. Features of Application of Machine Learning Methods for Classification of Network Traffic. *IEEE Access*, p. 3.
- Veríssimo, 2018. PCI and RSI Conflict Detection in a Real LTE Network Using Supervised Learning. *IEEE Access*, p. 7.
- Wu, J., 2018. Link Congestion Prediction using Machine Learning for Software-Defined-Network Data Plane. *IEEE Access*, p. 3.
- Yang, B., 2019. Research on Network Traffic Identification based on Machine Learning and Deep Packet Inspection. *IEEE Access*, p. 4.
- Zhang, M., 2019. Machine Learning Based Alarm Analysis and Failure Forecast in Optical Networks. *IEEE Access*, p. 2.

**[ Halaman ini sengaja dikosongkan ]**



## LAMPIRAN

**Lampiran 1. Data Variabel Prediktor Sebelum *Preprocessing***

No	KPI	Variabel	Tipe Data
1	Modulasi	y	Ordinal
2	SE_3	X1	Scale/interval
3	Max_RRC_Connected_User	X2	Scale/interval
4	Max_RRC_Connected_User_Mhz	X3	Scale/interval
5	Average_RRC_Connected_User	X4	Scale/interval
6	Average_RRC_Connected_User_Mhz	X5	Scale/interval
7	Max_Active_User	X6	Scale/interval
8	Max_Active_User_Mhz	X7	Scale/interval
9	Average_Active_User	X8	Scale/interval
10	Average_Active_User_Mhz	X9	Scale/interval
11	MIMO	X10	Scale/interval
12	Average_Pathloss_dB	X11	Scale/interval
13	_80__PL__85__	X12	Scale/interval
14	_85__PL__90__	X13	Scale/interval
15	_90__PL__95__	X14	Scale/interval
16	_95__PL__100__	X15	Scale/interval
17	_100__PL__105__	X16	Scale/interval
18	_105__PL__110__	X17	Scale/interval
19	_110__PL__115__	X18	Scale/interval
20	_115__PL__120__	X19	Scale/interval
21	_120__PL__125__	X20	Scale/interval
22	_125__PL__130__	X21	Scale/interval
23	_130__PL__135__	X22	Scale/interval
24	_135__PL__140__	X23	Scale/interval
25	_140__PL__145__	X24	Scale/interval
26	_145__PL__	X25	Scale/interval
27	PDCCH_CCE_Aggregation_8__	X26	Scale/interval
28	DL_PRB_Utilization__	X27	Scale/interval
29	cell_availability	X28	Scale/interval
30	sssr	X29	Scale/interval
31	s1_conn_est_success_rate	X30	Scale/interval
32	sarr	X31	Scale/interval
33	ul_packet_loss_rate	X32	Scale/interval
34	dl_packet_loss_rate	X33	Scale/interval
35	dl_uu_latency	X34	Scale/interval
36	dl_prb_utilization	X35	Scale/interval
37	ul_prb_utilization	X36	Scale/interval
38	pmrrcconmax	X37	Scale/interval
39	rrc_connected_users	X38	Scale/interval
40	dl_volume_gb	X39	Scale/interval
41	ul_volume_gb	X40	Scale/interval
42	cbra_success_rate	X41	Scale/interval
43	cfra_success_rate	X42	Scale/interval
44	rrc_setup_success_rate	X43	Scale/interval
45	erab_setup_success_rate	X44	Scale/interval
46	lte_csfb_activity	X45	Scale/interval
47	lte_csfb_volume	X46	Scale/interval

48	lte_csfb_act_rate	X47	Scale/interval
49	csfb_sr	X48	Scale/interval
50	lte_active_user_dl	X49	Scale/interval
51	lte_active_user_ul	X50	Scale/interval
52	pmrrcconnectabsucc	X51	Scale/interval
53	pmrrcconnectabatt	X52	Scale/interval
54	pmrrcconnectabattreatt	X53	Scale/interval
55	pms1sigconnectabsucc	X54	Scale/interval
56	pms1sigconnectabatt	X55	Scale/interval
57	pmerabestabsuccinit	X56	Scale/interval
58	pmerabestabattinit	X57	Scale/interval
59	pmerabrelabnormalenbact	X58	Scale/interval
60	pmerabrelabnormalmmeact	X59	Scale/interval
61	pmerabrelabnormalenb	X60	Scale/interval
62	pmerabrelnormalenb	X61	Scale/interval
63	pmerabrelmme	X62	Scale/interval
64	pmpdcppkttlostul	X63	Scale/interval
65	pmpdcppkttreceivedul	X64	Scale/interval
66	pmpdcppkttdiscdipelr	X65	Scale/interval
67	pmpdcppkttdiscdihho	X66	Scale/interval
68	pmpdcppkttdiscdipelruu	X67	Scale/interval
69	pmpdcppktttransdl	X68	Scale/interval
70	pmpdcplattimedl	X69	Scale/interval
71	pmpdcplatpkttransdl	X70	Scale/interval
72	pmprbuseddlfirsttrans	X71	Scale/interval
73	pmprbuseddlretrans	X72	Scale/interval
74	pmprbavaildl	X73	Scale/interval
75	pmprbusedulditch	X74	Scale/interval
76	pmprbavailul	X75	Scale/interval
77	pmpdcpvoldlrb	X76	Scale/interval
78	pmpdcpvoldlrbblasttti	X77	Scale/interval
79	pmuethptimedl	X78	Scale/interval
80	pmuethpvoul	X79	Scale/interval
81	pmuethptimeul	X80	Scale/interval
82	pmrrcconnlevsum	X81	Scale/interval
83	pmrrcconnlevsamp	X82	Scale/interval
84	pmschedactivitycelldl	X83	Scale/interval
85	pmpdcpvouldlrb	X84	Scale/interval
86	pmschedactivitycellul	X85	Scale/interval
87	pmpdcpvoldlrb	X86	Scale/interval
88	pmpdcpvouldlrb	X87	Scale/interval
89	pmrasuccbra	X88	Scale/interval
90	pmraattcra	X89	Scale/interval
91	pmrasuccfra	X90	Scale/interval
92	pmraattcra	X91	Scale/interval
93	pmrrcconnectabfaillic	X92	Scale/interval
94	pmpdcpvoldlrbca	X93	Scale/interval
95	pmpdcpvoldlrbblasttica	X94	Scale/interval
96	pmradiothpvoldlscellext	X95	Scale/interval
97	pmuethptimedlca	X96	Scale/interval
98	pmuethptimeulca	X97	Scale/interval
99	pmuethpvoulca	X98	Scale/interval

100	pmuextxtrelscwcdma	X99	Scale/interval
101	pmcriticalborderevalreport	X100	Scale/interval
102	pmactiveuedlsum	X101	Scale/interval
103	pmactiveueulsum	X102	Scale/interval
104	rsi	X103	Scale/interval
105	sinr_pusch	X104	Scale/interval
106	sinr_pucch	X105	Scale/interval
107	hosr_intraf	X106	Scale/interval

## Lampiran 2. Python Syntax Random forest

```
import numpy as np
import pandas as pd
import seaborn as sns
import matplotlib.pyplot as plt
from sklearn.preprocessing import LabelEncoder, OneHotEncoder
import warnings
warnings.filterwarnings("ignore")
from sklearn.svm import SVC
from sklearn.metrics import confusion_matrix
np.random.seed(123)
import statsmodels.formula.api as sm1
import statsmodels.api as sm
import pandas as pd
import numpy as np
# Scikit-learn template
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.preprocessing import PolynomialFeatures
from sklearn.pipeline import Pipeline
# Choose model
from sklearn.ensemble import RandomForestRegressor
from sklearn.ensemble import RandomForestClassifier
# Choose metric (http://scikit-learn.org/stable/modules/model\_evaluation.html)
from sklearn.metrics import mean_squared_error
from sklearn.metrics import r2_score
import matplotlib.pyplot as plt
from sklearn.metrics import f1_score, accuracy_score, auc, confusion_matrix,
    classification_report, cohen_kappa_score
import os
from IPython.display import Image
from sklearn.tree import export_graphviz
```

```

import seaborn as sns # visualization tool
from datetime import datetime
from sklearn.metrics import f1_score, accuracy_score, auc, confusion_matrix,
    classification_report,roc_auc_score,roc_curve
from IPython.display import Image
from sklearn import metrics
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import confusion_matrix
from sklearn.externals import joblib
import scikitplot as skplt
from sklearn.metrics import roc_curve, auc
from sklearn import datasets
from sklearn.multiclass import OneVsRestClassifier
from sklearn.svm import LinearSVC
from sklearn.preprocessing import label_binarize

df_FDD = pd.read_csv('data7_clean_1.csv')
X=df_FDD.drop('Average_CQI',1)
y=df_FDD['Average_CQI']
X_1 = sm.add_constant(X)
#Fitting sm.OLS model
model = sm.OLS(y,X_1).fit()
model.pvalues
cols = list(X.columns)
pmax = 1
while (len(cols)>0):
    p= []
    X_1 = X[cols]
    X_1 = sm.add_constant(X_1)
    model = sm.OLS(y,X_1).fit()

```

```

p = pd.Series(model.pvalues.values[1:],index = cols)
pmax = max(p)
feature_with_p_max = p.idxmax()
if(pmax>0.05):
    cols.remove(feature_with_p_max)
else:
    break
selected_features_BE = cols
print(selected_features_BE)
X = data[selected_features_BE]

y=data.Modulation_code

X.shape
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.25)

RF = RandomForestClassifier(n_estimators = 100, random_state = 42)
RF.fit(X_train, y_train)

y_pred=RF.predict(X_test)
pred_train = RF.predict(X_train)
pred_test = RF.predict(X_test)

accuracy_score_train = accuracy_score(y_train, pred_train)
print("  accuracy_score train = {:.5f}".format(accuracy_score_train))

# Test score
accuracy_score_test = accuracy_score(y_test, pred_test)
print("  accuracy_score test = {:.5f}".format(accuracy_score_test))

print("  accuracy:",metrics.accuracy_score(y_test, y_pred))
cohen_score = cohen_kappa_score(y_test, y_pred)

```

```

print(" Kappa Score= {:.2f} ".format(cohen_score))

confusion_matrix = pd.crosstab(y_test, y_pred, rownames=['Actual'],
                               colnames=['Predicted'])
sns.heatmap(confusion_matrix, annot=True)
print(confusion_matrix)
print("\nclassification report:")
print(classification_report(y_test, pred_test))
y_probas1=RF.predict_proba(X_test)
skplt.metrics.plot_roc(y_test, y_probas1, figsize=(10, 8))

#StratifiedKfold
from sklearn.model_selection import StratifiedKFold
from sklearn.metrics import make_scorer, accuracy_score, precision_score,
    recall_score, f1_score
from sklearn import model_selection
from sklearn.model_selection import cross_val_score

#precision1=make_scorer(precision_score, average = 'micro'),
accuracy=[]
precision=[]
recall=[]
f1score=[]
macro_roc_auc_ovo=[]
skf=StratifiedKFold(n_splits=5)
skf.get_n_splits(X,y)

for train_index, test_index in skf.split(X,y):
    print("Train:",train_index,"Validation:",test_index)

```

```

X1_train,X1_test=X.iloc[train_index],X.iloc[test_index]
y1_train,y1_test=y.iloc[train_index],y.iloc[test_index]

RF.fit(X1_train,y1_train)
prediction=RF.predict(X1_test)
y_prob = RF.predict_proba(X1_test)
macro_roc_auc_ovo = roc_auc_score(y1_test, y_prob,
    average="weighted",multi_class='ovr')
accuracy_score_test1 = accuracy_score(y1_test, prediction)
    #accuracy.append(round(accuracy_score(y_test, y_pred), 2))
#precision=precision_score(y1_test,prediction,average='micro')
#recall=recall_score(y1_test,prediction,average='micro')
#print('precision: ' + str(precision))
#print('recall: ' + str(recall))
    confusion_matrix = pd.crosstab(y1_test, prediction, rownames=['Actual'],
    colnames=['Predicted'])
print("    accuracy_score test = {:.5f}".format(accuracy_score_test1))
print(confusion_matrix)
print(classification_report(y1_test, prediction))

print("AUC:",macro_roc_auc_ovo)

y_probas=RF.predict_proba(X1_test)
skplt.metrics.plot_roc(y1_test, y_probas, figsize=(10, 8))

pd.set_option('display.max_rows', None)
pd.set_option('display.max_columns', None)
pd.set_option('display.width', None)
pd.set_option('display.max_colwidth', -1)
feature_imp =
    pd.Series(RF.feature_importances_,index=X.columns).sort_values(ascending
    =False)

```



```

print(feature_imp)
list_title=['LTE FDD ']
feat_imp = pd.DataFrame(
    {'cols':X.columns,
     'imp':RF.feature_importances_
    }).sort_values('imp', ascending=True)

space = np.arange(len(feat_imp.cols))
fig = plt.figure(figsize=(12,8))
fig.suptitle(list_title, fontsize=20)
plt.figure(figsize=(12,8))
plt.barh(space, feat_imp.imp,color = (0.3,0.9,0.4,0.6))
plt.yticks(space, feat_imp.cols)
_ = plt.grid(axis='x')
#color = (0.3,0.5,0.4,0.6) ;color = (0.3,0.9,0.4,0.6)
for index, value in enumerate(round(feat_imp.imp,4)):
    plt.text(value, index, str(value),weight='bold')

```

### Lampiran 3. Koefisien Relasi Variabel Prediktor terhadap Modulasi

Variabel	Korelasi polychoric y=Modulation	Korelasi pearson y=CQI
MIMO	0.663	0.780
PDCCH_CCE_Aggregation_8_	-0.551	-0.429
SE_3	0.610	0.148
sinr_pusch	0.604	0.562
sinr_pucch	0.520	0.339
_125_PL_130_	-0.501	-0.404
_130_PL_135_	-0.536	-0.446
DL_PRB_Utilization_	-0.310	-0.322
_135_PL_140_	-0.463	-0.358
lte_active_user_dl	-0.261	-0.196
pmrasucccfra	-0.232	-0.151
Average_Active_User	-0.260	-0.196
dl_uu_latency	-0.288	-0.140
pmrrconnestabattreatt	-0.283	-0.107
_145_PL_	0.205	-0.039
pmraattcfra	-0.246	-0.157
ul_packet_loss_rate	-0.349	-0.032
pmprbuseduldth	-0.253	-0.286
pmactiveueulsum	-0.288	-0.225
dl_packet_loss_rate	-0.305	-0.039
pmschedactivitycellul	-0.260	-0.292
lte_active_user_ul	-0.389	-0.210
pmerabrelabnormalenb	-0.311	-0.049
pmerabrelabnormalenbact	-0.326	-0.046
_95_PL_100_	0.291	0.278
pmpdcpvoldldrblasttica	0.041	0.077
pmuethptimedlca	-0.182	-0.163
Average_RRC_Connected_User_Mhz	-0.032	-0.023
_115_PL_120_	0.116	0.082
pmpdcpvoldldrb	-0.053	-0.090
_100_PL_105_	0.300	0.292
pmpdcppktrandsdl	-0.064	-0.100
_140_PL_145_	-0.149	-0.149
_105_PL_110_	0.266	0.254
pmrasucccbra	-0.185	-0.188
_90_PL_95_	0.264	0.237
_120_PL_125_	-0.205	-0.167
pmpdcplattimedl	-0.119	-0.137
_110_PL_115_	0.201	0.167
Max_Active_User_Mhz	-0.146	-0.023
cfra_success_rate	0.168	0.078
pmraattcbra	-0.226	-0.169
pmcriticalborderevalreport	-0.266	-0.158
pmrrconnlevsum	-0.121	-0.163
rrc_connected_users	-0.123	-0.165
pmrrconnestabatt	-0.172	-0.188

rrc_setup_success_rate	0.278	0.045
ul_prb_utilization	-0.254	-0.257
pmpdcpvoluldrb	-0.088	-0.127
lte_csfb_volume	-0.160	-0.183
pmpdcpktreceivedul	-0.109	-0.144
_85_PL_90_	0.231	0.189
cbra_success_rate	0.069	0.033
pmslsgconnestabatt	-0.172	-0.188
_80_PL_85_	0.196	0.158
sarr	-0.285	-0.044
Max_RRC_Connected_User_Mhz	-0.012	-0.002
lte_csfb_activity	0.071	0.114
lte_csfb_act_rate	-0.060	0.005
pmerabestabattinit	-0.164	-0.183
pmrrconnestabsucc	-0.171	-0.188
pmpdcpvoldlrbca	-0.027	-0.031
pmerabrelmme	-0.167	-0.115
erab_setup_success_rate	0.192	0.030
hosr_intraf	0.208	0.056
ul_volume_gb	-0.088	-0.127
pmpdcpktdiscldpelruu	-0.227	-0.100
sssr	0.189	0.029
Max_Active_User	-0.289	-0.029
pmuethpvulul	-0.157	-0.174
pmuextxtrelscwcdma	-0.168	-0.048
Max_RRC_Connected_User	-0.130	-0.154
pmrrconnmax	-0.130	-0.155
s1_conn_est_success_rate	0.103	-0.015
cell_availability	-0.013	0.003
pmrrconnlevsamp	0.003	0.009
csfb_sr	0.231	0.008

#### Lampiran 4. Deskripsi Variabel Prediktor

Variabel	Deskripsi
MIMO	KPI yang menunjukkan penetrasi MIMO <i>usage</i>
PDCCH_CCE_Aggregation_8_	KPI yang menunjukkan penggunaan kanal PDCCH
SE_3	Spectral Efficiency berhubungan dengan penggunaan spektrum frekuensi dari operator. KPI ini berkolerasi positif terhadap CQI dan penggunaan Modulasi 64 QAM
sinr_pusch	KPI yang menunjukan level kualitas jaringan di Kanal <i>Uplink</i> . <i>PUSCH</i> merupakan <i>uplink channel</i> yang akan membawa informasi CQI jika UE melakukan aktivitas <i>download</i> dan <i>upload</i> secara bersamaan. KPI ini berkolerasi positif terhadap CQI dan penggunaan Modulasi 64 QAM
sinr_pucch	KPI yang menunjukan level kualitas jaringan di Kanal <i>Uplink</i> . <i>PUSCH</i> merupakan <i>uplink channel</i> yang akan membawa informasi CQI jika UE hanya melakukan aktivitas <i>download</i> . KPI ini berkolerasi positif terhadap CQI dan penggunaan Modulasi 64 QAM
_125__PL__130_	KPI ini menunjukkan range Path loss antara 125 dB-130 dB yang diukur dari BTS ke UE. KPI ini berkolerasi negatif terhadap CQI dan penggunaan Modulasi 64 QAM
_130__PL__135_	KPI ini menunjukkan range Pathloss antara 130 dB - 135 dB yang diukur dari BTS ke UE. KPI ini berkolerasi negatif terhadap CQI dan penggunaan Modulasi 64 QAM
DL_PRB_Utilization_	KPI yang menunjukan kapasitas Physical Resource Block Dari BTS. semakin tinggi Nilainya mengindikasikan penggunaan PRB di BTS sangat tinggi dan berkolerasi negatif terhadap CQI dan penggunaan Modulasi 64 QAM
_135__PL__140_	KPI ini menunjukan nilai pathloss antara 135-140 dB
lte_active_user_dl	KPI ini menunjukan user aktif LTE di kanal <i>downlink</i> PDSCH
pmrasuccfra	<i>The number of successfully completed CFRA procedures</i>
Average_Active_User	KPI ini menunjukkan rata-rata user LTE
dl_uu_latency	KPI menunjukan <i>latency</i> antara UE dan BTS
pmrrconnectabattreatt	<i>The total number of RRC Connection Request attempts that are considered as re-attempts</i>
_145__PL_	KPI ini Menunjukkan pathloss $\geq 145$ dB
pmraattcfra	<i>The number of attempts completed CFRA procedures</i>
ul_packet_loss_rate	KPI ini menunjukkan kanal PUSCH <i>uplink packet loss</i>
pmprbuseduldth	<i>The total number of Physical Resource Block (PRB) pairs used for Data Radio Bearers (DRB) in the uplink</i>
pmactiveueulsum	Number of UEs considered active in the uplink direction
dl_packet_loss_rate	KPI ini menunjukkan kanal PDSCH <i>downlink packet loss</i>

pmschedactivitycellul	The aggregated number of ms in which DRB data was required to be scheduled in the uplink
lte_active_user_ul	KPI ini menunjukkan user aktif LTE di kanal <i>uplink</i> PUSCH
pmerabrelabnormalenb	<i>The total number of abnormal E-RAB Releases triggered by eNB per cell</i>
pmerabrelabnormalenbact	The total number of abnormal E-RAB Releases per cell initiated by the eNB and that there was data in either the UL or DL buffer (i.e. active).
_95__PL__100_	KPI yang menunjukkan <i>uplink pathloss</i> 95-100 dB
pmpdcpvoldlrbblasttica	The total volume (PDCP SDU) on Data Radio Bearers of carrier aggregation UE that has been transferred (acknowledged by the carrier aggregation UE) in the downlink direction in the last TTI when a buffer is emptied
pmuethptimedlca	The effective DL transport time of carrier aggregation UE comprises those periods from when the first part of the PDCP SDU of the DL buffer was transmitted on Uu until the buffer is emptied, excluding the TTI emptying the buffer. This is used for PDCP timebase
Average_RRC_Connected_User_Mhz	KPI yang menunjukkan rata-rata jumlah <i>user</i> pada fasa RRC dibagi <i>Bandwidth</i>
_115__PL__120_	KPI yang menunjukkan <i>uplink pathloss</i> 115-120 dB
pmpdcpvoldlrb	The total volume (PDCP SDU) on Data Radio Bearers that has been transferred (UM and AM) in the downlink direction.  When carrier aggregation is used, a PDCP SDU can be sent over multiple cells (PCell/SCell(s)). The total volume (PDCP SDU) on Data Radio Bearers that has been transferred (UM and AM) in the downlink direction is measured on PCell.
_100__PL__105_	KPI yang menunjukkan <i>uplink pathloss</i> 100-105 dB
pmpdcppktransdl	Total number of DRB packets (PDCP SDUs) successfully transmitted (RLC acknowledged by UE) in the downlink.  When carrier aggregation is used, a PDCP SDU can be sent over multiple cells (PCell/SCell(s)). Total number of DRB packets (PDCP SDUs) successfully transmitted (RLC acknowledged by UE) in the downlink is measured on PCell.
_140__PL__145_	KPI yang menunjukkan <i>uplink pathloss</i> 140-145 dB
_105__PL__110_	KPI yang menunjukkan <i>uplink pathloss</i> 105-110 dB
pmrassucccbra	The number of successfully detected RA Msg3 for CBRA
_90__PL__95_	KPI yang menunjukkan <i>uplink pathloss</i> 90-95 dB
_120__PL__125_	KPI yang menunjukkan <i>uplink pathloss</i> 120-125 dB

pmpdcplattimedl	<p>Aggregated DL Latency for a measurement period. The effective DL Latency time comprises the time from PDCP DRB SDU entering the buffer until the first data has been transmitted to the UE.</p> <p>When carrier aggregation is used, the DL Latency for all component carriers is registered on the UE's primary component carrier (PCell).</p>
_110__PL__115_	KPI yang menunjukkan <i>uplink pathloss</i> 110-115 dB
Max_Active_User_Mhz	KPI yang menunjukkan jumlah user maksimum dalam satu jam
cfra_success_rate	KPI yang menunjukan suksesnya <i>Contention Free Random Access</i>
pmraattcbra	The number of detected contention-based random-access preambles.
pmcriticalborderevalreport	The total number of A2 measurement reports received due to critical threshold is reached. This counter is used instead of pmBadCovEvalReport when the feature Mobility Control at Poor Coverage is activated.
pmrrconnlevsum	Sum of all sample values recorded for "number of UEs in RRC_CONNECTED mode".
rrc_connected_users	KPI yang menunjukkan jumlah user di fase RRC
pmrrconnestabatt	The total number of RRC Connection Request attempts.
rrc_setup_success_rate	KPI yang menunjukkan suksesnya proses RRC <i>request</i>
ul_prb_utilization	KPI yang menunjukkan penggunaan <i>uplink PRB</i>
pmpdcpvouludrb	The total volume (PDCP SDU) on Data Radio Bearers that has been received in the uplink direction and transmitted over the GTP-U.
lte_csfb_volume	KPI yang menunjukkan jumlah koneksi CS <i>Fallback</i>
pmpdcppktreceivedul	Total number of DRB packets (PDCP SDUs) received in the uplink.
_85__PL__90_	KPI yang menunjukkan <i>uplink pathloss</i> 80-90 dB
cbra_success_rate	KPI yang menunjukkan suksesnya <i>The Contention Based Random Access</i>
pms1sigconnestabatt	This measurement provides the number of S1 Signalling connection establishment attempts for any establishment cause.
_80__PL__85_	KPI yang menunjukkan <i>uplink pathloss</i> 80-85 dB
sarr	KPI yang menunjukan jumlah koneksi drop LTE pada channel PDSCH
Max_RRC_Connected_User_Mhz	KPI yang menunjukkan jumlah user maksimum dalam satu jam dibagi <i>Bandwith</i>
lte_csfb_activity	KPI yang menunjukkan CS Fallback Activity
lte_csfb_act_rate	KPI yang menunjukkan CS Fallback success rate
pmerabestabattinit	The total number of initial E-RAB Establishment attempts. Initial E-RABs are all E-RABs present in the S1 message Initial Context Setup Request.

pmrrconnestabsucc	The total number of successful RRC Connection Establishments.
pmpdcpvoldlrbca	The total volume (PDCP SDU) on Data Radio Bearers that has been transferred (UM and AM) in the downlink direction of carrier aggregation UE
pmerabrelmme	The total number of E-RAB Releases per cell initiated by the MME excluding successful handover. The counter is stepped regardless of whether data was or was not lost in UL/DL buffers.
erab_setup_success_rate	KPI yang menunjukkan fase suksesnya proses ERAB
hosr_intraf	KPI yang menunjukan mobility success rata antara LTE yang mempunyai frekuensi yang sama
ul_volume_gb	KPI yang menunjukkan traffic pada kanal <i>uplink</i>
pmpdcppktdiscldpelruu	<p>Total number of packets (PDCP SDUs) for which at least a part has been transmitted over the air in the downlink direction but not positively acknowledged, and it was decided that no more transmission attempts will be done, due to reasons other than handover. Only applicable to DRB packets.</p> <p>When carrier aggregation is used, a PDCP SDU can be sent over multiple cells (PCell/SCell(s)). Total number of packets (PDCP SDUs) for which at least a part has been transmitted over the air in the downlink direction but not positively acknowledged, and it was decided that no more transmission attempts will be done, due to reasons other than handover, is measured on PCell.</p>
sssr	KPI yang menunjukkan suksesnya proses <i>LTE call setup</i>
Max_Active_User	KPI yang menunjukkan jumlah maksimum user dalam satu jam pada kanal PDSCH
pmuethpvolul	The UL DRB volume used for UL UE Throughput. It comprises of the MAC SDU volume received on Uu, excluding the volume received in the first 4 data receptions of an UL buffer transfer and the TTI emptying the UL buffer.
pmuextxtrelscwdma	The number of Session Continuity RRC Connection Release with redirect to UTRA FDD.
Max_RRC_Connected_User	KPI yang menunjukkan jumlah maksimum user dalam satu jam pada fasa RRC
pmrrconnmax	Peak number of UE in RRC_CONNECTED mode.
s1_conn_est_success_rate	KPI yang menunjukkan suksesnya koneksi BTS LTE ke MME ( <i>Core network</i> )
cell_availability	KPI yang menunjukkan BTS down ( <i>availability</i> BTS)
pmrrconnlevsamp	Number of times the corresponding Sum counter has accumulated a new sample. Associated ACC pmCounter pmRrcConnLevSum.

csfb\_sr

KPI yang menunjukkan CS Fallback success rate dari LTE ke 3G