

# Penerapan Aplikasi *Machine Learning* Untuk Optimasi *Key Performance Indicator* (KPI) Pada Layanan Jaringan LTE

1<sup>st</sup> Fajar Maulana Arif  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia

ajarmarif@student.telkomuniversity.ac.id

2<sup>nd</sup> Ahmad Tri Hanuranto  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia

athanuranto@telkomuniversity.ac.id

3<sup>rd</sup> Ishak Ginting  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia

ishakg@telkomuniversity.ac.id

**Abstrak**—Saat ini kebutuhan akan informasi dan komunikasi terus berkembang pesat dari waktu ke waktu. Dalam dunia industri telekomunikasi, proses optimasi jaringan yang dilakukan oleh *RF engineer* saat ini masih memakan waktu proses dalam pengambilan keputusan untuk meningkatkan performansi jaringan karena kurangnya *tools* untuk menganalisa suatu jaringan. Dengan adanya permasalahan tersebut dirancanglah sebuah sistem *machine learning* yang dapat memprediksi KPI jaringan seluler LTE berdasarkan pada KPI yang memiliki hubungan yang kuat. Penelitian ini ditunjukan untuk membuat sebuah sistem berbasis web untuk memprediksi KPI *throughput* dan *utilization*. Dengan inputan prediksi dari KPI yang berdasarkan relasi tinggi terhadap KPI yang akan diprediksi. Metode algoritma yang digunakan untuk memprediksi KPI dalam sistem ini adalah *Random Forest*. Keluaran sistem ini berupa nilai prediksi dari KPI *Throughput* dan *Utilization*. Sistem yang dibuat menghasilkan *Mean Squared Error* yang sebesar 0,066 untuk model *Throughput* dan 0,841 untuk model *Utilization* dan nilai *R-Squared* sebesar 0,984 untuk model *Throughput* dan 0,986 untuk model *Utilization*.

**Keywords**— *machine learning, random forest, throughput, utilization.*

## I. PENDAHULUAN

Kebutuhan masyarakat akan informasi dan komunikasi terus berkembang pesat dari waktu ke waktu. Menyebabkan pihak penyedia jasa layanan telekomunikasi seluler dituntut berkembang untuk meningkatkan kualitas layanan terutama kepuasan user experience, yang dimana dipengaruhi oleh *Key Performance Indicator* (KPI). Pada jaringan telekomunikasi seluler terdapat berbagai jenis KPI yang terdiri dari *Accessibility*, *Retainability*, *Utilization*, *Availability*, *Latency*, *Integrity* dan yang lainnya [1]. Saat ini untuk mencapai kualitas jaringan yang berdasarkan KPI, *engineering seluler* melakukan tahapan *Radio Network Optimization* (RNO) dengan menggunakan *planning tools* dan *map tools*.

Dalam optimasi jaringan yang dilakukan oleh *RF engineer* akan menggunakan data site yang didapatkan dari *Drivertes team*, *Rigger team* dan *OSS team* yang selanjutnya dilakukan *performansi* menggunakan *processing tools* dan *Analysis tools*. Namun saat ini tahapan optimasi menggunakan 2 *tools* tersebut masih memiliki kekurangan seperti memakan waktu proses dalam

melakukan *performansi* dan pengambilan keputusan untuk meningkatkan kualitas suatu jaringan seluler.

*Performansi* jaringan sangat dipengaruhi oleh bagaimana pengaturan parameter KPI pada perangkat keras jaringan. Banyaknya komponen KPI yang harus diatur menyebabkan perlu dilakukannya optimasi secara terus menerus dengan memperhatikan KPI jaringan lainnya [2]. Pada aktivitas tersebut juga belum diketahuinya korelasi antara KPI dengan KPI lainnya pada jaringan. Perubahan pada satu atau beberapa KPI tertentu apakah akan berpengaruh tidak pada KPI yang ingin ditingkatkan. Oleh karena itu diperlukan analisis korelasi antara KPI terutama KPI yang terkait *User Experience* diantaranya menggunakan *machine learning* yang dapat memetakan antara KPI dengan KPI yang lainnya dan menganalisis hubungan antar KPI.


Untuk mengatasi masalah tersebut dibuatlah rancang bangun aplikasi yang bertujuan untuk memprediksi dan mengetahui korelasi dari KPI dengan KPI lainnya pada jaringan seluler dengan menggunakan *predictive model machine learning* dengan metode algoritma *Random Forest Regresion* untuk memprediksi *performansi* jaringan berdasarkan perubahan nilai dari KPI pada bagian *user experience Throughput* dan *Utilization*, dengan adanya aplikasi ini diharapkan dapat membantu untuk mengurangi waktu optimasi dan meningkatkan produktivitas dalam pengambilan keputusan untuk meningkatkan kualitas jaringan pada layanan jaringan telekomunikasi seluler.

## II. KAJIAN TEORI

### A. Long Term Evolution

*Long Term Evolution* (LTE) merupakan nama yang diberikan untuk standar teknologi komunikasi baru yang dikembangkan oleh 3GPP yang hadir menangani komunikasi data berbasis IP untuk mengatasi peningkatan permintaan kebutuhan akan layanan komunikasi. LTE adalah lanjutan dari evolusi 2G dan 3G yang mengadopsi teknologi *EPS* (*Evolved Packet System*), dimana terdapat komponen penting yang diantaranya [3]:

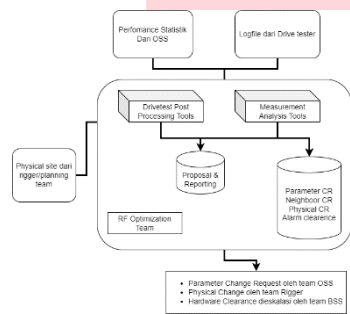
1. UE (*User Equipment*)
2. E-UTRAN
3. EPC (*Evolved Packet Core*) [5].



GAMBAR 2.1 ARSITEKTUR LTE [3]

B. Radio Network Optimization

RNO merupakan proses optimasi untuk meningkatkan dan mengawasi perfomansi jaringan dengan bertujuan untuk mencapai target KPI yang sudah ditentukan. Proses RNO dilakukan oleh RF Engineer dengan beberapa proses dan pengambilan keputusan yang bersumber dari data yang telah dikumpulkan melalui beberapa tahap.




GAMBAR 2.1 RF OPTIMIZATION PLANNING

Pada Radio Frekuensi (RF) terdapat 2 jenis optimasi perfomasi jaringan yang diantaranya adalah physical tuning dan parameter tuning. Pada parameter tuning, optimasi dilakukan pada pengaturan nilai-nilai parameter radio komunikasi. Dimana nilai-nilai tersebut diatur untuk mendapatkan pengaturan KPI yang sesuai agar komunikasi radio mendapatkan nilai yang lebih baik.

C. Key Performance Indicator

Key Performance Indicator (KPI) merupakan acuan nilai indicator perfomansi dari suatu jaringan. KPI pada masing-masing operator penyedia layanan jaringan seluler biasanya akan berbeda-beda namun menurut rekomendasi Internasional Telecommunication Union (ITU) terdapat beberapa pengklasifikasian KPI untuk evaluasi sebuah jaringan, yang diantaranya sebagai berikut [1].



GAMBAR 2.3 KPI PADA JARINGAN LTE [2]

D. Machine Learning

Machine learning merupakan program untuk melakukan inferensi terhadap data dengan pendekatan matematis dan membuat model matematis yang mereflesikan pola-pola data dengan memanfaatkan statistika dan aljabar linear dengan tujuan adalah menciptakan program yang mampu memprogram. Pada machine learning diperlukan adanya tiga komponen dasar yaitu algoritma matematis, prosesor komputer dan sebuah data [6].

E. Predictive Model


Predictive model merupakan model machine learning dengan proses training supervised learning dengan tujuan untuk memecahkan persoalan-persoalan yang memerlukan prediksi dan estimasi. Algoritma machine learning akan mencari hubungan antara target feature dengan feature lain yang tersedia di dalam dataset. Agar bisa membuat prediksi atau estimasi, machine learning diberi petunjuk tentang apa yang harus diprediksi, juga bagaimana caranya belajar agar modelnya terbentuk. [7].

F. Scikit-learn

Scikit-learn adalah library yang menyediakan banyak modul pembuatan model untuk bahasa pemrograman python yang dibangun diatas NumPy, SciPy dan matplotlib yang berfungsi untuk membantu melakukan processing data ataupun melakukan training data untuk kebutuhan machine learning supervised ataupun unsupervised. Scikit-learn mengutamakan kemudahan penggunaan namun tetap memberikan fleksibilitas yang memadai untuk pembuatan model yang kompleks.[7].

G. Random Forest

Random Forest merupakan algoritma machine learning supervised yang menggambarkan metode yang disebut ensemble. metode ini memungkinkan menggabungkan beberapa model untuk mendapatkan hasil yang lebih baik daripada menjalankan setiap model sendiri-sendiri [9].



GAMBAR 2.4 MODEL DENGAN METODE RANDOM FOREST [9]

Prinsip Random Forest adalah dengan membangun beberapa model Decision Tree dan kemudian menggabungkan hasilnya yang selanjutnya memilih hasil dari model yang terbaik dengan mekanisme voting yang menjadi keluaran mana yang akan di pakai. Setiap tree akan memberikan hak suaranya, dan kelas yang paling populer atau prediksi terbanyak pada seluruh pohon yang akan dimenangkan sebagai hasil akhir [9].

H. Exploratory Data Analysis

Dalam pembuatan model machine learning, kualitas dataset sangat berpengaruh terhadap kualitas model. Untuk mendapatkan data yang berkualitas diperlukan proses persiapan data dengan tujuan untuk membersihkan data, memanipulasi data dan mendapatkan statistik dari data tersebut. Dalam tahap ini merupakan proses investigasi pada data untuk menganalisis karakteristik, menemukan pola, anomaly, dan memeriksa asumsi pada data. Pada proses exploratory data terdapat proses yang diantaranya [7]:

1. Menganalisa jenis variabel pada dataset.
2. Mendistribusikan variabel dalam dataset.
3. Menemukan missing value.
4. Menemukan feature yang tidak berguna.
5. Menganalisa hubungan feature dengan target label.

I. *Evaluation Model*

Pengukuran terhadap kinerja suatu sistem machine learning merupakan hal yang penting dengan tujuan memeriksa dan memberi gambaran kinerja model sudah sesuai atau tidak. Secara umum dalam mengevaluasi model regression adalah jika prediksi mendekati nilai sebenarnya, maka performanya baik. Sedangkan jika tidak, performanya buruk. Secara teknis, selisih antara nilai sebenarnya dan nilai prediksi dinamakan error [11].


III. METODE

A. Gambaran Umum Perancangan

Pada bab ini mendeskripsikan perancangan sistem tugas akhir bagian-bagian dan alur kerja sistem yang bertujuan untuk menerangkan cara kerja dan alur perancangan sistem tersebut secara garis besar dengan tujuan agar sebuah perancang sistem dapat lebih mudah dimengerti dan dipahami. Berikut adalah spesifikasi perancangan sistem pada penerapan aplikasi machine learning untuk optimasi key performance indicator pada jaringan LTE.


B. Desain Sistem

Pada tahap ini membahas tentang gambaran umum dalam tahapan perancangan sistem yang akan dibangun untuk memprediksi KPI pada jaringan telekomunikasi seluler. Yang diantaranya sebagai berikut:



GAMBAR 3. 1  
GAMBARAN UMUM PERANCANGAN SISTEM

C. Perancangan Sistem Machine Learning



GAMBAR 3. 2  
PERACANGAN MODEL RANDOM FOREST


Pada tahap ini membahas tentang gambaran dari perancangan sistem yang akan dibangun dengan model machine learning. Tahap awal adalah Exploratory data dengan menganalisa setiap informasi yang terdapat dalam dataset tersebut. Dataset yang diperoleh akan dilakukan teknik preprocessing data atau data preparation untuk mempersiapkan data sebelum dilakukannya pemodelan. Setelah melakukan preprocessing data, selanjutnya melakukan pembangun model dengan metode algoritma random forest. Hasil dari prediksi yang didapatkan akan dievaluasi menggunakan dua metode metrik yaitu mean squared error (MSE) dan R-Squared.

1. *Analisis Missing value*

Missing value merupakan suatu kondisi dimana tidak ada data yang terdeteksi untuk suatu feature pada sampel pengamatan tertentu dalam dataset. Missing value biasanya muncul dengan tanda “NaN” atau tidak ada nilainya sama sekali (blank cell). Untuk menangani data yang hilang terdapat beberapa cara yang dapat digunakan diantaranya adalah dengan menghapus data yang mengandung missing values atau mengganti nilai missing values dengan suatu pilihan.

2. *Analisis Outliers*

Dalam data preprocessing terdapat tahapan menemukan outliers. Outliers merupakan data yang sangat jauh dari cakupan umum dari kumpulan data utama. Dari pengamatan kemunculannya sangat jarang dan berbeda dari hasil pengamatan lainnya. Dalam penelitian ini akan menggunakan teknik Inter Quartile Range (IQR) dengan bantuan visualisasi data boxplot. Perhitungan IQR adalah selisih dari kuartil ketiga (Q3) dengan kuartil pertama (Q1).

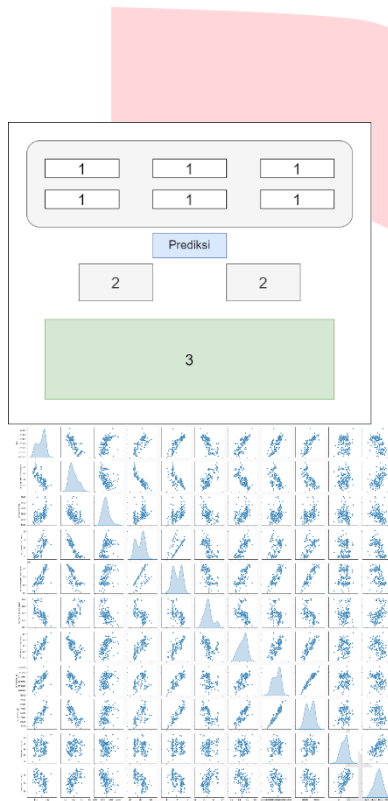


GAMBAR 3. 3  
BOXPLOT PADA KPI SINR\_PUCCH

3. *Analisis Numerical Features*


Tahap ini dilakukan pengamatan hubungan dan mengobservasi korelasi features KPI Throughput dan Utilization dengan KPI

yang lainnya. Untuk proses ini dilakukan dengan bantuan fungsi pairplot dari library seaborn untuk menunjukkan relasi pasangan dalam dataset. Misalnya, relasi antara KPI throughput pada sumbu X dengan KPI latency pada sumbu Y atau relasi antara KPI utilization pada sumbu X dengan KPI SINR pada sumbu Y. dari grafik, dapat dilihat plot relasi masing-masing features KPI pada dataset.



GAMBAR 3.4 PAIRPLOT KPI THROUGHPUT

Setelah menganalisa dan mendapatkan hasil KPI mana yang mendapatkan korelasi kuat terhadap KPI throughput dan utilization. Selanjutnya, dilakukan evaluasi skor terhadap KPI yang didapatkan dengan menggunakan method correlation.



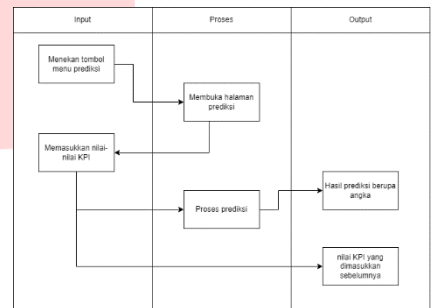
GAMBAR 3.5 KORELASI UTILIZATION & THROUGHPUT

D. Deployment Sistem

Perancangan pada deployment sistem terdapat dua: yaitu blok diagram proses system dan activity diagram dari website.

1. Proses Prediksi

Pengguna menekan tombol untuk memasuki halaman prediksi. Ketika masuk ke halaman prediksi. Proses awal yang dilakukan adalah user memasukkan nilai-nilai KPI untuk memprediksi KPI throughput dan utilization, setelah itu menekan tombol submit. Sistem akan mengolah data dengan model random forest yang menghasilkan hasil berupa angka prediksi.



GAMBAR 3.6 DIAGRAM BLOK PROSES PREDIKSI

2. Perancangan Antarmuka Web

Pada tahap ini merupakan rancangan pembangunan antarmuka aplikasi web untuk prediksi KPI throughput dan utilization.

IV. HASIL DAN PEMBAHASAN

A. Deskripsi

Hasil perencanaan implementasi aplikasi machine learning pada jaringan LTE terbagi dua yang diantaranya: pembangunan model machine learning dan pembangunan aplikasi berbasis pemrograman python untuk penerapan machine learning agar bisa digunakan oleh user.

B. Implementasi Model

Perancangan machine learning dalam model algoritma random forest dengan melalui tahap data understanding, data preparation, dan data exploratory analysis. Setelah melakukan analisa terhadap KPI yang terdapat pada dataset. Didapatkan terdapat 7 KPI yang memiliki korelasi kuat terhadap KPI utilization dan throughput. Berikut diantaranya:


TABEL 4.1 HASIL ANALISA KORELASI KPI

Features	Label	
	Throughput	Utilization
Latency	-86%	91%
RSSI	-84%	87%
User Connected	-89%	92%
Throughput Carrier Aggregation	96%	-98%
SINR PUCCH	84%	-86%
Tx Rank	89%	-84%
SINR PUSCH	89%	-88%

Hasil dari analisis pemodelan machine learning pada tabel 4.1 didapatkan hasil KPI yang memiliki relasi atau hubungan yang tinggi terhadap KPI throughput dan utilization adalah KPI throughput carrier aggregation yang bernilai 96% dan -98%.

C. Implementasi Aplikasi

Tampilan antarmuka aplikasi ini dirancang menggunakan framework Flask dengan bahasa pemrograman Python dan framework front-end Bootstrap. Aplikasi ini dibangun untuk mempermudah user dalam melakukan proses prediksi KPI Utilization dan Throughput. Jika dilihat dari gambar dibawah ini aplikasi memiliki fitur inputan untuk memasukan nilai KPI, tombol submit untuk melakukan proses prediksi, fitur hasil prediksi dan hasil inputan dari nilai yang telah dimasukkan.



GAMBAR 4.1 APLIKASI WEB

D. Analisa Hasil Pengujian Model

Pada penelitian ini, dirancang sebuah pemodelan machine learning dengan metode algoritma random forest. Pada penelitian model ini akan dilakukan 3 skenario pengujian dengan masing-masing skenario akan menggunakan 2 metode evaluasi yaitu R-Squared dan MSE. Skenario pertama adalah simulasi menggunakan semua KPI yang memiliki korelasi tinggi dari hasil data preparation, dan data expolatory analysis. Scenario kedua adalah simulasi menggunakan semua KPI yang memiliki korelasi tinggi mengarah positif, skenario ketiga adalah menggunakan KPI yang memiliki korelasi tinggi mengarah negative dan scenario terakhir adalah dengan menggunakan KPI yang memiliki korelasi tinggi dari hasil analisa analytic.

TABEL 4.2 SKENARIO PENGUJIAN MODEL

Skenario	Label	
	Throughput	Utilization
1	Latency, RSSI, User Connected, TH Carrier Aggregation, SINR PUCCH, Tx Rank, SINR PUSCH	Latency, RSSI, User Connected, TH Carrier Aggregation, SINR PUCCH, Tx Rank, SINR PUSCH
2	TH Carrier Aggregation, SINR PUCCH, Tx Rank, SINR PUSCH	User Connected, RSSI, Latency
3	User Connected, RSSI, Latency	TH Carrier Aggregation, SINR PUCCH, Tx Rank, SINR PUSCH
4	Rssi, rrc_connected_users, dl_uu_latency, sinr_pusch	Rssi, rrc_connected_users, dl_uu_latency, sinr_pusch

1. Evaluasi Mean Squared Error

Tabel 4.3 Evaluasi Model MSE

Pengujian Ke-	Label	
	Kecepatan	Kapasitas
1	0,066	0,841
2	0,146	1,135
3	0,113	3,006
4	0,134	2,817

Dari hasil pengujian model dengan evaluasi metriks Mean Squared Error dapat disimpulkan bahwa model terbaik adalah pada skenario ke-1 dengan memprediksi KPI yang dimana mendapatkan nilai sebesar 0,066 untuk model throughput dan 0,841 untuk model utilization.

2. Evaluasi R-Squared

TABEL 4.4 EVALUASI R-SQUARED

Pengujian Ke-	Label	
	Throughput	Utilization
1	0,9843	0,986
2	0,9655	0,9811
3	0,9732	0,95
4	0,968	0,958

Dari hasil pengujian model dengan evaluasi metriks R-Squared dapat disimpulkan bahwa model terbaik adalah pada skenario ke-1 dengan memprediksi KPI yang dimana mendapatkan skor 0,9843 untuk model throughput dan 0,986 untuk model utilization.



## E. Hasil Pengujian Aplikasi

TABEL 4.6  
HASIL PENGUJIAN APLIKASI

No	Nilai Inputan				Hasil Prediksi	
	RSSI (dBm)	Jumlah User (Unit)	Latency (ms)	SINR (dB)	Throughput (Mbps)	Utilization (%)
1	-113.86	51.67	6.32	10.20	1.767	47.807
2	-113.56	17.153	3.33	12.96	14.609	17.137
3	-113.56	55.76	3.33	12.96	13.999	22.192
4	-113.56	17.153	6.32	12.96	2.297	45.741
5	-117.76	57.479	5.6546	10.32	2.216	46.688
6	-115.415	25.95	3.912	11.786	5.816	28.739
7	-112.68	20.31	3.11	12.97	14.751	17.369
8	-117.579	20.31	3.11	12.97	16.271	13.823
9	-112.68	50.23	3.11	12.97	14.639	21.782
10	-117.76	50.76	5.122	12.97	3.872	42.111

Dari hasil pengujian dapat disimpulkan bahwa KPI RSSI, jumlah user, Latency dan SINR memiliki keterkaitan hubungan dalam memprediksi KPI Throughput dan Utilization dimana jika salah satu atau lebih KPI bernilai buruk akan merubah nilai prediksi dan sebaliknya. Dan dari hasil yang didapatkan nilai Kecepatan user (Throughput) tertinggi sebesar 16.271 Mbps dan terendah sebesar 1.767 Mbps dan untuk kapasitas user (Utilization) tertinggi sebesar 47.807 % dan terendah sebesar 13.823 %.

## V. KESIMPULAN

### A. Kesimpulan

Dari hasil pengujian dan analisis yang sudah dilakukan terhadap sistem yang sudah dirancang maka ditarik kesimpulan sebagai berikut:

- 1) Pembangunan model machine learning yang telah dibuat menghasilkan KPI Latency, RSSI, User Connected, TH Carrier Aggregation, SINR PUSCH, Tx Rank dan SINR PUCCH memiliki korelasi kuat terhadap perubahan KPI Utilization dan Throughput.
- 2) Kinerja pada model prediksi Throughput dapat bekerja baik dengan nilai MSE adalah 0,066 dan nilai R-Squared adalah 0,984.
- 3) Kinerja pada model prediksi Utilization dapat bekerja baik dengan nilai MSE adalah 0,841 dan nilai R-Squared adalah 0,986.
- 4) Sistem yang dibuat dapat bekerja dengan baik karena semua fungsi sudah dapat berjalan untuk memprediksi pada aplikasi web.

### B. Saran

Untuk penelitian lebih lanjut, penulis mempunyai beberapa saran terhadap sistem agar nantinya dapat diperbaiki atau ditingkatkan lagi:

- 1) Penelitian selanjutnya diharapkan sistem dapat menggunakan metode algoritma lainnya untuk memprediksi jaringan seluler

agar dapat dibandingkan kinerja antar model yang mana lebih baik.

- 2) Penelitian selanjutnya diharapkan menggunakan lebih banyak data KPI pada jaringan agar memiliki sampel data yang lebih beragam untuk menunjang penelitian tentang penerapan machine learning pada jaringan seluler.
- 3) Menggunakan lebih banyak metode exploratory data analysis sebagai penunjang kualitas pada dataset yang akan digunakan.

## REFERENSI

- [1]. T. D. Sector, "Quality of service Regulation Manual," January 2017. [Online]. Available: [https://www.itu.int/dms\\_pub/itu-d/opb/pref/D-PREF-BB.QOS\\_REG01-2017-PDF-E.pdf](https://www.itu.int/dms_pub/itu-d/opb/pref/D-PREF-BB.QOS_REG01-2017-PDF-E.pdf). [Accessed 8 12 2021].
- [2]. R. Kreher and K. Gaenger, "Key Performance Indicators and Measurements for LTE Radio Network Optimization," LTE Signaling: Troubleshooting and Performance Measurement, pp. 267-336, 2015.
- [3]. U. K. Usman, G. Prihatmoko, D. K. Hendraningrat and S. D. Purwanto, Fundamental Teknologi Seluler LTE, Bandung: Rekayasa Sains, 2012.
- [4]. Sibro, "ThinkCorp Indonesia: Jenis-jenis Optimasi RF," Training & Workshop, 30 September 2021. [Online]. Available: <https://www.thinkcorpindonesia.com/jenis-jenis-optimasi-rf/>. [Accessed 16 Desember 2021].
- [5]. H. Elsherbiny, H. M. Abbas, H. Abou-zeid, H. S. Hassanein and A. Noureldin, "4G LTE Network Throughput Modelling and Prediction," IEEE Global Communications Conference, 2021.
- [6]. J. W. G. Putra, Pengenalan Konsep Pembelajaran Mesin Dan Deep Learning, Tokyo: Tokyo Institute of Technology, 2018.
- [7]. M. Dios Kurniawan, Pengenalan Machine Learning dengan Python, Jakarta: PT Elex Media Komputindo, 2020.
- [8]. A. NG, Machine Learning Yearning Techinal Strategy for AI Engineers, In the Era of Deep Learning, 2018.
- [9]. L. Breiman, "Random forest," vol. 45, no. 1, pp. 5-32, 2001.
- [10]. N. Stepanov, . D. Alekseeva, A. Ometov and E. S. Lohan, "Applying Machine Learning to LTE Traffic Prediction: Comparison of Bagging, Random Forest, and SVM," International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT), no. 12, 2020.
- [11]. C. N. Dengen, K. and E. T. Luthfi, "Penentuan Association Rule Pada Kelulusan Mahasiswa Menggunakan Algoritma Apriori," JURTI, vol. 3, no. 1, pp. 20-22, 2019.
- [12]. A. Sani, "Penerapan Metode K-Means Clustering Pada Perusahaan," Jurnal Ilmiah Teknologi Informasi, pp. 1-7, 2018.
- [13]. H. Priyatman, F. Sajid and D. Haldivany, "Klasterisasi Menggunakan Algoritma K-Means Clustering Untuk Mmprediksi Waktu Kelulusan

Mahasiswa," JEPIN (Jurnal Edukasi dan Penelitian Informatika), vol. V, no. 1, pp. 62-64, April 2019.

- [14]. M. Nasri and M. Hamdi, LTE QoS Parameters Prediction Using Multivariate Linear Regression Algorithm, Ariana: Carthage University, 2019.

