

## SIMULASI MACHINE LEARNING UNTUK QUALITY OF TRANSMISSION PADA KOMUNIKASI OPTIK

### MACHINE LEARNING SIMULATION FOR QUALITY OF TRANSMISSION OPTICAL COMMUNICATION

Alifia Safrida Arini<sup>1</sup>, Kris Sujatmoko<sup>2</sup>, Brian Pamukti<sup>3</sup>

<sup>1,2,3</sup>Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom  
<sup>1</sup>alifiasafrida@student.telkomuniversity.ac.id, <sup>2</sup>krissujatmoko@telkomuniversity.co.id,  
<sup>3</sup>brianp@telkomuniversity.ac.id

#### Abstrak

Seiring dengan munculnya *data science*, penerapan *machine learning* pada sistem komunikasi optik mulai banyak dilakukan. Dengan *machine learning*, waktu komputasi yang diperlukan menjadi lebih cepat dengan tingkat akurasi yang tinggi. Dalam penelitian ini, parameter *Q-factor* untuk *Quality of Transmission (QoT)* pada sistem komunikasi fiber optik diprediksi menggunakan tiga algoritma *machine learning*, yaitu *Linear Regression (LR)*, *Decision Tree (DT)* dan *Random Forest (RF)*. Data sintetik yang digunakan untuk melatih algoritma *machine learning* tersebut merupakan sistem komunikasi fiber optik dengan tiga jumlah kanal yang berbeda, yaitu 16, 32 dan 64. Hasil dari algoritma DT dan RF memiliki tingkat akurasi yang tinggi dengan nilai prediksi hampir sama dengan nilai asli. Sedangkan algoritma LR memiliki performansi yang lebih rendah.

**Kata kunci :** machine learning, QoT, Q-factor, linear regression, decision tree, random forest.

#### Abstract

Along with the emergence of data science, the application of machine learning in optical communication systems is widely used. By using machine learning, the computation time can be done quickly with high accuracy rate. This study, Q-factor parameter for Quality of Transmission (QoT) of an optical fiber communication system is predicted by using three machine learning algorithm, namely Linear Regression (LR), Decision Tree (DT) and Random Forest (RF). The synthetic data that used for training machine learning algorithms are optical fiber communication system with three different number of channels, i.e., 16, 32 and 64. The results of DT and RF algorithms has high accuracy rate with predicted values almost the same as the original. While the LR algorithm has lower performance.

**Keywords:** machine learning, QoT, Q-factor, linear regression, decision tree, random forest.

#### 1. Pendahuluan

Komunikasi optik merupakan suatu teknologi yang digunakan pada jaringan telekomunikasi untuk pengiriman data berkecepatan tinggi [1]. Komunikasi optik menggunakan sinyal dalam bentuk cahaya dan kabel optik sebagai media transmisinya. Dalam perancangan jaringan komunikasi optik, banyaknya data yang harus diproses memerlukan waktu komputasi yang cukup panjang. Dengan munculnya *data science*, banyak sektor pada komunikasi optik mencoba mengadaptasi *machine learning* [1]. Penggunaan *machine learning* memberikan kemudahan dalam waktu komputasi serta pengambilan keputusan secara *real time*.

*Machine Learning (ML)* merupakan bagian dari *Artificial Intelligence (AI)* yang mempelajari tentang algoritma dan model statistik dan diterapkan pada sistem komputer agar dapat menjalankan tugas tanpa perlu diprogram berulang kali [2]. *Machine learning* membutuhkan data yang nantinya digunakan sebagai data latihan dan data validasi. Konsep dari *machine learning* sendiri adalah tentang menentukan pola, dengan cara menganalisis data latihan sampai algoritma terlatih dan dapat melakukan tugas yang sebelumnya tidak diprogram [3].

Penelitian mengenai penerapan *machine learning* pada komunikasi optik sudah cukup banyak dilakukan. Salah satunya adalah penelitian dari Amal A. Algedir dan Taissir Y. Elganimi yang membahas penerapan *machine learning* untuk memprediksi *Q-factor* pada sistem *Free Space Optical* (FSO) [4]. Dari penelitian tersebut, didapatkan bahwa algoritma *decision tree* dan *random forest* dapat memprediksi *Q-factor* pada sistem FSO dengan tingkat akurasi 95.3% untuk *random forest* dan 90.4% untuk *decision tree*. Sedangkan untuk algoritma *Multi-linear Regression* (MLR) dan *Support Vector Regression* (SVR) tidak dapat digunakan untuk memprediksi *Q-factor* karena tingkat akurasi yang dihasilkan hanya sebesar 9%.

Penelitian berikutnya membahas penerapan *machine learning* untuk estimasi *Quality of Transmission* (QoT) *lightpath* [5]. Dari penelitian tersebut didapatkan kesimpulan bahwa teknik *supervised machine learning* dapat digunakan untuk memperkirakan QoT *lightpath* sebelum pembentukan jaringan, dengan menggunakan algoritma *K nearest neighbors* (K-NN), *random forest* dan *support vector machine* (SVM). Dari ketiga algoritma tersebut, SVM menunjukkan kinerja yang lebih baik dengan tingkat akurasi sebesar 99.15% dalam akurasi namun waktu komputasi yang diperlukan lebih lama dibandingkan K-NN dan *decision tree*.

Dalam penelitian ini tiga algoritma *machine learning* digunakan untuk memprediksi nilai *Q-factor* jaringan komunikasi fiber optik sebagai estimasi QoT. Beberapa jumlah kanal, frekuensi serta *input power* digunakan sebagai parameter input untuk *machine learning*. Tiga algoritma *machine learning* yang digunakan yaitu *Linear Regression* (LR), *Decision Tree* (DT) dan *Random Forest* (RF). Kinerja serta akurasi dari ketiga *machine learning* dibandingkan dengan tujuan untuk mengetahui algoritma mana yang memiliki kinerja serta akurasi yang terbaik, agar dapat menemukan solusi terbaik serta untuk optimasi desain dan perencanaan pada jaringan fiber optik.

## 2. Material dan Metodologi

### 2.1 Sistem Komunikasi Optik

Komunikasi optik merupakan suatu metode komunikasi dimana sinyal yang ditransmisikan berbentuk cahaya dan menggunakan kabel fiber optik sebagai media transmisinya. Fiber optik merupakan sebuah *waveguide* dielektrik yang beroperasi pada frekuensi optikal [6]. Teknologi fiber optik diciptakan untuk dapat mengirimkan gelombang cahaya sepanjang serat tipis yang dibuat dengan tepat. Sinyal input yang berupa sinyal digital maupun analog diubah terlebih dahulu menjadi sinyal cahaya pada transmitter, lalu sinyal cahaya selanjutnya ditransmisikan melalui kabel fiber optik dengan bantuan sumber cahaya.

Dalam penelitian ini sumber cahaya yang digunakan adalah *Light Amplification by Stimulated Emission of Radiation* (LASER). Pada kabel optik, jenis laser yang digunakan adalah semikonduktor laser dioda. Selanjutnya sinyal cahaya yang ditransmisikan melalui fiber optik ditangkap oleh *photodetector*. Salah satu jenis *photodetector* yang dapat digunakan dalam sistem penerima komunikasi optik adalah *photodiode*. *Photodiode* berfungsi untuk menyerap foton sinyal optik yang masuk dan mengubahnya kembali menjadi arus listrik melalui proses yang berlawanan dengan yang terjadi pada semikonduktor laser. Semua foton yang masuk dengan energi yang lebih besar dari bandgap struktur semikonduktor p-n dapat menghasilkan sepasang *electron-hole* [7]. Pasangan *electron-hole*, yang dipisahkan oleh medan listrik yang kuat pada *p-n junction*, dapat meningkatkan arus listrik yang disebut *photocurrent* [8].

### 2.2 Parameter Performansi Sistem

Parameter pengukuran performansi sistem jaringan optik pada penelitian ini yaitu *Q-factor* dan *Bit Error Rate* (BER), yang merupakan parameter *Quality of Transmission* (QoT) sistem komunikasi optik.

#### 2.2.1 *Q-factor*

*Quality factor* (*Q-factor*) merupakan sebuah parameter penting dalam komunikasi optik yang digunakan untuk mengevaluasi performansi jaringan optik [1]. Nilai *Q-factor* dapat diperoleh dari

$$Q \text{ factor} = \frac{10^{\frac{SNR}{10}}}{2}. \quad (1)$$

Nilai SNR didapatkan dengan rumus

$$\frac{S}{N} = \frac{\langle i_p^2 \rangle M^2}{2q(I_p + I_D)M^2 F(M)B + 2qI_L B + 4k_B T B / R_L}, \quad (2)$$

### 2.3 Machine Learning

*Machine Learning* (ML) merupakan bagian dari *Artificial Intelligence* (AI) yang mempelajari tentang algoritma dan model statistik dan diterapkan pada sistem komputer agar dapat menjalankan tugas tanpa perlu diprogram berulang kali [2]. *Machine learning* membutuhkan data yang nantinya digunakan sebagai *training data* dan sebagai data validasi. Konsep dari *machine learning* sendiri adalah tentang menentukan pola, dengan cara menganalisis data latihan sampai algoritma terlatih dan dapat melakukan tugas yang sebelumnya tidak diprogram [3]. Terdapat tiga jenis *machine learning*, yaitu *Supervised Learning*, *Unsupervised Learning* dan *Reinforcement Learning*. Pada penelitian ini *machine learning* yang digunakan adalah *supervised learning* dan algoritma yang digunakan adalah *Linear Regression* (LR), *Decision Tree* (DT) dan *Random Forest* (RF).

#### 2.3.1 Algoritma Linear Regression

Regresi linear merupakan sebuah algoritma pembelajaran regresi yang mempelajari model yang merupakan kombinasi linear dari contoh fitur input [9]. Pada regresi linear variabel  $y$  yang merupakan variabel prediksi atau output yang belum diketahui nilainya, didapatkan dengan cara menghitung beberapa fungsi dari variabel  $x$  yang nilainya telah diketahui serta menambahkan angka konstan, yang disebut bias [3]. Secara matematis, persamaan umum regresi linear dapat dituliskan:

$$y = \beta X + \alpha, \quad (3)$$

dengan  $y$  merupakan vektor dari nilai respon.  $X$  menyatakan matriks dari variabel  $x$  yang digunakan untuk menebak variabel  $y$ . Alpha ( $\alpha$ ) adalah nilai bias, yang merupakan konstanta, sedangkan beta ( $\beta$ ) adalah vektor koefisien yang digunakan model regresi linear dengan bias untuk membuat prediksi [3].

#### 2.3.2 Algoritma Decision Tree

*Decision tree* merupakan salah satu jenis *supervised machine learning* yang digunakan untuk permasalahan klasifikasi dan regresi [2]. Sesuai dengan namanya, *decision tree* menggunakan pohon sebagai representasi pengambilan keputusan, dimulai dari *root node* yang merupakan node awal yang mewakili seluruh sampel yang selanjutnya dibagi ke dalam *interior node*. *Interior Node* mewakili fitur dalam kumpulan data dan setiap node memiliki cabang yang merupakan suatu kondisi yang harus dipenuhi. Dan dibagian akhir cabang, terdapat *Leaf Node* yang mewakili output yang dihasilkan. Proses pada *decision tree* yaitu mengubah bentuk data dari tabel menjadi model pohon, kemudian mengubah model pohon tersebut menjadi aturan. Ross Quinlan menciptakan algoritma *decision tree* berdasarkan algoritma *information gain* (ID3) pada tahun 1979 [3]. *Information gain* bergantung pada rumus *information entropy*, menjelaskan nilai yang diharapkan dari sebuah informasi yang terdapat dalam sebuah variabel.

#### 2.3.3 Algoritma Random Forest

*Random forest* merupakan algoritma *supervised machine learning* untuk klasifikasi dan regresi yang disusun dari banyak *decision tree* pada waktu pelatihan dan menghasilkan kelas untuk *random forest classification* dan rata-rata prediksi untuk *random forest regression* dari setiap pohon pada *decision tree*. Penggabungan *decision tree* pada algoritma *random forest* menggunakan metode *bagging* (juga dikenal sebagai *bootstrap aggregation*) pada data latihnya yang digunakan untuk meningkatkan hasil keseluruhan [3]. Dalam *bootstrapping*, sampel diambil dari contoh data latih untuk membuat dataset latih baru, yang memungkinkan algoritma untuk mengambil sampel dari data latih beberapa kali.

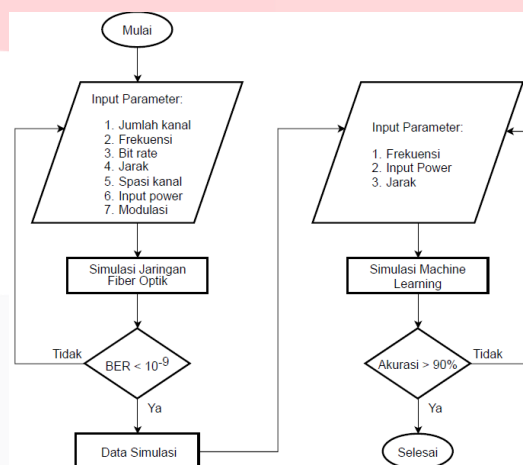
## 2.4 Tingkat Akurasi

Tingkat akurasi dari suatu algoritma dapat dilihat dari prediksi output yang dihasilkan. Apabila prediksi yang dihasilkan semakin mendekati data asli, maka tingkat akurasinya semakin tinggi. Pada penelitian ini, metode yang digunakan untuk mengukur tingkat akurasi adalah  $R^2$  (R square).  $R^2$  juga dikenal sebagai koefisien penentuan, yang memiliki nilai mulai dari 0 hingga 1 [3].  $R^2$  menunjukkan skala variansi dalam variabel dependen yang dapat diprediksi dari variabel independen. Persamaan  $R^2$  dapat dituliskan:

$$R^2 = 1 - \frac{\Sigma(Xw-y)^2}{\Sigma(\hat{y}-y)^2}, \quad (4)$$

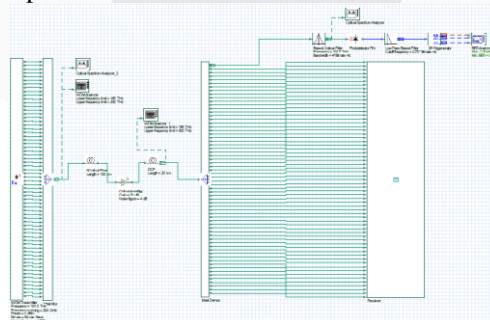
bagian pembilang mewakili perbedaan antara nilai respon dan prediksi, sedangkan bagian penyebut mewakili perbedaan antara rata-rata respon dengan respon itu sendiri.

## 2.5 Diagram Alir Penelitian



Gambar 1. Diagram Alir Penelitian

Pada Gambar 1 menunjukkan tahapan-tahapan yang dilakukan dalam penelitian ini. Langkah pertama yaitu menentukan parameter yang digunakan dalam simulasi jaringan optik. Model simulasi jaringan optik dengan 64 kanal ditunjukkan pada Gambar 2. Terdapat tujuh parameter yang digunakan pada penelitian ini, yaitu jumlah kanal, frekuensi, bit rate, jarak, spasi kanal, input power dan modulasi. Terdapat tiga jumlah kanal yang digunakan yaitu 16, 32 dan 64. Frekuensi pertama yang digunakan dimulai dari 191,5 THz dengan spasi kanal sebesar 200 GHz. Modulasi yang digunakan adalah modulasi *On-Off Keying – Non-Return to Zero* (OOK-NRZ). Setiap kanal dilakukan simulasi sebanyak enam kali dengan nilai input power yang berbeda, yaitu 0-5 dBm. Parameter simulasi jaringan fiber optik selengkapnya pada Tabel 1. Setelah menentukan nilai masing-masing parameter, dilakukan simulasi QoT jaringan fiber optik dengan menggunakan software simulasi jaringan optik.



Gambar 2. Model Simulasi Jaringan Fiber Optik 64 Kanal.

Tabel 1. Parameter Simulasi Jaringan Fiber Optik.

Parameter		
Transmitter	Jenis	LASER
	Input Power	0-5 dBm
	Frekuensi Pertama	191,5 THz
	Spasi Kanal	200 GHz
	Jumlah Kanal	16, 32 dan 64
Fiber Optik	Modulasi	OOK-NRZ
	Jenis	SMF
	Jarak	50, 100, 150 dan 200 Km
Receiver	Sensitivitas	0,8 A/W
Lain-lain	Bit Rate	5, 10 dan 20 Gbps

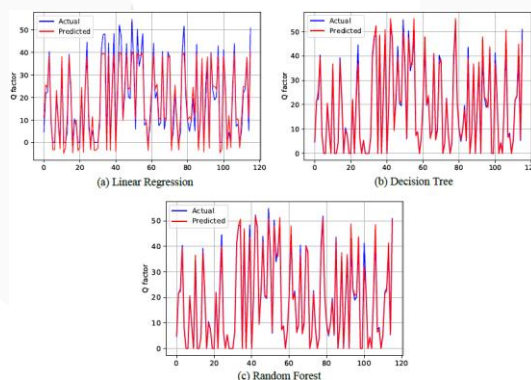
Nilai BER yang dihasilkan dari simulasi dijadikan sebagai parameter kualitas. Apabila nilai BER lebih kecil dari  $10^{-9}$ , maka dilanjutkan pada simulasi menggunakan *machine learning*. Jenis *machine learning* yang digunakan adalah *Linear Regression*, *Decision Tree* dan *Random Forest*. Tetapi jika nilai BER lebih besar dari  $10^{-9}$ , maka perlu dilakukan pengkajian ulang pada parameter yang digunakan dan melakukan simulasi QoT jaringan fiber optik ulang hingga memenuhi nilai BER yang telah ditentukan.

Dari simulasi jaringan fiber optik, selain parameter input, data yang dikumpulkan adalah nilai min BER dan *Q-factor*. Dari data-data tersebut, ditentukan parameter yang digunakan dalam simulasi *machine learning*. Dari enam parameter, dipilih tiga parameter input yaitu jumlah kanal, frekuensi dan input power. Kemudian simulasi kedua dilakukan dengan menggunakan Python 3.

Pada simulasi *machine learning*, hasil yang didapat adalah prediksi nilai *Q-factor* dan akurasi masing-masing algoritma. Sama halnya dengan simulasi pertama, parameter kualitas pada simulasi kedua adalah nilai akurasi. Akurasi dari masing-masing algoritma harus lebih besar dari 90%. Apabila kurang dari 90%, maka dilakukan pengkajian ulang pada parameter input. Selanjutnya hasil prediksi dari ketiga algoritma *machine learning* dianalisis untuk menentukan mesin mana yang memiliki tingkat akurasi terbaik.

### 3. Pembahasan Analisis Simulasi

#### 3.1 Hasil Prediksi *Machine Learning* pada 16 Kanal

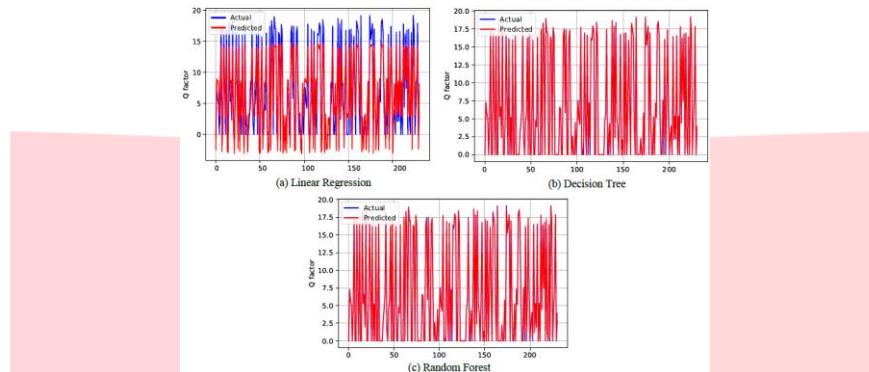


Gambar 3. Grafik Perbandingan Nilai *Q-factor* Data Sintetik 16 Kanal dengan Nilai Prediksi *Machine Learning*: (a) *Linear Regression*, (b) *Decision Tree* dan (c) *Random Forest*.

Gambar 3 menunjukkan grafik perbandingan nilai *Q-factor* data sintetik 16 kanal dengan nilai *Q-factor* yang diprediksi menggunakan ketiga algoritma *machine learning*. Dari Gambar 3 (a) dapat dilihat bahwa hasil prediksi LR masih terdapat beberapa titik yang tidak sesuai. Hal sama juga terjadi pada algoritma DT dan RF. Namun DT dan RF memiliki lebih sedikit kesalahan

prediksi jika dibandingkan dengan LR. Hal tersebut dapat dilihat dari kurva pada Gambar 3 (b) dan (c) memiliki lebih sedikit garis yang tidak sesuai dengan kurva data sintetik.

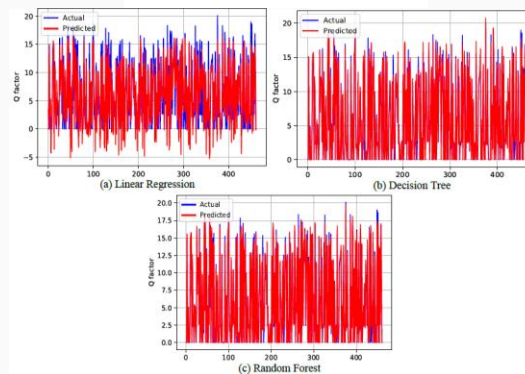
### 3.2 Hasil Prediksi *Machine Learning* pada 32 Kanal



Gambar 4. Grafik Perbandingan Nilai  $Q$ -factor Data Sintetik 32 Kanal dengan Nilai Prediksi *Machine Learning*: (a) *Linear Regression*, (b) *Decision Tree* dan (c) *Random Forest*.

Gambar 4 menunjukkan grafik perbandingan nilai  $Q$ -factor data sintetik 32 kanal dengan nilai  $Q$ -factor yang diprediksi menggunakan ketiga algoritma *machine learning*. Dari ketiga algoritma yang digunakan, dapat dilihat bahwa terdapat penurunan performansi pada algoritma LR. Pada Gambar 4 (a), hasil prediksi dengan algoritma LR masih terdapat beberapa titik yang tidak sesuai. Hal tersebut menunjukkan bahwa algoritma LR mengalami *overfitting*. Sedangkan algoritma DT dan RF memiliki lebih sedikit kesalahan prediksi jika dibandingkan dengan algoritma LR. Hal tersebut dapat dilihat dari kurva pada Gambar 4 (b) dan (c) memiliki lebih sedikit garis yang tidak sesuai dengan kurva data sintetik.

### 3.3 Hasil Prediksi *Machine Learning* pada 64 Kanal

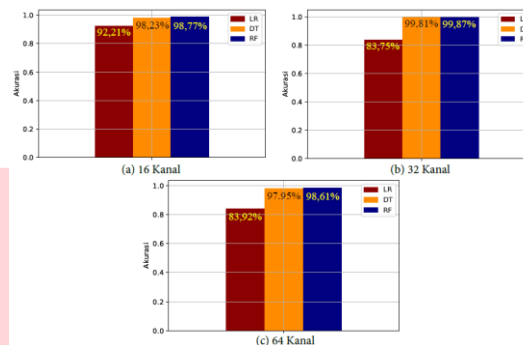


Gambar 5. Grafik Perbandingan Nilai  $Q$ -factor Data Sintetik 64 Kanal dengan Nilai Prediksi *Machine Learning*: (a) *Linear Regression*, (b) *Decision Tree* dan (c) *Random Forest*.

Gambar 5 menunjukkan grafik perbandingan nilai  $Q$ -factor data sintetik 64 kanal dengan nilai  $Q$ -factor yang diprediksi menggunakan ketiga algoritma *machine learning*. Dari ketiga algoritma yang digunakan, hasil prediksi dengan algoritma LR yang paling kurang mendekati data sintetik. Dapat dilihat pada Gambar 5 (a), terdapat banyak bagian pada kurva data prediksi yang melebihi atau bahkan kurang dari kurva data sintetik. Sedangkan algoritma DT dan RF prediksi yang dihasilkan lebih mendekati data sintetik, sesuai dengan bentuk kurva hasil pada Gambar 5 (b) dan (c) yang sesuai dengan kurva data sintetik. Namun jika dilihat lebih seksama, kesalahan prediksi pada algoritma RF lebih minimum jika dibandingkan dengan kesalahan prediksi pada

algoritma DT. Hal ini membuktikan bahwa algoritma RF mampu mengontrol permasalahan *overfitting* yang terjadi pada algoritma DT.

### 3.4 Akurasi



Gambar 6. Grafik Perbandingan Akurasi Algoritma *Machine Learning*: (a) 16 Kanal, (b) 32 Kanal dan (c) 64 Kanal.

Gambar 6. Grafik Perbandingan Akurasi Algoritma *Machine Learning*: (a) 16 Kanal, (b) 32 Kanal dan (c) 64 Kanal. Nilai akurasi dari ketiga algoritma *machine learning* pada 16 Kanal yang ditunjukkan pada Gambar 6 (a), memiliki nilai yang rendah yaitu kurang mencapai 90%, dengan LR yang paling rendah. Pada Gambar 6 (b) menunjukkan tingkat akurasi ketiga algoritma pada 32 kanal yang mencapai 99% untuk RF dan DT, sedangkan LR turun menjadi 83% akibat *overfitting*. Pada Gambar 6 (c) menunjukkan tingkat akurasi ketiga algoritma pada 64 kanal. Algoritma DT dan RF, mengalami sedikit penurunan akurasi, dengan DT mencapai 97% dan RF mencapai 98%.

Berdasarkan tingkat akurasi pada Gambar 6, dapat diambil kesimpulan bahwa algoritma DT dan RF dapat digunakan untuk memprediksi nilai *Q-factor* sebagai standar *QoT* dari sistem komunikasi fiber optik. Sedangkan algoritma LR kurang tepat untuk digunakan, karena terjadi *overfitting* yang mempengaruhi tingkat akurasi.

### 3.5 Perbandingan Hasil Simulasi Skenario I dan Skenario II

Tabel 2 menunjukkan beberapa sampel data sintetik nilai *Q-factor* hasil simulasi skenario I dan hasil prediksi *Q-factor* menggunakan *machine learning* pada skenario II. Data hasil simulasi secara lengkap berada pada Lampiran.

Tabel 2. Sampel Perbandingan Data Sintetik dengan Hasil Simulasi *Machine Learning*.

Jumlah Kanal	Frekuensi (THz)	Q factor			
		Data Sintetik	LR	DT	RF
16	193,3	6,9799	10,942	6,0249	6,1715
32	197,5	6,3201	8,7303	6,3314	6,2908
64	197,7	6,0552	7,1591	6,3711	6,2990

Dari sampel data pada Tabel 2, menunjukkan hasil prediksi *machine learning* semakin mendekati nilai asli dari data sintetik, seiring dengan bertambahnya jumlah kanal. Hal ini menunjukkan bahwa *machine learning* akan bekerja secara optimal apabila data yang digunakan berjumlah banyak. *Machine learning* bekerja dengan cara memecah data menjadi dua bagian, yaitu data latihan dan data validasi. Karena data latihan umumnya memiliki persentase hanya 20-30% dari data keseluruhan, maka sangat jelas apabila jumlah data berpengaruh terhadap hasil prediksi. Semakin banyak algoritma berlatih, maka hasil prediksi yang dikeluarkan akan semakin akurat.

Selain jumlah data, penggunaan jenis algoritma juga berpengaruh terhadap hasil prediksi. Dalam Tabel 2, menunjukkan bahwa algoritma *Linear Regression* (LR) kurang tepat dalam memprediksi *Q-factor*, dibandingkan dengan *Decision Tree* (DT) dan *Random Forest* (RF). Hal ini disebabkan karena terjadinya *overfitting* pada algoritma LR, yang menyebabkan adanya kesalahan

prediksi akibat algoritma terlalu fokus pada data latihan. *Overfitting* juga terjadi pada algoritma DT dan RF, namun kedua algoritma tersebut dapat meminimalisir terjadinya *overfitting* dengan menggunakan metode *bagging*.

Tabel 3. Tabel Perbandingan Waktu Komputasi *Software* Simulasi Jaringan Optik dengan *Machine Learning*.

Jumlah Kanal	Waktu Komputasi			
	Software Simulasi	LR	DT	RF
16	1 menit 13 s	0.000112 s	0.000037 s	0.000114 s
32	54 s	0.000075 s	0.000044 s	0.000059 s
64	20 menit 18 s	0.000089 s	0.000079 s	0.000106 s

Tabel 3 menunjukkan perbandingan waktu komputasi antara *software* simulasi jaringan optik dengan *machine learning*. Waktu komputasi yang diperlukan *machine learning* jauh lebih singkat dibandingkan dengan waktu yang diperlukan *software* simulasi jaringan optik. Perbedaan waktu komputasi antara kedua simulasi yang dilakukan terpaut cukup jauh. Simulasi *machine learning* rata-rata memerlukan waktu sekitar 0.000079 detik. Sedangkan untuk *software* simulasi jaringan optik memerlukan waktu rata-rata 7 menit 28 detik. Maka dapat disimpulkan bahwa penerapan *machine learning* untuk memprediksi QoT sistem komunikasi fiber optik, mampu mempersingkat waktu komputasi yang dibutuhkan.

#### 4. Kesimpulan

Dalam penelitian ini, tiga algoritma *machine learning* diuji untuk memprediksi *Q-factor* jaringan komunikasi fiber optik dengan beberapa jumlah kanal, jarak dan *input power* yang berbeda. Berdasarkan hasil yang diperoleh, algoritma *Decision Tree* (DT) dan *Random Forest* (RF) memiliki tingkat akurasi yang tinggi untuk memprediksi *Q-factor*. Sedangkan algoritma *Linear Regression* (LR) tidak dapat digunakan karena mengalami *overfitting*. Jumlah data yang digunakan untuk simulasi *machine learning* memiliki pengaruh yang besar terhadap tingkat akurasi algoritma. Waktu komputasi yang diperlukan *machine learning* lebih singkat yaitu 0.000079 detik.

#### Referensi:

- [1] K. F. Rahman, F. Afrin, and F. S. bin Taip, "Optical Network Performance Analysis through Prediction of Q Factor on Simulated and Validated Dataset," in *2018 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAJET)*, 2018, pp. 1–4.
- [2] S. Marsland, *Machine learning: an algorithmic perspective*. Chapman and Hall/CRC, 2014.
- [3] J. P. Mueller and L. Massaron, *Machine learning for dummies*. John Wiley & Sons, 2016.
- [4] A. A. Algedir and T. Y. Elganimi, "Machine Learning Models for Predicting the Quality Factor of FSO Systems with Multiple Transceivers," in *2020 2nd Global Power, Energy and Communication Conference (GPECOM)*, 2020, pp. 308–311.
- [5] C. Tremblay and S. Aladin, "Machine learning techniques for estimating the quality of transmission of lightpaths," in *2018 IEEE Photonics Society Summer Topical Meeting Series (SUM)*, 2018, pp. 237–238.
- [6] G. Keiser, "Optical fiber communications," *Wiley Encycl. Telecommun.*, 2003.
- [7] M. Cvijetic, *Optical transmission systems engineering*. Artech House, 2004.
- [8] R. Ramaswami, K. Sivarajan, and G. Sasaki, *Optical networks: a practical perspective*. Morgan Kaufmann, 2009.
- [9] A. Burkov, *The hundred-page machine learning book*. Andriy Burkov Quebec City, Can., 2019.