

DISERTASI

**PEMODELAN PREDIKSI *PATH LOSS* PADA SKENARIO
MODA TRANSPORTASI FREKUENSI UHF (*ULTRA HIGH
FREQUENCY*) DENGAN MENGGUNAKAN METODE
*HYBRID EMPIRIS MACHINE LEARNING***

**Diajukan untuk memenuhi salah satu syarat memperoleh gelar
Doktor Ilmu Teknik pada Fakultas Teknik Universitas Sriwijaya**



**BENGAWAN ALFARESI
03043681823007**

**PROGRAM STUDI DOKTOR ILMU TEKNIK
FAKULTAS TEKNIK UNIVERSITAS SRIWIJAYA
PALEMBANG
2023**

HALAMAN PENGESAHAN

PEMODELAN PREDIKSI *PATH LOSS* PADA SKENARIO MODA TRANSPORTASI FREKUENSI UHF (*ULTRA HIGH FREQUENCY*) DENGAN MENGGUNAKAN METODE *HYBRID EMPIRIS* *MACHINE LEARNING*

DISERTASI

Diajukan untuk memenuhi salah satu syarat memperoleh gelar
Doktor Ilmu Teknik pada Fakultas Teknik Universitas Sriwijaya


Oleh:

BENGAWAN ALFARESI


03043681823007

Indralaya, 4-Agustus- 2023

Promotor


Prof. Ir. Zainuddin Nawawi, Ph.D., IPU
NIP. 195903031985031004

Co Promotor



Dr. Ir. Bhakti Yudho S.S.T., M.T., IPM
NIP. 1975021120031231002

Mengetahui

Dekan Fakultas Teknik


Prof. Dr. Eng. Ir. H. Joni Arliansyah, M.T.
NIP. 196706151995121002

Ketua Program Studi


Prof. Dr. Ir. Nukman, M.T.
NIP. 195903211987031001

LEMBAR PERSETUJUAN


Karya Tulis Ilmiah berupa Laporan Akhir Disertasi ini dengan Judul " Pemodelan Prediksi Kinerja Siswa dengan "Pemodelan Prediksi *Path Loss* pada Skenario Moda Transportasi Frekuensi UHF (*Ultra High Frequency*) dengan Menggunakan Metode *Hybrid Empiris-Machine learning*" telah dipertahankan dihadapan Tim Penguji Karya Tulis Ilmiah Fakultas Teknik Universitas Sriwijaya pada tanggal 4 Agustus 2023.

Indralaya, 4 Agustus 2023

Tim Penguji Karya Tulis Ilmiah berupa Disertasi.

Ketua :

Prof. Dr. Ir. Nukman, M.T.
NIP. 195903211987031001

()

Anggota :


1. M. Irfan Jambak, ST, M.Eng, Ph.D.
NIP. 197110012006041001

()

2. DR. Eng. Tresna Dewi, S.T., M.ENG.
NIP. 197711252000032001

()

3. Dr. Eng. Ir. Suci Dwijayanti, ST, MS.
NIP. 198407302008122001

()

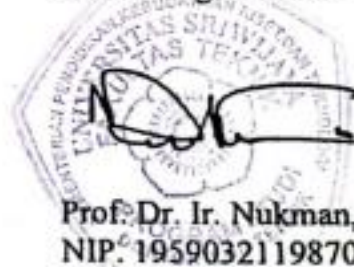
Mengetahui

Dekan Fakultas Teknik



Prof. Dr. Eng. Ir. H. Joni Arliansyah, M.T.
NIP. 196706151995121002

Ketua Program Studi



Prof. Dr. Ir. Nukman, M.T.
NIP. 195903211987031001

HALAMAN PERNYATAAN INTEGRITAS

Yang bertanda tangan di bawah ini:

Nama : Bengawan Alfaresi

NIM : 03043681823007

Judul : “Pemodelan Prediksi *Path loss* pada Skenario Moda Transportasi Frekuensi UHF (*Ultra High Frequency*) dengan Menggunakan Metode *Hybrid Empiris-Machine learning*”

Menyatakan bahwa Laporan Akhir Disertasi saya merupakan hasil karya sendiri didampingi Promotor dan Co-Promotor dan bukan hasil penjiplakan/plagiat. Apabila ditemukan unsur penjiplakan/plagiat dalam Disertasi ini, maka saya bersedia menerima sanksi akademik dari Universitas Sriwijaya sesuai aturan yang berlaku.

Demikian, pernyataan ini saya buat dalam keadaan sadar dan tanpa ada paksaan dari siapapun.

Palembang, 4 Agustus 2023

A handwritten signature in black ink is written over a 1000 Rupiah postage stamp. The stamp features the Garuda Pancasila emblem and the text '1000', 'METERAI', and '1 TEMPEL'. The serial number '148AKX762751798' is visible at the bottom of the stamp.

Bengawan Alfaresi

KATA PENGANTAR

Alhamdulillahirobbil'alamin, Puji syukur penulis panjatkan kehadirat Allah SWT, karena atas rahmat hidayah-Nya lah penulis dapat menyelesaikan disertasi yang berjudul "Pemodelan Prediksi *Path loss* pada Skenario Moda Transportasi Frekuensi UHF (*Ultra High Frequency*) dengan Menggunakan Metode *Hybrid Empiris-Machine learning*". Shalawat serta Salam semoga selalu tercurahkan kepada Rasulullah Nabi Muhammad SAW yang telah membawa cahaya Islam di alam semesta.

Penyusunan Disertasi ini merupakan salah satu syarat dalam rangka menyelesaikan pendidikan pada Program Studi Doktor Ilmu Teknik pada Fakultas Teknik Universitas Sriwijaya. Banyak pihak yang telah membantu dan berkontribusi dalam proses penulisan disertasi ini, sehingga penulis ingin menyampaikan terima kasih kepada:

1. Kedua orang tua: Ayahanda Prof. Dr. Ir. H. Suntoro Wongso Atmojo, MS, dan Ibunda Prapti Rahayu yang selalu memberikan inspirasi, dorongan, tangis dan Doa yang selalu mengiringi penulis dalam menempuh perjalanan perkuliahan sampai menyelesaikan program doktoral ini.
2. Istriku tercinta Asti Gumartifa, S.Pd, M.Pd dan anak-anakku tersayang: Diandra Muhammad Arrayan, Asyifa Putri Batrisya dan Abrisam Muhammad Al-fatih yang selalu memberikan Doa, semangat dan dukungan tak terhingga kepada penulis. Penulis ingin sampaikan permohonan maaf jika dalam perjalanan perkuliahan S3 ini, banyak waktu keluarga yang telah dikorbankan dan terkuras untuk perjalanan perkuliahan S3 ini. Dan Penulis ucapkan terima kasih kepada ayahanda Gunhi dan Ibunda Maryani yang selalu memberikan Doa dan dukungan kepada penulis.
3. Prof. Dr. Ir. H. Anis Saggaff, MSCE, IPU, ASEAN. Eng selaku Rektor Universitas Sriwijaya.
4. Prof. Dr. Eng. Ir. H. Joni Arliansyah, M.T., selaku Dekan Fakultas Teknik Universitas Sriwijaya.
5. Prof. Dr. Ir. Nukman, M.T., selaku Koordinator Program Studi Ilmu Teknik Program Doktor, Fakultas Teknik, Universitas Sriwijaya.
6. Prof. Ir. Zainuddin Nawawi, Ph.D, IPU selaku Promotor yang telah memberikan arahan dan bimbingan selama penyusunan disertasi ini.
7. Dr. Bhakti Yudho Suprpto, S.T, M.T., selaku Co-Promotor yang telah memberikan

arahan dan bimbingan selama penyusunan disertasi ini.

8. (alm) Dr. Reza Firsandaya Malik, S.T., M.T selaku yang semasa hidupnya telah memberikan masukan, arahan, dan bimbingan.
9. Rektor Universitas Muhammadiyah Palembang Dr. Abid Djazuli, S.E., M.M. Dekan Fakultas Teknik Dr. Ir. Kgs. Ahmad Roni, M.T, Kepala Program Studi Teknik Elektro Ir. Taufik Barlian, M.Eng dan seluruh rekan-rekan teknik elektro UM-Palembang yang telah memfasilitasi, memberikan kesempatan dan memberikan semangat luar biasa kepada Penulis, sehingga Penulis dapat menyelesaikan S3.

Penulis menyadari dalam penyusunan disertasi ini masih terdapat kekurangan dan kekeliruan. Kritik dan saran yang bersifat membangun sangat diharapkan demi perbaikan dan perkembangan ilmu pengetahuan di masa mendatang. Semoga Disertasi ini dapat bermanfaat bagi para pembaca, peneliti, pemerhati ilmu pengetahuan, serta bagi dunia pendidikan secara luas. Akhir kata penulis mengucapkan terima kasih.

Palembang, 4 Agustus 2023

Penulis

RINGKASAN

PEMODELAN PREDIKSI *PATH LOSS* PADA SKENARIO TRANSPORTASI FREKUENSI UHF (ULTRA HIGH FREQUENCY) DENGAN MENGGUNAKAN METODE *HYBRID EMPIRIS MACHINE LEARNING*

Karya Tulis Ilmiah Berupa Disertasi, 4-Agustus-2023

Bengawan Alfaresi, S.T, M.T dipromotori oleh Prof.Ir. Zainuddin Nawawi, Ph.D dan Dr. Bhakti Yudho Suprpto, S.T, M.T

Path loss Prediction Modelling in Transportation Skenario s with UHF (Ultra High Frequency) Using Hybrid Empirical-Machine learning Methods

Pemodelan prediksi *path loss* merupakan hal yang sangat penting dalam perencanaan dan optimasi jaringan *Wireless*. Model eksisting yang digunakan dalam prediksi *path loss* yaitu model empiris masih memiliki keterbatasan dalam akurasi dan penerapan wilayah. Keterbatasan fitur yang digunakan dalam model empiris juga menyebabkan salah satu faktor terhadap tingkat akurasi yang kurang baik. Perbedaan wilayah menyebabkan perbedaan fitur baik lingkungan maupun cuaca. Penelitian ini bertujuan untuk pengembangan model *hybrid empiris-machine learning* untuk prediksi *path loss* pada 3 skenario moda transportasi yaitu darat (mobil), perairan (kapal) dan LRT pada frekuensi UHF. Metode penelitian pada prediksi *path loss* dilakukan dengan menggunakan 3 proses yaitu seleksi fitur, pemodelan *hybrid Empiris-Machine learning* dan optimasi. Metode seleksi fitur dengan membandingkan 3 metode yaitu *Univariate*, *Genetic Algorithm (GA)* dan *Particle Swarm Optimization (PSO)*. Pemodelan hybrid dengan menggunakan model empiris Cost-Hatta dan 3 algoritma *machine learning* yaitu RF, ANN-MLP, KNN. Kontribusi penelitian ini yaitu memberikan keunggulan dalam hal jumlah fitur, dan pengintegrasian model empiris dengan *machine learning* dengan pendekatan model seleksi fitur *Univariate-GA-PSO* pada eksplorasi lokasi moda transportasi yang belum diteliti sebelumnya. Hasil yang diperoleh dari penelitian ini menunjukkan bahwa pada moda transportasi darat (mobil), model hybrid terbaik yaitu model CostHatta-RF dengan implementasi 13 fitur hasil seleksi fitur PSO dengan tingkat akurasi RMSE 2.777. Pada moda transportasi air (kapal), model hybrid terbaik yaitu model CostHatta-RF dengan implementasi 17 fitur hasil seleksi fitur *Univariate* dengan tingkat akurasi RMSE 3.010. Pada moda transportasi LRT, model hybrid terbaik yaitu model CostHatta-RF dengan implementasi 16 fitur hasil seleksi fitur *Univariate* dengan tingkat akurasi RMSE 3.401. Hasil tersebut memiliki tingkat akurasi yang lebih baik dibandingkan dengan penelitian sebelumnya.

Keyword: *Path loss*, *Machine learning*, Hybrid, Empiris, UHF, Moda Transportasi

SUMMARY

MODELING OF PATH LOSS PREDICTION IN TRANSPORTATION SKENARIO S USING UHF (ULTRA HIGH FREQUENCY) USING HYBRID EMPIRICAL MACHINE LEARNING METHOD

Doctoral Research, 4th August 2023

Bengawan Alfaresi, S.T, M.T Supervised by Prof.Ir. Zainuddin Nawawi, Ph.D and Dr. Bhakti Yudho Suprpto, S.T, M.T

Modeling of Path loss Prediction in Transportation Skenario s Using UHF (Ultra High Frequency) Using Empirical-Machine Leaning Method

Path loss prediction modeling is very important in planning and optimizing Wireless networks. The existing model used in path loss prediction, namely the empirical model, still has limitations in accuracy and regional application. The limited features used in the empirical model also cause a poor level of accuracy. Regional differences cause differences in both environmental and weather features. This research aims to develop a hybrid empirical-machine learning model for predicting path loss in three transportation mode scenarios, namely land (car), water (ship) and LRT on UHF frequencies. The research method for path loss prediction is carried out using 3 processes, namely feature selection, hybrid Empirical-Machine learning modeling and optimization. Feature selection method by comparing 3 methods, namely Univariate, Genetic Algorithm (GA) and Particle Swarm Optimization (PSO). Hybrid modeling uses the Cost-Hatta empirical model and three machine learning algorithms, namely RF, ANN-MLP, and KNN. The contribution of this research is providing superiority in terms of the number of features and integrating empirical models with machine learning with the Univariate-GA-PSO feature selection model approach in exploring the location of transportation modes that have not been studied previously. The results obtained from this research show that in the land transportation mode (car), the best hybrid model is the CostHatta-RF model with the implementation of 13 features resulting from PSO feature selection with an accuracy level of RMSE 2,777. In the water transportation mode (ships), the best hybrid model is the CostHatta-RF model with the implementation of 17 features resulting from Univariate feature selection with an accuracy level of RMSE 3,010. In the LRT transportation mode, the best hybrid model is the CostHatta-RF model with the implementation of 16 features resulting from Univariate feature selection with an accuracy level of RMSE 3,401. These results have a better level of accuracy compared to previous research.

Keyword: Path loss, Machine learning, Hybrid, Empirical model, UHF, transportation

DAFTAR ISI

HALAMAN PENGESAHAN	i
LEMBAR PERSETUJUAN	ii
HALAMAN PERNYATAAN INTEGRITAS	iii
KATA PENGANTAR.....	iv
RINGKASAN	vi
SUMMARY	vii
DAFTAR ISI	viii
DAFTAR GAMBAR	xi
DAFTAR TABEL	xii
DAFTAR SINGKATAN.....	xiv
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	5
1.3 Tujuan dan Manfaat	5
1.3.1 Tujuan.....	5
1.3.2 Manfaat.....	6
1.4 Hipotesis	6
1.5 Novelty	7
1.6 Batasan Masalah	7
1.7 Sistematika Penulisan	8
BAB II TINJAUAN PUSTAKA	9
2.1. Pemodelan <i>Path loss</i> Propagasi Jaringan Nirkabel	9
2.1.1 Model Empiris pada Jaringan Nirkabel.....	10
2.1.1.1 Model Okumura-Hatta	10
2.1.1.2 COST231-Hatta Model	11
2.1.1.3 ECC -33 Model	12
2.1.1.4 Ericsson Model.....	12
2.2. <i>Machine learning</i>	15
2.2.1 Arsitektur <i>Machine learning</i>	16
2.2.1.1 <i>Random Forest (RF) Regressor</i>	16
2.2.1.2 <i>K-Nearest Neighbor (KNN) Regressor</i>	17
2.2.1.3 <i>Artificial Neural Network – Multi Layer Perceptron (ANN-MLP)</i>	18

2.2.2	Model <i>Machine learning</i> pada Prediksi <i>Path loss</i> Jaringan <i>Wireless</i>	21
2.2.3	Alur Penelitian Terdahulu pada Pemodelan Prediksi <i>Path loss</i> dengan <i>Machine learning</i>	41
2.2.4	Dataset Pemodelan <i>Path loss</i> pada <i>Machine learning</i>	42
2.3.	Gap Penelitian.....	45
2.4.	Evaluasi Metrik Kinerja pada Pemodelan <i>Path loss</i> Propagasi.....	45
2.4.1	Matrik Kinerja Model <i>Machine learning</i>	46
2.4.2	Penggunaan Matrik Kinerja pada Pemodelan <i>Path loss</i>	46
2.5.	Algoritma Optimasi Evolusioner	47
2.5.1	Penggunaan <i>Genetic Algorithm</i> (GA) untuk Seleksi Fitur.....	47
2.5.2	Penggunaan <i>Particle swarm optimization</i> (PSO) untuk Seleksi Fitur	48
2.6.	Metode <i>Drive test</i> pada Pengukuran <i>Path loss</i>	49
BAB III METODE PENELITIAN.....		51
3.1.	Kerangka Penelitian.....	51
3.1.1.	Kerangka Dasar Penelitian	51
3.1.2.	Kerangka Konseptual Penelitian	53
3.1.3.	Grafik Proses Penelitian	56
3.2.	Tempat dan Alat Penelitian	57
3.2.1	Tempat Penelitian	57
3.2.2	Alat Penelitian.....	60
3.3.	Tahapan Proses Penelitian	60
3.3.1	Tahap pengukuran (pengambilan data).....	61
3.3.2	Tahap Pengolahan Data	68
BAB IV PEMODELAN PREDIKSI <i>PATH LOSS</i> DENGAN MENGGUNAKAN HYBRID EMPIRIS-MACHINE LEARNING.....		69
4.1	Pendahuluan.....	69
4.2	Metodologi Penelitian <i>Hybrid Empiris-Machine learning</i>	70
4.3	Pemodelan Empiris dan <i>Hybrid Empiris-Machine learning</i>	71
4.4	Performansi Model Empiris pada Moda Transportasi.....	78
4.5	Performansi Model <i>Hybrid Empiris-Machine learning</i> pada Moda Transportasi	82
4.6	Perbandingan Model Empiris dan <i>Hybrid Empiris-Machine learning</i>	86
BAB V PENGEMBANGAN MODEL PREDIKSI <i>PATH LOSS</i> DENGAN PENDEKATAN <i>FEATURE SELECTION-MACHINE LEARNING</i>.....		89
5.1	Pendahuluan.....	89

5.2 Metodologi Penelitian Teknik Seleksi Fitur- <i>Machine learning</i>	90
5.3 Pengembangan Model dengan Pendekatan Seleksi Fitur- <i>Machine learning</i>	91
5.4 Proses Seleksi Fitur dengan Menggunakan Metode <i>Univariate</i>	93
5.5 Proses Seleksi Fitur dengan <i>Genetic Algorithm (GA)</i>	103
5.6 Proses Seleksi Fitur dengan <i>Particle Swarm Optimization (PSO)</i>	106
5.7 Evaluasi Proses Seleksi Fitur.....	110
BAB VI OPTIMASI <i>HYPER-PARAMETER MACHINE LEARNING</i> PADA PEMODELAN PREDIKSI <i>PATH LOSS</i> PADA MODA TRANSPORTASI	114
6.1 Pendahuluan.....	114
6.2 Metodologi Penelitian Optimasi Hyper-Parameter <i>Machine learning</i>	114
6.3 Optimasi <i>Hyper-Parameter</i> pada <i>Random Forest (RF)</i>	115
6.3.1 Optimasi Parameter : <i>max_features</i>	116
6.3.2 Optimasi Parameter : <i>max_depth</i>	117
6.3.3 Optimasi Parameter : <i>n_estimators</i>	119
6.4 Optimasi <i>Hyper-Parameter</i> pada ANN-MLP	120
6.4.1 Optimasi Parameter : <i>Optimizer</i>	121
6.4.2 Optimasi Parameter : <i>Activation Function</i>	123
6.4.3 Optimasi Parameter : Jumlah <i>Hidden layer</i>	125
6.4.4 Optimasi Parameter : Jumlah <i>Neuron</i>	127
6.5 Optimasi Hyper-Parameter pada <i>K-Nearest Neighbor (KNN)</i>	128
6.5.1 Optimasi Parameter : <i>Metric</i>	129
6.5.2 Optimasi Parameter : <i>Algorithm</i>	131
6.5.3 Optimasi Parameter : <i>weighting</i> dan jumlah <i>n_neighbor</i>	132
6.6 Evaluasi Proses Optimasi Hyper-Parameter <i>Machine learning</i>	134
6.7 Perbandingan antara <i>Proposed Model</i> dengan Model Sebelumnya	137
BAB VII KESIMPULAN	142
DAFTAR PUSTAKA.....	143
LAMPIRAN	153

DAFTAR GAMBAR

Gambar 2. 1 Multi Layer Perceptron Sederhana dengan 1 Hidden Layer	19
Gambar 2. 2 Multi Layer Perceptron lebih dari 1 hidden layer	20
Gambar 2. 3 Alur Penelitian Terdahulu pada Pemodelan Path loss Machine learning....	41
Gambar 3. 1 Kerangka Dasar Penelitian	53
Gambar 3. 2 Kerangka Konseptual Penelitian	55
Gambar 3. 3 Grafik Proses Penelitian	56
Gambar 3. 4 Rute Pengukuran pada Transportasi Darat (Mobil).....	58
Gambar 3. 5 Rute pengukuran pada moda Transportasi Air (Kapal).....	58
Gambar 3. 6 Rute pengukuran pada moda Transportasi LRT	59
Gambar 3. 7 Peralatan yang digunakan dalam pengukuran di Lapangan	60
Gambar 3. 8 Skenario Pengukuran pada Transportasi Darat (Mobil)	62
Gambar 3. 9 Skenario Pengukuran pada Trasnportasi Air (Kapal).....	62
Gambar 3. 10 Skenario Pengukuran pada Transportasi LRT.....	63
Gambar 3. 11 Pola Radiasi Antenna Uni-directional (a) Horizontal Pattern (b) Vertical Pattern.....	65
Gambar 3. 12 (a) Sudut Horizontal RX from main-beam TX (β) (b) Sudut Vertical RX dari main-beam TX (α).....	65
Gambar 3. 13 (a) map overlay Bangunan pada Google Earth (b) Peta Distribusi Bangunan.....	67
Gambar 4. 1 Metodologi Penelitian Hybrid Empiris-Machine learning	70
Gambar 4. 2 Diagram flow Pengembangan Model Hybrid Empiris-Machine learning ..	76
Gambar 4. 3 Arsitektur ANN-MLP dengan 2 Hidden Layer	78
Gambar 5. 1 Metodologi Peneltian Seleksi Fitur	90
Gambar 5. 2 Diagram flow Pengembangan Model dengan Pendekatan Seleksi Fitur....	93
Gambar 5. 3 Nilai mutual_info_regression (MI) pada Moda Transportasi Darat (Mobil)	94
Gambar 5. 4 Nilai mutual_info_regression (MI) pada Moda Transportasi Air (Kapal) ..	97
Gambar 5. 5 Nilai mutual_info_regression (MI) pada Moda Transportasi LRT	100
Gambar 6. 1 Metodologi Penelitian Optimasi Hyper-Parameter Machine learning	115
Gambar 6. 2 Nilai RMSE untuk Optimasi Max_depth pada Random Forest	118
Gambar 6. 3 Nilai RMSE pada Optimasi n_estimators pada arsitektur Random Forest	119
Gambar 6. 4 Arsitektur Jaringan ANN-MLP pada Optimasi Hyper-parameter.....	120
Gambar 6. 5 Perbandingan RMSE untuk Optimizer (MLP) pada Moda Transportasi ..	122
Gambar 6. 6 Perbandingan RMSE untuk Activation Function (MLP) pada Moda Transportasi	124
Gambar 6. 7 Perbandingan RMSE untuk jumlah Hidden layer (MLP) pada Moda Transportasi	126
Gambar 6. 8 Nilai RMSE pada optimasi n_Metric pada arsitektur KNN	130
Gambar 6. 9 Nilai RMSE pada optimasi jenis 'Algorithm' pada arsitektur KNN.....	131
Gambar 6. 10 Nilai RMSE pada optimasi weight dan n_neighbor pada arsitektur KNN	133

DAFTAR TABEL

Tabel 2. 1 Parameter Lingkungan pada Model Ericsson.....	13
Tabel 2. 2 Literatur Penelitian Path loss.....	32
Tabel 2. 3 Literatur Penelitian Path loss Berdasarkan Skenario Pengukuran Dataset	36
Tabel 2. 4 Literatur Penelitian Path loss Berdasarkan Pemodelan Machine learning.....	39
Tabel 2. 5 Dataset pada Pemodelan Machine learning	43
Tabel 3. 1 Fitur Output Pemodelan Prediksi Path loss.....	63
Tabel 4. 1 Rumus Persamaan Matematis Model Empiris	71
Tabel 4. 2 Rumus Persamaan Matematis Model Machine learning.....	72
Tabel 4. 3 Parameter Setting pada Algoritma Machine learning	77
Tabel 4. 4 Performansi Model Empiris pada moda Transportasi Darat (Mobil)	79
Tabel 4. 5 Performansi Model Empiris pada moda Transportasi Air (Kapal)	80
Tabel 4. 6 Performansi Model Empiris pada moda Transportasi LRT	81
Tabel 4. 7 Performansi Model Hybrid Empiris-Machine learning pada moda Transportasi Darat (Mobil).....	83
Tabel 4. 8 Performansi Model Hybrid Empiris-Machine learning pada moda Transportasi Air (Kapal)	84
Tabel 4. 9 Performansi Model Hybrid Empiris- <i>Machine learning</i> pada Moda Transportasi LRT	85
Tabel 4. 10 Perbandingan Performansi Model Empiris & Hybrid pada Moda Transportasi Darat (Mobil).....	87
Tabel 4. 11 Perbandingan Performansi Model Empiris & Hybrid pada Moda Transportasi Air (Kapal)	87
Tabel 4. 12 Perbandingan Performansi Model Empiris & Hybrid pada Moda Transportasi LRT	88
Tabel 5. 1 Cara Kerja Teknik Seleksi Fitur.....	91
Tabel 5. 2 Pemingkatan Fitur berdasarkan Nilai MI pada Moda Transportasi Darat (Mobil).....	95
Tabel 5. 3 Nilai Evaluasi pada Kombinasi Jumlah Fitur pada Transportasi Darat (Mobil)	96
Tabel 5. 4 Pemingkatan Fitur berdasarkan Nilai MI pada Moda Transportasi Air (Kapal).....	98
Tabel 5. 5 Nilai Evaluasi pada Kombinasi Jumlah Fitur pada Transportasi Air (Kapal).	99
Tabel 5. 6 Pemingkatan Fitur berdasarkan Nilai MI pada Moda Transportasi LRT ..	101
Tabel 5. 7 Nilai Evaluasi pada Kombinasi Jumlah Fitur pada Transportasi LRT.....	102
Tabel 5. 8 Kombinasi Fitur pada Genetic Algorithm Moda Transportasi Darat (Mobil)	103
Tabel 5. 9 Kombinasi Fitur pada Genetic Algorithm Moda Transportasi Air (Kapal) ..	104
Tabel 5. 10 Kombinasi Fitur pada Genetic Algorithm Moda Transportasi LRT	105
Tabel 5. 11 Kandidat Kombinasi Variabel PSO pada Moda Transportasi Darat (Mobil)	106
Tabel 5. 12 Kandidat Kombinasi Fitur PSO pada Moda Transportasi Air (Kapal)	108
Tabel 5. 13 Kandidat Kombinasi fitur PSO pada Moda Transportasi LRT	109

Tabel 5. 14 Perbandingan Model CH-ML dengan Pendekatan FS pada Transportasi Darat	110
Tabel 5. 15 Perbandingan Model CH-ML dengan Pendekatan FS pada Transportasi Air (Kapal Perahu).....	111
Tabel 5. 16 Perbandingan Model CH-ML dengan Pendekatan FS pada Transportasi LRT	112
Tabel 6. 1 Tahapan Optimasi Parameter RF Regressor	116
Tabel 6. 2 Perbandingan nilai RMSE tiap features pada Random Forest	116
Tabel 6. 3 Tahapan Optimasi Parameter ANN-MLP	120
Tabel 6. 4 Perbandingan nilai RMSE pada tiap jumlah Neuron	127
Tabel 6. 5 Tahapan Optimasi Parameter KNN Regressor.....	129
Tabel 6. 6 Konfigurasi Parameter Terbaik pada Moda Transportasi Darat (Mobil)	135
Tabel 6. 7 Konfigurasi Parameter Terbaik pada Moda Transportasi Air (Kapal).....	135
Tabel 6. 8 Konfigurasi Parameter Terbaik pada Moda Transportasi LRT.....	136
Tabel 6. 9 Parameter seting terbaik pada Algoritma Machine learning	136
Tabel 6. 10 Hasil Perbandingan Step Optimasi Model pada Moda Transportasi Darat	137
Tabel 6. 11 Hasil Perbandingan Step Optimasi Model pada Moda Transportasi Air	138
Tabel 6. 12 Hasil Perbandingan Step Optimasi Model pada Moda Transportasi LRT ..	138
Tabel 6. 13 Perbandingan antara Proposed Model dengan Model Sebelumnya	139

DAFTAR SINGKATAN

ANFIS	: <i>Adaptive Network Based Fuzzy Inference System</i>
ANN	: <i>Artificial Neural Network</i>
AoA	: <i>Angle of Arrival</i>
AoD	: <i>Angle of Departure</i>
ARHO	: <i>American River Hydrologic Observatory</i>
BPNN	: <i>Back-Propagation Neural Network</i>
BTS	: <i>Base Transceiver Station</i>
CNN	: <i>Convolutional Neural Network</i>
COST	: <i>COopération européenne dans le domaine de la recherche Scientifique et Technique</i>
CW	: <i>Continuous Wave</i>
DNN	: <i>Deep Neural Network</i>
DT	: <i>Drive Test</i>
ECC-RF	: <i>ECC-Random Forest</i>
ELM	: <i>Extreme Learning Machine</i>
E-RF	: <i>Ericsson-Random Forest</i>
FNBW	: <i>Fist Null Band Width</i>
GA	: <i>Genetic Algorithm</i>
GHz	: <i>Giga Hertz</i>
GLCM	: <i>Gray Level Co-occurrence Matrix</i>
GP	: <i>Gaussian Process</i>
GPS	: <i>Global Positioning System</i>
GVU	: <i>Ground Vehicle Unit</i>
HP	: <i>Hand Phone</i>
HPBW	: <i>Half Power Band Width</i>
IEEE	: <i>Institute of Electrical and Electronics Engineers</i>
ITU	: <i>International Telecommunication Union</i>
KKN	: <i>K-Nearest Neighbour</i>
Lf	: <i>Floor Attenuation</i>
LOS	: <i>Line of Sight</i>
LRT	: <i>Light Rail Transit</i>
Lw	: <i>Wall Attenuation</i>
MAE	: <i>Mean Absolute Error</i>
MDA	: <i>Mean Decrease Accuracy</i>
MDI	: <i>Mean Decrease Impurity</i>
MHz	: <i>Mega Hertz</i>
ML	: <i>Machine learning</i>
MLP	: <i>Multi-Layer Perceptron</i>
MSE	: <i>Mean Square Error</i>
NFS	: <i>Neuro-Fuzzy System</i>
NLOS	: <i>Not-Line of Sight</i>

NN	: <i>Neural Network</i>
OH-RF	: <i>Okumura-Hatta Random Forest</i>
PCA	: <i>Principal Component Analysis</i>
PCC	: <i>Physical Carrying Capacity</i>
PDCP	: <i>Packet Data Convergence Protocol</i>
PL	: <i>Path loss</i>
PSO	: <i>Particle Swarm Optimization</i>
RBF	: <i>Radial Basis Function</i>
RF	: <i>Random Forest</i>
RMSE	: <i>Root Mean Square Error</i>
RMSprop	: <i>Root Mean Square Propagation</i>
RSSI	: <i>Receive Signal Strength Indicator</i>
RX	: <i>Receiver</i>
SGD	: <i>Stochastic Gradient Descent</i>
SUI	: <i>Stanford University of Interim</i>
SVR	: <i>Support Vector Regression</i>
TX	: <i>Transmitter</i>
UAV	: <i>Unmanned Aerial Vehicle</i>
UHF	: <i>Ultra High Frequency</i>
WCDMA	: <i>Wide-band Code Division Multiple Access</i>

BAB I

PENDAHULUAN

1.1 Latar Belakang

Komunikasi nirkabel memiliki peranan yang sangat penting dalam kehidupan sosial pada dewasa ini [1][2] [3]. Penggunaan data internet pada teknologi komunikasi terus meningkat dan diprediksi terus melonjak dari tahun ke tahun [4]. Permintaan dalam pemenuhan layanan serta peningkatan berbagai aplikasi yang terus berkembang menyebabkan kebutuhan pada kualitas dan kapasitas menjadi hal yang sangat penting [5][6]. Untuk mendapatkan kualitas jaringan yang baik, handal dan efisiensi tinggi, diperlukan suatu perencanaan jaringan nirkabel dengan prediksi *path loss* yang akurat [7][8][9].

Proses pengiriman informasi pada jaringan komunikasi nirkabel, informasi ditransmisikan dari pengirim ke penerima dengan menggunakan propagasi gelombang elektromagnetik [9]. Pada proses perambatannya, gelombang elektromagnetik mengalami beberapa perlakuan yaitu *free space loss*, pantulan (*reflection*), hamburan (*scattering*), pembelokan (*diffraction*) yang disebabkan oleh obyek yang berada di sekitarnya [10][11]. Efek dari beberapa perlakuan tersebut menyebabkan terjadinya redaman rugi-rugi daya (*path loss*) [12]. Variasi redaman rugi-rugi daya (*path loss*) menyebabkan terjadinya *fading*. *Fading* merupakan fluktuasi sinyal daya terima yang terjadi akibat dari superposisi gelombang elektromagnetik yang berupa sinyal langsung maupun sinyal tidak langsung yang disebabkan oleh beberapa obyek yang ada disekitarnya dimana masing-masing gelombang memiliki amplitudo dan fasa yang berbeda [13][14]. *Fading* yang terjadi terbagi menjadi dua macam yaitu *large scale fading* dan *small scale fading*. *Large scale fading* memprediksi redaman gelombang sinyal terhadap jarak yang terjadi akibat keberadaan obyek pemantul dan penghalang pada saat propagasi gelombang sinyal, sedangkan *small scale fading* merupakan perubahan fluktuasi amplitudo kuat sinyal yang cepat pada sisi penerima [15].

Prediksi *path loss* merupakan salah satu hal yang sangat penting perencanaan jaringan *Wireless* dan menjadi faktor penting terhadap kualitas penerimaan sinyal. Pemodelan prediksi *path loss* yang akurat berguna dalam perencanaan, desain dan implementasi jaringan komunikasi nirkabel, serta dapat digunakan untuk menganalisa dan mengoptimasi kualitas sinyal suatu jaringan nirkabel [2][16][17]. Pemodelan *path*

loss sangat penting dalam analisa *interference*, perencanaan frekuensi dan penentuan parameter *cell* pada sistem jaringan telekomunikasi bergerak [18] [19]. Perkembangan jaringan teknologi generasi ke depan membutuhkan kinerja dengan kualitas yang optimal [20] dan dalam pengoptimalan jaringan dibutuhkan prediksi *path loss* yang sangat akurat dengan kompleksitas yang rendah [21][22].

Model yang paling populer digunakan dalam prediksi *path loss* yaitu model empiris. Model empiris merupakan model yang sering digunakan dalam perencanaan dan optimasi jaringan telekomunikasi. Model empiris memberikan gambaran secara statistik terhadap hubungan antara *dependent variable* yaitu *Path loss* (PL) terhadap beberapa parameter hasil pengukuran yaitu frekuensi, ketinggian pemancar, ketinggian penerima dan jarak antara pengirim dan penerima [21][23]. Pemodelan empiris yang ada saat ini terdapat beberapa macam antara lain yaitu *Okumura-Hatta*, *Cost231-Hatta*, *ECC model* dan *Ericsson model* [12][24][25].

Permasalahan yang terjadi yaitu model empiris konvensional yang digunakan saat ini memiliki beberapa keterbatasan dalam akurasi pada penggunaan wilayah yang memiliki karakteristik khusus. Hal ini melatar belakangi diperlukannya suatu penelitian untuk memperbaiki model eksisting empiris dengan metode prediksi lain dalam memprediksi nilai error kesalahan. Pada penelitian [16] melakukan penelitian dasar dalam perbaikan model empiris ECC-33 dengan menggunakan prediksi error kesalahan dengan menggunakan regresi linear logaritmik. Dalam penelitian tersebut ditemukan peningkatan akurasi yang cukup baik.

Salah satu model yang saat ini berkembang yaitu model *Machine learning* (ML) yang merupakan metode yang didapatkan dari kumpulan data yang luas dan memiliki model arsitektur yang fleksibel dalam pembentukan suatu model [21][26]. Pada dasarnya saat ini *machine learning* telah digunakan dalam prediksi *path loss* [27]. Beberapa peneliti telah mengembangkan model prediksi *path loss* dengan menggunakan algoritma *machine learning* yaitu pada penelitian Zhang *et al*, 2019 [21] dan Dohnalek, 2014 [28] melakukan pengembangan model prediksi *path loss* dengan menggunakan algoritma *Random Forest* (RF). Moraitis, 2020 [29] and Zhang *et al*, 2019 [21] menggunakan algoritma *Support Vector Regression* (SVR) pada pengembangan prediksi PL. Oroza *et al*, 2019 [26], Zhang *et al*, 2018 [30] dan Moraitis, 2020 [29] menggunakan algoritma *K-Nearest Neighbor* (KNN) sebagai algoritma pemodelan prediksi PL. Faruk *et al*, 2019 [31] menggunakan algoritma *Adaptive Network Based Fuzzy Inference System* (ANFIS) untuk

mengembangkan model prediksi *path loss*. Popoola *et al*, 2018 [32] mengusulkan pemodelan prediksi PL dengan menggunakan *Extreme Learning Machine* (ELM). Model yang paling banyak digunakan dalam pemodelan prediksi PL yaitu *artificial neural network* (ANN). Popoola *et al*, 2019 [33], Park *et al*, 2020 [34], Eichie *et al*, 2017 [35] dan Ayadi *et al*, 2017 [36] menggunakan pengembangan dari algoritma ANN sebagai algoritma pemodelan *path loss*. Pada penelitian [19] melakukan model hybrid antara model FSL, ECC dengan menggunakan model NN. Pada penelitian fitur yang dipakai yaitu fitur tunggal yaitu hanya jarak. Beberapa penelitian tersebut melakukan pengembangan model prediksi *path loss* dengan menggunakan model empiris maupun model *machine learning* secara terpisah. Perlu adanya pengembangan model dengan menggunakan metode hybrid model konvensional empiris Cost-Hatta dengan pengembangan metode variasi *machine learning*.

Permasalahan lain yang melatar belakangi penelitian ini yaitu dalam hal penggunaan fitur yang digunakan dalam pembuatan model. Penentuan fitur pada pemodelan prediksi *path loss* juga sangat berpengaruh pada tingkat akurasi prediksi. Beberapa peneliti menggunakan bermacam-macam fitur, baik fitur yang sering digunakan dalam pemodelan *path loss* empiris maupun pengembangan fitur disesuaikan dengan model yang ingin dikembangkan. Beberapa penelitian tentang penggunaan fitur masih dalam jumlah yang terbatas dalam pemodelan prediksi *path loss*. Pada penelitian [21] dan [32] dalam proses pemodelannya hanya menggunakan single fitur yaitu fitur jarak antara TX-RX. Penelitian lain yang menggunakan fitur terbatas terdapat pada penelitian yang dilakukan oleh Park *et al.*, 2015 [37]. Jumlah fitur yang digunakan hanya 2 fitur yaitu jarak TX-RX dan Frekuensi. Pada penelitian [35][38][39] menggunakan 3 fitur dengan macam fitur yang berbeda-beda. Perlu adanya penelitian untuk bervariasi jenis fitur maupun jumlah fitur yang lebih banyak untuk mendapatkan fitur terbaik dalam pemodelan.

Literatur penelitian mengenai seleksi fitur pada pengembangan model prediksi *path loss* masih sangat terbatas. Beberapa penelitian yang menggunakan seleksi fitur yaitu seperti pada penelitian [34] dengan menggunakan metode PCA dari 4 fitur input, sedangkan penelitian [40] menggunakan teknik seleksi fitur *Feature Importance* dari 8 fitur input. Untuk penelitian yang lain, metode seleksi fitur masih jarang digunakan dalam proses pemodelan prediksi *path loss*, sehingga perlu adanya pengembangan metode seleksi fitur dalam pengembangan model prediksi *path loss* baik dengan metode filter

univariate maupun metode *wrapper* untuk mendapatkan kombinasi fitur terbaik dalam pemodelan.

Pada perkembangan pemodelan prediksi *path loss*, beberapa riset terus dikembangkan pada berbagai macam kondisi dan karakteristik wilayah yang berbeda. Hal ini disebabkan oleh perbedaan kondisi lingkungan, *terrain* maupun iklim yang ada pada suatu tempat berbeda dengan kondisi yang ada wilayah lain. Secara teori, tidak ada pemodelan *path loss* yang dapat diterima secara mutlak untuk semua wilayah [41], akan tetapi pemodelan *path loss* terus dikembangkan untuk mendapatkan model yang mempunyai tingkat akurasi yang lebih baik. Pemilihan model prediksi *path loss* yang paling ideal pada suatu wilayah bergantung pada karakteristik medan pada suatu wilayah tertentu [8]. Kondisi lingkungan yang sangat bervariasi menyebabkan perbedaan nilai *path loss* yang dihasilkan pada saat propagasi gelombang sinyal di udara [42].

Beberapa tipe lokasi yang telah digunakan dalam penelitian pemodelan prediksi *path loss* dengan menggunakan *machine learning* baik di lokasi *indoor* maupun *outdoor*. Pada penelitian [22][43] melakukan pengukuran pada kondisi *indoor* dalam kabin pesawat dimana *transceiver* (TX) dan receiver (RX) terletak dalam kabin pesawat. Sedangkan pada penelitian [44] melakukan pengambilan dataset pada kondisi *indoor* di dalam perkantoran dimana letak pemancar dan penerima terletak pada dalam ruangan yang sama. Beberapa penelitian juga dilakukan dalam penelitian air yaitu [45] [46]. Sebagian besar penelitian prediksi *path loss* ini menggunakan data pengukuran *outdoor* yang dibagi menjadi tiga tipe wilayah yaitu rural, sub-urban dan urban. Beberapa penelitian yang menggunakan kondisi tersebut yaitu sub-urban dan urban [21][36][35][37]. Oleh karena itu, pada pengembangannya perlu adanya pengembangan fitur dan arsitektur model yang sesuai dengan karakteristik lokasinya.

Kondisi lokasi penelitian yang memiliki karakteristik yang unik yaitu pada berbagai moda transportasi. Saat ini moda transportasi memiliki alat transportasi darat, LRT dan juga alat transportasi air yaitu kapal perahu. Perbedaan kondisi lingkungan antara ketiga alat transportasi tersebut menyebabkan perbedaan karakteristik *path loss* yang berbeda antara satu dengan yang lain. Pada moda transportasi darat, karakteristik bangunan mendominasi perubahan karakteristik *path loss* yang dihasilkan. Pada moda transportasi *Light Rail Transit* (LRT) yang memiliki rel kereta di atas ketinggian rata-rata gedung yang ada disekitar menyebabkan sinyal langsung mendominasi dari pada sinyal pantul. Pada penggunaan moda transportasi kapal perahu, efek dari refraksi sinyal sangat

mendominasi terhadap *path loss* yang dihasilkan. Berdasarkan perbedaan pada ketiga kondisi tersebut diperlukan suatu pemodelan prediksi *path loss* pada 3 skenario moda transportasi untuk mendapatkan model prediksi dengan tingkat akurasi yang lebih baik.

Berdasarkan pada uraian di atas, landasan dasar dalam pengembangan kerangka pada metode penelitian yaitu pengembangan model prediksi *path loss* dengan menggunakan pengembangan model *hybrid feature selection* pada tahap pra-pemrosesan data dan *hybrid empirical-machine learning* untuk meningkatkan akurasi. Pada tahap selanjutnya dilakukan rekayasa *hyper-parameter* untuk optimasi hasil dari *machine learning*. Topik Pada disertasi ini dengan judul: “Pemodelan Prediksi *Path loss* pada Skenario Moda Transportasi Publik pada *Ultra High Frequency* (UHF) dengan Menggunakan Metode *Hybrid Empiris-Machine learning*”

1.2 Rumusan Masalah

Berdasarkan pada kondisi dan aspek pada perumusan masalah pada latar belakang, peneliti merumuskan beberapa permasalahan terkait dengan prediksi *path loss* sebagai berikut:

1. Bagaimana perbaikan model empiris dengan melakukan *hybrid empiris-machine learning* untuk meningkatkan akurasi prediksi *path loss*?
2. Bagaimana pengaruh jumlah variasi fitur dalam pengembangan metode seleksi fitur (*Univariate-GA-PSO*) pada penentuan konfigurasi fitur terbaik untuk meningkatkan akurasi prediksi *path loss*?
3. Bagaimana pengembangan model *machine learning* dengan melakukan optimasi *hyper-parameter* untuk mengoptimalkan tingkat akurasi prediksi *path loss*?
4. Bagaimana memodelkan prediksi *path loss* pada 3 skenario transportasi publik yang berbeda yaitu LRT, Bus dan Perahu?

1.3 Tujuan dan Manfaat

1.3.1 Tujuan

Adapun tujuan dari penelitian ini adalah:

1. Mengembangkan model prediksi *path loss* dengan menggunakan metode *Hybrid empiris-machine learning*
2. Peningkatan akurasi prediksi *path loss* dengan bervariasi fitur dan pengembangan metode seleksi fitur dengan membandingkan 3 metode yaitu

Univariate, GA, PSO untuk mendapatkan komposisi fitur terbaik pada prediksi *path loss*

3. Pengembangan model prediksi *path loss* dengan melakukan rekayasa *hyper-parameter* pada *Machine learning* untuk mendapatkan akurasi yang lebih baik
4. Pengembangan model prediksi *path loss* pada 3 skenario pengukuran pada 3 moda transportasi yaitu moda darat, moda perairan dan LRT dengan menggunakan metode *Hybrid Empiris-Machine learning*

1.3.2 Manfaat

Manfaat yang dapat diperoleh dari penelitian ini adalah:

1. Model prediksi *path loss* propagasi yang dihasilkan dapat bermanfaat bagi operator maupun vendor dalam perencanaan dan optimasi jaringan komunikasi *Wireless*
2. Manfaat bagi pengguna, yaitu dapat meningkatkan *coverage* layanan dan kualitas layanan yang diterima oleh pengguna jaringan
3. Untuk pengembangan ilmu pengetahuan mengenai pemodelan prediksi *path loss* dengan menggunakan metode *hybrid empirical-machine learning*

1.4 Hipotesis

Berdasarkan pada uraian latar belakang dan analisa dari beberapa studi literature di atas, hipotesis dari penelitian ini dapat dirumuskan sebagai berikut:

1. Pengembangan model empiris dengan menggunakan *hybrid machine learning* dapat meningkatkan akurasi prediksi *path loss* dari model empiris konvensional sebelumnya pada skenario moda transportasi
2. Peningkatan variasi jumlah fitur dalam pengembangan metode seleksi fitur mempermudah pencapaian komposisi penggunaan fitur yang optimal dalam peningkatan akurasi prediksi *path loss*.
3. Pengembangan metode seleksi fitur yang membandingkan tiga metode, yaitu *Univariate*, GA (Genetic Algorithm), dan PSO (Particle Swarm Optimization), dapat meningkatkan akurasi prediksi *path loss*.
4. optimasi *hyper-parameter* pada model *machine learning* dapat menghasilkan konfigurasi parameter terbaik yang dengan tingkat akurasi yang optimal

5. Pengembangan model pada moda transportasi publik yang memiliki karakteristik yang berbeda perlu penambahan fitur dan pembaharuan arsitektur model.

1.5 Novelty

Berdasarkan pada uraian latar belakang dan analisa dari beberapa studi literature di atas, hipotesis dari penelitian ini dapat dirumuskan sebagai berikut

1. Penelitian ini berkontribusi dalam penggunaan metode hybrid yang mengintegrasikan model empiris konvensional dengan keunggulan model variasi *machine learning* dalam konteks prediksi *path loss* untuk menghasilkan perbaikan akurasi yang lebih akurat dan handal khususnya pada moda transportasi.
2. Penelitian ini unggul dalam hal jumlah fitur input yang tersedia dibandingkan dengan penelitian sebelumnya dalam pemodelan prediksi *path loss*. Pada penelitian ini mengidentifikasi dan memasukkan sejumlah fitur yang relevan untuk memberikan pemahaman yang lebih komprehensif tentang pemodelan prediksi *path loss*.
3. Kontribusi ketiga dari penelitian ini terletak pada penerapan 3 metode fitur seleksi *Univariate-GA-PSO*, yang hingga saat ini belum pernah diterapkan dalam penelitian sebelumnya pada pemodelan prediksi *path loss*. Pendekatan ini untuk secara efektif mengidentifikasi fitur yang paling signifikan dan memberikan solusi yang lebih inovatif dalam pemodelan prediksi *path loss*
4. Penelitian ini fokus pada analisis karakteristik lokasi pada moda transportasi publik yang beragam dan sebelumnya tidak pernah dieksplorasi secara mendalam oleh penelitian-penelitian sebelumnya.

1.6 Batasan Masalah

Beberapa batasan masalah penelitian ini diuraikan sebagai pembatas ruang lingkup pembahasan pada disertasi ini:

1. Metode pengukuran yang digunakan pada penelitian ini yaitu metode *drive test*
2. Jaringan yang digunakan pada penelitian merupakan jaringan 4G LTE eksisting pada pita frekuensi 1800 MHz dan frekuensi 2100 MHz
3. Skenario rute yang dipakai menggunakan alat transportasi publik di Kota Palembang yaitu Bus Trans-Musi Palembang, *Light Rail Transit* (LRT) dan Kapal Perahu pada Sungai Musi

4. Metode Empiris yang digunakan pada penelitian yaitu Okumura-Hatta, COST231-Hatta, Erricsson dan ECC Model
5. Algoritma yang digunakan pada pengembangan *Machine learning* dengan menggunakan perbandingan RF, KNN dan ANN-MLP
6. Metode seleksi fitur yang digunakan yaitu dengan perbandingan 3 algoritma *Univariate*, *Genetic Algorithm (GA)*, *Particle Swarm Optimization (PSO)*
7. Data cuaca yang digunakan merupakan data real di lapangan pada saat pengambilan data dengan menggunakan alat *Weather Station*

1.7 Sistematika Penulisan

Rencana sistematika laporan penelitian ini terdiri dari tujuh Bab, dengan uraian sebagai berikut:

Bab-1 adalah bagian pendahuluan berisi latar belakang, tujuan dan manfaat penelitian, ruang lingkup penelitian yang meliputi objek penelitian, metodologi penelitian, dan metode pengumpulan data. Bagian akhir dari bab ini berisi sistematika laporan penelitian.

Bab-2 berisi studi literatur publikasi atau artikel terkait yang membahas tentang prediksi *path loss* secara empiris maupun menggunakan algoritma *machine learning*.

Bab-3 berisi metodologi penelitian dengan pembahasan tentang rancangan riset (*research design*), pembahasan skenario dan lokasi penelitian, peralatan yang digunakan dan tahap pengukuran serta pengolahan data.

Bab-4 berisi tentang pengembangan *framework* atau model *hybrid empiris-machine learning* untuk meningkatkan akurasi prediksi *path loss* pada beberapa kondisi transportasi (studi kasus di Kota Palembang).

Bab-5 berisi tentang peningkatan akurasi prediksi *path loss* dengan pengembangan metode seleksi fitur dengan 3 metode yaitu *Univariate*, GA dan PSO untuk mendapatkan tingkat akurasi yang lebih akurat.

Bab-6 berisi tentang pengembangan model dengan optimasi *hyper-parameter* pada algoritma *machine learning* serta komparasi framework/metode yang diajukan dengan metode/framework/model terdahulu.

Bab-7 adalah bagian kesimpulan dari penelitian yang telah dilakukan dan dilengkapi dengan saran dan peluang pengembangan riset dimasa mendatang.

DAFTAR PUSTAKA

- [1] A. Ubaidillah, M. Ulum, and S. Pramono, "Planning of Path Loss in Large Scale Signal Propagation Model at 5G Network by Using Linear Regression Methods," *Journal of Physics: Conference Series*, vol. 1569, no. 3. pp. 1–13, 2020, doi: 10.1088/1742-6596/1569/3/032080.
- [2] T. Zhou, H. Li, Y. Wang, L. Liu, and C. Tao, "Channel modeling for future high-speed railway communication systems: A survey," *IEEE Access*, vol. 7, no. March, pp. 52818–52826, 2019, doi: 10.1109/ACCESS.2019.2912408.
- [3] S. P. Sotiroudis, S. K. Goudos, and K. Siakavara, "Neural Networks and Random Forests : A Comparison Regarding Prediction of Propagation Path Loss for NB-IoT Networks," in *2019 8th International Conference on Modern Circuits and Systems Technologies (MOCASST)*, 2019, pp. 1–4, doi: 10.1109/MOCASST.2019.8741751.
- [4] A. Al-Samman, "Path loss model for indoor emergency stairwell environment at millimeter wave band for 5G network," *Turkish J. Electr. Eng. Comput. Sci.*, vol. 26, no. 6, pp. 3024–3032, 2018, doi: 10.3906/elk-1710-248.
- [5] M. Majed, T. Rahman, and O. Azis, "Propagation path loss modeling and outdoor coverage measurements review in millimeter wave bands for 5G cellular communications," *International Journal of Electrical and Computer Engineering*, vol. 8, no. 4. pp. 2254–2260, 2018, doi: 10.11591/ijece.v8i4.pp2254-2260.
- [6] M. B. Majed, T. A. Rahman, O. A. Aziz, M. N. Hindia, and E. Hanafi, "Channel characterization and path loss modeling in indoor environment at 4.5, 28, and 38GHz for 5G cellular networks," *Int. J. Antennas Propag.*, vol. 2018, 2018, doi: 10.1155/2018/9142367.
- [7] C. Emeruwa and P. . Iwuji, "Determination Of A Pathloss Model For Long Term Evolution (Lte) In Yenagoa," *Int. J. Eng. Sci.*, vol. 7, no. 10, pp. 38–44, 2018, doi: 10.9790/1813-0710033844.
- [8] A. Bhuvaneshwari, "Path loss model optimization using stochastic hybrid genetic algorithm," *Int. J. Eng. Technol.*, vol. 7, no. 4, pp. 464–469, 2018, doi: 10.14419/ijet.v7i4.10.21041.
- [9] O. J. Famoriji, "Path Loss Prediction in Tropical Regions using Machine Learning Techniques : A Case Study," pp. 1–13, 2022.
- [10] P. Maina, G. Chandra Manna, and N. Sahayam, "Validation Study of Path Loss

- Models on Wimax At 2.6 Ghz Frequency Band in Suburban Environment for Cell Size Planning,” *Int. J. Next-Generation Networks*, vol. 6, no. 2, pp. 17–29, 2014, doi: 10.5121/ijngn.2014.6202.
- [11] Z. Xiao, H. Wen, A. Markham, N. Trigoni, P. Blunsom, and J. Frolik, “Non-Line-of-Sight Identification and Mitigation Using Received Signal Strength,” *IEEE Trans. Wirel. Commun.*, vol. 14, no. 3, pp. 1689–1702, 2015, doi: 10.1109/TWC.2014.2372341.
- [12] D. A. V. Sreevardhan Cheerla, K. Sindhuja, Ch. Indra Kiran, “Analysis of different path loss models in urban suburban and rural environment,” *Int. J. Emerg. Trends Eng. Res.*, vol. 8, no. 7, pp. 2972–2976, 2020, doi: 10.30534/ijeter/2020/14872020.
- [13] S. Pattanayak, “A genetically trained neural network for prediction of path loss in outdoor microcell,” *Int. J. Adv. Res. Eng. Technol.*, vol. 11, no. 4, pp. 346–351, 2020, doi: 10.34218/IJARET.11.4.2020.034.
- [14] J. C. Silva, G. L. Siquera, and P. V. G. Castellanos, “Propagation Model for Path Loss Through Vegetated Environments at 700 – 800 MHz Band,” *J. Microwaves, Optoelectron. Electromagn. Appl.*, vol. 17, no. 1, pp. 102–120, 2018, doi: 10.1590/2179-10742018v17i11183.
- [15] N. O. Oyie and T. J. O. Afullo, “Measurements and Analysis of Large-Scale Path Loss Model at 14 and 22 GHz in Indoor Corridor,” *IEEE Access*, vol. 6, pp. 17205–17214, 2018, doi: 10.1109/ACCESS.2018.2802038.
- [16] B. Alfaresi, T. Barlian, F. Ardianto, and M. Hurairah, “Path Loss Propagation Evaluation and Modelling based ECC-Model in Lowland Area on 1800 MHz Frequency,” *J. Robot. Control*, vol. 1, no. 5, pp. 167–172, 2020, doi: 10.18196/jrc.1534.
- [17] A. Genc, “A new path loss model based on the volumetric occupancy rate for the pine forests at 5G frequency band,” *Int. J. Microw. Wirel. Technol.*, 2020, doi: 10.1017/S175907872000152X.
- [18] H. Lasisi, Y. A. Adediran, and A. A. Ayodele, “Development of A Propagation Path Loss Prediction Model for Mobile Communication Networks Deployment in Osogbo, Nigeria,” *Eur. J. Eng. Res. Sci.*, vol. 2, no. 11, p. 13, 2017, doi: 10.24018/ejers.2017.2.11.370.
- [19] B. J. Cavalcanti, G. A. Cavalcante, L. M. De Mendonça, G. M. Cantanhede, M. M. M. De Oliveira, and A. G. D’Assunção, “A hybrid path loss prediction model based on

- artificial neural networks using empirical models for LTE and LTE-A at 800 MHz and 2600 MHz,” *J. Microwaves, Optoelectron. Electromagn. Appl.*, vol. 16, no. 3, pp. 708–722, 2017, doi: 10.1590/2179-10742017v16i3925.
- [20] M. Nordin and HUDA ADIBAH MOHD RAMLI, “Performance analysis of 5G path loss models for rural macrocell environment,” *IJUM Eng. J.*, vol. 21, no. 1, pp. 85–99, 2020, doi: 10.31436/iiumej.v21i1.1247.
- [21] Y. Zhang, J. Wen, G. Yang, Z. He, and J. Wang, “Path loss prediction based on machine learning: Principle, method, and data expansion,” *Appl. Sci.*, vol. 9, no. 9, 2019, doi: 10.3390/app9091908.
- [22] J. Wen, Y. Zhang, G. Yang, Z. He, and W. Zhang, “Path Loss Prediction Based on Machine Learning Methods for Aircraft Cabin Environments,” *IEEE Access*, vol. 7, pp. 159251–159261, 2019, doi: 10.1109/ACCESS.2019.2950634.
- [23] H. Singh, S. Gupta, C. Dhawan, and A. Mishra, “Path Loss Prediction in Smart Campus Environment: Machine Learning-based Approaches,” *IEEE Veh. Technol. Conf.*, vol. 2020-May, 2020, doi: 10.1109/VTC2020-Spring48590.2020.9129444.
- [24] O. Shoewu, L. A. Akinyemi, and L. Oborkhale, “Modelling Path Loss in Mobile Communication 4G Network System for Dryland and Wetland Terrains,” in *Southern Africa Telecommunication Networks and Applications Conference (SATNAC)*, 2019, pp. 44–49.
- [25] U. Masood, H. Farooq, and A. Imran, “A machine learning based 3D propagation model for intelligent future cellular networks,” *2019 IEEE Glob. Commun. Conf. GLOBECOM 2019 - Proc.*, no. M1, 2019, doi: 10.1109/GLOBECOM38437.2019.9014187.
- [26] C. Oroza *et al.*, “A Machine-Learning Based Connectivity Model for Deployments To cite this version : A Machine-Learning Based Connectivity Model for Complex Terrain Large-Scale Low-Power Wireless Deployments,” *IEEE Trans. Cogn. Commun. Netw.*, vol. 3, no. 4, pp. 576–584, 2017, doi: 10.1109/TCCN.2017.2741468.
- [27] S. P. Sotiroudis, S. K. Goudos, and K. Siakavara, “Deep learning for radio propagation: Using image-driven regression to estimate path loss in urban areas,” *ICT Express*, vol. 6, no. 3, pp. 160–165, 2020, doi: 10.1016/j.icte.2020.04.008.
- [28] P. Dohnalek, M. Dvorsky, P. Gajdos, L. Michalek, R. Sebesta, and M. Voznak, “A signal strength fluctuation prediction model based on the random forest algorithm,” *Elektron. ir Elektrotechnika*, vol. 20, no. 5, pp. 123–126, 2014, doi:

- 10.5755/j01.eee.20.5.7112.
- [29] N. Moraitis, “Machine Learning-Based Methods for Path Loss Prediction in Urban Environment for LTE Networks,” 2020.
- [30] Y. Zhang, J. Wen, G. Yang, Z. He, and X. Luo, “Air-to-Air Path Loss Prediction Based on Machine Learning Methods in Urban Environments,” *Wirel. Commun. Mob. Comput.*, vol. 2018, 2018, doi: 10.1155/2018/8489326.
- [31] N. Faruk *et al.*, “ANFIS Model for Path Loss Prediction in the GSM and WCDMA Bands in Urban Area,” *Elektr. J. Electr. Eng.*, vol. 18, no. 1, pp. 1–10, 2019, doi: 10.11113/elektrika.v18n1.140.
- [32] S. I. Popoola, S. Misra, and A. A. Atayero, “Outdoor Path Loss Predictions Based on Extreme Learning Machine,” *Wirel. Pers. Commun.*, vol. 99, no. 1, pp. 441–460, 2017, doi: 10.1007/s11277-017-5119-x.
- [33] S. I. Popoola *et al.*, “Determination of neural network parameters for path loss prediction in very high frequency wireless channel,” *IEEE Access*, vol. 7, no. October, pp. 150462–150483, 2019, doi: 10.1109/ACCESS.2019.2947009.
- [34] H. S. Jo, C. Park, E. Lee, H. K. Choi, and J. Park, “Path loss prediction based on machine learning techniques: Principal component analysis, artificial neural network and gaussian process,” *Sensors (Switzerland)*, vol. 20, no. 7, pp. 1–23, 2020, doi: 10.3390/s20071927.
- [35] E. J. Ofure, O. D. Oyedum, M. O. Ajewole, and A. M. Aibinu, “Artificial Neural Network model for the determination of GSM Rxlevel from atmospheric parameters,” *Eng. Sci. Technol. an Int. J.*, vol. 20, no. 2, pp. 795–804, 2016, doi: 10.1016/j.jestch.2016.11.002.
- [36] M. Ayadi, A. Ben Zineb, and S. Tabbane, “A UHF Path Loss Model Using Learning Machine for Heterogeneous Networks,” *IEEE Trans. Antennas Propag.*, vol. 65, no. 7, pp. 3675–3683, 2017, doi: 10.1109/TAP.2017.2705112.
- [37] C. Park, D. K. Tettey, and H.-S. Jo, “Artificial Neural Network Modeling for Path Loss Prediction in Urban Environments,” *J. LATEX Cl. FILES*, vol. 14, no. 8, pp. 9–13, 2019, [Online]. Available: <http://arxiv.org/abs/1904.02383>.
- [38] S. Ojo, A. Imoize, and D. Alienyi, “Radial basis function neural network path loss prediction model for LTE networks in multitransmitter signal propagation environments,” *Int. J. Commun. Syst.*, vol. 34, no. 3, pp. 1–26, 2021, doi: 10.1002/dac.4680.

- [39] A. Tahat, T. Edwan, H. Al-Sawwaf, J. Al-Baw, and M. Amayreh, "Simplistic Machine Learning-Based Air-to-Ground Path Loss Modeling in an Urban Environment," *2020 5th Int. Conf. Fog Mob. Edge Comput. FMEC 2020*, pp. 158–163, 2020, doi: 10.1109/FMEC49853.2020.9144965.
- [40] G. Yang, Y. Zhang, Z. He, J. Wen, Z. Ji, and Y. Li, "Machine-learning-based prediction methods for path loss and delay spread in air-to-ground millimetre-wave channels," *IET Microwaves, Antennas Propag.*, vol. 13, no. 8, pp. 1113–1121, 2019, doi: 10.1049/iet-map.2018.6187.
- [41] B. O. . Akinwole and C. . Esobinenwu, "Adjustment of Cost 231 Hata Path Model For Cellular Transmission in Rivers State," *IOSR J. Electr. Electron. Eng.*, vol. 6, no. 5, pp. 16–23, 2013, doi: 10.9790/1676-0651623.
- [42] H. F. Ates, S. M. Hashir, T. Baykas, and B. K. Gunturk, "Path Loss Exponent and Shadowing Factor Prediction From Satellite Images Using Deep Learning," *IEEE Access*, vol. 7, pp. 101366–101375, 2019, doi: 10.1109/access.2019.2931072.
- [43] X. Zhao, C. Hou, and Q. Wang, "A new SVM-based modeling method of cabin path loss prediction," *Int. J. Antennas Propag.*, vol. 2013, 2013, doi: 10.1155/2013/279070.
- [44] K. Saito, Y. Jin, C. Kang, J. Takada, and J.-S. Leu, "Two-step path loss prediction by artificial neural network for wireless service area planning," *IEICE Commun. Express*, vol. 8, no. 12, pp. 611–616, 2019, doi: 10.1587/comex.2019gcl0038.
- [45] ALLAN DOS S. BRAGA *et al.*, "Radio Propagation Models Based on Machine Learning Using Geometric Parameters for a Mixed City-River Path," *IEEE Access*, vol. 8, pp. 146395–146407, 2020, doi: 10.1109/ACCESS.2020.3012661.
- [46] J. Yu, W. Chen, K. Yang, C. Li, F. Li, and Y. Shui, "Path Loss Channel Model for Inland River Radio Propagation at 1 . 4 GHz," *Int. J. Antennas Propag.*, vol. 2017, pp. 1–15, 2017, doi: <https://doi.org/10.1155/2017/5853724>.
- [47] J. Of and A. In, "Pathloss Modelling of less dense urban area in Lagos State using Lee Model," *J. Adv. Eng. Technol.*, vol. 4, no. 4, pp. 1–4, 2017, doi: 10.15297/JAET.V4I4.01.
- [48] S. Aldossari and K. C. Chen, "Predicting the Path Loss of Wireless Channel Models Using Machine Learning Techniques in MmWave Urban Communications," *Int. Symp. Wirel. Pers. Multimed. Commun. WPMC*, vol. 2019-Novem, 2019, doi: 10.1109/WPMC48795.2019.9096057.
- [49] S. I. Popoola, E. Adetiba, A. A. Atayero, N. Faruk, and C. T. Calafate, "Optimal model

- for path loss predictions using feed-forward neural networks,” *Cogent Eng.*, vol. 5, no. 1, 2018, doi: 10.1080/23311916.2018.1444345.
- [50] M. Alnatoor, M. Omari, and M. Kaddi, “Path Loss Models for Cellular Mobile Networks Using Artificial Intelligence Technologies in Different Environments,” *MDPI*, vol. 12, no. 24, pp. 1–23, 2022, doi: 10.3390/app122412757.
- [51] C. Study and N. Elfadil, “Impact of Using Modified Open Area Okumura-Hata Propagation Model in Determination of Path-loss: Malaysia as Case Study,” *Int. J. Mod. Eng. Res.*, vol. 7, no. 5, pp. 1–6, 2017.
- [52] S. O. Olatinwo, L. I. Oborkhale, and O. O. Shoewu, “Wireless Network Modelling and Analysis using Path Loss Models,” *Pacific J. Sci. Technol.*, vol. 18, no. 2, pp. 132–143, 2017.
- [53] H. K. Hoomod, I. Al-Mejibli, and A. I. Jabboory, “Analyzing Study of Path loss Propagation Models in Wireless Communications at 0.8 GHz,” *J. Phys. Conf. Ser.*, vol. 1003, no. 1, pp. 0–8, 2018, doi: 10.1088/1742-6596/1003/1/012028.
- [54] Z. Nossire, N. Gupta, L. Almazaydeh, and X. Xiong, “New Empirical Path Loss Model for 28 GHz and 38 GHz Millimeter Wave in Indoor Urban under Various Conditions,” *MDPI*, vol. 8, pp. 1–14, 2018, doi: 10.3390/app8112122.
- [55] D. Cama-Pinto, M. Damas, J. A. Holgado-Terriza, F. Gómez-Mula, and A. Cama-Pinto, “Path loss determination using linear and cubic regression inside a classic tomato greenhouse,” *Int. J. Environ. Res. Public Health*, vol. 16, no. 10, pp. 1–15, 2019, doi: 10.3390/ijerph16101744.
- [56] A. M. Al-Samman, T. A. Rahman, M. H. D. N. Hindia, A. Daho, and E. Hanafi, “Path loss model for outdoor parking environments at 28 GHz and 38 GHz for 5G wireless networks,” *Symmetry (Basel)*, vol. 10, no. 12, pp. 1–15, 2018, doi: 10.3390/sym10120672.
- [57] N. Pooja, R. Anitha, and C. S. Hanchinal, “Optimized Path loss model for the effects of Environmental Factors on Mobile Signal Strength,” *Int. Res. J. Eng. Technol.*, vol. 5, no. 04, pp. 4513–4516, 2018.
- [58] S. Lin *et al.*, “ATPC : Adaptive Transmission Power Control for Wireless Sensor Networks,” *ACM Trans. Sens. Networks*, vol. 12, no. 1, pp. 1–31, 2016.
- [59] K. Bannister, G. Giorgetti, and S. K. S. Gupta, “Wireless Sensor Networking for ‘ Hot ’ Applications : Effects of Temperature on Signal Strength , Data Collection and Localization,” 2008.

- [60] E. Essien, “Simulating the Effect of Rainfall on Microwave Attenuation,” 2016, [Online]. Available: https://www.academia.edu/29995349/SIMULATING_THE_EFFECT_OF_RAINFALL_ON_MICROWAVE_ATTENUATION.
- [61] Tin Kam Ho, “Random Decision Forests,” 1995, doi: 10.1109/ICDAR.1995.598994.
- [62] L. E. O. Breiman, “Random Forests,” pp. 5–32, 2001.
- [63] A. Liaw and M. Wiener, “Classification and Regression by randomForest,” vol. 2, no. December 2002, pp. 18–22, 2002.
- [64] S. K. Lakshmanaprabu, K. Shankar, M. Ilayaraja, A. W. Nasir, V. Vijayakumar, and N. Chilamkurti, “Random forest for big data classification in the internet of things using optimal features,” *Int. J. Mach. Learn. Cybern.*, vol. 10, no. 10, pp. 2609–2618, 2019, doi: 10.1007/s13042-018-00916-z.
- [65] J. Chen, Q. Li, H. Wang, and M. Deng, “A machine learning ensemble approach based on random forest and radial basis function neural network for risk evaluation of regional flood disaster: A case study of the yangtze river delta, China,” *Int. J. Environ. Res. Public Health*, vol. 17, no. 1, pp. 1–21, 2020, doi: 10.3390/ijerph17010049.
- [66] I. Ouedraogo, P. Defourny, and M. Vanclooster, “Application of random forest regression and comparison of its performance to multiple linear regression in modeling groundwater nitrate concentration at the African continent scale,” *Hydrogeol. J.*, vol. 27, no. 3, pp. 1081–1098, 2019, doi: 10.1007/s10040-018-1900-5.
- [67] C. Wang, Q. Shu, X. Wang, B. Guo, P. Liu, and Q. Li, “A random forest classifier based on pixel comparison features for urban LiDAR data,” *ISPRS J. Photogramm. Remote Sens.*, vol. 148, no. December 2018, pp. 75–86, 2019, doi: 10.1016/j.isprsjprs.2018.12.009.
- [68] C. Yoo, D. Han, J. Im, and B. Bechtel, “Comparison between convolutional neural networks and random forest for local climate zone classification in mega urban areas using Landsat images,” *ISPRS J. Photogramm. Remote Sens.*, vol. 157, no. September, pp. 155–170, 2019, doi: 10.1016/j.isprsjprs.2019.09.009.
- [69] S. Duangsuwan, “Comparison of path loss prediction models for UAV and IoT air-to-ground communication system in rural precision farming environment,” *J. Commun.*, vol. 16, no. 2, pp. 60–66, 2021, doi: 10.12720/jcm.16.2.60-66.
- [70] S. P. Sotiroudis, “Mobile radio propagation path loss prediction using Artificial Neural Networks with optimal input information for urban environments,” *AEU - Int. J.*

- Electron. Commun.*, vol. 69, no. 10, pp. 1453–1463, 2015, doi: 10.1016/j.aeue.2015.06.014.
- [71] V. C. Ebhota and V. M. Srivastava, “Effect of Architectural Composition of MLP ANN in Neural Network Learning for Signal Power Loss Prediction,” *J. Commun.*, vol. 16, no. 1, pp. 20–29, 2021, doi: 10.12720/jcm.16.1.20-29.
- [72] S. Cheerla, D. Ratnam, and H. Borra, “Neural network-based path loss model for cellular mobile networks at 800 and 1800 MHz bands,” *AEU - Int. J. Electron. Commun.*, vol. 94, pp. 179–186, 2018, doi: 10.1016/j.aeue.2018.07.007.
- [73] T. Zhang, S. Liu, W. Xiang, L. Xu, K. Qin, and X. Yan, “A real-time channel prediction model based on neural networks for dedicated short-range communications,” *Sensors (Switzerland)*, vol. 19, no. 16, 2019, doi: 10.3390/s19163541.
- [74] J. E. Ofure, O. D. Oyedum, M. O. Ajewole, and A. M. Aibinu, “Comparative analysis of basic models and artificial neural network based model for path loss prediction,” *Prog. Electromagn. Res. M*, vol. 61, no. October, pp. 133–146, 2017, doi: 10.2528/PIERM17060601.
- [75] A. Ben Zineb and M. Ayadi, “A Multi-wall and Multi-frequency Indoor Path Loss Prediction Model Using Artificial Neural Networks,” *Arab. J. Sci. Eng.*, vol. 41, no. 3, pp. 987–996, 2016, doi: 10.1007/s13369-015-1949-6.
- [76] S. S. Oh, “Comparison of 0.75–24-GHz Reach Distances and Ratios Using Propagation Path Loss Measurements from Urban and Rural Line-of-Sight Environments,” *J. Electromagn. Eng. Sci.*, vol. 21, no. 1, pp. 1–7, 2021, doi: 10.26866/jees.2021.21.1.1.
- [77] U. Khair, H. Fahmi, S. Al Hakim, and R. Rahim, “Forecasting Error Calculation with Mean Absolute Deviation and Mean Absolute Percentage Error,” *J. Phys. Conf. Ser.*, vol. 930, no. 1, 2017, doi: 10.1088/1742-6596/930/1/012002.
- [78] S. O, S. N. O, O. A. O, and O. L. I, “Path Loss Measurement and Modeling for Lagos State G.S.M Environments,” *Rev. Comput. Eng. Res.*, vol. 3, no. 4, pp. 69–81, 2016, doi: 10.18488/journal.76/2016.3.4/76.4.69.81.
- [79] F. Moslehi and A. Haeri, “A novel hybrid wrapper–filter approach based on genetic algorithm, particle swarm optimization for feature subset selection,” *J. Ambient Intell. Humaniz. Comput.*, vol. 11, no. 3, pp. 1105–1127, 2020, doi: 10.1007/s12652-019-01364-5.

- [80] Y. C. Hsieh, P. J. Lee, and P. S. You, “Immune-based evolutionary algorithm for determining the optimal sequence of multiple disinfection operations,” *Sci. Iran.*, vol. 26, no. 2 C, pp. 959–974, 2019, doi: 10.24200/sci.2018.20324.
- [81] K. Indira and S. Kanmani, “Mining association rules using hybrid genetic algorithm and particle swarm optimisation algorithm,” *Int. J. Data Anal. Tech. Strateg.*, vol. 7, no. 1, pp. 59–76, 2015, doi: 10.1504/IJDATS.2015.067701.
- [82] J. Ahuja and S. D. Ratnoo, “Feature Selection using Multi-objective Genetic Algorithm: A Hybrid Approach,” *INFOCOMP J. Comput. Sci.*, vol. 14, no. 1, pp. 26–37, 2015, doi: 10.18760/ic.14120153.
- [83] S. Mokeddem, B. Atmani, and M. Mokaddem, “An effective feature selection approach driven genetic algorithm wrapped Bayes naïve,” *Int. J. Data Anal. Tech. Strateg.*, vol. 8, no. 3, pp. 220–243, 2016, doi: 10.1504/IJDATS.2016.079056.
- [84] S. Rukhaiyar, M. N. Alam, and N. K. Samadhiya, “A PSO-ANN hybrid model for predicting factor of safety of slope,” *Int. J. Geotech. Eng.*, vol. 12, no. 6, pp. 556–566, 2018, doi: 10.1080/19386362.2017.1305652.
- [85] B. A. A. Yousef, H. Rezk, M. A. Abdelkareem, A. G. Olabi, and A. M. Nassef, “Fuzzy modeling and particle swarm optimization for determining the optimal operating parameters to enhance the bio-methanol production from sugar cane bagasse,” *Int. J. Energy Res.*, vol. 44, no. 11, pp. 8964–8973, 2020, doi: 10.1002/er.5605.
- [86] S. Karkheiran, A. Kabiri-Samani, M. Zekri, and H. M. Azamathulla, “Scour at bridge piers in uniform and armored beds under steady and unsteady flow conditions using ANN-APSO and ANN-GA algorithms,” *ISH J. Hydraul. Eng.*, vol. 00, no. 00, pp. 1–9, 2019, doi: 10.1080/09715010.2019.1617796.
- [87] M. Khari, D. Jahed Armaghani, and A. Dehghanbanadaki, “Prediction of Lateral Deflection of Small-Scale Piles Using Hybrid PSO–ANN Model,” *Arab. J. Sci. Eng.*, vol. 45, no. 5, pp. 3499–3509, 2020, doi: 10.1007/s13369-019-04134-9.
- [88] G. P. Ferreira, L. J. Matos, and J. M. M. Silva, “Improvement of Outdoor Signal Strength Prediction in UHF Band by Artificial Neural Network,” *IEEE Trans. Antennas Propag.*, vol. 64, no. 12, pp. 5404–5410, 2016, doi: 10.1109/TAP.2016.2617379.
- [89] S. Ojo, “Radial basis function neural network path loss prediction model for LTE networks in multitransmitter signal propagation environments,” *Int. J. Commun. Syst.*, vol. 34, no. 3, 2021, doi: 10.1002/dac.4680.

- [90] J. Yu, "Path Loss Channel Model for Inland River Radio Propagation at 1.4 GHz," *Int. J. Antennas Propag.*, vol. 2017, 2017, doi: 10.1155/2017/5853724.