

PEMETAAN DAN PREDIKSI INTEFRFERENSI ELEKTROMAGNETIK PADA SMPS MENGGUNAKAN METODE MULTI REGRESSION

1stHaykal Azrel Putra Sugijanto
Department of Computer Engineering
Telkom University, Surabaya Campus
Surabaya, Indonesia
chelix@student.telkomunivesity.ac.id

2ndIsa Hafidz
Department of Computer Engineering
Telkom University, Surabaya Campus
Surabaya, Indonesia
isahafidz@telkomuniversity.ac.id

3rdMohammad Yanuar Hariyawan
Department of Computer Engineering
Telkom University, Surabaya Campus
Surabaya, Indonesia
myanuar@telkomuniversity.ac.id

Electromagnetic Interference (EMI) merupakan gangguan yang dapat menurunkan kinerja perangkat elektronik, terutama pada Switched-Mode Power Supply (SMPS), dengan meningkatkan emisi elektromagnetik dan menurunkan efisiensi daya. Oleh karena itu, diperlukan metode prediksi yang akurat untuk mengidentifikasi dan mengurangi dampak EMI. Penelitian ini mengusulkan model prediksi EMI dengan pendekatan Regresi Linear Berganda (MLR) dan Neural Network (NN). MLR digunakan untuk memahami hubungan linear antara parameter sistem dan EMI, sementara NN diterapkan untuk menangkap hubungan non-linear yang lebih kompleks. Data yang digunakan berasal dari sinyal Lorenz dan sinyal Ramp, yang memiliki karakteristik berbeda dalam merepresentasikan pola EMI. Hasil penelitian menunjukkan bahwa kombinasi MLR dan NN mampu meningkatkan akurasi prediksi dibandingkan metode konvensional. Selain itu, analisis menunjukkan bahwa karakteristik unik dari sinyal Lorenz dan Ramp memberikan pengaruh berbeda terhadap performa model. Dengan pendekatan ini, penelitian ini memberikan kontribusi dalam pengembangan teknik pembelajaran mesin untuk prediksi dan mitigasi EMI pada perangkat elektronik, khususnya dalam sistem daya seperti SMPS.

.Kata kunci— EMI, Regresi Linear Berganda, Neural Network, Sinyal Lorenz, Sinyal Ramp, SMPS.

I. PENDAHULUAN

Pada zaman modern ini banyak sekali elektromagnetik yang bermunculan dikarenakan banyaknya perangkat elektronik yang telah dipakai dimasyarakat seperti *handphone*, PC, *laptop*, dan lain sebagainya. EMI (*Electromagnetic Interference*) merupakan gangguan yang mempengaruhi kinerja suatu sistem elektronik karena adanya sumber gangguan elektromagnetik. Dampak yang bisa terjadi dikarenakan EMI bisa seperti dapat mempengaruhi kinerja dari elektronik itu sendiri, bisa merusak perangkat elektronik dan lain sebagainya. SMPS (*Switch Mode Power Supply*) juga merupakan jenis perangkat yang mengeluarkan gangguan elektromagnetik, SMPS merupakan salah satu jenis power supply yang banyak digunakan dalam berbagai perangkat elektronik [1]. SMPS bekerja dengan memanfaatkan prinsip kerja *switching* untuk mengubah tegangan dan arus listrik dari sumber masukan ke sumber keluaran sesuai dengan kebutuhan. SMPS mempunyai gangguan elektromagnetik (EMI). Gangguan ini mempengaruhi kinerja sistem elektronik dan dapat merusak perangkat. EMI khususnya bermasalah pada perangkat yang menggunakan *Switching*

Mode Power Supplies (SMPS), yang banyak digunakan dalam berbagai perangkat elektronik karena prinsip kerja *switching*-nya untuk mengubah tegangan dan arus listrik.

Pada penelitian sebelumnya membahas desain dan implementasi Filter EMI Pasif untuk mengurangi interferensi elektromagnetik pada catu daya, menguraikan standar untuk penggunaan komersial dan perumahan, merinci standar frekuensi untuk emisi yang dilakukan, menjelaskan proses penandaan frekuensi, dan memberikan penghitungan nilai komponen. Selain itu, juga mencakup pengujian prototipe filter dan analisis efektivitasnya dalam mengurangi emisi kebisingan. Filter EMI Pasif berhasil mengurangi emisi yang dihasilkan, memenuhi standar yang disyaratkan [2]. Untuk mengatasi masalah ini, penelitian ini mengembangkan model prediksi untuk gangguan EMI. Ini penting dalam banyak aplikasi, termasuk komunikasi nirkabel dan sistem kontrol industri.

Secara keseluruhan, penelitian ini bisa membantu pada mengurangi gangguan elektromagnetik pada SMPS, yang bisa membantu pada menaikkan efisiensi serta keandalan asal sistem tadi. Dalam penelitian ini menggunakan pendekatan *software* yakni *machine learning* regresi linear dan *neural network* untuk mengembangkan model prediksi EMI. Model ini dianalisis berdasarkan data Lorenz dan Ramp untuk membandingkan performanya. Pendekatan ini mengharapkan tidak hanya untuk mengurangi EMI pada SMPS tetapi juga untuk meningkatkan efisiensi dan keandalan sistem secara keseluruhan.. Salah satu metode *machine learning* yang digunakan untuk mengetahui hubungan fungsional sebuah variabel tak bebas (*dependent variable*) yang menggunakan dua atau lebih variabel bebas (*independent variable*) [3]. Tujuan dari *multi linear regression* ini ialah untuk mengetahui seberapa besar efek dari beberapa variabel independen terhadap variabel dependen dan juga bisa memprediksi nilai variabel independen apabila semua variabel independen sudah diketahui nilainya. pada analisis *multiple linear regression* menggunakan banyak variabel independen, seringkali ada korelasi (hubungan) antara 2 atau lebih variabel independen. Variabel independen yang saling berkorelasi disebut multikolinearitas. Permasalahan yang terjadi pada *multiple linear regression* yang disebabkan oleh multikolinearitas pada antara variabel independennya, evaluasi model serta di penelitian ini penilaian *R-squared* serta *adjusted R-squared* yang akan dijadikan sebagai

perhitungan uji hubungan antara variabel dependen terhadap variabel independen nya serta penilaian MAE serta MAPE sebagai penilaian ramalan antara data aktual terhadap yang akan terjadi prediksi.

II. KAJIAN TEORI

A. EMI (*Electromagnetic Interference*)

EMI (*Electromagnetic Interference*), adalah gangguan yang terjadi pada sinyal elektronik akibat adanya radiasi elektromagnetik dari perangkat atau sistem lain di sekitarnya [2]. Sumber EMI berasal dari komponen internal yang terdapat pada SMPS, seperti switching transistor, induktor, dan kapasitor. Faktor eksternal seperti kabel listrik, perangkat lain, dan lingkungan juga dapat menyebabkan EMI. EMI sering juga disebut *Radio Frequency Interference (RF)* apabila dalam konteks spektrum RF. Gangguan ini dapat mempengaruhi rangkaian listrik melalui induksi elektromagnetik, sambungan elektrostatik, atau konduksi.

B. EMC (*Electromagnetic Compatibility*)

EMC (*Electromagnetic Compatibility*) adalah kemampuan suatu peralatan atau sistem untuk beroperasi secara normal di lingkungan elektromagnetik tanpa terpengaruh atau pun menghasilkan interferensi (gangguan) terhadap lingkungannya, sehingga memastikan bahwa perangkat tersebut tidak hanya aman dan andal tetapi juga tidak mengganggu perangkat elektronik lain di sekitarnya.

C. SMPS (*Switch Mode Power Supply*)

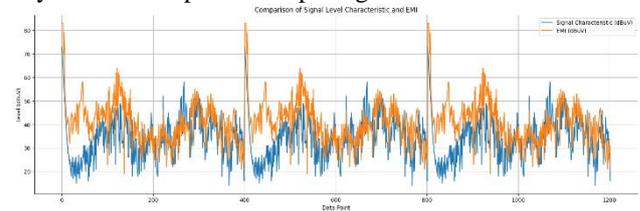
SMPS (*Switch Mode Power Supply*) adalah jenis power supply elektronik yang menggabungkan regulator switching untuk mengubah daya listrik secara efisien [2]. SMPS ini berbeda dengan power supply linier yaitu transistor lulasan dari SMPS terus-menerus beralih antara keadaan penuh-dalam dan penuh-mati, yang meminimalkan energi yang terbuang.

D. Mitigasi EMI Pada SMPS

Mitigasi EMI adalah metode untuk mengurangi dampak negatif EMI yang dimiliki oleh perangkat elektronik itu sendiri. Untuk memitigasi EMI pada SMPS memiliki dua cara yaitu dengan mengurangi EMI di jalur propagasi atau bisa langsung pada sumber EMI itu sendiri [2]. Ada beberapa cara atau metode untuk memitigasi EMI seperti filter, *shield*, *spread spectrum*, dan lain sebagainya.

E. Sinyal Lorenz

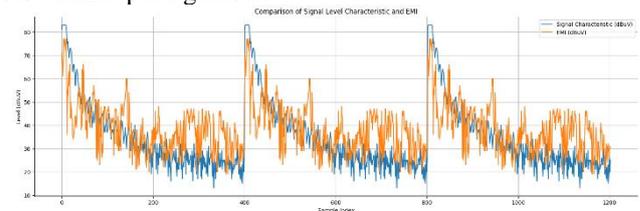
Sinyal Lorenz merupakan hasil dari sistem dinamis non-linear yang diperkenalkan oleh Edward Lorenz dalam kajian teori *chaos*, model Lorenz sering digunakan untuk merepresentasikan dinamika sistem yang kompleks seperti cuaca, turbulensi fluida, dan analisis sinyal *non-linear*, sinyal Lorenz diklasifikasikan sebagai sinyal chaotic yang sering digunakan dalam pemrosesan sinyal dan teknik *denoising* [4]. Sinyal Lorenz dapat dilihat pada gambar



GAMBAR 1
(GAMBAR FREKUENSI LORENZ)

F. Sinyal Ramp

Sinyal Ramp adalah jenis sinyal yang memiliki perubahan linear terhadap waktu, baik dalam bentuk peningkatan (ramp naik) maupun penurunan (ramp turun). Sinyal ini sering digunakan dalam sistem kontrol, pemodelan dinamika sistem, serta pemrosesan sinyal elektronik [5]. Sinyal ramp bisa dilihat pada gambar.



GAMBAR 2
(GAMBAR SINYAL RAMP)

G. Algoritma Multi-Linear Regression

Multi-Linear Regression merupakan salah satu teknik *machine learning* menganalisis hubungan antarvariabel yang akan menghasilkan model machine learning yang prediktif. *Multi-Linear Regression* adalah metode statistik yang digunakan untuk mengestimasi hubungan antara dua atau lebih variabel bebas dan satu variabel terikat. Variabel terikat adalah hasil yang ingin diprediksi atau jelaskan, misalnya presentase penduduk disuatu kota yang pengangguran bisa menjadi variabel terikat. Variabel bebas adalah faktor-faktor yang mungkin memengaruhi variabel terikat. Ada dua variabel bebas: jumlah hambatan yang dihasilkan dan besaran frekuensi dihasilkan oleh SMPS. *Multi-linear Regression* mengasumsikan hubungan antara variabel terikat dan variabel bebas dapat direpresentasikan oleh persamaan linear.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon \quad (1)$$

Dimana:

(Y) adalah variabel tak bebas.

(β_0) adalah *intercept* (nilai (Y) ketika semua variabel bebas bernilai nol).

($\beta_1, \beta_2, \dots, \beta_k$) adalah koefisien regresi (*slope*) untuk masing-masing variabel bebas.

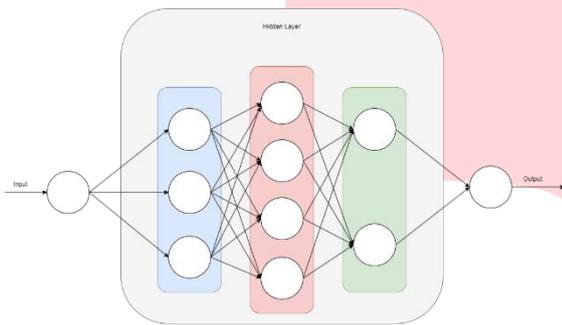
(X_1, X_2, \dots, X_k) adalah nilai-nilai variabel bebas.

(ϵ) adalah *error term* (perbedaan antara nilai prediksi dan nilai aktual).

(y_i)[^] adalah nilai dari hasil prediksi
n adalah jumlah sampel

H. Neural Network dan Backpropagation

Neural Network adalah sistem *multi-input, multi-output* yang terdiri dari neuron buatan (*artificial neurons*) untuk menangkap pola-pola kompleks dalam data. *Neural network* terdiri dari beberapa lapisan [6]. *Input Layer*, Lapisan ini yang dimana awalan dari proses *neural network* yang berisi data awal yang dimasukkan ke dalam model. *Hidden Layers*, Lapisan tersembunyi dimana data diolah menggunakan bobot (*weight*) dan bias yang melalui fungsi aktivasi *non-linear* seperti *ReLU*. *Output Layer*, Merupakan hasil akhir atau hasil keluaran dari model prediksi berdasarkan data yang dimasukkan.



GAMBAR 3
(ILUSTRASI NEURAL NETWORK)

Backpropagation adalah algoritma pelatihan *neural network* yang bertugas memperbaiki bobot dan bias *neuron* untuk meminimalkan kesalahan prediksi (*error*) [7]. Algoritma *backpropagation* digunakan untuk melatih jaringan saraf tiruan. Proses dari *backpropagation*. *Forward propagation* merupakan proses dari data input diteruskan melalui jaringan *hidden layer* untuk menghasilkan output prediksi. Untuk setiap node yang ada di *neural network* disebut *neuron*, *neuron - neuron* ini melakukan komputasi untuk mengolah data.

$$z^{(l)} = W^{(l)} \cdot a^{(l-1)} + b^{(l)}$$

$$a^{(l)} = \sigma(z^{(l)}) \quad (2)$$

Di mana:

$z^{(l)}$ adalah input teragregasi pada lapisan ke-l.

$W^{(l)}$ adalah matriks bobot pada lapisan ke-l.

$a^{(l-1)}$ adalah output dari lapisan sebelumnya.

$b^{(l)}$ adalah bias pada lapisan ke-l.

σ adalah fungsi aktivasi yang diterapkan pada setiap *neuron*.

Setelah menghitung kesalahan antara *output* prediksi dan nilai aktual yang menggunakan fungsi *loss*, seperti MSE (*Mean Squared Error*) yang dimana parameter banyak digunakan untuk menghitung seberapa besar kesalahan yang ada dimodel dimana jika nilai MSE mendekati nol maka semakin bagus model yang telah dibuat. Berikut untuk rumus menghitung fungsi *loss*.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

Yang dimana:

y_i adalah nilai aktual

Untuk *backward propagation* merupakan cara kebalikan dari *forward propagation* dengan *output* hasil prediksi dan *error*. *Backward propagation* digunakan untuk memperbaiki bobot dan bias jaringan dengan menghitung fungsi *loss* terhadap parameter dan memperbaruinya menggunakan *gradient decent*. Sebagai berikut untuk menghitung hasil dari fungsi *loss* menggunakan *gradient decent*

$$W^{(l)} = W^{(l)} - \eta \cdot \frac{\partial Loss}{\partial W^{(l)}}$$

$$b^{(l)} = b^{(l)} - \eta \cdot \frac{\partial Loss}{\partial b^{(l)}} \quad (4)$$

Dimana η merupakan *learning rate* yang akan menentukan langkah selanjutnya untuk *backwad propagation*

I. Evaluasi Hasil Prediksi Model

R-Squared berkisar antara nilai 0 sampai 1, 0 yang artinya tidak menjelaskan variabilitas apapun dan nilai 1 menjelaskan semua variabilitas yang bisa mengindikasi besarnya variabel bebas dan tidak bebas [8]. Berikut merupakan persamaan dari *R-Squared* [9].

TABEL 1
(KOEFSISIEN KORELASI ANTAR DATA)

No	Nilai Koefisien Korelasi	Keterangan
1.	$0 < r < 0.2$	Hubungan yang sangat kecil
2.	$0.2 \leq r < 0.4$	Hubungan yang kecil atau tidak erat
3.	$0.4 \leq r < 0.7$	Hubungan yang moderat atau sedang
4.	$0.7 \leq r < 0.9$	Hubungan yang erat
5.	$0.9 \leq r < 1$	Hubungan yang sangat erat

Untuk perhitungan error menggunakan MAE (*Mean Absolut Error*) merupakan pengukur rata - rata kesalahan (*error*) dalam suatu rangkaian prediksi. Metode MAE ini memperlihatkan nilai rata - rata kesalahan (*error*) antara hasil prediksi dengan nilai data sebenarnya [10].

Mean Absolut Presentage Error (MAPE) merupakan pengukur rata - rata kesalahan (*error*) absolut yang menyatakan kesalahan tersebut dengan presentase (%). Metode MAPE ini memberi tahu seberapa besar kesalahan dari hasil prediksi dengan data sebenarnya. Pada MAPE, semakin kecil presentase kesalahan yang dihasilkan, semakin bagus dari model tersebut.

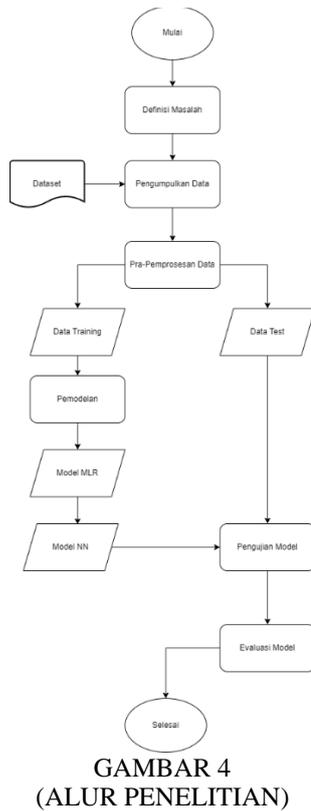
TABEL 2
(PRESENTASE ERROR DALAM PREDIKSI)

Nilai Presentase MAPE	Keterangan
> 10%	Kemampuan model prediksi sangat baik.
10% - 20%	Kemampuan model prediksi baik.
20% - 50%	Kemampuan model prediksi layak.
< 50%	Kemampuan model prediksi buruk.

III. METODE

A. Alur Penelitian

Alur dalam penelitian yang akan dilakukan untuk membuat pemodelan prediksi untuk memprediksi EMI pada SMPS.



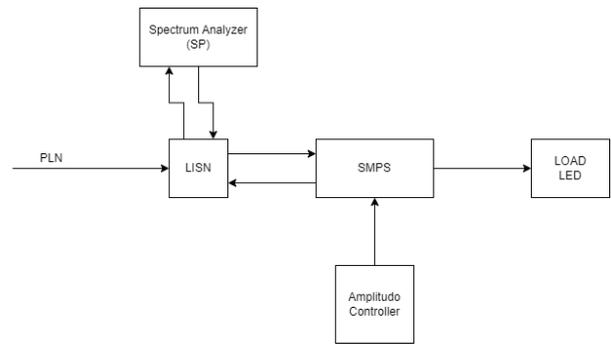
GAMBAR 4

(ALUR PENELITIAN)

Flowchart diatas pada gambar 4 memperlihatkan alur penelitian yang dimulai dengan mengidentifikasi masalah, setelah mendefinisikan masalah mengenai mitigasi EMI pada SMPS memakai *machine learning* dilanjut dengan pengumpulan data, setelah *Dataset* dikumpulkan akan langsung lanjut dengan pra-pemrosesan data yang dimana data akan diolah dan dinormalisasi, setelah dinormalisasi data akan dipisah menjadi data untuk *training* dan data untuk *testing*. Setelah dipisah dilanjut dengan melatih data *training* dengan melakukan pemodelan menggunakan model *Multi-Linear Regression* untuk memprediksi hubungan *linear* dari data dan dilanjut menggunakan *Neural Network Backpropagation* untuk memprediksi hubungan yang *non-linear* yang ada dalam data. Setelah model dibuat akan diteruskan ketahap pengujian model yang dimana akan diuji oleh data *testing* yang dipisah secara *random* tadi untuk di uji coba. Setelah itu akan dilanjut dengan melakukan evaluasi model yang dimana akan diukur seberapa akurat model ini dibuat.

B. Pengumpulan Data

Pada penelitian ini mengambil data dari SMPS yang terhubung LISN. LISN yang menjadi penerima *noise* dari inverter SMPS dan menghubungkan ke *Spectrum Analyzer EMI reciever*, SMPS yang digunakan untuk mengubah tegangan DC ke AC dengan metode *switching*.



GAMBAR 5

(DESAIN PERANGKAT)

Dengan ini mempunyai sekitar 1203 sampel data dari jenis sinyal Lorenz dan Ramp yang akan digunakan untuk pembuatan model *machine learning*, dengan patokan parameter EMI yang dihasilkan dari masing – masing sinyal yang akan dijadikan variabel dependen dan independen. Tabel dependen bisa dilihat pada tabel 3.

TABEL 3
(VARIABEL DEPENDEN)

Jenis Data	Frekuensi (kHz)	Jumlah Sampel
Frekuensi	150 – 30000	1203
Sinyal Lorenz	150 – 30000	1203
Sinyal Ramp	150 – 30000	1203

Selanjutnya parameter *dataset* yang digunakan untuk dijadikan variabel independen, seperti frekuensi, jenis sinyal, dan jumlah sampel untuk setiap EMI dari jenis sinyal yang dihasilkan bisa dilihat pada tabel 4.

TABEL 4
(VARIABEL INDEPENDEN)

Jenis Data	Frekuensi (kHz)	Jumlah Sampel
EMI Lorenz	150 – 30000	1203
EMI Ramp	150 – 30000	1203

C. Pra-Pemrosesan Data

Pada tahap ini merupakan tahap untuk mengolah data dari data yang belum siap untuk model *training* dan model tes menjadi data yang lebih matang lagi. Sebelum digunakan dalam pemodelan, data yang dikumpulkan melalui eksperimen dan simulasi harus melalui proses pra-pemrosesan agar siap digunakan dalam model *machine learning*. Pembagian data ini setelah data melewati tahap pra-pemrosesan, data tersebut langsung dipecah menjadi 2 bagian yakni data training dan data test. Data training adalah data yang akan dilatih untuk model MLR, dan pada data test data test ini langsung menuju pengujian data nantinya akan dijadikan data sebenarnya (aktual). Dataset ini dibagi menjadi data untuk *training* (70%) dan untuk data *testing* menggunakan (30%) untuk menghindari *overfitting*. Pengecekan nilai yang hilang dan normalisasi data. Untuk normalisasi data menggunakan *Standard scaler*, *Standard Scaler* merupakan salah satu teknik normalisasi data yang digunakan dalam pra-pemrosesan data sebelum diterapkan pada model pembelajaran mesin yang dimana normalisasi data yang digunakan untuk mengubah skala fitur dalam dataset dengan membuatnya memiliki rata-rata (*mean*) 0 dan standar deviasi 1 [11].

$$X_{scaled} = \frac{X - \mu}{\sigma} \quad (5)$$

Yang dimana:
 X = nilai asli fitur
 μ = rata – rata fitur
 σ = standar deviasi fitur

D. Pemodelan

Pada tahap ini, dilakukan pemodelan untuk memprediksi *Electromagnetic Interference* (EMI) pada *Switched-Mode Power Supply* (SMPS) menggunakan pendekatan *Multiple Linear Regression* (MLR) dan *Neural Network* (NN). Dalam penelitian ini, dipilih dua model untuk memprediksi EMI berdasarkan karakteristik *dataset* yang digunakan mengolah data *training* menjadi data prediksi menggunakan algoritma MLR dan *Neural Network* yang dimana MLR cocok untuk hubungan yang lebih sederhana antara variabel untuk analisis *linear*. Sementara NN digunakan untuk meneruskan hasil MLR untuk mampu menangkap hubungan kompleks dan *non-linear* dalam data EMI, yang dimana untuk MLRnya seperti berikut.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 \quad (6)$$

(Y) adalah variabel tak bebas.

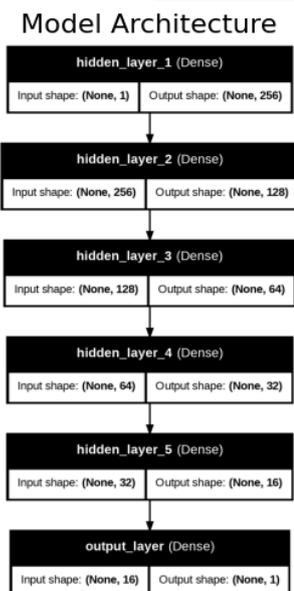
(β_0) adalah intercept (nilai (Y) ketika semua variabel bebas bernilai nol).

(β_1, β_2) adalah koefisien regresi (*slope*) untuk masing-masing variabel bebas.

X_1 = Frekuensi 150kHz – 30MHz

X_2 = Frekuensi Lorenz dan Ramp

Setelah membuat model untuk *multi linear regression* dilanjutkan membuat model *Neural Network backpropagation* model ini dipilih karena memiliki kemampuan mengenali pola yang lebih kompleks, yang tidak bisa ditangkap oleh model MLR. Prediksi EMI pada SMPS ini yang difungsikan untuk menghitung nilai yang *non-linear* dari perhitungan *multi linear regression*. Berikut merupakan gambaran dari model *backpropagation* bisa dilihat digambar 5.



GAMBAR 5
(ARSITEKTUR NEURAL NETWORK)

Dari gambar diatas bisa dilihat bahwa hasil dari model *multiple linear regression* akan dilanjut dengan pelatihan *neural network backpropagation* yang terdiri dari 5 *hidden layer* yang dimana di *layer* pertama memiliki 256 *node*, di *layer* kedua memiliki 128 *node*, di *layer* ketiga memiliki 64 *node*, di *layer* keempat memiliki 32 *node*, dan di *layer* kelima memiliki 16 *node*. Setelah dari *hidden layer* keluar lah 1 *output* untuk memprediksi EMI. Untuk aktivatornya menggunakan *ReLU* pada saat memasuki *hidden layer* dan aktivator *Linear* setelah selesai *training* dan dijadikan *output* untuk *testing*.

IV. HASIL DAN PEMBAHASAN

Pada analisis menggunakan model MLR, hasil evaluasi menunjukkan bahwa metode ini mampu memberikan prediksi yang cukup baik untuk EMI, parameter EMI dari setiap sinyal. Hasil evaluasi pelatihan dengan MLR dapat dilihat pada tabel 5.

TABEL 5
(HASIL EVALUASI MODEL MLR)

Model	Data	MSE	R^2	R^2_{adj}	MAE	MAPE
MLR	Lorenz	58.6011	0.3552	0.3516	6.0211	15.6246%
MLR	Ramp	76.8373	0.3277	0.3240	7.2980	21.0474%

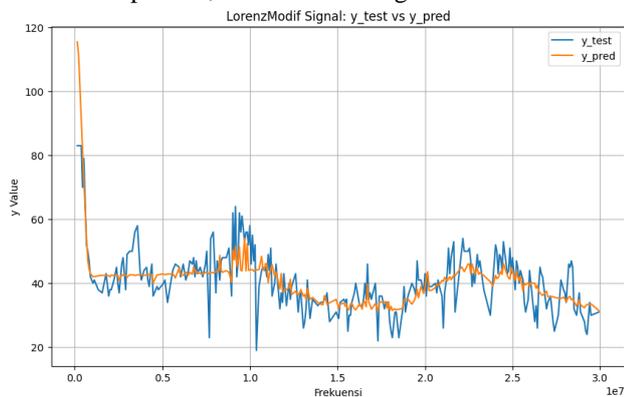
Hasil evaluasi model MLR untuk prediksi EMI pada SMPS menunjukkan kinerja yang terbatas. Pada data Lorenz, MSE sebesar 58.6011 dan R^2 sebesar 0.3552 mengindikasikan bahwa model hanya menjelaskan 35.52% variasi EMI, dengan MAE 6.0211 dan MAPE 15.6246%. *Adjusted R^2* sebesar 0.3516 menunjukkan minimnya peningkatan kinerja meskipun jumlah fitur diperhitungkan. Pada data Ramp, MSE sebesar 76.8373 dan R^2 sebesar 0.3277 menunjukkan model hanya menjelaskan 32.77% variasi EMI, dengan MAE 7.2980 dan MAPE 21.0474%. *Adjusted R^2* sebesar 0.3240 menegaskan kinerja yang masih kurang optimal. Secara keseluruhan, model MLR kurang akurat dalam memprediksi EMI pada SMPS, sehingga model yang lebih kompleks seperti *neural network* diperlukan untuk meningkatkan akurasi.

TABEL 6
(HASIL EVALUASI MODEL NN)

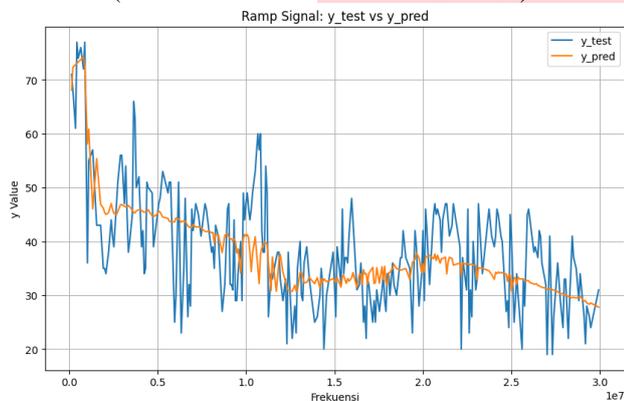
Data	MSE	R^2	R^2_{adj}	MAE	MAPE
Lorenz	42.9635	0.5272	0.5233	4.8482	12.4270%
Ramp	62.6745	0.4517	0.4470	6.4385	18.4317%

Neural Network (NN) memiliki performa lebih baik dibandingkan *Multiple Linear Regression* (MLR) untuk kedua jenis data. NN memiliki MSE lebih rendah serta R^2 dan *Adjusted R^2* lebih tinggi, menunjukkan kemampuannya yang lebih baik dalam menangkap pola data. Pada data Lorenz, NN mencatat MSE 42.9635, lebih rendah dari MLR (58.6011), dengan R^2 dan *Adjusted R^2* masing-masing 0.5272 dan 0.5233, lebih tinggi dibandingkan MLR (0.3552 dan 0.3516). MAE dan MAPE NN juga lebih kecil (4.8482 dan 12.4270%) dibandingkan MLR. Pada data Ramp, NN juga unggul dengan MSE 62.6745 dibandingkan MLR (76.8373), serta R^2

dan *Adjusted R²* lebih tinggi (0.4517 dan 0.4470 vs. 0.3277 dan 0.3240). NN juga mencatat MAE dan MAPE lebih rendah (6.4385 dan 18.4317%) dibandingkan MLR (7.2980 dan 21.0474%), menunjukkan prediksi yang lebih akurat. Berikut merupakan perbandingan prediksi EMI dari setiap variabel independen, bisa dilihat dari gambar 4.1 dan 4.2.



GAMBAR 6
(HASIL PREDIKSI DATA LORENZ)



GAMBAR 7
(HASIL PREDKSI DATA RAMP)

Grafik prediksi EMI menunjukkan bahwa *Neural Network Backpropagation* mampu menangkap pola utama data uji (*y_test*), meskipun akurasi bervariasi antar dataset. Pada data Lorenz, model memiliki *R²* lebih tinggi (0.5272), menunjukkan prediksi yang lebih baik. Grafik memperlihatkan bahwa *y_pred* mengikuti tren data aktual dengan baik pada frekuensi rendah hingga menengah, meskipun terdapat sedikit penyimpangan pada frekuensi tinggi, di mana fluktuasi tajam cenderung diredam. Pada data Ramp, model lebih sulit menangkap variasi EMI, dengan *R²* lebih rendah (0.4517). Meskipun tren global diikuti, terdapat deviasi lebih besar, terutama pada frekuensi menengah hingga tinggi. Model cenderung menghasilkan prediksi lebih halus, kurang menangkap lonjakan tajam dalam data aktual.

V. KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi EMI menggunakan *Multiple Linear Regression* (MLR) dan *Neural Network* (NN). Hasil analisis menunjukkan bahwa NN lebih efektif dalam menangkap pola kompleks dibandingkan MLR, yang terbatas dalam memodelkan hubungan non-linear. Eksperimen menunjukkan bahwa model dengan data Lorenz memiliki akurasi lebih tinggi dibandingkan Ramp, terlihat dari MSE lebih rendah dan *R²*

lebih tinggi, terutama pada NN. MLR unggul dalam interpretasi yang lebih sederhana, tetapi kurang efektif untuk hubungan *non-linear*. Sebaliknya, NN lebih akurat dalam prediksi, namun memerlukan pelatihan lebih lama dan tuning *hyperparameter* yang kompleks.

REFERENSI

- [1] F. Fauzi, M. E. Zaidi, U. Udom, and N. A. A. Manaf, "Switch Mode Power Supply (SMPS) Utilizing Flyback Converter Topology: Simulation and Experiment," *J. Phys. Conf. Ser.*, vol. 2312, no. 1, 2022, doi: 10.1088/1742-6596/2312/1/012050.
- [2] F. Ahmad, M. Y. Hariyawan, and S. N. Posma, "Perancangan Dan Implementasi Passive Emi Filter Pada Switching Mode Power Supply (SMPS)," *J. Elektro dan Mesin Terap.*, vol. 5, no. 1, pp. 29–37, 2019, doi: 10.35143/elementer.v5i1.2519.
- [3] L. M. Ginting, M. M. Sigirow, E. D. Manurung, and J. J. P. Sinurat, "Perbandingan Metode Algoritma Support Vector Regression dan Multiple Linear Regression Untuk Memprediksi Stok Obat," *J. Appl. Technol. Informatics Indones.*, vol. 1, no. 2, pp. 29–34, 2021, doi: 10.54074/jati.v1i2.36.
- [4] H. Yang, Y. Cheng, and G. Li, "A denoising method for ship radiated noise based on Spearman variational mode decomposition, spatial-dependence recurrence sample entropy, improved wavelet threshold denoising, and Savitzky-Golay filter," *Alexandria Eng. J.*, vol. 60, no. 3, pp. 3379–3400, 2021, doi: 10.1016/j.aej.2021.01.055.
- [5] Y. Ji, Y. Ji, Y. Wu, Y. Wu, and Y. Zhang, "Excitation process under the ramp-step waveform of inductive source-induced polarization method," *Geophysics*, vol. 85, no. 2, pp. E57–E65, 2020, doi: 10.1190/geo2019-0216.1.
- [6] A. Thakur, "Fundamentals of Neural Networks," *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 9, no. VIII, pp. 407–426, 2021, doi: 10.22214/ijraset.2021.37362.
- [7] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning Representations by Back-Propagating Errors," *Cogn. Model.*, no. 2, pp. 213–222, 2019, doi: 10.7551/mitpress/1888.003.0013.
- [8] A. Bhandari, "Key Difference between R-squared and Adjusted R-squared for Regression Analysis." Accessed: Jun. 11, 2024. [Online]. Available: <https://www.analyticsvidhya.com/blog/2020/07/difference-between-r-squared-and-adjusted-r-squared/>
- [9] C. GOYAL, "The Game of Increasing R-squared in a Regression Model." Accessed: Jun. 11, 2024. [Online]. Available: <https://www.analyticsvidhya.com/blog/2021/05/the-game-of-increasing-r-squared-in-a-regression-model/>
- [10] A. Kumar, "MSE vs RMSE vs MAE vs MAPE vs R-Squared: When to Use?" Accessed: Jun. 12, 2024. [Online]. Available: <https://vitalflux.com/mse-vs-rmse-vs-mae-vs-mape-vs-r-squared-when-to-use/>
- [11] M. M. Ahsan, M. A. P. Mahmud, P. K. Saha, K. D. Gupta, and Z. Siddique, "Effect of Data Scaling Methods on Machine Learning Algorithms and Model Performance," *Technologies*, vol. 9, no. 3, pp. 5–9, 2021, doi: 10.3390/technologies9030052.

