

Estimasi Kecepatan Reaksi Elektrolisis berdasarkan Energi Listrik dari Sumber Energi Terbarukan dengan Estimator *Extreme Learning Machine*

I Putu Eka Suartana¹, Didit Widyanto²

Informatika

Fakultas Ilmu Komputer

Jl. RS. Fatmawati, Cilandak, Jakarta Selatan, 12450, Indonesia

ipes@upnvj.ac.id¹, didit.widyanto@upnvj.ac.id²

Abstrak. Indonesia memiliki potensi yang sangat besar untuk mengembangkan energi baru terbarukan karena kaya akan sumber daya alam yang berkelanjutan seperti air. Air dapat dimanfaatkan sebagai penggerak generator dari PLTA dan juga dapat menghasilkan zat hidrogen untuk di manfaatkan sebagai sumber energi panas dan listrik. Hidrogen menjadi sumber yang dapat menggantikan bahan yang mengandung hidrokarbon. Perkembangan teknologi yang pesat pada era ini memungkinkan teknologi machine learning dapat dimanfaatkan untuk melakukan estimasi kecepatan produksi hidrogen melalui proses elektrolisis air. Algoritma yang digunakan untuk membangun model machine learning adalah Extreme Learning Machine karena pemrosesan data yang relatif cepat dan hasil yang didapatkan juga akurat. Proses pembangunan model menggunakan pembagian data sebesar 30% untuk data uji, 70% untuk data latih dan menggunakan parameter 40 hidden neuron, inialisasi bobot random antara -1 sampai 1, dan menggunakan fungsi aktivasi sigmoid biner sehingga mendapatkan hasil nilai R2 sebesar 0.995, untuk RMSE 23.29, dan MAE sebesar 17.061

Kata Kunci: Hidrogen, Machine Learning, ELM, Energi Terbarukan.

1 Pendahuluan

Pada dasarnya, energi sudah menjadi salah satu kebutuhan utama yang menjamin keberlangsungan aktivitas dari semua makhluk hidup khususnya manusia. Salah satu energi yang tidak pernah lepas dari kehidupan manusia adalah energi listrik (Yuwa Phiadelvira et al., 2021). Sumber dari energi listrik biasanya terdiri dari 2 macam, yaitu energi tak terbarukan (fosil) dan energi terbarukan. Energi terbarukan adalah energi yang dibentuk menggunakan unsur – unsur dari proses alam yang berkelanjutan. Indonesia memiliki potensi yang sangat besar untuk mengembangkan energi baru terbarukan (EBT) karena kaya akan sumber daya alam yang berkelanjutan seperti air, angin, surya dan masih banyak energi lainnya. Air dapat dimanfaatkan sebagai energi terbarukan, bukan hanya sebagai penggerak generator dari PLTA tetapi dapat menghasilkan zat hidrogen untuk dimanfaatkan sebagai sumber energi panas dan listrik (Hasan & Widayat, 2022).

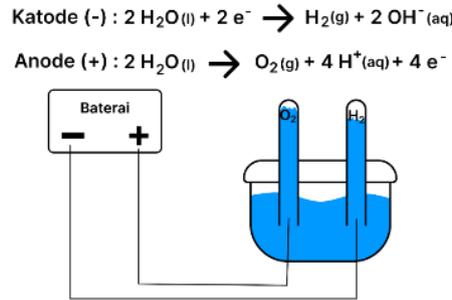
Perkembangan teknologi yang pesat pada era ini dapat diterapkan untuk mendukung penelitian dalam mengembangkan produksi hidrogen menjadi lebih bermanfaat bagi masyarakat luas dan menjamin keselamatan para peneliti. Selain itu dari dampak ekonomi, penerapan teknologi dalam proses produksi hidrogen dapat meningkatkan efisiensi proses produksinya sehingga menekan biaya produksi (Agyekum et al., 2022). Penerapan teknologi pada tahapan awal digunakan untuk membuat estimator dalam proses estimasi kecepatan proses pembentukan hidrogen. Dalam proses pembangunan model estimasi dapat menggunakan metode jaringan syaraf tiruan dari algoritma *machine learning*, karena memiliki keunggulan untuk belajar layaknya otak manusia dari data – data yang berikan (Mohamed et al., 2022). Metode *Extreme Learning Machine* adalah salah satu metode dari jaringan syaraf tiruan, penerapan *Extreme Learning Machine* didasari dari pemrosesan data yang relatif cepat dan hasil yang didapatkan juga akurat (Mohamed et al., 2022).

2 Landasan Teori

2.1 Proses Pembentukan Hidrogen Melalui Elektrolisis Air

Elektrolisis air adalah proses kimia yang menggunakan arus listrik untuk memisahkan senyawa air H₂O menjadi gas hidrogen H₂ dan oksigen O₂. Dalam proses ini, dua elektroda, katoda elektroda negatif dan anoda elektroda positif, direndam dalam air. Di katoda, dua molekul air berinteraksi dengan elektron yang disuplai oleh sumber arus. Dalam reaksi reduksi, setiap molekul air menangkap dua elektron dan berubah menjadi molekul gas hidrogen H₂ dan ion hidroksida OH⁻. Reaksi ini diwakili oleh persamaan kimia berikut $2\text{H}_2\text{O} + 2\text{e}^- = \text{H}_2 + 2\text{OH}^-$ Sedangkan dua molekul air yang tersisa di anoda mengalami oksidasi. energi listrik akan

dihasilkan menggunakan hidrogen yang telah terbentuk melalui proses elektrolisis air (Hasan & Widayat, 2022). Proses reaksi elektrolisis yang terjadi diilustrasikan pada Gambar 1.



Gambar. 1. Proses Elektrolisis Air

Proses elektrolisis air menghasilkan 2 molekul gas, yakni oksigen dan hidrogen yang dapat digunakan sebagai bahan bakar dalam bentuk gas. Penggunaan hidrogen sebagai bahan bakar potensial telah menjadi topik penting dalam pengembangan teknologi energi bersih dan berkelanjutan (Agyekum et al., 2022). Pengimplementasian teknologi bersih dalam pengembangan energi khususnya produksi hidrogen dapat menggunakan panel surya dalam proses pemecahan senyawa air. Proses panel surya dalam menghasilkan energi listrik diawali ketika sinar matahari jatuh pada sel surya, elektron-elektron dalam material semikonduktor dilepaskan dan diarahkan ke arah medan listrik dalam sel surya. Medan listrik ini diciptakan oleh lapisan yang terbuat dari material semikonduktor yang bermuatan berlawanan (Junaidi, 2020).

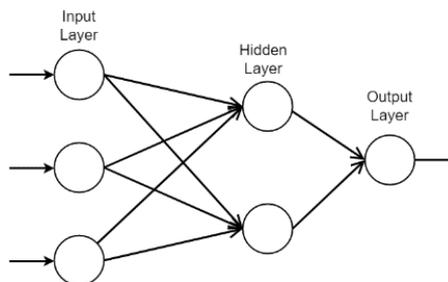
2.2 Estimator

Estimator adalah variabel atau fungsi statistik yang digunakan untuk memperkirakan atau mengestimasi suatu parameter dalam suatu populasi. Estimator digunakan dalam konteks analisis statistik untuk membuat perkiraan tentang sifat-sifat suatu populasi, seperti nilai rata-rata, variansi, atau proporsi (Ananda et al., 2018). Estimator digunakan sebagai alat untuk membuat perkiraan tentang parameter populasi yang tidak diketahui. Estimator dapat digunakan dalam berbagai teknik statistik, seperti regresi, analisis varian, atau pengujian hipotesis.

2.3 Jaringan Syaraf Tiruan (JST)

Jaringan syaraf tiruan adalah sistem komputasi untuk pemrosesan informasi yang terinspirasi dari karakteristik pemodelan otak manusia. Struktur dasar JST terdiri dari *artificial neurons* dikelompokkan menjadi beberapa *layers* seperti yang diilustrasikan pada Gambar 2. Struktur JST memiliki 3 lapisan, antara lain:

1. *Input layer*
 Pada lapisan ini adalah tempat dari masuknya data yang ingin di proses.
2. *Hidden layer*
 Pada lapisan ini berisi sekumpulan prosedur atau menambah instruktur logika untuk menghasilkan keluaran.
3. *Output layer*
 Pada lapisan ini tempat dari hasil proses.



Gambar. 2. Arsitektur JST

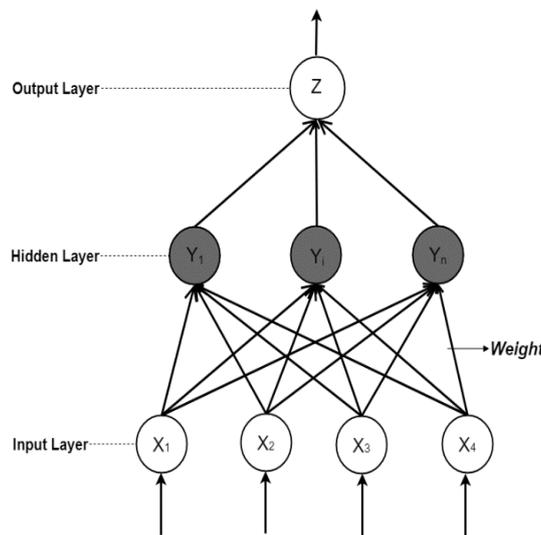
Jaringan syaraf tiruan (JST) memiliki beberapa bentuk pemodelan arsitektur jaringan, berikut 3 bentuk yang paling umum digunakan (Soebroto et al., 2019):

- 1) *Single-Layer Neural Network*
 Model paling sederhana dari jaringan syaraf tiruan yakni *single layer neural network*. Hal ini dikarenakan cara kerja yang dimulai dari input layer (sumber data) dikoneksikan langsung menuju ke output layer (hasil).

- 2) *Multilayer Perceptron Neural Network*
Multi layer Perceptron Neural Network (MLP) adalah perkembangan dari bentuk *single layer neural network* karena MLP digunakan untuk menangani kasus yang lebih sulit dari *single layer*, tetapi proses yang terjadi menjadi lebih lama.
- 3) *Recurrent Neural Network*
Recurrent neural network (RNN) adalah model yang memproses dengan melalui sebuah loop yang berisi informasi yang telah didapatkan sebelumnya sebagai pertimbangan data atau informasi yang pernah di proses dalam mengolah data baru.

2.4 Algoritma Extreme Learning Machine

Extreme Learning Machine (ELM) merupakan pengoptimal dari metode jaringan syaraf tiruan (JST). Hal ini bertujuan karena ELM akan mengatasi permasalahan *learning speed* yang terjadi pada JST. Metode *Extreme Learning Machine* termasuk dalam tipe *Single Hidden Layer Feedforward Neural Networks* (SLFNs). *Learning speed* dalam proses pembangunan model yang cepat dan *good generalization performance* pada ELM disebabkan input weight dan bias pada parameter ELM dipilih secara acak (Mohamed et al., 2022).



Gambar. 3. Arsitektur ELM

Perhitungan pada metode Elm dibagi menjadi 2 proses yaitu proses *training* dan proses *testing*. Proses *testing* bertujuan untuk mendapatkan model jaringan ELM yang kemudian diterapkan pada proses *testing* untuk mengevaluasi hasil yang didapatkan (Ashar Nirzha Maulidya, 2018). Berikut langkah-langkah pelatihan pada model machine learning:

- 1) Menginisialisasi *input weight* dan bias secara acak dengan rentang 1 sampai -1
- 2) Menghitung keluaran *hidden layer* menggunakan persamaan 1.

$$H_{init_{train}} = X_{train} \cdot W^T + b \tag{1}$$

$H_{init_{train}}$ = Matriks hasil *hidden layer* untuk proses latih

X_{train} = Data latih

W^T = *Transpose input weight*

- 3) Nilai matriks hidden layer yang dihasilkan dihitung dengan fungsi aktivasi sigmoid biner menggunakan persamaan 2.

$$H = \frac{1}{1 + \exp(-H_{init_{test}})} \tag{2}$$

H = Fungsi aktivasi *sigmoid biner*

\exp = Eksponensial

$H_{init_{test}}$ = Matriks hasil *hidden layer* untuk proses pengujian

- 4) Melakukan perhitungan matriks Moore-Penrose Generalized Invers dari hasil yang didapat pada tahap sebelumnya menggunakan persamaan 3.

$$H^+ = (H^T H)^{-1} H^T \tag{3}$$

H^+ = *Moore-Penrose Generalized Inverse*

H^T = Matriks H *transpose*

H = Matriks hasil *hidden layer*

5) Tahap akhir adalah menghitung nilai output weight menggunakan persamaan 4.

$$\hat{\beta} = H^+ \cdot Y \tag{4}$$

$\hat{\beta}$ = Matriks *output weight*
 H^+ = Matriks *Moore-Penrose Generalized Invers* dari matriks H
 Y = Matriks target

Nilai yang didapat dari pelatihan data berupa nilai input weight, bias, dan output weight. Nilai yang didapat kemudian digunakan untuk pengujian data, tahapan yang dilakukan untuk pengujian data, sebagai berikut:

- 1) Menggunakan inialisasi input weight dan bias
- 2) Menghitung nilai matriks hidden layer menggunakan persamaan 5.

$$H_{init_{test}} = X_{test} \cdot W^T + b \tag{5}$$

$H_{init_{test}}$ = Matriks hasil *hidden layer* untuk proses pengujian
 X_{test} = Data uji
 W^T = *Transpose input weight*

3) Menghitung fungsi aktivasi dengan data hasil matriks hidden layer menggunakan persamaan 6.

$$H = \frac{1}{1 + \exp(-H_{init_{test}})} \tag{6}$$

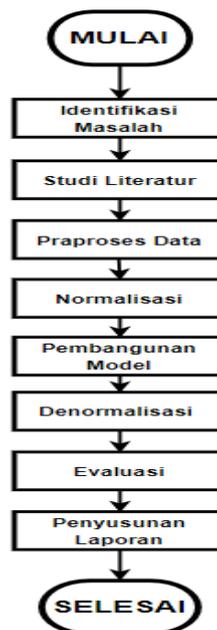
H = Fungsi aktivasi *sigmoid biner*
 exp = Eksponensial
 $H_{init_{test}}$ = Matriks hasil *hidden layer* untuk proses pengujian

4) Menghitung hasil prediksi menggunakan nilai output weight dari proses pelatihan data menggunakan persamaan

$$\hat{Y} = H \cdot \hat{\beta} \tag{7}$$

$\hat{\beta}$ = Nilai *output weight* dari proses pelatihan data
 H = Keluaran di *hidden layer* dihitung dengan fungsi aktivasi
 \hat{Y} = Hasil prediksi

3 Metodologi Penelitian



Gambar. 4. Tahapan Penelitian

3.1 Identifikasi Masalah

Tahap ini merupakan proses mengidentifikasi masalah dan dilanjutkan dengan merumuskan permasalahan kecepatan waktu yang diperlukan dalam proses pembentukan gas hidrogen.

3.2 Studi Literatur

Pada tahap studi literatur dilaksanakan pencarian dokumen berupa buku, jurnal, atau artikel penelitian yang berkaitan dengan permasalahan yang akan diteliti dan bermanfaat untuk memberikan pemahaman lebih dalam tentang metode *extreme learning machine* (ELM) dan efektivitas penerapannya untuk masalah yang dirumuskan dalam penelitian ini.

3.3 Praproses Data

Data yang telah dikumpulkan kemudian dilakukan praproses data menggunakan beberapa teknik praproses data yang berfungsi untuk menghasilkan data yang layak untuk digunakan dalam proses pembangunan model estimasi *extreme learning machine* dengan akurasi yang baik.

3.4 Normalisasi

Data yang telah dilakukan pembersihan melalui tahapan praproses data kemudian dilakukan normalisasi untuk mengatasi persebaran yang tinggi pada nilai yang ada di setiap fitur. Teknik normalisasi data menggunakan metode Min-Max Normalization yang akan menghasilkan nilai pada setiap fitur akan berada pada rentang nilai 0 – 1. Persamaan 8 menjelaskan rumus matematis dari metode *Min-Max Normalization*.

$$d' = \frac{d - \min}{\max - \min} \tag{8}$$

d' = Hasil normalisasi

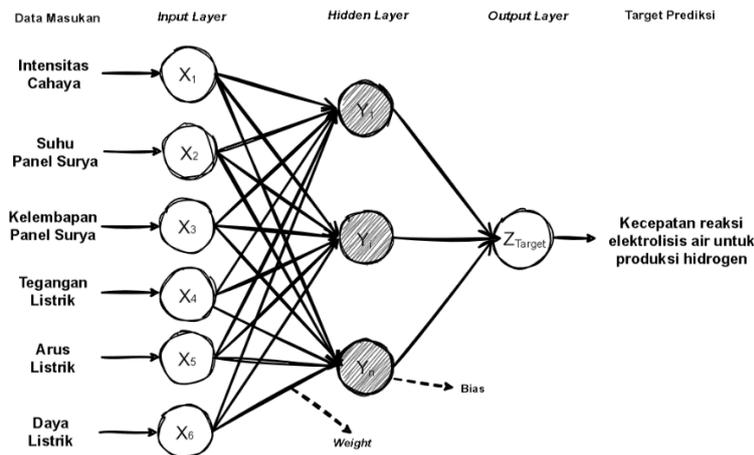
d = Data

\min = Nilai terkecil dari semua fitur

\max = Nilai terbesar dari semua fitur

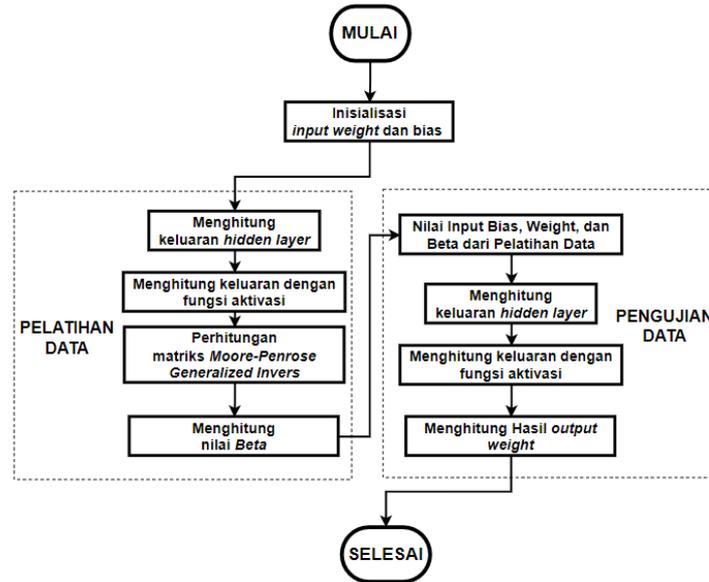
3.5 Pembangunan Model

Model yang dibangun menggunakan algoritma *extreme learning machine* dengan arsitektur seperti gambar yang terdiri dari 6 *input layer*, 1 *hidden layer* dan *output layer*.



Gambar. 4. Arsitektur *Extreme Learning Machine*

Pada tahapan pembangunan model dari algoritma *extreme learning machine*, akan dilakukan proses pelatihan data menggunakan data latih dan juga pengujian menggunakan data uji. Kemudian pada tahapan ini dilakukan pengujian parameter yang kemudian akan digunakan untuk untuk pembangunan model. Proses pembangunan model yang dimulai dari tahap pelatihan hingga pengujian di ilustrasikan pada gambar.



Gambar. 5. Tahapan Pembangunan Model

3.6 Denormalisasi Data

Hasil yang didapatkan dari proses pembangunan model dilakukan denormalisasi untuk mengembalikan nilai ke nilai asal sebelum di normalisasi.

3.7 Evaluasi

Setelah di lakukan denormalisasi data kemudian data yang didapatkan dilakukan proses evaluasi menggunakan metrik evaluasi RMSE yang berfungsi untuk mengukur kesalahan model prediksi dalam memprediksi nilai kontinu, MAE yang berfungsi untuk mengukur perbedaan antara nilai yang diprediksi dan nilai yang diamati dalam sebuah model, dan yang terakhir adalah R-squared (R^2) untuk mengevaluasi kinerja model pembelajaran mesin dalam melakukan prediksi.

3.7 Penyusunan Laporan

Tahap akhir adalah penulisan laporan dari setiap penelitian yang dilakukan dan hasil yang didapatkan.

4 Hasil dan Pembahasan

4.1 Formulasi Data

Data yang digunakan dalam penelitian ini bersumber dari data yang diambil langsung atau data primer yang bersumber dari penelitian yang dilakukan di daerah cilengsi menggunakan panel surya dan juga reaktor hidrogen dengan sistem IoT untuk pengumpulan datanya.

Tabel 1. Dataset Yang Digunakan

NO	LUX	HUMIDITY	TEMPERATURE	VOLTAGE	AMPERE	WATT	VOLUME
1	49803.27 Lux	46 %	47.9 °C	11.58 V	2.95A	34.1W	239.896 cm ³ /120 sec
2	25417.73 Lux	66.7 %	35.9 °C	10.81 V	1.27A	13.7W	0 cm ³ /120 sec
3	64253.96 Lux	58.4 %	40.6 °C	12.04 V	3.58A	43.1W	396.268 cm ³ /120 sec
4	88252.41 Lux	46.2 %	48.3 °C	12.22 V	5A	61.1W	973.4 cm ³ /120 sec
5	57286.66 Lux	57.2 %	36.7 °C	12.21 V	4.91A	59.9W	965.864 cm ³ /120 sec
...
799	63479.81 Lux	60.3 %	35.9 °C	12.24 V	5.05A	61.8W	1023.012 cm ³ /120 sec

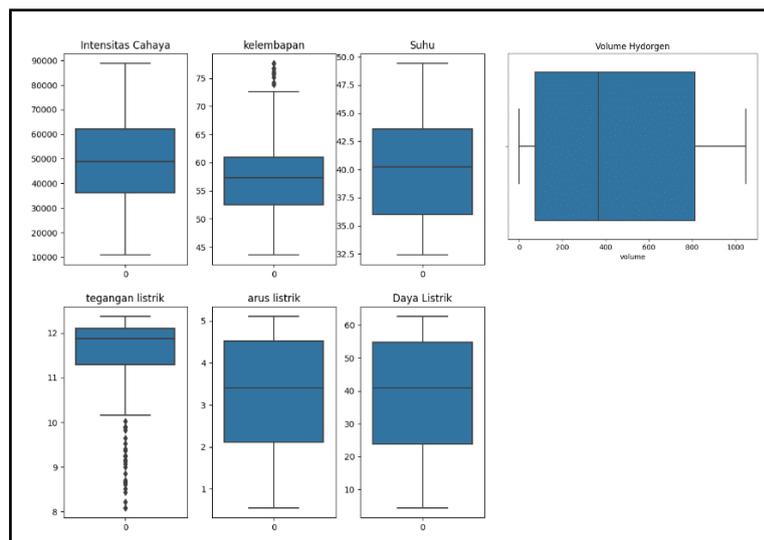
Isi dari data yang di deskripsikan pada tabel 1 adalah data yang akan digunakan dalam membuat model estimasi. Variabel data yang akan digunakan sebagai fitur dalam pembuatan model, seperti:

- Intensitas cahaya matahari (LUX)
- Kelembapan udara panel surya (HUMIDITY)
- Suhu dari panel surya (TEMPERATURE)
- Tegangan listrik yang dihasilkan oleh panel surya (VOLTAGE)
- Arus listrik yang dihasilkan oleh panel surya (AMPERE)
- Daya Listrik yang dihasilkan oleh panel surya (WATT)

Variabel hasil produksi hidrogen dari elektrolisis (VOLUME) akan digunakan sebagai target/label dalam pembuatan model estimasi. Penggunaan variabel volume produksi sebagai target dari estimasi kecepatan reaksi disebabkan semakin cepat reaksi yang berlangsung dalam satuan waktu sebanding lurus juga dengan volume yang dihasilkan. Total keseluruhan data yang digunakan sebagai pembangunan model estimasi kecepatan rekasi elektrolisis sejumlah 799 data.

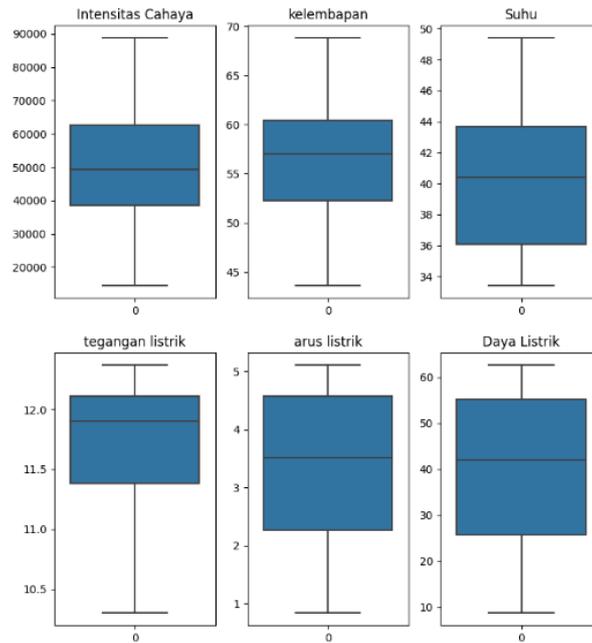
4.3 Praproses Data

Data sebelum digunakan untuk pembuatan model prediksi sebaiknya dilakukan pra proses data untuk memastikan data yang digunakan sudah bagus dan dapat menghasilkan model estimasi dengan tingkat error prediksi yang rendah. Data yang digunakan dilakukan analisis boxplot untuk mengetahui *outlier* atau nilai unik yang terlihat berbeda sangat jauh dari populasi atau bahkan bukan populasi yang diambil sebagai data yang digunakan. Dari hasil ilustrasi gambar 7 didapatkan pada fitur kelembapan dan tegangan terdapat adanya outlier.



Gambar. 6. Visualisasi Boxplot Terdapat Outlier

Proses penghilangan *outlier* dilakukan dengan teknik IQR, yaitu metode statistik yang digunakan untuk mengukur persebaran data dalam suatu dataset. Teknik IQR bekerja dengan cara mendapatkan nilai kuartil atas (Q3) dan nilai kuartil bawah (Q1), yang kemudian diambil selisihnya. Setelah penerapan teknik IQR dataset berkurang dari 799 data menjadi 767 data. Berikut hasil visualisasi boxplot setelah melakukan teknik IQR untuk menghilangkan adanya *outlier* pada data. Dapat dilihat pada gambar 8 mengilustrasikan tidak adanya *outlier* pada dataset yang akan digunakan.



Gambar. 7. Visualisasi Boxplot Bersih *Outlier*

4.3 Normalisasi

Data yang sudah bersih kemudian dilakukan normalisasi dengan menggunakan perhitungan *Min-Max Normalization* untuk menyamakan rentang nilai tertinggi dan terendah pada tiap fitur. Perbedaan rentang nilai yang tinggi antar fitur dapat mempengaruhi hasil akurasi pada model yang dibangun. Oleh karena itu, tahap ini penting dilakukan. Setelah dilakukan normalisasi rentang nilai akan berada pada rentang 0 – 1, yang dapat diilustrasikan pada gambar 9.

	lux	humidity	temperature	voltage	ampere	watt
count	756.000000	756.000000	756.000000	756.000000	756.000000	756.000000
mean	0.479015	0.510089	0.431184	0.671615	0.590508	0.579907
std	0.220651	0.228103	0.267978	0.250561	0.298123	0.299731
min	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
25%	0.315698	0.344246	0.168750	0.511421	0.348946	0.330241
50%	0.470945	0.535714	0.425000	0.766497	0.639344	0.620594
75%	0.650477	0.674603	0.650000	0.868020	0.875878	0.866883
max	1.000000	1.000000	1.000000	1.000000	1.000000	1.000000

Gambar. 8. Deskripsi Dataset

4.3 Pembagian Data

Setelah tahapan pra-proses data selesai dilakukan, kemudian sisa data yang akan digunakan dalam pembangunan model sejumlah 767 data. Data tersebut dibagi dengan rasio 70:30, dengan rincian 70% atau 536 data untuk data latih dan 30% atau 231 data untuk data uji.

4.4 Pembangunan model estimasi

Tahapan pertama dalam pembangunan model estimasi dengan metode *extreme learning machine* adalah menentukan parameter – parameter yang akan digunakan untuk menghasilkan akurasi yang baik. Parameter – parameter yang digunakan dalam uji parameter pembangunan model estimasi dengan metode *extreme learning machine* di deskripsikan pada tabel 2.

Tabel. 2. Parameter dalam Uji Parameter

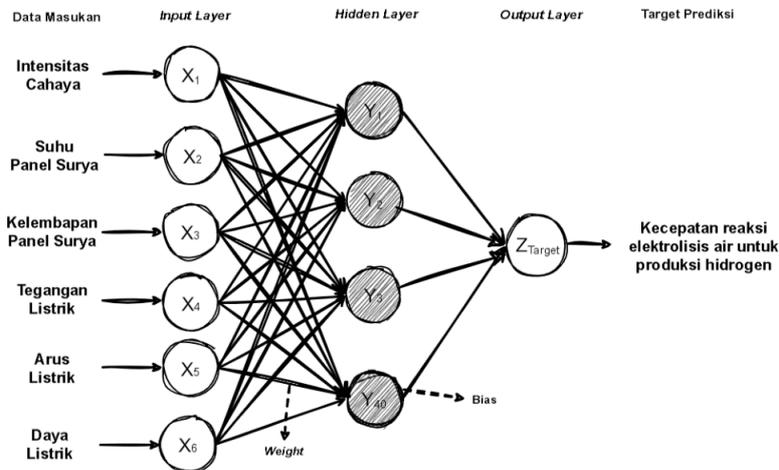
Parameter	Isi Parameter
Input Neuron	6
Output Neuron	1
Hidden Neuron	2, 4, 6, 8, 10, 12, 14, 16, 18, 20, 22, 24, 26, 28, 30, 32, 34, 36, 38, 40
Fungsi aktivasi	Sigmoid Biner
Nilai random bobot dan bias	- -1 sampai 1 (Bipolar) - 0 sampai 1 (Unipolar)

Hasil evaluasi pada uji parameter didapatkan nilai rmse paling kecil sebesar 0.022521 dengan jumlah *hidden neuron* sebanyak 40 dan inisialisasi bobot random -1 sampai 1.

Tabel. 3. Hasil Evaluasi Uji Parameter

Hidden Neuron	Nilai RMSE	
	Bipolar	Unipolar
2	0.124716	0.226952
4	0.10365	0.126867
6	0.081971	0.100145
8	0.058481	0.075347
10	0.0549	0.068486
12	0.039322	0.033568
14	0.028537	0.037173
16	0.026493	0.029279
18	0.028127	0.029512
20	0.027409	0.026227
22	0.025746	0.025308
24	0.025772	0.02617
26	0.025493	0.025492
28	0.026321	0.02562
30	0.024195	0.023941
32	0.02354	0.024651
34	0.023206	0.02441
36	0.023531	0.02384
38	0.023555	0.023632
40	0.022521	0.022778

Setelah menemukan parameter terbaik dan optimal, selanjutnya bisa dilakukan proses pelatihan (*training*) dan proses pengujian (*testing*). Arsitektur pada metode *extreme learning machine* yang dibangun diilustrasikan pada gambar 10.



Gambar. 9. Arsitektur Model Estimasi

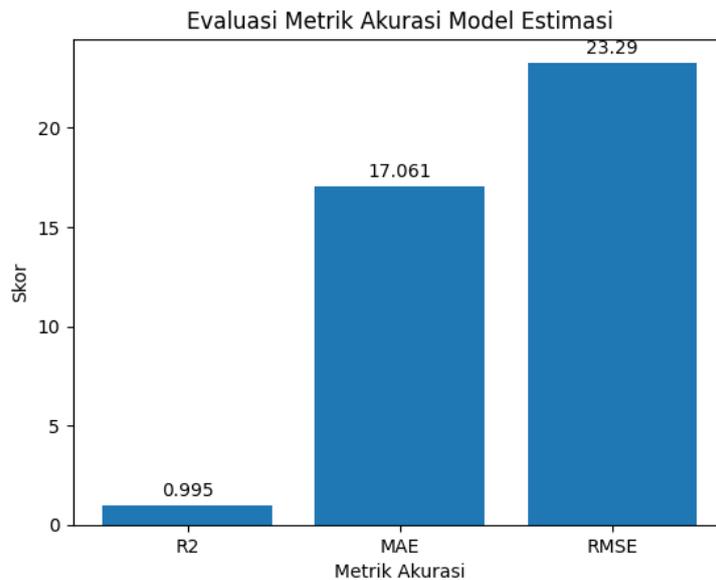
Setelah dilakukan pelatihan dengan 536 data latih menghasilkan nilai input bias, bobotm dan beta. Nilai tersebut digunakan kembali untuk proses pengujian data dengan 231 data uji untuk menghasilkan nilai output weight. Nilai output weight kemudian di denormalisasi untuk mengembalikan nilai ke bentuk semula sebelum normalisasi, seperti yang di deskripsikan pada tabel 4.

Tabel 4. Proses Denormalisasi

Output Weight	Denormalisasi
0.895667	938.777
1.013677	1062.467
0.351553	368.474
0.316547	331.783
0.403058	422.458
0.741366	777.049
0.745147	781.012
0.349337	366.151
0.927702	972.354
0.085387	89.497

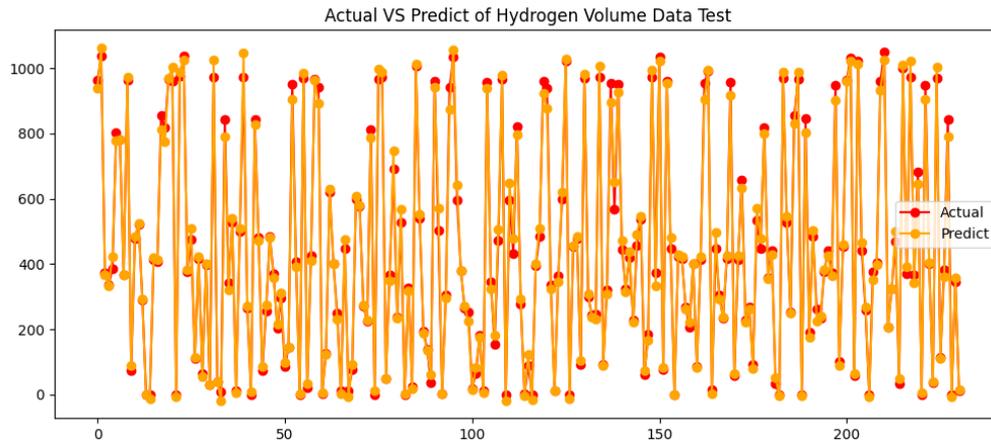
4.5 Evaluasi Metode *Extreme Learning Machine*

Hasil evaluasi dari proses pembangunan model estimasi untuk kecepatan reaksi elektrolisis pada gambar 11 berisi nilai evaluasi R^2 sebesar 0.995, untuk RMSE 23.29, dan MAE sebesar 17.061 dengan akurasi yang baik menunjukkan model dapat melakukan estimasi kecepatan reaksi elektrolisis dalam produksi hidrogen dengan baik.



Gambar. 10. Hasil Evaluasi Model

Gambar 12 mengilustrasikan dengan volume produksi hidrogen dengan nilai prediksi volume produksi hidrogen menggunakan algoritma *extreme learning machine*. Dari posisi nilai aktual dan prediksi terlihat berdekatan dan menempel. Hal ini menunjukkan bahwa performa dari algoritma *extreme learning machine* sudah baik.



Gambar. 11. Visualisasi Nilai Estimasi dan Sebenarnya

5 Penutup

5.1 Kesimpulan

Berdasarkan dari hasil penelitian yang telah dijalankan dan dilakukan evaluasi pada setiap tahapan pembuatan model estimasi kecepatan reaksi elektrolisis menggunakan algoritma *extreme learning machine* didapatkan beberapa kesimpulan, antara lain:

- Model *extreme learning machine* sudah berhasil mempelajari pola dari data – data dalam membangun model estimasi kecepatan reaksi elektrolisis melalui energi terbarukan dengan parameter yang digunakan seperti Jumlah *hidden neuron* yang digunakan sejumlah 40, inialisasi bobot random antara -1 sampai 1 dan penggunaan fungsi aktivasi sigmoid biner. Proses mempelajari pola data dengan melakukan proses pelatihan untuk mendapatkan nilai weight, bias, dan beta. Ketiga nilai tersebut digunakan untuk pengujian dan mendapatkan nilai *output* yang kemudian dilakukan denormalisasi data untuk mendapatkan hasil prediksi dari model.
- Hasil evaluasi yang didapatkan dari pembangunan model estimasi, antara lain untuk nilai metrik evaluasi R2 memiliki nilai 0.995. Dikarenakan Hasil terbaik dari R2 adalah 1, maka dapat disimpulkan bahwa pengaruh tiap variabel data yang digunakan berkategori kuat. Untuk nilai evaluasi RMSE dan MAE yang didapatkan dari pembangunan model, adalah 23.29 dan 17.061 yang menunjukkan bahwa kinerja dari model untuk melakukan estimasi sudah baik.

5.2 Saran

Dalam penelitian ini, penulis masih memiliki banyak kekurangan. Beberapa masukan yang dapat diberlakukan jika ada penelitian dengan topik terkait prediksi produksi hidrogen melalui kecepatan reaksi elektrolisis air yang ditenagai dari energi terbarukan, yaitu:

- Pada penelitian selanjutnya dapat menggunakan energi terbarukan yang sumber energinya selain dari panel surya, dikarenakan banyak sumber energi terbarukan lain.
- Menggunakan algoritma jaringan syaraf tiruan lainnya sebagai pembandingan untuk melihat metode apa yang paling cocok untuk kasus estimasi.
- Menambah variasi jumlah data yang digunakan baik sebagai data latih maupun data uji dan menyamakan jumlah setiap labelnya untuk meningkatkan akurasi dan kemampuan dari model yang dibangun.

Referensi

- [1] Agyekum, E. B., Nutakor, C., Agwa, A. M., & Kamel, S. (2022). A Critical Review of Renewable Hydrogen Production Methods: Factors Affecting Their Scale-Up and Its Role in Future Energy Generation. *Membranes*, 12(2), 173. <https://doi.org/10.3390/membranes12020173>
- [2] Alrahim, A. Z., Kanedi, I., & Suryana, E. (2022). The Implementation Of Extreme Learning Machine Methods In Predicting The Total Production Of Palm Oil (Case Study In pt. Bumi Rafflesia Indah).
- [3] Apriliza, F., Darmansah, D., Oktavyani, A., & Al Kaazhim, D. (2022). Perbandingan Metode Linear Regression dan Exponential Smoothing Dalam Peramalan Penerimaan Mahasiswa Baru. *JURIKOM (Jurnal Riset Komputer)*, 9(3), 726-732.

- [4] Arwani, M., Rizal, A. C., Hardianto, T. (2020). Perancangan Sistem Tracking Panel Surya Menggunakan Metode Kendali Logika Fuzzy.
- [5] Ashar Nirzha Maulidya. (2018). Penerapan Metode Extreme Learning Machine (Elm) Untuk Memprediksi Jumlah Produksi Pipa Yang Layak (Studi Kasus Pada Pt. Khi Pipe Industries).
- [6] Fayaz, M., & Kim, D. (2018). A prediction methodology of energy consumption based on deep extreme learning machine and comparative analysis in residential buildings. *Electronics (Switzerland)*, 7(10). <https://doi.org/10.3390/electronics7100222>
- [7] Hasan, M. S., & Widayat, W. (2022). Produksi Hidrogen dengan Memanfaatkan Sumber Daya Energi Surya dan Angin di Indonesia. *Jurnal Energi Baru Dan Terbarukan*, 3(1), 38–48. <https://doi.org/10.14710/jebt.2022.13374>
- [8] Rivanie, T. (2020). Implementasi Finite State Automata dalam Proses Registrasi Workout Plan pada Pusat Kebugaran. *MATICS*, 12(1), 94. <https://doi.org/10.18860/mat.v12i1.8573>
- [9] Roihan, A., Sunarya, P. A., & Rafika, A. S. (2020). Pemanfaatan Machine Learning dalam Berbagai Bidang. *Jurnal Khatulistiwa Informatika*, 5(1), 490845.
- [10] Rukajat, A. (2018). Teknik evaluasi pembelajaran. Deepublish.
- [11] Soebroto, A. A., Cholissodin, I., Sutrisno, Hasanah, U., & Febiola, Y. I. (2019). Buku Ajar AI, Machine Learning & Deep Learning (1.01). <https://www.researchgate.net/publication/348003841>
- [12] Wang, Z., Wang, X., Ma, C., & Song, Z. (2021). A Power Load Forecasting Model Based on FA-CSSA-ELM. *Mathematical Problems in Engineering*, 2021. <https://doi.org/10.1155/2021/9965932>
- [13] Yuwa Phiadelvira, B., Zatusiva Haq, D., Rini Novitasari, D. C., Setiawan Program Studi Matematika, F., Sunan Ampel Surabaya, U., & Ji Ahmad Yani No, I. (2021). Prediksi Besar Daya Listrik Tenaga Gelombang Laut Metode Oscillating Water Coloumn (PLTGL-OWC) di Banyuwangi Menggunakan Extreme Learning Machine (ELM). In *UJM (Vol. 11, Issue 1)*. <http://journal.unnes.ac.id/sju/index.php/ujm>
- [14] Ananda, R., & Fadhli, M. (2018). *Statistik Pendidikan (Teori Dan Praktik Dalam Pendidikan)*. (S. Saleh, Ed.). CV. Widya Puspita.