

Metode Pengukuran Percepatan Kendaraan Bermotor Berbasis Data GPS menggunakan Jaringan Saraf Tiruan

Sigit Tri Atmaja¹, Agus Wahidin^{*,2}, Muhammad Samsul Maarif^{1,3}

¹Pusat Riset Teknologi Transportasi, Badan Riset dan Inovasi Nasional (BRIN)

Gedung 720, KST BJ. Habibie Serpong, Setu – Tangerang Selatan, 15314, Indonesia

²Pusat Riset Konversi dan Koservasi Energi, Badan Riset dan Inovasi Nasional (BRIN)

Gedung 720, KST BJ. Habibie Serpong, Setu – Tangerang Selatan, 15314, Indonesia

³Malaysia-Japan International Institut of Technology, Universiti Teknologi Malaysia (UTM)

Jalan Sultan Yahya Petra, Kampung Datuk Keramat, Kuala Lumpur 54100, Malaysia

*E-mail: agus.wahidin@brin.go.id

Diterima: 16 Maret 2024, direvisi: 4 November 2024, disetujui: 11 Juni 2025,
tersedia daring: 25 Juni 2025, diterbitkan: 30 Juni 2025

Abstrak

Penelitian ini bertujuan untuk mengembangkan metode pengukuran percepatan kendaraan bermotor dengan menggunakan data kecepatan tanpa memerlukan alat ukur percepatan tambahan, sehingga alat pengukuran tersebut lebih efisien dan ekonomis. Dasar teori yang dipergunakan adalah bahwa percepatan merupakan perubahan kecepatan pada waktu tertentu. Hasil dari percepatan secara teori dapat menggunakan perhitungan formula penurunan dari hasil pengukuran kecepatan, akan tetapi hasil perhitungan konvensional dengan formula penurunan kecepatan dibandingkan dengan hasil pengukuran alat ukur percepatan memberikan deviasi hasil konversi yang terlalu besar. Oleh sebab itu, formula konvensional tersebut digantikan oleh pendekatan berbasis Jaringan Saraf Tiruan (JST) untuk memodelkan hubungan antara kecepatan dan percepatan secara lebih akurat. Pada penelitian ini, data kecepatan kendaraan diukur menggunakan *global positioning system* (GPS) dengan frekuensi akuisisi data sebesar 10 Hz. Data tersebut digunakan sebagai data *set* pada JST yang terbagi atas 90% data *training* dan 10% data *testing*. Jika dibandingkan dengan pendekatan yang lain optimasi *hyperparameter* JST dilakukan secara otomatis menggunakan pendekatan *Bayesian Optimization* karena kemampuannya dalam memilih parameter secara efisien dan menghindari hasil optimal pada lokal minimum. Model JST yang terbaik diuji menggunakan data testing pertama dengan hasil nilai *Mean Absolute Error* (MAE) sebesar 0.06373, *root mean square error* (RMSE) sebesar 0.08434, dan koefisien determinasi (R^2) sebesar 0.82456, selanjutnya data *testing* kedua dengan hasil nilai MAE sebesar 0.07061, RMSE sebesar 0.09112, dan R^2 sebesar 0.78517. Hasil metode ini menunjukkan potensi penerapan dalam pengukuran percepatan kendaraan dengan akurat dan bisa dikembangkan lebih lanjut untuk berbagai skenario kendaraan dinamis, integrasi *real-time* dengan sistem navigasi, serta penerapan pada kendaraan otonom atau sistem monitoring berbasis *IoT*.

Kata kunci: GPS berbasis JST, jaringan saraf tiruan, optimasi *hyperparameter*, percepatan.

Abstract

Motor vehicle acceleration measurement method based on GPS data using artificial Neural Networks: This research aims to develop a method for measuring motor vehicle acceleration solely using speed data without requiring additional acceleration measuring devices, thus making the measurement tool more efficient and economical. Theoretical acceleration results can be calculated using the derivative formula derived from speed measurements. However, conventional calculations using the derivative formula for speed result in significant deviations when compared to measurements obtained with acceleration measuring instruments that are too large. Therefore, the velocity derivation formula will be replaced by Artificial Neural Networks (ANN). In this study, vehicle speed data was measured using the global positioning system (GPS) with a data acquisition frequency of 10 Hz. This data was used as the dataset for the ANN, divided into two stages: the first data and the second data. The first data was divided into two parts: 90% for training and 10% for testing. The second data was used for full testing. This data was then processed using the ANN trained with reference acceleration data from accelerometer measurements at the same frequency. The search for the best hyperparameter model of the ANN is done using a Bayesian algorithm approach with automatic optimization. The best ANN model was tested using the first testing dataset with a mean absolute error (MAE) of 0.06373, root mean square error (RMSE) of 0.08434, and a coefficient of determination (R^2) of 0.82456. Subsequently, it was tested with the second testing dataset, yielding an MAE of 0.07061, RMSE of 0.09112, and R^2 of 0.78517. The results of this method indicate the potential for accurate measurement of vehicle acceleration.

Keywords: acceleration, artificial Neural Networks, ANN-based GPS, hyperparameter optimization.

1. Pendahuluan

Percepatan merupakan salah satu parameter untuk menilai performa kerja mesin penggerak yang terpasang pada kendaraan bermotor [1]. Pada umumnya mengukur percepatan dilakukan menggunakan alat ukur percepatan sensor akselerometer. Namun, pada dasarnya percepatan adalah perubahan

kecepatan sebuah benda pada durasi waktu tertentu, sehingga percepatan bisa didapatkan dengan melakukan konversi hasil data ukur kecepatan menggunakan perbandingan Δv dan Δt [2] dengan formula untuk percepatan merujuk ke (1).

$$a = \frac{\Delta v}{\Delta t} \quad (1)$$


dimana a merupakan percepatan, Δv merupakan perubahan kecepatan dan Δt merupakan perubahan waktu.

Pada kejadian sebuah kendaraan yang sedang melaju, percepatannya adalah perubahan kecepatan kendaraan tersebut setiap satu detik dengan menggunakan satuan internasional, yaitu ms^{-2} [3]. Penelitian ini memberikan kontribusi pemecahan masalah pada kondisi pengukuran percepatan kendaraan yang sedang melaju menggunakan alat ukur kecepatan tanpa dilengkapi dengan fungsi untuk mengukur percepatan pada alat tersebut, maka dengan menggunakan (1) dapat diperoleh nilai percepatan. Berdasarkan hal tersebut maka konversi percepatan pada sebuah kendaraan yang sedang melaju bisa dilakukan dengan cara mengolah data kecepatan kendaraan pada durasi waktu tertentu. Jika tersedia hasil pengukuran kecepatan secara periodik pada durasi waktu tertentu, maka konversi percepatan bisa diperoleh dengan menghitung perubahan kecepatan pada durasi waktu tertentu yang konsisten.

Sesuai dengan teori yang dijelaskan tersebut di atas maka pada tulisan ini dilakukan proses konversi data hasil pengukuran kecepatan sebuah kendaraan pada sebuah uji kendaraan di jalan lurus menjadi data percepatan kendaraan dengan menggunakan (1) tersebut. Kemudian hasil tersebut dibandingkan dengan data hasil ukur percepatan kendaraan tersebut yang diukur dengan menggunakan sensor akselerometer sebagai pembandingnya. Data teknis sumber data kecepatan kendaraan tersebut di antaranya adalah berupa waktu sampling merupakan periode waktu pengambilan data kecepatan kendaraan adalah 0,1 detik dan menggunakan satuan meter per detik (m/s).

Pada penelitian yang dilakukan oleh Yajie Zou membuktikan bahwa dengan kecerdasan buatan memberikan kinerja yang memuaskan dalam prediksi percepatan kendaraan [4], menggunakan metode prediksi *long short-term memory* (LSTM) dan *gate recurrent unit* (GRU) dapat meningkatkan ketepatan prediksi kendaraan secara signifikan. Demikian juga dengan menggunakan teknik kecerdasan buatan pada proses pengolahan data sensor yang lebih maju pada bidang prediksi percepatan kendaraan seperti pada penelitian Haoquan Luo mampu meningkatkan ketepatan prediksi [5]. Ok, dkk mengusulkan metode untuk memperkirakan sikap kendaraan, percepatan, dan kecepatan sudut menggunakan *convolutional Neural Network* dan *dual extended Kalman Filter* [6]. Selain itu, Bai mempresentasikan model koreksi bias dan diagnosis cacat berbasis data untuk pengukuran percepatan kendaraan yang sedang beroperasi [7]. Meskipun topiknya berbeda, penggunaan JST dalam mengolah data dan menghasilkan prediksi yang akurat dapat menjadi inspirasi dalam pengembangan model untuk mengukur akselerasi kendaraan berbasis data GPS. Penelitian ini diarahkan untuk menangani masalah akurasi dalam pengukuran percepatan kendaraan bermotor berbasis GPS. Solusi yang diusulkan adalah penggunaan metode optimasi *hyperparameter* Bayesian dalam JST. Metode ini dipilih berdasarkan potensinya dalam melakukan penyesuaian parameter yang lebih efisien dan efektif untuk meningkatkan akurasi model. Penggunaan JST, dengan optimasi *hyperparameter* Bayesian berpotensi memberikan pendekatan baru dalam pengukuran percepatan kendaraan yang lebih akurat dan dapat diandalkan.

Dalam konteks pemilihan fungsi aktivasi untuk Jaringan Saraf Tiruan, penelitian Pamungkas menyoroti pentingnya memilih fungsi aktivasi yang tepat untuk meningkatkan kinerja model [8]. Pemilihan ini berperan kritis dalam optimasi *hyperparameter* Bayesian, yang menjadi fokus utama penelitian ini. Penelitian ini membuktikan bahwa pemilihan fungsi aktivasi yang sesuai dapat secara signifikan memengaruhi efektivitas JST dalam aplikasi spesifik, seperti pengukuran percepatan kendaraan. Penelitian lain oleh Jonas mengenai penerapan JST dalam sistem keamanan kendaraan bermotor berbasis IoT juga memberikan perspektif penting [9]. Studi ini menunjukkan bagaimana JST dapat diterapkan dalam konteks yang lebih luas, termasuk untuk peningkatan keamanan kendaraan. Wawasan dari penelitian ini dapat dimanfaatkan dalam mengoptimalkan *hyperparameter* untuk aplikasi pengukuran percepatan.



Gambar 1. Alat ukur dan pemasangan.

Lebih lanjut, penelitian Zulfikri (2021) tentang deteksi dan estimasi kecepatan kendaraan menggunakan pengolahan citra digital memberikan dasar metodologi yang relevan [10]. Meskipun fokusnya berbeda, konsep pengolahan data untuk mendapatkan informasi tentang kendaraan dapat diadaptasi untuk pengembangan metode pengukuran percepatan kendaraan bermotor berbasis data GPS. Studi oleh Parsa (2020) yang fokus pada optimasi *hyperparameter* multi-objektif Bayesian dalam merancang JST menunjukkan pentingnya penelitian lebih lanjut dalam konteks ini [11]. Selain itu, He (2023) mengimplementasikan model *deep learning* hibrida untuk prediksi jumlah kendaraan menggunakan optimasi Bayesian, memberikan bukti kegunaan optimasi Bayesian dalam konteks yang berbeda [12]. Namun, aplikasi spesifik ini pada pengukuran percepatan kendaraan bermotor berbasis GPS belum tercakup secara mendalam dalam literatur yang ada. Beberapa studi yang ada memberikan dasar yang kuat dalam penerapan JST, masih ada kesenjangan dalam penelitian khususnya dalam pengukuran percepatan kendaraan bermotor berbasis GPS, terutama dalam hal pemanfaatan optimasi *hyperparameter* Bayesian. Oleh karena itu, penelitian ini bertujuan untuk mengisi *gap* tersebut dengan mengembangkan model JST yang dioptimasi untuk mengukur percepatan kendaraan secara efisien dan akurat hanya menggunakan data GPS.

Penelitian ini bertujuan mengembangkan metode pengukuran percepatan kendaraan bermotor yang efisien dan akurat dengan memanfaatkan data GPS melalui penerapan optimasi *hyperparameter* Bayesian pada jaringan syaraf tiruan (JST). Kebaruan penelitian terletak pada penggunaan optimasi *hyperparameter* Bayesian dalam JST untuk tujuan spesifik pengukuran percepatan kendaraan. Pertanyaan penelitian yang diajukan adalah apakah penerapan optimasi *hyperparameter* Bayesian dalam JST pada pengolahan data kecepatan berbasis GPS dapat menghasilkan estimasi percepatan yang lebih akurat dibandingkan metode perhitungan konvensional.

2. Metodologi

Penelitian ini dilakukan dengan cara mengukur kecepatan dan percepatan kendaraan yang melaju menggunakan alat ukur kecepatan dan percepatan. Alat ukur tersebut dipasang pada kaca depan kendaraan bermotor yang digunakan sebagai obyek pengujian tersebut, alat ukur dan posisi pemasangan alat ukur ditunjukkan pada Gambar 1. Alat ukur yang dipergunakan adalah Vericom VC4000DAQ yang menggunakan GPS internal dengan kecepatan 10Hz dan sensor akselerometer sebagai pengukur percepatan dengan spesifikasi sebagai berikut di antaranya rentang pengukuran ± 2 G hingga ± 6 G,

Tabel 1. Data kecepatan dan hasil pengolahan (percepatan).

No.	Kecepatan (m/s)	Konversi kecepatan menjadi percepatan (m/s ²)
1	3.750	-0.833
2	3.883	1.3333
3	3.908	0.250
4	3.911	0.028
5	4.011	1.000
...		
277	13.575	0.056
278	13.597	0.022
279	13.650	0.528
280	13.794	1.444



Gambar 2. Flowchart pengembangan model JST.

resolusi terbaik mencapai 0.0001 G, kecepatan sampling pengambilan data 1 Hz hingga 1000 Hz dan akurasi pengukuran ± 0.003 G.

Hasil pengukuran kecepatan kendaraan kemudian dikonversi menjadi percepatan dengan menggunakan (1), kemudian data kecepatan dan hasil konversi tersebut disajikan dalam Tabel 1. Selanjutnya dilakukan metodologi pengembangan JST dengan serangkaian langkah-langkah yang dilakukan untuk membangun model JST yang dapat menyelesaikan permasalahan seperti prediksi, klasifikasi, dan optimasi. JST merupakan teknik pemodelan yang kuat karena mampu memodelkan tanpa asumsi tertentu mengenai sifat mekanisme fenomenologis, memahami latar belakang matematika dari masalah yang mendasarinya dan memiliki kemampuan untuk belajar. Pada penelitian ini JST digunakan untuk memprediksi percepatan pada alat ukur yang belum mempunyai nilai ukuran percepatan. Untuk mengembangkan model JST pada riset ini menggunakan langkah-langkah seperti dalam gambar *flowchart* pada Gambar 2.

Penjelasan langkah-langkah pengembangan JST sebagai berikut ini,

2.1. Pengumpulan Data

Data yang digunakan adalah data eksperimen dari pengambilan alat ukur yang mengukur data kecepatan saat kendaraan melaju. Data yang digunakan dalam penelitian ini telah diekstraksi menggunakan EDA (analisis data eksplorasi). Total data set yang digunakan adalah sebanyak 1062 data.

2.2. Menentukan Data *Input* dan *Output*

Langkah kedua adalah menentukan data *input* dan *output*. Data *input* adalah data yang akan diberikan kepada model JST, sedangkan data *output* adalah data yang diharapkan dihasilkan oleh model JST. Pada penelitian ini data *input* adalah kecepatan pada alat ukur GPS (m/s) dan data *output* adalah percepatan (m/s^2) pada alat ukur lainnya yang sudah dilengkapi dengan hasil pengukuran percepatan.

2.3. Membagi Data Set

Data set dibagi ke dalam dua bagian, yaitu data 1 sampai dengan 835 dinamakan data kesatu dan data 836 sampai dengan 1062 data kedua, di mana data kesatu dibagi menjadi dua, yaitu 90% untuk data pelatihan dan 10% untuk data pengujian kesatu. Selanjutnya data kedua digunakan sebagai data pengujian kedua. Data pelatihan digunakan untuk melatih model, sedangkan data pengujian digunakan untuk mengevaluasi kinerja model JST.

2.4. Normalisasi Data

Normalisasi data adalah teknik yang digunakan dalam penambangan data untuk mengubah nilai kumpulan data menjadi skala umum [14]. Hal ini penting karena banyak algoritma pembelajaran mesin sensitif terhadap skala fitur masukan dan dapat memberikan hasil yang lebih baik saat data

dinormalisasi [15]. Normalisasi data dilakukan juga untuk menyetarakan skala data sehingga model dapat belajar dengan lebih efektif [16]. Pada riset normalisasi data menggunakan metode *min max*. Formula metode *min max* merujuk ke (2).

$$x_{norm} = \frac{x' - \min(x)}{\max(x) - \min(x)} (new_{max}(x) - new_{min}(x)) + new_{min}(x) \quad (2)$$

dimana, x adalah atribut data, $\min(x)$ dan $\max(x)$ adalah nilai absolut minimal dan maksimal dari x , x' adalah nilai lama dari setiap entri dalam data, $new_{max}(x)$ dan $new_{min}(x)$ adalah nilai *min* dan *max* dari *range*.

2.5. Optimasi *Hyperparameter* menggunakan Bayesian

Hyperparameter sangat penting untuk algoritma model JST karena *hyperparameter* mengontrol perilaku secara langsung algoritma pelatihan dan memiliki pengaruh yang signifikan terhadap kinerja model JST. Optimasi *hyperparameter* JST penting dilakukan karena *hyperparameter* dapat mempengaruhi kinerja model JST. *Hyperparameter* adalah parameter yang tidak dipelajari oleh model selama proses pelatihan. *Hyperparameter* dapat berupa jumlah *epoch*, *learning rate*, *batch size*, dan sebagainya.


Ada dua metode utama untuk mengoptimalkan *hyperparameter*, yaitu pencarian manual dan pencarian otomatis. Pertama adalah pencarian manual dilakukan dengan mencoba-coba berbagai kombinasi *hyperparameter* secara manual. Metode ini bergantung pada intuisi dan pengalaman mendalam pengguna. Pengguna harus bisa mengidentifikasi parameter penting yang berdampak besar pada hasil, lalu menentukan hubungan antara parameter tertentu dengan hasil akhir menggunakan alat visualisasi. Kedua adalah pencarian otomatis menggunakan algoritma komputer untuk menjelajahi ruang *hyperparameter* dan menemukan kombinasi yang optimal. Metode ini tidak memerlukan intuisi atau pengalaman pengguna, dan bisa lebih efisien serta tidak bisa dibandingkan pencarian secara manual.

Pada penelitian ini kami menggunakan cara pencarian otomatis untuk melakukan optimasi *hyperparameter* model JST ini. Metode pencarian otomatis optimasi *hyperparameter* JST ini menggunakan Bayesian. Optimasi Bayesian digunakan untuk mengoptimasi *hyperparameter* JST karena memiliki tiga kelebihan dibandingkan metode lainnya. Pertama efisiensi, optimasi Bayesian dapat menjelajahi ruang *hyperparameter* secara efisien, sehingga dapat menemukan kombinasi *hyperparameter* optimal dalam waktu yang lebih singkat. Kedua Akurasi, optimasi Bayesian dapat memberikan estimasi yang lebih akurat tentang kombinasi *hyperparameter* optimal. Ketiga Nonbias, optimasi Bayesian tidak terpengaruh oleh bias yang mungkin ada dalam data pelatihan.

Pengoptimalan Bayesian banyak digunakan untuk mendapatkan nilai *hyperparameter* yang dioptimalkan, menghemat waktu, dan meningkatkan kinerja. Jia Wu dkk. menggunakan optimasi Bayesian untuk berbagai model pembelajaran mesin, termasuk algoritma *random forest*, jaringan saraf, dan *multi-grained cascade forest* [17]. Helen dan Maragatham menggunakan optimasi Bayesian untuk mendapatkan nilai yang dioptimalkan untuk semua *hyperparameter deep learning* jaringan saraf konvolusional yang diterapkan pada kumpulan data CIFAR-10 [18]. Tinu mengusulkan kerangka kerja untuk penyetelan *hyperparameter* pada data besar menggunakan optimasi Bayesian dengan membagi seluruh kumpulan data menjadi beberapa bagian dan menghasilkan penyetelan *hyperparameter* pada bagian tersebut secara paralel [19]. Nguyen menerapkan optimasi Bayesian pada material canggih untuk desain paduan penerbangan, desain perlakuan panas, serat polimer pendek, pencetakan 3D, dan jaminan algoritmik [20]. Metode lain untuk mengoptimalkan *hyperparameter* adalah *hyperband* kontekstual Bayesian adaptif.

Pada penelitian ini, *hyperparameter* JST yang dioptimasi sebagai berikut ini:

- *Learning Rate*: 1e-4 s.d 1e-2
- Jumlah *Neuron*: 2 s.d 15
- Jumlah *Hidden Layer*: 1 s.d 5
- Nilai *Drop Out*: 0 s.d 0.5
- Fungsi Aktivasi: Elu, Relu, TanH, Sigmoid



Gambar 3. Gambar arsitektur JST terbaik.

Dan untuk *hyperparameter* tetap JST yaitu:

- EPOCH = 100
- Batch size = 2
- Optimizer = Adam

Setelah dilakukan optimasi *hyperparameter* JST, maka mendapatkan hasil terbaik arsitektur JST seperti Gambar 3.

2.6. Pelatihan dan Menyimpan Model JST

Langkah selanjutnya adalah melakukan pelatihan model JST. Pelatihan model dilakukan dengan menggunakan data pelatihan. Pada saat pelatihan JST nilai *mean absolute error* (MAE) dihitung mendekati nilai *epsilon* sebesar 0.0001, nilai *epoch* mencapai 100 dan *batch size* dataset bernilai 2.

2.6.1. Pengujian Model JST

Setelah pelatihan, model diuji menggunakan data set pengujian kesatu dari 10% data set dan pengujian kedua menggunakan data set eksperimen berikutnya. Hasilnya dievaluasi untuk menentukan kinerja model terhadap data yang tidak dikenal sebelumnya. Setelah pengujian kedua maka model tersebut dievaluasi dengan skor akurasi, seperti *R-squared*, *mean absolute error* (MAE), dan *root mean squared error* (RMSE). Skor ini memberikan gambaran tentang seberapa baik model memprediksi percepatan. Jika skor-skor ini memenuhi kriteria kinerja yang diinginkan, maka proses pengembangan model dianggap selesai. Namun, jika tidak, langkah-langkah perbaikan atau peningkatan lebih lanjut mungkin diperlukan.

2.6.2. Evaluasi Akurasi Prediksi Model JST

Untuk mengevaluasi kinerja model prediktif digunakan MAE, RMSE, dan *R-squared* (R^2). MAE adalah ukuran rata-rata kesalahan absolut antara nilai prediksi dan nilai sebenarnya. Dihitung dengan mengambil rata-rata selisih absolut antara nilai prediksi dan nilai aktual, merujuk (3). RMSE adalah ukuran akar kuadrat dari rata-rata selisih kuadrat antara nilai prediksi dan nilai sebenarnya. Ini memberi bobot lebih pada kesalahan besar dibandingkan dengan MAE karena MAE mengkuadratkan perbedaan sebelum mengambil rata-rata dan kemudian mengambil akar kuadrat, seperti merujuk (4). *R-squared* merupakan ukuran statistik yang merepresentasikan proporsi varians variabel dependen yang dijelaskan oleh variabel independen dalam model. Nilainya berkisar antara 0 hingga 1, di mana 0 menunjukkan bahwa model tidak menjelaskan variabilitas apa pun, dan 1 menunjukkan bahwa model menjelaskan semua variabilitas. Persamaan *R-squared* merujuk (5). dimana, n adalah jumlah sampel, y adalah nilai sebenarnya, $\hat{y}$ adalah nilai prediksi.

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

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$


$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i)^2} \quad (5)$$

3. Hasil dan Pembahasan

Untuk mempermudah pengamatan dan interpretasi maka data percepatan hasil konversi konvensional yang tercantum pada tabel 1. dibandingkan dengan data percepatan hasil pengukuran menggunakan akselerometer dan disajikan dalam bentuk grafik perbandingan Gambar 4. Dari grafik pada Gambar 4 tersebut dapat diamati bahwa hasil proses konversi data kecepatan menjadi data percepatan dengan menggunakan teori penurunan kecepatan menjadi percepatan merujuk (1) memberikan deviasi hasil konversi yang terlalu besar terhadap referensi dengan nilai akurasi $R^2 = -2.30348$ sehingga tidak layak untuk dipergunakan. Secara umum nilai R^2 mempunyai rentang antara 0 hingga 1, namun demikian nilai minus bisa terjadi jika model yang dipergunakan lebih buruk daripada model rata-rata sederhana. Dalam kasus ini metode konversi konvensional tersebut tidak efektif mengonversi data kecepatan menjadi data percepatan. Setelah model JST dilatih, model JST yang diperoleh digunakan untuk memprediksi percepatan kendaraan. Kemudian model tersebut dievaluasi dengan membandingkan hasil prediksi dengan hasil metode perhitungan konvensional, berdasarkan nilai MAE, RMSE, dan R^2 . Tabel 2 di bawah ini menunjukkan hasil pengujian pada data kesatu testing 10% dan data *testing* yang kedua.

Gambar 5 menunjukkan sebuah plot dispersi dengan garis regresi yang menggambarkan hubungan antara nilai prediksi dari model Jaringan Saraf Tiruan (JST) dan nilai percepatan aktual, dengan koefisien determinasi (R^2) sebesar 0.82456. Nilai R^2 yang tinggi ini menunjukkan korelasi positif yang kuat, yang mengindikasikan bahwa model dapat memprediksi percepatan dengan andal dari kumpulan data pengujian yang diberikan. Gambar 6 memperlihatkan sebuah grafik yang menampilkan hasil prediksi percepatan menggunakan model JST dibandingkan dengan nilai referensi pada data testing pertama. Dari grafik, terlihat bahwa prediksi JST umumnya mengikuti pola referensi.


Pada data pengujian yang kedua ini, hasil prediksi model JST dievaluasi dengan membandingkan hasil metode perhitungan konvensional. Hasil perbandingan di antara kedua metode tersebut dapat dilihat pada Gambar 7, Gambar 8, dan Gambar 9. Gambar 7 menunjukkan hasil konversi perhitungan terhadap




Gambar 4. Grafik perbandingan hasil konversi dan referensi.

Tabel 2. Hasil pengujian JST.

Dataset	MAE	RMSE	R^2
Data kesatu 10%	0.06373	0.08434	0.82456
Data kedua	0.07061	0.09112	0.78517



Gambar 5. Grafik regresi hasil prediksi model JST dengan nilai $R^2 = 0.82456$ pada data testing kesatu.




Gambar 6. Hasil prediksi percepatan pada data testing kesatu.


referensi percepatan dengan nilai R^2 yang sangat rendah, yaitu -2.30348, yang mengindikasikan ketidakcocokan antara metode perhitungan konvensional dan data yang diamati. Sebaliknya, Gambar 8 menunjukkan hasil prediksi Model JST dengan nilai R^2 yang lebih masuk akal, yaitu 0.78517, menunjukkan kesesuaian yang jauh lebih baik antara prediksi model dan nilai referensi, serta menandakan korelasi yang cukup kuat dan prediksi yang lebih akurat terhadap data referensi percepatan.

Dalam perbandingan antara metode perhitungan konvensional dan model JST, seperti yang terlihat pada Gambar 9, model JST secara konsisten mendekati tren data referensi, sementara metode konvensional menunjukkan variasi yang signifikan dan sering kali tidak mengikuti tren yang sama. Hal ini menegaskan bahwa model JST lebih unggul dalam penggunaan data yang kompleks dan menyesuaikan prediksi dengan lebih akurat dibandingkan metode konvensional.

cara nyata melalui grafik pada Gambar 9 dapat diamati bahwa nilai kesalahan pada metode konvensional jauh lebih besar dibandingkan dengan metode JST dan diperkuat dengan perbedaan nilai R^2




Gambar 7. Grafik regresi hasil metode perhitungan konvensional dengan nilai $R^2 = -2.30348$ pada data *testing* kedua.



Gambar 8. Grafik regresi hasil prediksi model JST dengan nilai $R^2 = 0.7817$ pada data *testing* kedua.

yang juga berbeda signifikan. Perbedaan kinerja tersebut sebagai akibat bahwa dengan menggunakan metode prediksi pada JST memberikan perbaikan kinerja yang signifikan dibandingkan dengan tanpa menggunakan metode prediksi pada metode konvensional.

Bahwa pembelajaran mendalam JST pada penelitian ini cukup akurat senada dengan penelitian untuk aplikasi sejenis seperti yang dilakukan [21] menyatakan bahwa menggunakan algoritma pembelajaran mesin memungkinkan identifikasi pola yang berbeda dalam data yang dapat digunakan untuk menyimpulkan percepatan dari pengukuran kecepatan. Kemudian pembelajaran mendalam digunakan untuk memprediksi pola kemacetan dalam jaringan transportasi dengan memproses data GPS, yang menggambarkan potensi pendekatan serupa untuk mengubah data kecepatan menjadi estimasi percepatan [22]. Hal ini selanjutnya juga didukung oleh temuan, yang mencatat bahwa model yang menggunakan data GPS dan akselerometer dapat mendeteksi aktivitas dengan profil pergerakan yang berbeda secara andal, yang menekankan pentingnya mengintegrasikan sumber data ini untuk meningkatkan akurasi prediktif [23]. Mengingat bahwa beberapa kondisi mempengaruhi kinerja GPS maka kami mengelaborasi



Gambar 9. Hasil prediksi percepatan antara metode perhitungan konvensional dan model JST pada data *testing* kedua.

akurasi GPS terutama untuk aplikasi di Indonesia. Untuk negara yang terletak di lempeng tektonik seperti Indonesia akurasi GPS dipengaruhi oleh variasi atmosfer [24]. Di lingkungan luar ruangan, teknologi GPS umumnya memberikan keakuratan penentuan posisi berkisar antara 3 hingga 15 meter, dengan rata-rata sekitar 10 meter [25]. Dengan demikian hal ini memberikan wawasan kepada kita bahwa hasil penelitian ini ada kemungkinan terpengaruh oleh kondisi-kondisi tersebut. Dengan demikian bisa diambil asumsi bahwa variasi pengukuran GPS terpengaruh oleh faktor-faktor dari kondisi yang dijelaskan pada paragraf di atas yang menyebabkan hasil yang tidak akurat seperti yang terlihat pada Gambar 9. Pada penelitian ini JST dengan kemampuan prediksinya yang lebih akurat melalui proses *learning* bisa memperbaiki kelemahan metode tersebut sehingga memberikan hasil yang jauh lebih baik.

Pada akhirnya implikasi dari temuan ini sangat signifikan, karena menunjukkan pentingnya penggunaan model prediktif canggih, seperti penerapan model JST yang menggunakan optimasi *hyperparameter* Bayesian untuk pengukuran percepatan kendaraan bermotor dapat menggantikan metode perhitungan konvensional yang kurang akurat. Model JST tidak hanya meningkatkan akurasi prediksi dalam konteks ilmiah tetapi juga memiliki potensi untuk diaplikasikan dalam industri karena dapat menghemat waktu dan biaya, serta meningkatkan kinerja. Dengan demikian, temuan ini tidak hanya memperkuat pemahaman teoritis tentang model prediktif tetapi juga dapat diandalkan dalam implementasi praktis yang akan memanfaatkan prediksi berbasis data.

4. Kesimpulan

Penerapan jaringan syaraf tiruan (JST) dengan metode optimasi *hyperparameter* otomatis berbasis Bayesian untuk memprediksi percepatan dari data kecepatan kendaraan menghasilkan nilai Mean Absolute Error (MAE) dan Root Mean Square Error (RMSE) yang mendekati nol, serta koefisien determinasi (R^2) yang mendekati satu. Hasil ini menunjukkan bahwa JST tersebut berhasil memprediksi percepatan dari masukan data kecepatan (m/s) menjadi percepatan (m/s^2) secara akurat, sekaligus mampu menggantikan metode perhitungan konvensional yang cenderung kurang presisi.

Secara ilmiah, temuan ini memiliki dampak signifikan, khususnya dalam industri transportasi dan pengembangan perangkat pengukur percepatan. Metode ini memungkinkan pengukuran percepatan dilakukan secara efisien tanpa memerlukan sensor akselerometer tambahan, sehingga dapat mengurangi biaya serta kompleksitas peralatan. Dalam penerapannya, metode ini berpotensi digunakan pada kendaraan otonom, sistem pemantauan kinerja kendaraan, maupun perangkat pengukur kecepatan untuk analisis transportasi secara real-time.

Untuk mendapatkan aplikasi yang lebih praktis, penelitian lanjutan disarankan berfokus pada pengembangan perangkat lunak yang mengintegrasikan parameter hasil penelitian ini, termasuk konstanta

hyperparameter yang telah dioptimalkan, sehingga dapat langsung digunakan dalam sistem pengukuran percepatan berbasis GPS.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Laboratorium Termodinamika Motor dan Propulsi (LTMP) dan Organisasi Riset Energi dan Manufaktur (OREM)-Badan Riset dan Inovasi Nasional (BRIN) telah menyediakan ruang, fasilitas laboratorium, dan pengetahuan. Penulis sangat mengapresiasi dukungan tersebut.

Pernyataan Kesetaraan Kontribusi Penulis

Semua penulis berkontribusi secara signifikan dalam perencanaan penelitian, pengumpulan data, analisis data, dan penulisan naskah.

Daftar Pustaka

- [1] A. S. Mohammed, A. Olalekan Salau, B. Sigweni, and A. M. Zungeru, "Conversion and performance evaluation of petrol engine to electric powered three-wheeler vehicle with an onboard solar charging system," *Energy Convers. Manag. X*, vol. 20, no. April, p. 100427, 2023, doi: 10.1016/j.ecmx.2023.100427.
- [2] F. Aiello *et al.*, "Do non-contact injuries occur during high-speed running in elite football? Preliminary results from a novel GPS and video-based method," *J. Sci. Med. Sport*, vol. 26, no. 9, pp. 465–470, 2023, doi: 10.1016/j.jsams.2023.07.007.
- [3] W. Djuriatno, E. Maulana, Hasan, E. D. Arisandi, and Wijono, "Velocity measurement based on inertial measuring unit," *Telkomnika (Telecommunication Comput. Electron. Control)*, vol. 17, no. 4, pp. 1898–1906, 2019, doi: 10.12928/telkomnika.v17i4.11826.
- [4] Y. Zou, L. Ding, H. Zhang, T. Zhu, and L. Wu, "Vehicle Acceleration Prediction Based on Machine Learning Models and Driving Behavior Analysis," *Appl. Sci.*, vol. 12, no. 10, 2022, doi: 10.3390/app12105259.
- [5] H. Luo, X. Hu, and L. Huang, "A Hybrid Model for Vehicle Acceleration Prediction," *Sensors*, vol. 23, no. 16, pp. 1–17, 2023, doi: 10.3390/s23167253.
- [6] M. Ok, S. Ok, and J. H. Park, "Estimation of vehicle attitude, acceleration and angular velocity using convolutional neural network and dual extended Kalman filter," *Sensors (Switzerland)*, vol. 21, no. 4, pp. 1–22, 2021, doi: 10.3390/s21041282.
- [7] L. Bai, R. Liu, and Q. Li, "Data-driven bias correction and defect diagnosis model for in-service vehicle acceleration measurements," *Sensors (Switzerland)*, vol. 20, no. 3, 2020, doi: 10.3390/s20030872.
- [8] I. Pamungkas, S. Sumadi, and S. Alam, "Studi Komparasi Fungsi Aktivasi Sigmoid Biner, Sigmoid Bipolar dan Linear pada Jaringan Saraf Tiruan dalam Menentukan Warna RGB Menggunakan Matlab," *J. Serambi Eng.*, vol. 7, no. 4, 2022, doi: 10.32672/jse.v7i4.4776.
- [9] D. Jonas, I. A. Supriyono, and H. Junianto, "Perancangan Sistem Pencegahan Pencurian Kendaraan Bermotor Berbasis ESP32 pada PT. Suwarna Dwipa Maju," *Technomedia J.*, vol. 7, no. 2, pp. 216–230, 2022, doi: 10.33050/tmj.v7i2.1748.
- [10] M. Zulfikri, K. Abd Latif, R. Hammad, M. Syahrir, and P. Studi, "Deteksi dan Estimasi Kecepatan Kendaraan dalam Sistem Pengawasan Lalu Lintas Menggunakan Pengolahan Citra Detection and Estimation of Vehicle Speed in Traffic Control Systems Using Image Processing," *Techno.COM*, Vol. 20, No.3, Agustus 2021: 455-467
- [11] M. Parsa, J. P. Mitchell, C. D. Schuman, R. M. Patton, T. E. Potok, and K. Roy, "Bayesian Multi-objective Hyperparameter Optimization for Accurate, Fast, and Efficient Neural Network Accelerator Design," *Front. Neurosci.*, vol. 14, no. July, pp. 1–16, 2020, doi: 10.3389/fnins.2020.00667.
- [12] C. He, D. Wang, Y. Yu, and Z. Cai, "A Hybrid Deep Learning Model for Link Dynamic Vehicle Count Forecasting with Bayesian Optimization," *J. Adv. Transp.*, vol. 2023, 2023, doi: 10.1155/2023/5070504.
- [13] Syarif Iskandar, Valentinus Galih Vidia Putra, dan A. Hermansyah. "Prediksi End Breakage Benang Kapas Di Mesin Rotor Spinning Menggunakan Pendekatan Jaringan Saraf Tiruan," *Edufisika*, Vol. 7, No.01, Juni 2022, doi:10.59052/edufisika.v7i1.19543
- [14] W. Amelia, "Implementasi Jaringan Syaraf Tiruan Sebagai Sistem Diagnosis Stunting Balita Menggunakan Metode Backpropagation Di Puskesmas Brebes," vol. 12, no.2, September 2023
- [15] I. U. W. Mulyono, Y. Kusumawati, and A. Susanto, "Analisa Perfoma Algoritma Jaringan Syaraf Tiruan Dalam Klasifikasi Karakter Hiragana," *Semnastek (Seminar Nas. Ris. dan Inov. Teknol.)*, vol. 8, no. 01, pp. 60–64, 2024, doi: 10.30998/semnasristek.v8i01.7134.
- [16] A. Nugroho and A. Husin, "Performance Analysis of Random Forest Using Attribute Normalization," *Sistemasi*, vol. 11, no. 1, p. 186, 2022, doi: 10.32520/stmsi.v11i1.1681.
- [17] J. Wu, X. Y. Chen, H. Zhang, L. D. Xiong, H. Lei, and S. H. Deng, "Hyperparameter optimization for machine learning models based on Bayesian optimization," *J. Electron. Sci. Technol.*, vol. 17, no. 1, pp. 26–40, 2019, doi: 10.11989/JEST.1674-862X.80904120.
- [18] A. H. Victoria and G. Maragatham, "Automatic tuning of hyperparameters using Bayesian optimization," *Evol. Syst.*, vol. 12, no. 1, pp. 217–223, 2021, doi: 10.1007/s12530-020-09345-2.
- [19] T. T. Joy, S. Rana, S. Gupta, and S. Venkatesh, "Hyperparameter tuning for big data using Bayesian optimisation," *Proc. - Int. Conf. Pattern Recognit.*, vol. 0, pp. 2574–2579, 2016, doi: 10.1109/ICPR.2016.7900023.
- [20] T. D. Ngo, A. Kashani, G. Imbalzano, K. T. Q. Nguyen, and D. Hui, "Additive manufacturing (3D printing): A review of materials, methods, applications and challenges," *Compos. Part B Eng.*, vol. 143, no. December 2017, pp. 172–196, 2018, doi: 10.1016/j.compositesb.2018.02.012.
- [21] Lee, K. and Kwan, M., "Automatic physical activity and in-vehicle status classification based on gps and accelerometer data: a hierarchical classification approach using machine learning techniques," *Transactions in Gis*, 22(6), 1522-1549, 2018. <https://doi.org/10.1111/tgis.12485>.
- [22] Ma, X., Yu, H., Wang, Y., & Wang, Y., "Large-scale transportation network congestion evolution prediction using deep learning theory," *Plos One*, 10(3), e0119044, 2015. <https://doi.org/10.1371/journal.pone.0119044>.

- [23] Allahbakhshi, H., Conrow, L., Naimi, B., & Weibel, R., "Using accelerometer and gps data for real-life physical activity type detection," *Sensors*, 20(3), 588, 2020. <https://doi.org/10.3390/s20030588>.
- [24] Safi'i, A., Ramdani, D., & Muslim, B., "Utilization of Indonesia's regional ionosphere model to improve the accuracy of gps measurements to support disaster mitigation studies," *Iop Conference Series Earth and Environmental Science*, 950(1), 012097, 2022. <https://doi.org/10.1088/1755-1315/950/1/012097>.
- [25] Arsan, T., "Accurate indoor positioning with ultra-wide band sensors," *Turkish Journal of Electrical Engineering & Computer Sciences*, 28(2), 1014-1029, 2020. <https://doi.org/10.3906/elk-1911-79>.