

Sistem Monitoring *Electric-Powered Wheelchair* (EPW) Berbasis Sensor Accelerometer Terintegrasi Kalman Filter Dan Auto-Encoder Machine Learning

Jalasecca Wya Dewaruci, I Wayan Widhiada, I Gusti Komang Dwijana
Jurusan Teknik Mesin Universitas Udayana, Kampus Bukit Jimbaran Bali

Abstrak

Penyandang disabilitas pada kehidupan sehari-harinya membutuhkan kursi roda sebagai alat bantu dalam mobilisasi, Seiring berjalannya waktu dan perkembangan teknologi peningkatan kursi roda sebagai alat bantu mobilitas bagi penyandang disabilitas tidak hanya terfokus pada kuantitas, tetapi juga pada peningkatan fungsionalitas. Pengembangan sistem kontrol mencakup penggunaan kontrol langsung berbasis joystick dan modifikasi sistem penggerak pada kursi roda manual menjadi elektrik. Penggunaan kursi roda electric atau *Electric Powered Wheelchair* (EPW) harus diawasi oleh pihak ketiga agar keamanan penyandang disabilitas lebih terjamin, tetapi pada kondisi tertentu para penyandang disabilitas membutuhkan ruang untuk sendiri dan terkadang pengawasan oleh pihak ketiga tidak bisa dilakukan terus menerus secara langsung. Sistem monitoring dapat menjadi sistem yang membantu dalam pengawasan penyandang disabilitas namun harus ada hal yang harus diperhatikan yakni keakuratan sinyal dari sensor accelerometer sebagai dasar dari sistem monitoring. Hal ini dapat diatasi dengan mengintegrasikan algoritma Kalman Filter dan Autoencoder, untuk mengevaluasi algoritma tersebut pada penelitian ini EPW dilakukan pengujian pada pola lintasan 1 dan pola lintasan 2 dan didapatkan besar nilai akurasi (1) tanpa integrasi Kalman Filter dan auto-encoder machine learning sebesar 16,84 %, (2) dengan integrasi Kalman Filter 93,06 %, (3) dengan integrasi auto-encoder machine learning didapatkan sebesar 95,59 %, dan (4) dengan integrasi Kalman Filter dan auto-encoder machine learning 98%. Hal ini menunjukkan bahwa algoritma yang digunakan dalam upaya pengurangan noise dari output data sensor accelerometer memiliki kapabilitas yang baik dalam mereduksi noise output data dari sensor accelerometer yang digunakan.

Kata kunci: Kursi roda listrik, sistem monitoring, sensor MPU6050, Kalman Filter, autoencoder

Abstract

In their daily lives, people with disabilities require a wheelchair as a mobility aid. Over time and with technological advancements, the improvement of wheelchairs for people with disabilities has not only focused on quantity but also on enhancing functionality. The development of control systems includes the use of direct joystick-based controls and the modification of manual wheelchair propulsion systems to electric. The use of *Electric Powered Wheelchairs* (EPW) needs to be supervised by a third party to ensure the safety of people with disabilities. However, in certain conditions, individuals with disabilities require personal space, and continuous direct supervision by a third party may not be feasible. Monitoring systems can assist in supervising people with disabilities, but the accuracy of signals from the accelerometer sensor, the foundation of the monitoring system, needs careful consideration. This can be addressed by integrating Kalman Filter and Autoencoder algorithms. To evaluate these algorithms in this study, EPW testing was conducted on track patterns 1 and 2. The obtained accuracy values were (1) without integrating Kalman Filter and Autoencoder Machine Learning, 16.84%, (2) with Kalman Filter integration, 93.06%, (3) with Autoencoder Machine Learning integration, 95.59%, and (4) with Kalman Filter and Autoencoder Machine Learning integration, 98%. This indicates that the algorithms used to reduce noise from the output data of the accelerometer sensor have good capabilities in reducing noise from the accelerometer sensor's output data.

Keywords: electric powered wheelchair, monitoring system, sensor MPU6050, kalman filter, autoencoder

1. Pendahuluan

Penyandang disabilitas adalah setiap orang yang mengalami keterbatasan fisik, intelektual, mental, dan sensorik [1]. Karena keterbatasan ini para penyandang disabilitas memiliki kesulitan dalam menjalani aktivitas sosial, pada kehidupan sehari-harinya dalam hal mobilitas penyandang disabilitas memerlukan kursi roda sebagai alat mobilisasi di kehidupannya. kursi roda digunakan agar pengguna bisa bergerak bebas mengatur pergerakan sesuai yang di kehendaknya, Seiring berjalannya waktu dan berkembangnya teknologi, kursi roda sendiri mengalami pengembangan. Penambahan sistem penggerak motor listrik hal ini sangat memudahkan bagi para penyandang disabilitas.


Penggunaan kursi roda elektrik tanpa pengawasan dapat membahayakan penyandang disabilitas, sementara itu pengawasan tidak dapat dilakukan secara terus menerus oleh pihak yang mengawasi. Sistem monitoring jarak jauh dapat diaplikasikan sebagai solusi dalam pengawasan penggunaan kursi roda oleh penyandang disabilitas [2]. Namun, yang menjadi titik baliknya adalah pemanfaatan teknologi sensor yang terjangkau untuk sistem ini masih memiliki kekurangan akurasi yang tepat pada keadaan sebenarnya, merujuk pada permasalahan tersebut, upaya yang dapat dilakukan adalah memanfaatkan algoritma statistik maupun filter yang mampu mengoreksi error dari data diskrit seperti hasil pada sensor ini. Algoritma Kalman Filter dan model auto-encoder machine learning memiliki

karakteristik ini dan dapat diaplikasikan pada permasalahan ini. Dengan demikian, pengguna kursi roda dapat ter-monitoring dengan akurat dan mitigasi terhadap mobilisasinya dapat terawasi.

2. Dasar Teori

2.1 Sensor Accelerometer

Sensor *accelerometer* merupakan alat ukur yang umumnya memiliki data untuk 3D spasial. Pendekatan metode yang umum digunakan pada sensor accelerometer adalah dengan menggunakan *capacitance sensing*, yang berhubungan dengan perubahan posisi dari *mass capacitance* [3]. Dengan kata lain, bahwa sensor *accelerometer* ini dapat dijadikan sebagai variabel kapasitor, sebagaimana diilustrasikan pada Gambar 1.



Gambar 1. Visual dari Pendekatan yang digunakan pada Accelerometer

2.2 Kalman Filter

Secara sederhana, Kalman Filter sebagai algoritma penyedia perkiraan berbagai variabel yang didapat berdasarkan dari pengukuran dengan mengikuti iterasi. *Output* data dari algoritma yang diestimasi ini sama dengan proses mereduksi *noise* pada sinyal [3]. Kalman Filter memiliki dua bagian pada algoritmanya, prediksi dan *update* (pembaruan) [4]. Berikut persamaan dari Kalman filter yang ditunjukkan pada (1)-(5)

Bagian Prediksi:

$$\hat{x}_{t|t-1} = F_t \hat{x}_{t-1|t-1} + B_t u_t \quad (1)$$

$$P_{t|t-1} = F_t P_{t-1|t-1} F_t^T + Q_t \quad (2)$$

Bagian Update:

$$K_t = P_{t|t-1} H_t^T (H_t P_{t|t-1} H_t^T + R_t)^{-1} \quad (3)$$

$$\hat{x}_{t|t} = \hat{x}_{t|t-1} + K_t (y_t - H_t \hat{x}_{t|t-1}) \quad (4)$$


$$P_{t|t} = (I - K_t H_t) P_{t|t-1} \quad (5)$$

Keterangan:

x	: Perkiraan kondisi
F	: Matriks kondisi
u	: Variabel kontrol
B	: Matriks kontrol
P	: Matriks varians kondisi
Q	: Matriks varians proses
y	: Variabel pengukuran
H	: Matriks pengukuran
K	: Gain Kalman
R	: Matriks pengukuran
$t t$: Periode waktu sekarang
$t-1 t-1$: Periode waktu sebelumnya
$t t-1$: Tahap peralihan

2.3 Autoencoder

Model *autoencoder* merupakan turunan model ANN dengan karakteristik yang dimiliki adalah mereduksi dan mengembalikan *feature extraction* dari *input* di awal [5]. Terdapat dua bagian pada model ini, yaitu *encoder* dan *decoder*. *Encoder* merupakan tahapan dari model untuk melakukan *feature extraction*, yaitu menentukan nilai dari beberapa parameter *input* berdasarkan *weight* yang bersesuaian melalui metode *backpropagation* hingga bagian menjadi *bottleneck* dari model. Bagian kedua adalah *decoder*, yaitu bagian *layer* yang mengembalikan ke bentuk semula namun tetap menyesuaikan *weight* melalui metode *backpropagation*. Secara visual dapat dilihat pada gambar 3



Gambar 2. Rancangan Model Peramalan Autoencoder

Beberapa hyperparameter utama yang dilakukan proses tuning ini adalah loss function, optimizer, dan learning rate. Untuk proses loss function menggunakan mean squared error, serta optimizer yang digunakan adalah Stochastic Gradient Descent dengan learning rate $\alpha = 10^{-4}$. Berikut merupakan persamaan yang mendukung hyperparameter yang disebutkan.

$$\text{mean squared error} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$


$$w_i = w_{i-1} - \alpha$$

Keterangan:

y_i	: data sesungguhnya
\hat{y}_i	: data prediksi
n	: jumlah data pada dataset
w	: parameter-parameter yang dimuat oleh model autoencoder.

2.4 Support Vector Machine

Support vector machine (SVM) adalah konsep *machine learning* dengan jenis supervised learning, yaitu membutuhkan dataset awal sebelum akhirnya menjadi model fungsional [6]. Secara praktikal, SVM menggunakan beberapa parameter dalam pembangunan modelnya. Hal pertama adalah dataset yang sudah menjadi karakteristik algoritmanya sebagai *machine learning* selain itu, kernel trick turut dilakukan untuk menyesuaikan kebutuhan *classifier*. Untuk memudahkannya, akan ditinjau dengan menggunakan sistem persamaan linear.



Gambar 3. Ilustrasi Vektor pada Support Vector Machine

$$g(\vec{x}) = \vec{w} \cdot \vec{x} + b \quad (6)$$

$$g^*(\vec{x}) = \vec{w} \cdot \vec{x} + b \pm \epsilon \quad (7)$$

Pada persamaan 6 Asumsikan bahwa suatu nilai yang menjadi pembatas antara dua kelas disini juga dibangun margin sebagai *support vector* yang secara *state-of-the-art* mampu mengoptimalkan dari nilai luaran model, ditunjukkan pada Persamaan 7. Dari persamaan ini, yang dapat kita tentukan adalah mengoptimalkan dari nilai $g(\vec{x})$ yang terpengaruh pada vektor \vec{w}

$$\min \left(\frac{1}{2} \|\vec{w}\|^2 + C \sum \epsilon_i \right) \quad (8)$$

Sehingga diperoleh Persamaan 8 sebagai normalisasi dari Persamaan 6 untuk nilai optimum yang diperoleh, dengan C dan ϵ sebagai konstanta *trade-off*. Namun tentunya terdapat *constraint* yang harus dipenuhi dikarenakan penerapan margin ini, yang ditunjukkan oleh Persamaan 9.

$$g(\vec{x}) = \vec{w} \cdot \vec{x} + b \geq 1 - \epsilon_i \quad (9)$$

3. Metode Penelitian

3.1 Metode Rancangan

Sistem kontrol yang hendak dikembangkan pada *wheelchair* ini akan dimanfaatkan sebagai media monitoring terhadap keselamatan pengguna saat melakukan mobilisasi secara mandiri. Pengembangan *wheelchair* dilakukan dengan menggunakan konsep *electrical-power wheelchair* (EPW) yang menggunakan tenaga elektrikal sebagai penggerak. EPW dirancang dengan berbasis Arduino dengan alasan memberikan efektivitas dalam integrasi sistem penggerak dan sistem monitoring, dalam merealisasikan prototipe *electric-powered wheelchair* yang hendak dibuat, dilakukan kajian sederhana terhadap pemilihan sistem penggerak yang dipasangkan pada prototipe. dengan mengabaikan efek sentripetal dan gangguan sekitar, maka kebutuhan torsi dapat dinyatakan dalam hubungannya dengan inersia dari sistem kursi roda. Simplifikasi bentuk Persamaan tersebut, maka diperoleh Persamaan

$$T = \mu_s M g r \quad (10)$$

Analisis kebutuhan torsi tanpa beban

$$T_{\text{tanpa beban}} = \mu_s g r M_{\text{tanpa beban}}$$

$$T_{\text{tanpa beban}} = (0,566) \left(9,8 \frac{m}{s^2} \right) (0,3 m) (15,8 kg)$$

$$T_{\text{tanpa beban}} = 26,29 N.m$$

Analisis kebutuhan torsi dengan beban

$$T_{\text{dengan beban}} = \mu_s g r M_{\text{dengan beban}}$$

$$T_{\text{dengan beban}} = (0,566) (9,8 \frac{m}{s^2}) (0,3 m) (115,8 kg)$$

$$T_{\text{dengan beban}} = 191,37 N.m$$

Agar tidak terjadi kegagalan pada sistem penggerak. Transmisi ini dilakukan dengan sistem rantai *sprocket* dengan *pitch of chain* (p) sebesar 6 mm, Hal ini ditunjukkan pada dua bagian gear yang dihitung berdasarkan *pitch circle diameter* (D) serta jumlah giginya (t).

$$p = D \sin \frac{180^\circ}{t} \quad (11)$$

$$D_{\text{besar}} = 102 \text{ mm}$$

$$t_{\text{besar}} = 50T$$

$$D_{\text{kecil}} = 22 \text{ mm}$$

$$t_{\text{kecil}} = 11T$$


Sprocket gear yang besar	Sprocket gear yang kecil
$p = D_{\text{besar}} \sin \frac{180^\circ}{t_{\text{besar}}}$	$p = D_{\text{kecil}} \sin \frac{180^\circ}{t_{\text{kecil}}}$
$p = (102 \text{ mm}) \sin \frac{180^\circ}{50}$	$p = (22 \text{ mm}) \sin \frac{180^\circ}{11}$
$p = 6,405 \text{ mm}$	$p = 6,198 \text{ mm}$
$p \approx 6 \text{ mm}$	$p \approx 6 \text{ mm}$

Dengan demikian, adapun rasio torsi (T) *input* serta *output* pada sistem transmisi ini ditunjukkan pada Persamaan

$$\text{Torque ratio} = \frac{t_{\text{besar}}}{t_{\text{kecil}}} = 4,5 \quad (12)$$


$$\therefore T_{\text{output}} = 4,5 T_{\text{input}}$$

Sehingga, merujuk pada kebutuhan torsi serta Persamaan 3.3, dengan *torque ratio* ini, motor DC (24V/350W) dengan torsi 45 N.m akan memperoleh torsi output sebesar 202,5 N.m, yang memiliki nilai lebih besar dari analisis kebutuhan torsi yaitu 191,37 N.m.



Gambar 4. Electric-Powered Wheelchair


Sistem kontrol berbasis mikrokontroler digunakan dalam upaya efisiensi rancangan dan maintenance. Sistem diawali dengan rangkaian motor driver dengan motor dan power supply. Dirangkai sedemikian rupa sehingga seluruh motor memperoleh daya yang sesuai. Selanjutnya, mikrokontroler dipasangkan dengan driver motor ini sekaligus pada kontrol joystick untuk memberikan interface kontrol ke motor. Serta poin terakhir adalah pembacaan data sensor accelerometer dilakukan oleh sensor MPU6050 serta untuk perekaman secara real-time dilakukan melalui SD Card Reader. Rangkaian yang disampaikan, divisualisasi pada Gambar 5.



Gambar 5. Rangkaian Sistem Kontrol

3.2 Metode Eksperimental

Merujuk pada tujuan penelitian, Secara lebih lanjut, terdapat dua buah pengujian yang akan dilakukan. Pengujian pertama adalah evaluasi terhadap akurasi posisi dari sensor perekaman data secara real-time akan dilakukan. Pengumpulan ini dilakukan dengan mencoba prototipe EPW secara langsung dengan mengikuti beberapa pola lintasan. Pola lintasan ini akan diarahkan untuk menguji bagaimana perilaku hasil algoritma sistem kontrol pada berbagai arah di semua spasial/sumbu. Visualisasi lintasan ini dapat dilihat pada Gambar 6.




Gambar 6. Lintasan Pengujian Prototipe EPW

Hasil pengujian ini akan dipetakan setiap 10 milisekon pada hasil algoritma: (1) tanpa integrasi Kalman Filter dan *auto-encoder machine learning*, (2) dengan integrasi Kalman Filter, (3) dengan integrasi *auto-encoder machine learning*, dan (4) dengan integrasi Kalman Filter dan *auto-encoder machine learning*. Pemetaan dilakukan dengan visualisasi posisi. Pada pengujian kedua, yaitu evaluasi akurasi kondisi kursi roda berdasarkan posisi *roll*, *yaw*, dan *pitch*, akan dilakukan pada berbagai medan yang diberikan label sebagai keadaan aman dan keadaan bahaya. Metode pengambilan *dataset* sama seperti pengujian pertama yaitu pengambilan secara *real-time*. Sementara, evaluasi algoritmanya akan divalidasi dengan *cross-validation*.


4. Hasil dan Pembahasan

4.1. Hasil Pengambilan Data Set Sistem Monitoring Kursi Roda

Pada penelitian ini pengambilan data mengalami gangguan dari noise yang ada sehingga interpretasi posisi dari data yang diambil dengan masih adanya gangguan dari Noise dapat dilihat pada plot grafik pada Gambar 7.



(a)




(b)

Gambar 7. Grafik Plot Interpretasi Output Data Tanpa Integrasi Algoritma Pola Lintasan 1(a) & Pola lintasan 2(b)


Dapat dilihat pada gambar 7 bahwa hasil plot output data dengan adanya gangguan dari noise mengakibatkan eror posisi perpindahan dari EPW yang didapatkan sangat jauh dari keadaan sebenarnya.

4.2. Kalman Filter Pada Sistem Monitoring Kursi Roda

Dengan implementasi pada data sensor yang diterapkan, diperoleh nilai sinyal yang lebih baik dibandingkan pada data sebelum implementasi extended kalman filter. algoritma ini telah berhasil menunjukkan koreksi terhadap sinyal dalam mereduksi noise yang terjadi. Bagan plot berikut menunjukkan perbandingan antara sinyal noise dan sinyal setelah algoritma Kalman Filter (Gambar 8.).



(a)



(b)


Gambar 8. Grafik Plot Posisi Hasil Reduksi Noise oleh Integrasi Model Kalman Filter Pada Pola Lintasan 1(a) dan Pola Lintasan 2 (b)

Kalman filter secara menyeluruh dapat mereduksi noise dengan sangat baik pada pola lintasan 1 maupun pada pola lintasan 2, pada titik 1-2 pola lintasan 1 dapat dilihat Kalman filter mampu mereduksi noise dengan baik, tetapi apabila dilihat dari posisi titik 1 pada pola lintasan prediksi model Kalman filter mengalami kesalahan hal ini mempengaruhi prediksi model kalman filter ke titik berikutnya (pola lintasan 1 titik 2-3, titik 3-4, dan 4-1) dilihat pada grafik semakin menuju titik akhir akurasi dari prediksi model Kalman filter mengalami kesalahan prediksi yang cukup signifikan dikarenakan


adanya eror prediksi yang dilakukan dari titik pertama pola lintasan 1. Begitu pun hal yang sama terjadi pada pola lintasan 2.

4.3. Autoencoder pada Sistem Monitoring Kursi Roda

Melalui beberapa proses epoch, model autoencoder menunjukkan penurunan loss function diikuti oleh peningkatan metrics *coefficient of determination* (Gambar 10.). Hal ini mengindikasikan bahwa model telah berhasil untuk melakukan proses training terhadap dataset yang dikumpulkan. Berikut adalah tampilan visualisasi plot posisi hasil reduksi noise oleh autoencoder (Gambar 9.).




(a)



(b)

Gambar 9. Grafik Plot Posisi Hasil Reduksi Noise oleh Integrasi Model Autoencoder (a) Pola Lintasan 1 dan (b) Pola Lintasan 2

Model auto encoder memiliki hal yang serupa dengan apa yang terjadi pada model Kalman filter, dimana eror prediksi posisi perpindahan yang terjadi dari titik 1 ke titik 2 mempengaruhi hasil prediksi posisi perpindahan EPW sampai ke titik akhir.




Gambar 10. Grafik Metrics pada Saat Proses Training Autoencoder

Model menunjukkan nilai mean squared error yang diperoleh pada akhir training sebesar 0,2982 m serta coefficient of determination $r_squared$ sebesar 98,66%. Nilai *metrics* ini menunjukkan bahwa model telah mampu melakukan reduksi noise yang muncul pada dataset.


4.4. Analisis Integrasi Autoencoder dan Kalman Filter pada Sistem Monitoring Kursi Roda

Pada penelitian ini melalui integrasi autoencoder dan Kalman Filter pada algoritma sistem kontrol. Sistem ini diintegrasikan dengan tujuan mendapatkan improvement dari hasil algoritma hanya dengan autoencoder. Beberapa metode yang dilakukan adalah dengan melakukan analisis error yang dihasilkan dari 4 algoritma, algoritma tanpa intervensi, algoritma Kalman Filter, algoritma Autoencoder, dan algoritma integrasi Kalman Filter dan Autoencoder. Analisis error akan diterapkan dengan membandingkan (mencari selisih) setiap algoritma dengan nilai ground truth. Nilai ground truth ditentukan dari jalur lintasan yang telah ditetapkan. Sebagai pembanding yang lebih visual, grafik plot untuk lintasan dengan spasial x-y turut ditampilkan untuk mengamati proses yang dapat teramati baik masing-masing sumbu maupun

keseluruhannya. Tabel 1 menunjukkan hasil analisis error pada tiap algoritma dan Gambar 11. menunjukkan plot posisinya.



(a)



(b)

Gambar 11 Plot Posisi Untuk Hasil Reduksi Noise oleh Integrasi Kalman Filter Dan Auto Encoder (a) Pola Lintasan I dan (b) Pola Lintasan II

Pada Gambar 11 dapat dilihat integrasi autoencoder dan Kalman filter memiliki hasil pengurangan noise yang sangat baik dengan tingkat akurasi sebesar 97,9 %.

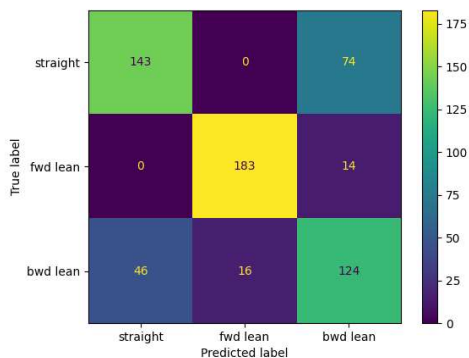
Tabel 1. Analisis Error Hasil Reduksi Noise terhadap Ground Truth

Algoritma	Root Mean Squared Error (m) – sumbu-x	Root Mean Squared Error (m) – sumbu-y	Root Mean Squared Error (m) – overall	Accuracy (%)
Tanpa algoritma (controlled)	11.39647	36.41151	23.90399	16.8495
Hanya Kalman Filter (KF)	5.98001	3.92260	4.95130	93.0619
Hanya Autoencoder	4.92788	2.39877	3.66332	95.5948
Autoencoder dengan KF	0.04482	0.09713	0.07097	97.9993

Pada Tabel 1. Seluruh hasil optimal ditunjukkan pada bagian yang dicetak tebal. Integrasi autoencoder dan Kalman Filter memberikan hasil yang paling optimal pada seluruh aspek pengujian. Ketika meninjau secara spesifik, tidak ada signifikansi pengaruh sumbu pada analisis error, sehingga dapat dinyatakan bahwa mode spasial tidak mempengaruhi performa algoritma nantinya. Peningkatan performa (penurunan error) terjadi pada implementasi tunggal algoritma KF dan Autoencoder. Terlebih lagi, penurunan error secara signifikan terjadi pada model integrasi kedua algoritma tersebut. Hal ini menunjukkan bahwa jenis algoritma ini memiliki kapabilitas dalam mereduksi noise dengan baik. Secara lebih dalam, accuracy mendominasi sebesar lebih dari 90% pada seluruh algoritma, yang mengindikasikan model ini telah mampu dan siap untuk diimplementasikan nantinya.

4.5 Cross Validation Algoritma

Algoritma support vector machine (SVM) digunakan untuk evaluasi ini dengan mengklasifikasikan posisi realtime pada hasil sinyal sensor. Sinyal sensor diklasifikasikan berdasarkan tiga posisi: mendatar, miring ke depan, dan miring ke belakang. Adapun hasil dari evaluasi algoritma ini menghasilkan confusion matrix sebagaimana ditunjukkan pada Gambar 11. Hasil menunjukkan didominasi pada true positive untuk semua posisi. Secara sekilas, hal ini mengindikasikan akurasi yang relative tinggi. Hal ini diperkuat dengan penghitungan skor akurasi sebesar 75% untuk model SVM dalam mengklasifikasikan posisi. Sehingga dapat disimpulkan keseluruhan model telah mampu memberikan gambaran keadaan kursi roda untuk sistem monitoring walaupun dengan sensor yang memberikan sinyal noise.



Gambar 11 Grafik confusion matrix model SVM pada sistem monitoring kursi roda

5. Kesimpulan

1. Sistem monitoring berhasil diterapkan untuk proses reduksi noise pada sinyal sensor accelerometer MPU6050 untuk memantau posisi dan perubahannya tiap waktu. Sistem ini akan mampu dengan baik diimplementasikan pada

model monitoring sebagai sistem odometry dari alat untuk memberikan data real-time.

2. Hasil analisis komparasi mengindikasikan integrasi Autoencoder dan Kalman Filter memberikan hasil yang optimal dalam fungsinya untuk mereduksi noise. Hal ini telah dilakukan dengan melakukan komparasi terhadap masing-masing dan algoritma kontrol (tanpa algoritma apapun) yang menyatakan hasil paling optimal ada pada model terintegrasi.

Daftar Pustaka

- [1] Nanda, A. R., & Herawati, R. (2021). Kendala dan Solusi Bagi Penyandang Disabilitas Kota Semarang dalam Mengakses Pekerjaan. *Jurnal Pembangunan Hukum Indonesia*, 3(3), 325–336.
- [2] Teodorescu, C. S., Zhang, B., & Carlson, T. (2020). A stochastic control strategy for safely driving a powered wheelchair. *IFAC-PapersOnLine*, 53, 10148–10153. <https://doi.org/10.1016/j.ifacol.2020.12.2741>
- [3] Dadafshar, M. (2014). Accelerometer and Gyroscopes Sensors: Operation, Sensing, and Applications. *Maxim Integrated*, 1–11.
- [4] Ma'arif, A., Iswanto, I., Nuryono, A. A., & Alfian, R. I. (2019). Kalman Filter for Noise Reducer on Sensor Readings. *Signal and Image Processing Letters*, 1(2), 11–22. <https://doi.org/10.31763/simple.v1i2.2>
- [5] Edla, D. R., Ansari, M. F., Chaudhary, N., & Dodia, S. (2018). Classification of Facial Expressions from EEG signals using Wavelet Packet Transform and SVM for Wheelchair Control Operations. *Procedia Computer Science*, 132, 1467–1476. <https://doi.org/10.1016/j.procs.2018.05.081>
- [6] Shao, H., Zhao, H., Sun, Y., Zhang, J., & Xu, Y. (2016). QoE-Aware Downlink User-Cell Association in Small Cell Networks: A Transfer-matching Game Theoretic Solution with Peer Effects. *IEEE Access*, 4, 10029–10041. <https://doi.org/10.1109/ACCESS.2016.2628382>



Jalasecca Wya Dewaruci menyelesaikan studi program sarjana di jurusan Teknik Mesin Universitas Udayana dari tahun 2019 sampai 2024. Bidang penelitian yang diminati adalah sistem kontrol dan sistem monitoring dengan konsentrasi Rekayasa Manufaktur.