

Deteksi Penonaktifan Perangkat Automatic Identification System Memakai Neural Network

¹Widyadi Setiawan

²*Teknik Elektro, Fakultas Teknik, Universitas Udayana*
Denpasar, Indonesia
widyadi@unud.ac.id

²Rukmi Sari Hartati, ³Sri Andirati Asri

²*Teknik Elektro, Fakultas Teknik, Universitas Udayana*
Denpasar, Indonesia
rukmisari@unud.ac.id

³*Managemen Informatika Politeknik Negeri Bali*
Denpasar, Indonesia
sriandriati@pnb.ac.id

Abstract— Penonaktifan perangkat Automatic Identification System (AIS) secara disengaja sering dilakukan untuk menyembunyikan aktivitas ilegal, seperti penangkapan ikan ilegal, perdagangan manusia, dan penyelundupan. Penelitian ini bertujuan untuk mendeteksi penonaktifan AIS menggunakan pendekatan berbasis Neural Network. Data AIS yang digunakan mencakup informasi dan dinamis yang diproses melalui tahapan data cleansing, ekstraksi lintasan, dan pembersihan lintasan. Dataset penelitian ini berasal dari Receiver Base Station (RBS) Universitas Udayana, yang mencatat data dari 28 September 2022 hingga 19 April 2023, dengan total 126 juta data mencakup 12 ribu MMSI. Setelah tahapan data cleansing dengan kriteria tertentu untuk validasi data, jumlah data yang tersaring menjadi 48,5 juta baris dengan 6597 MMSI. Pada tahap ekstraksi lintasan, data dipisahkan menjadi lintasan individual berdasarkan selisih waktu antar koordinat yang berturut-turut, menghasilkan 31 ribu lintasan. Selanjutnya, tahap pembersihan lintasan menggunakan kriteria tambahan menghasilkan 12 ribu lintasan yang sesuai untuk pelabelan otomatis dan pengembangan model klasifikasi. Sebanyak 46,4 juta data koordinat berhasil dilabeli secara otomatis untuk mendeteksi data anomali dengan kriteria selisih waktu > 45 menit dan selisih jarak > 1 km. Pengujian model deteksi dilakukan dengan menghasilkan Confusion Matrix yang menunjukkan distribusi 626 data non-anomali dan 529 data anomali. Model menunjukkan performa yang sangat baik dengan Akurasi 100%, Precision 100%, Recall 100%, dan F1-Score 100% untuk kedua kelas (anomali dan non-anomali). Kinerja optimal ini menandakan bahwa model tidak membuat kesalahan dalam klasifikasi, baik untuk mendeteksi data anomali maupun non-anomali. Dengan hasil ini, penelitian ini memberikan kontribusi signifikan dalam mendeteksi anomali AIS secara otomatis, sehingga dapat meningkatkan pengawasan maritim.

Kata Kunci— Anomali Maritim, Deteksi Penonaktifan AIS, Data Cleansing, Ekstraksi Lintasan, Neural Network.

I. PENDAHULUAN

Peningkatan keamanan maritim menjadi isu utama dalam era globalisasi saat ini. Automatic Identification System (AIS) adalah teknologi yang umum digunakan untuk melacak kapal di laut, namun, seringkali terjadi penonaktifan perangkat AIS dengan sengaja, menyebabkan celah dalam pemantauan dan meningkatkan risiko kecelakaan laut. Fenomena ini menciptakan kebutuhan mendesak untuk mengembangkan metode deteksi yang handal agar tindakan yang dapat membahayakan dapat diidentifikasi dan dicegah secara dini. Peningkatan keamanan maritim menjadi isu utama dalam era globalisasi saat ini. AIS adalah teknologi yang umum digunakan untuk melacak kapal di laut, namun, seringkali terjadi penonaktifan perangkat AIS dengan sengaja, menyebabkan celah dalam pemantauan dan meningkatkan risiko kecelakaan laut. Fenomena ini menciptakan kebutuhan mendesak untuk mengembangkan metode deteksi yang handal agar tindakan yang dapat membahayakan dapat diidentifikasi dan dicegah secara dini.

Penelitian ini sangat penting karena penonaktifan perangkat AIS yang disengaja dapat mengakibatkan dampak serius terhadap keamanan dan ketertiban maritim. Risiko kecelakaan, penyelundupan, dan kegiatan ilegal lainnya dapat meningkat tanpa adanya sistem deteksi yang efektif. Oleh karena itu, pengembangan metode deteksi penonaktifan perangkat AIS menggunakan pendekatan Neural Network menjadi kebutuhan mendesak dalam rangka meningkatkan efektivitas pemantauan dan keamanan laut.

Penelitian terkini menunjukkan berbagai pendekatan inovatif dalam deteksi dan analisis data AIS serta pengawasan maritim. Studi pertama memperkenalkan metode baru untuk mendeteksi pengaktifan dan penonaktifan AIS secara disengaja [1], yang memiliki hasil menjanjikan meskipun memerlukan validasi lebih luas pada dataset beragam dan pengujian efisiensi komputasi serta integrasi dengan infrastruktur AIS yang ada. Penelitian lain mengeksplorasi penggunaan teknik pembelajaran mesin dalam pengawasan maritim [2], membahas tantangan dalam mendeteksi perilaku abnormal seperti penangkapan ikan ilegal dan penyelundupan, serta membandingkan metode pembelajaran tradisional dan mendalam untuk adaptasi terhadap ancaman keamanan yang terus berkembang.

Selain itu, studi terkait deteksi anomali data AIS mengusulkan arsitektur untuk mendeteksi kehilangan data AIS (drop-out) dengan analisis pola cakupan dan propagasi gelombang radio [3]. Meskipun penting untuk keamanan maritim, pendekatan ini membutuhkan validasi lebih lanjut dan pengkajian dampak alarm palsu. Pendekatan deep learning menggunakan model transformator juga diperkenalkan untuk mendeteksi penonaktifan AIS secara akurat pada dataset besar [4], namun kurang membahas generalisasi wilayah maritim yang beragam serta interpretabilitas model.

Dari segi analisis lintasan kapal, PyVT menawarkan alat yang efektif untuk segmentasi, kompresi, dan penghitungan area tambat jangkar, yang telah menunjukkan efektivitas dalam publikasi ilmiah [5]. Sementara itu, PTRAIL mendukung prapemrosesan data lintasan paralel dengan efisiensi tinggi, fleksibilitas, dan integrasi dengan alat geospasial seperti GeoPandas [6]. Secara keseluruhan, penelitian-penelitian ini memberikan kemajuan signifikan dalam deteksi anomali dan analisis data AIS, meskipun masih memerlukan validasi lebih lanjut untuk penerapan yang lebih luas dan andal di dunia nyata.

II. METODE DAN PROSEDUR

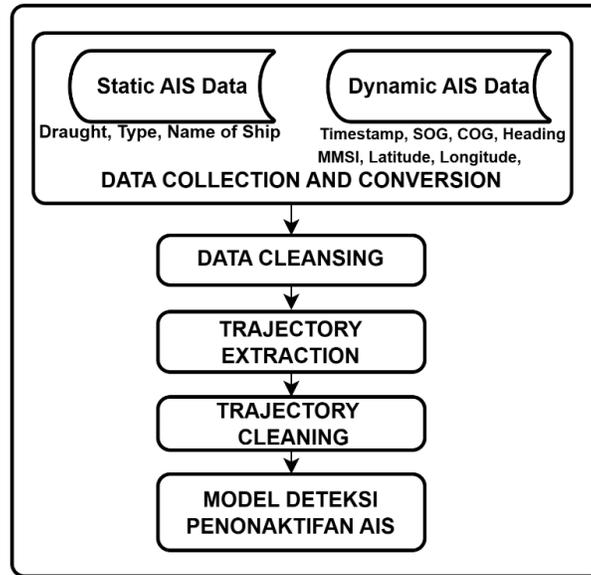
Gambaran umum sistem terkait penelitian "Deteksi Penonaktifan Perangkat Automatic Identification System (AIS) Memakai Metode Neural Network" mencakup berbagai komponen dan langkah-langkah yang dilibatkan dalam pengembangan sistem deteksi. Berikut adalah gambaran umumnya:

1. **Pengumpulan Data:**
Sistem dimulai dengan pengumpulan data AIS dari berbagai sumber. Data ini dapat mencakup informasi seperti identifikasi kapal, posisi, kecepatan, dan status perangkat AIS. Dataset harus mencakup situasi normal dan skenario penonaktifan perangkat untuk melatih model dengan baik.
2. **Pra-Pemrosesan Data:**
Data AIS yang dikumpulkan kemudian melewati tahap pra-pemrosesan untuk membersihkan dan merapikan data. Pra-pemrosesan ini dapat mencakup penghapusan outlier, normalisasi data, dan konversi data menjadi format yang sesuai untuk digunakan sebagai input pada model deteksi.
3. **Pengembangan Model Neural Network:**
Langkah kunci adalah pengembangan model deteksi menggunakan metode Neural Network, khususnya dengan memanfaatkan shallow Neural Network. Model ini dilatih menggunakan data historis yang mencakup keadaan normal dan penonaktifan perangkat AIS. Proses pelatihan melibatkan tuning parameter model untuk meningkatkan akurasi dan generalisasi model.
4. **Validasi dan Pengujian Model:**
Setelah model dilatih, langkah selanjutnya adalah melakukan validasi dan pengujian model menggunakan dataset yang belum pernah dilihat sebelumnya. Performa model dievaluasi dengan metrik seperti akurasi, presisi, recall, dan F1-score.

Gambar 1 menggambarkan alur penelitian deteksi penonaktifan AIS yang dimulai dari pengumpulan dan konversi data AIS statis (seperti nama kapal, tipe kapal, dan draught) serta data AIS dinamis (seperti timestamp, SOG, COG, heading, MMSI, latitude, dan longitude). Setelah itu, data tersebut melalui beberapa tahap pemrosesan, yaitu:

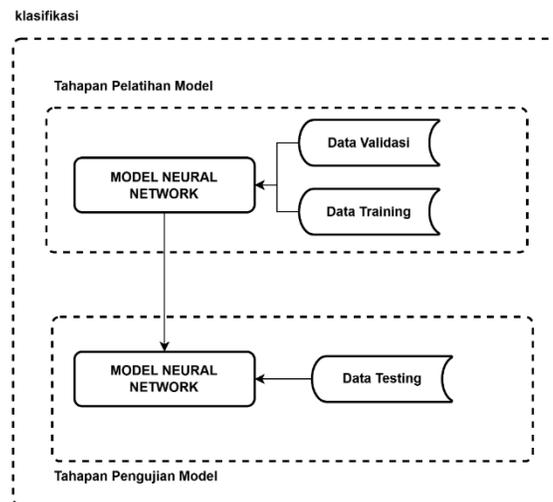
1. **Data Cleansing:** Proses membersihkan data dari kesalahan atau informasi yang tidak relevan.
2. **Trajectory Extraction:** Ekstraksi lintasan kapal dari data AIS yang telah dibersihkan.

3. **Trajectory Cleaning:** Penyempurnaan data lintasan untuk menghilangkan anomali atau inkonsistensi.
4. **Model Deteksi Penonaktifan AIS:** Pembuatan dan penerapan model untuk mendeteksi penonaktifan AIS yang disengaja berdasarkan data lintasan yang telah diproses.



GAMBAR 1. DIAGRAM ALIR PENELITIAN

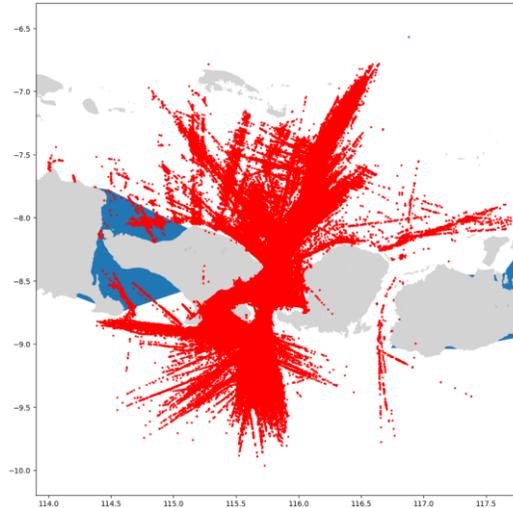
Gambar 2 menunjukkan tahapan klasifikasi yang menggambarkan proses pelatihan dan pengujian model Neural Network. Diagram ini menunjukkan dua fase utama dalam proses pengembangan model Neural Network: pelatihan dan pengujian. Selama pelatihan, model dilatih dan divalidasi untuk mencapai performa terbaik, sementara selama pengujian, model dievaluasi untuk menentukan seberapa baik ia dapat menggeneralisasi dan memberikan prediksi yang akurat pada data baru.



GAMBAR 2. TAHAPAN KLASIFIKASI

III. HASIL DAN PEMBAHASAN

Visualisasi Koordinat Data yang didapat dari Receiver Base Station (RBS) di Universitas Udayana, dari tanggal 28 September 2022 s/d 19 April 2023, sebanyak 126 juta baris, didalamnya terdapat 12ribu MMSI, yang ditunjukkan pada gambar 3.



GAMBAR 3. VISUALISASI KOORDINAT DATA

Pada tahapan Data Cleansing, memakai filter atau kriteria seperti yang tersaji, untuk memastikan Data koordinat yang akan diolah benar-benar akurat dan valid. Didapatkan jumlah data sebesar 48.5 juta dan 6597 MMSI

TABEL 1. CLEANSING DATA

	Jumlah Data	MMSI	Jumlah Lintasan
Clean AIS Data	48.501.813	6.597	31.415
Pembersihan Lintasan	46.458.863	3.422	12.393

Pada tahapan ekstaksi lintasan memisahkan data menjadi lintasan individual, yang merupakan serangkaian titik koordinat dari sebuah kapal selama periode waktu tertentu. Kriteria yang dipakai dengan melihat timestamp tiap koordinat dan dihitng selisih antar koordinat yang berurutan, selama nilainya masih ≤ 45 menit akan dijadikan lintasan dengan ID yang sama. Pada tahapan ini didapatkan 31 ribu lintasan, diperlihatkan pada tabel 1 baris pertama.

Pada tahapan pembersihan Lintasan, dengan memakai kriteria, jumlah koordinat tiap lintasan ≥ 400 titik dan rerata SOG (kecepatan) < 60 knot serta varians Heading < 300 , didapatkan lintasan yang sesuai dengan keperluan pembuatan model klasifikasi. Dari tahapan ini didapatkan 12 ribuan lintasan, diperlihatkan pada tabel 1 baris kedua.

Pada tabel 1 merupakan hasil untuk melabeli secara otomatis sebanyak 46.4 juta data koordinat, mana data koordinat yang memiliki fitur anomaly dan mana yang tidak. Pada tahapan ini kriteria yang dipakai adalah anomaly terjadi jika Selisih Waktu > 45 menit dan Selisih Jarak > 1 km)

TAHAPAN PELATIHAN MODEL

Setelah melakukan tuning hyperparameter dengan kombinasi terbaik yang didapatkan, model neural network menunjukkan peningkatan performa dalam mengklasifikasi anomaly mematikan perangkat AIS. Dengan pengaturan berikut:

- Optimizer: RMSprop
- Jumlah Neuron di Hidden Layers: 64 (layer pertama), 16 (layer kedua), dan 64 (layer ketiga)
- Dropout Rate: 0% untuk layer pertama dan ketiga, 10% untuk layer kedua
- Aktivasi: Sigmoid (layer pertama), Tanh (layer kedua), dan ReLU (layer ketiga)
- Epochs: 50
- Batch Size: 128

Model mencapai kinerja yang optimal, dengan hasil metrik evaluasi (akurasi, presisi, recall, dan F1-score) yang lebih baik dibandingkan sebelum tuning. Pengaturan ini mengurangi overfitting dan meningkatkan kemampuan generalisasi model terhadap data validasi, yang terlihat dari hasil evaluasi pada data validasi yang konsisten

	mmsi	created_at	lat	lon	sog	cog	hdg	lintasan	time_diff	distance_diff	is_anomaly
0	205083000	2023-10-06 12:54:36+00:00	-7.481122	115.179705	0.0	122.6	134.0	205083000-2	0.0	0.000000	False
1	205083000	2023-10-06 12:54:45+00:00	-7.481122	115.179705	0.0	128.3	134.0	205083000-2	9.0	0.000000	False
2	205083000	2023-10-06 12:55:26+00:00	-7.481122	115.179708	0.0	151.0	135.0	205083000-2	41.0	0.367927	False
3	205083000	2023-10-06 12:55:36+00:00	-7.481122	115.179710	0.0	144.7	135.0	205083000-2	10.0	0.183964	False
4	205083000	2023-10-06 12:56:36+00:00	-7.481122	115.179710	0.0	160.7	135.0	205083000-2	60.0	0.000000	False

	mmsi	created_at	lat	lon	sog	cog	hdg	lintasan	time_diff	distance_diff	is_anomaly
2431	205194000	2023-12-11 09:21:46+00:00	-9.461150	115.820245	11.0	348.2	347.0	205194000-0	3142.0	17687.548057	True
5030	205195000	2023-08-17 23:06:01+00:00	-7.393872	116.360532	12.8	196.9	193.0	205195000-0	3983.0	26547.755008	True
8646	205195000	2023-09-24 23:40:52+00:00	-7.590467	116.247832	12.7	204.6	205.0	205195000-1	9230.0	60258.029589	True
8663	205195000	2023-09-25 01:45:12+00:00	-7.962622	116.039032	11.8	210.8	210.0	205195000-1	3277.0	20221.708666	True
16448	205195000	2023-12-07 11:10:11+00:00	-7.426855	116.344563	12.1	203.0	203.0	205195000-4	5863.0	36275.385209	True

GAMBAR 4. PENAMBAHAN FITUR ANOMALI PADA DATASET

TAHAPAN PENGUJIAN MODEL

Hasil pengujian model pada Confusion matrix yang menghasilkan 626 data non-anomali dan 529 data anomali menunjukkan performa yang sangat baik, dengan metrik evaluasi sbb:

- Akurasi: 1.00 (100%), menunjukkan bahwa model mampu mengklasifikasikan semua data dengan benar.
- Precision, Recall, dan F1-Score: 1.00 (100%) untuk kedua kelas (True dan False), menunjukkan bahwa model tidak membuat kesalahan dalam prediksi baik untuk anomali maupun non-anomali.
- Support: 626 data non-anomali dan 529 data anomali, menunjukkan distribusi kelas yang seimbang.

Secara keseluruhan, model memiliki kinerja yang sangat optimal dalam mendeteksi anomali perangkat AIS, dengan tidak ada kesalahan klasifikasi dalam pengujian ini.

Hasil pengujian model menunjukkan performa yang sangat baik, dengan metrik evaluasi sbb:

- Akurasi: 1.00 (100%), menunjukkan bahwa model mampu mengklasifikasikan semua data dengan benar.
- Precision, Recall, dan F1-Score: 1.00 (100%) untuk kedua kelas (True dan False), menunjukkan bahwa model tidak membuat kesalahan dalam prediksi baik untuk anomali maupun non-anomali.
- Support: 626 data non-anomali dan 529 data anomali, menunjukkan distribusi kelas yang seimbang.

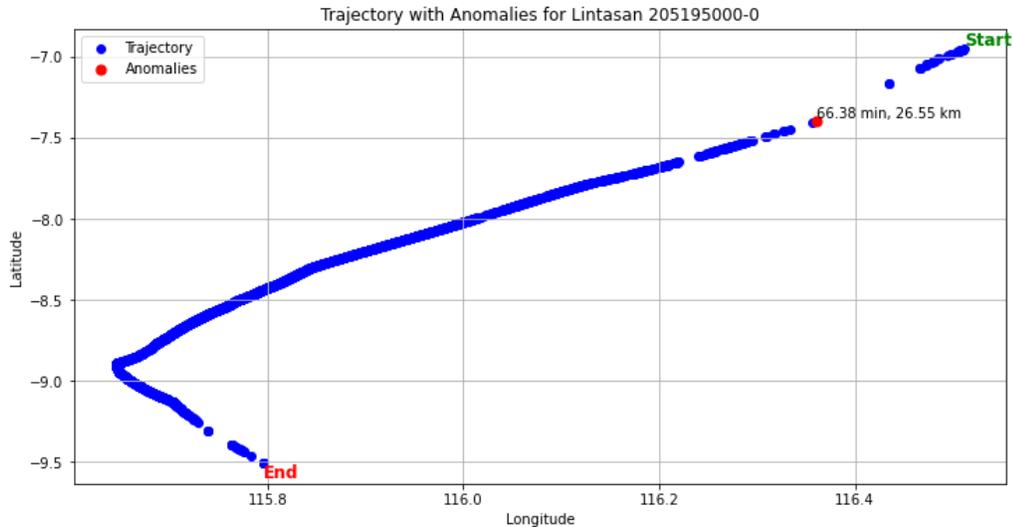
Secara keseluruhan, model memiliki kinerja yang sangat optimal dalam mendeteksi anomali perangkat AIS, dengan tidak ada kesalahan klasifikasi dalam pengujian ini.

CONTOH PENGUJIAN MODEL

Gambar 5 yang ditampilkan menunjukkan lintasan kapal (digambarkan dengan titik-titik biru) dan anomali yang terdeteksi (ditandai dengan titik merah). Berikut adalah analisis dari anomali yang terdeteksi. Jalur lintasan kapal digambarkan secara kontinu dengan titik-titik biru, yang mewakili posisi kapal pada interval waktu tertentu. Jalur ini menunjukkan pergerakan kapal dari titik "Start" (di pojok kanan atas) menuju titik "End" (di bagian bawah). Anomali lintasan ditandai dengan titik merah pada lintasan kapal. Pada titik anomali ini, terlihat adanya selisih waktu (time_diff) sebesar 66.38 menit dan jarak (distance_diff) sejauh 26.55 km dari koordinat sebelumnya.

Selisih waktu yang signifikan dan jarak yang besar antara titik anomali dan titik sebelumnya mengindikasikan adanya sesuatu yang tidak biasa. Biasanya, dalam kondisi normal, perangkat AIS (Automatic Identification System) di kapal terus-menerus mengirimkan data posisi dalam interval waktu yang relatif pendek.

Namun, karena selisih waktu dan jarak yang besar ini, dapat diduga bahwa perangkat AIS kapal mungkin telah dimatikan secara sengaja selama periode tersebut. Hal ini bisa saja dilakukan untuk menghindari deteksi, misalnya untuk menghindari patroli atau menghindari zona tertentu, sehingga tidak terekam dalam lintasan normal.



GAMBAR 5. CONTOH PENGUJIAN SATU KOORDINAT ANOMALI

IV. KESIMPULAN

Dari hasil penelitian yang telah didapat, dapat ditarik beberapa kesimpulan, diantaranya yaitu:

1. Model neural network yang dilatih mampu mengidentifikasi anomali pematian AIS dengan akurasi yang memuaskan.
2. Penggunaan metrik evaluasi seperti akurasi, presisi, recall, dan F1-score menunjukkan kinerja model yang baik dalam membedakan antara anomali dan non-anomali.
3. Kemampuan untuk mendeteksi mematikan perangkat AIS dengan akurasi tinggi penting untuk keamanan maritim, membantu dalam identifikasi aktivitas ilegal seperti penangkapan ikan ilegal atau perdagangan manusia.

UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan untuk semua pihak yang sudah membantu dan memberikan kontribusi pada penulisan makalah ini dan tidak lupa kami ucapkan terima kasih pada Universitas Udayana dalam program penelitian unggulan program studi berdasarkan Surat Perjanjian Penugasan Pelaksanaan (SP3) penelitian dana PNBPN tahun anggaran 2024 nomor : B/255.85/Un14.4.A/Pt.01.03/2024.

DAFTAR PUSTAKA

- [1] F. Mazzarella, M. Vespe, A. Alessandrini, D. Tarchi, G. Aulicino, and A. Vollero, "A novel anomaly detection approach to identify intentional AIS on-off switching," *Expert Syst. Appl.*, vol. 78, 2017, doi: 10.1016/j.eswa.2017.02.011.
- [2] C. Gamage, R. Dinalankara, J. Samarabandu, and A. Subasinghe, "A comprehensive survey on the applications of machine learning techniques on maritime surveillance to detect abnormal maritime vessel behaviors," *WMU J. Marit. Aff.*, 2023, doi: 10.1007/s13437-023-00312-7.
- [3] F. Mazzarella, M. Vespe, D. Tarchi, G. Aulicino, and A. Vollero, "AIS reception characterisation for AIS on/off anomaly detection," 2016.
- [4] P. Bernabé, A. Gotlieb, B. Legeard, D. Marijan, F. Sem-Jacobsen, and H. Spieker, "Detecting Intentional AIS Shutdown in Open Sea Maritime Surveillance Using Self-Supervised Deep Learning," *IEEE Trans. Intell. Transp. Syst.*, 2023, doi: 10.1109/TITS.2023.3322690.
- [5] Q. Liu, Z. Qiao, and Y. Lv, "PyVT: A python-based open-source software for visualization and graphic analysis of fluid dynamics datasets," *Aerosp. Sci. Technol.*, vol. 117, 2021, doi: 10.1016/j.ast.2021.106961.
- [6] S. Haidri, Y. J. Haranwala, V. Bogorny, C. Renso, V. P. da Fonseca, and A. Soares, "PTRAIL — A python package for parallel trajectory data preprocessing," *SoftwareX*, vol. 19, 2022, doi: 10.1016/j.softx.2022.101176.