



Rekomendasi Alokasi Kendaraan Logistik Menggunakan Model Hibrida Transformer Autoencoder dan Algoritma Genetika

Faizura Zadri ¹, Arya Adhyaksa Waskita ², Mardiyanto ³

^{1,2,3} Teknik Informatika S-2, Program Pascasarjana, Universitas Pamulang, Kota Tangerang Selatan, Banten

Email: ¹faizurazadri00@gmail.com, ²aawaskita@unpam.ac.id, ³dosen00027@unpam.ac.id

ABSTRACT

The vehicle allocation system in logistics operations is generally still carried out manually (rule-based), including at PT XYZ, so the vehicle selection process becomes less effective when facing high delivery requests. The increasing number of delivery requests each month causes the decision-making process to become increasingly complex and has the potential to cause allocation errors, such as the use of vehicles that exceed the load capacity (overload) or the selection of vehicle types that do not match the characteristics of the goods. This study proposes a hybrid model that integrates Transformer Autoencoder and Genetic Algorithm to produce more optimal vehicle allocation recommendations according to the company's operational needs. Transformer Autoencoder was chosen because it is able to learn normal operational patterns unsupervised, thus matching the characteristics of PT XYZ's historical data which only stores a history of successful vehicle allocations without data on failures or rejections. The vehicle allocation recommendation process is carried out through two main stages. In the first stage, Transformer Autoencoder generates an anomaly score as an indicator of the level of suitability of the vehicle and load combination to the historical operational pattern. Next, Genetic Algorithm performs multi-objective optimization by considering the anomaly score (60%), distance to the load pickup location (20%), and the vehicle capacity utilization rate (20%). Test results show that the Transformer Autoencoder is able to learn normal operational patterns with a reconstruction loss of 0.0214 at the end of the training process. Furthermore, the Genetic Algorithm produces the best vehicle recommendations with a fitness score of 0.8263 and an anomaly score of 0.0411, thus filtering out vehicle candidates that do not match historical operational patterns before the optimization process is carried out.

Keywords: Transformer AutoEncoder, Genetic Algorithm, Multi-Objective Optimization, Vehicle Unit Allocation, Anomaly Detection.

ABSTRAK

Sistem alokasi kendaraan pada operasional logistik umumnya masih dilakukan secara *manual (rule-based)*, termasuk pada PT XYZ, sehingga proses pemilihan kendaraan menjadi kurang efektif ketika menghadapi tingginya permintaan pengiriman. Meningkatnya jumlah permintaan pengiriman setiap bulan menyebabkan proses pengambilan keputusan menjadi semakin kompleks dan berpotensi menimbulkan kesalahan alokasi, seperti penggunaan kendaraan yang melebihi kapasitas muatan (*overload*) maupun pemilihan jenis kendaraan yang tidak sesuai dengan karakteristik barang. Penelitian ini mengusulkan model hibrida yang mengintegrasikan Transformer Autoencoder dan Algoritma Genetika untuk menghasilkan rekomendasi alokasi kendaraan yang lebih optimal sesuai dengan kebutuhan operasional perusahaan. Transformer Autoencoder dipilih karena mampu mempelajari pola operasional normal secara *unsupervised*, sehingga sesuai dengan karakteristik data historis PT XYZ yang hanya menyimpan riwayat alokasi kendaraan yang berhasil tanpa data kegagalan atau penolakan. Proses rekomendasi alokasi kendaraan dilakukan melalui dua tahapan utama. Pada tahap pertama, Transformer Autoencoder menghasilkan *anomaly score* sebagai indikator tingkat kesesuaian kombinasi kendaraan dan muatan terhadap pola historis operasional. Selanjutnya, Algoritma Genetika melakukan optimasi multiobjektif dengan mempertimbangkan *anomaly score* (60%), jarak menuju lokasi pengambilan muatan (20%), dan tingkat pemanfaatan kapasitas kendaraan (20%). Hasil pengujian menunjukkan bahwa Transformer

Autoencoder mampu mempelajari pola operasional normal dengan *reconstruction loss* sebesar 0,0214 pada akhir proses pelatihan. Selanjutnya, Algoritma Genetika menghasilkan rekomendasi kendaraan terbaik dengan *fitness score* sebesar 0,8263 dan *anomaly score* sebesar 0,0411, sehingga mampu menyaring kandidat kendaraan yang tidak sesuai dengan pola historis operasional sebelum proses optimasi dilakukan.

Kata kunci: Transformer Autoencoder, Genetic Algorithm, Optimasi Multi-Objektif, Alokasi Unit Kendaraan, Deteksi Anomali.

1. PENDAHULUAN

Peningkatan volume transaksi harian memunculkan tantangan operasional yang semakin kompleks bagi sektor logistik modern. Pada penelitian ini di PT XYZ, sebuah Perusahaan logistik berskala nasional, memiliki volume rata-rata pengiriman mencapai 30.000 pesanan setiap bulannya. Untuk mengelola operasional tersebut, sistem alokasi kendaraan memegang peranan yang sangat penting dalam mencocokkan spesifikasi pesanan dengan ketersediaan kendaraan [1]. Proses alokasi ini melibatkan berbagai batasan (*constraints*) operasional yang ketat, seperti status kesiapan unit kendaraan, jarak titik penjemputan, hingga kecocokan fisik antara jenis muatan dengan tipe kendaraan.

Saat ini, proses alokasi kendaraan masih mengandalkan pendekatan manual (*manual rule-based*) yang rentan terhadap inefisiensi serta dapat terjadi bias dalam pengambilan keputusan. Pendekatan ini memiliki beberapa keterbatasan karena harus mempertimbangkan beberapa parameter secara bersamaan dalam waktu singkat. Akibatnya, masih terdapat kesalahan dalam pengalokasian unit kendaraan, seperti pemanfaatan ruang kargo yang belum optimal, serta pemilihan jenis kendaraan yang kurang sesuai. Akibat kesalahan tersebut dapat meningkatkan biaya operasional, menurunkan efisiensi distribusi serta dapat berpotensi terjadinya keterlambatan pengiriman.

Beberapa penelitian terdahulu telah mencoba menyelesaikan masalah optimasi logistik melalui berbagai pendekatan heuristic. Penelitian yang dilakukan oleh Q. S. Nur dan S. Tedjo mengimplementasikan Algoritma Genetika untuk meminimalkan jarak tempuh dan biaya bahan bakar [2], Sementara itu M. T. Sembiring, dkk menggunakan metode serupa untuk konsolidasi rute logistik [1]. Namun, untuk optimasi yang murni berfokus pada jarak sering kali mengabaikan batasan keselamatan fisik dan kesesuaian operasional di lapangan. Di sisi lain, adopsi arsitektur *deep learning* seperti Transformer

mulai menunjukkan keunggulan dalam memecahkan masalah logistik yang dinamis [3]. Secara spesifik, arsitektur *Self-Attention* and *Intersample Attention* (SAINT) terbukti sangat bagus dalam menangkap korelasi non-linear pada struktur data tabular [4]. Sejalan dengan hal tersebut penelitian yang dilakukan oleh D. Huang telah membuktikan bahwa pemodelan Transformer Autoencoder sangat efektif untuk mendeteksi *anomaly* yang ada pada data logistik multidimensi melalui perhitungan *reconstruction error* [5].


Berdasarkan celah penelitian tersebut, penelitian ini mengusulkan pengembangan arsitektur hibrida yang mengintegrasikan kecerdasan Transformer Autoencoder dengan Algoritma Genetika untuk menyelesaikan kompleksitas alokasi unit kendaraan yang ada pada PT XYZ. Mengingat karakteristik data operasional perusahaan umumnya hanya memiliki data alokasi positif (*positive only dataset*), Transformer Autoencoder dilatih untuk mempelajari representasi pola historis sehingga mampu menghasilkan anomaly score tanpa memerlukan data yang berlabel negatif. Dalam sistem hibrida ini, Transformer bertindak sebagai filter kelayakan yang memetakan batas aman pengalokasian. Nilai *anomaly* kemudian digunakan pada fungsi kebugaran (*fitness function*) yang ada pada algoritma genetika. Melalui integrasi ini, optimasi rute tidak sekedar mengedepankan efisiensi jarak, tetapi juga memastikan alokasi unit kendaraan dapat berjalan dengan aman, optimal dari segi kapasitas serta mematuhi Batasan-batasan operasional riil yang terjadi di lapangan.

2. METODE

Metode yang diusulkan dalam penelitian ini menggunakan metode hibrida yang mengintegrasikan arsitektur Transformer Autoencoder dan Algoritma Genetika untuk menghasilkan rekomendasi alokasi kendaraan pada proses pengiriman muatan pelanggan. Secara umum, penelitian ini terdiri atas beberapa tahapan, yaitu pengumpulan dan pra-pemrosesan data, pembelajaran pola historis menggunakan metode Transformer Autoencoder, perhitungan *anomaly score*, optimasi menggunakan Algoritma Genetika, serta evaluasi dari hasil rekomendasi unit kendaraan yang dihasilkan.

2.1. Desain Arsitektur Transformer Autoencoder

Pada penelitian ini model Transformer Autoencoder dirancang untuk memetakan karakteristik operasional logistik kedalam *latent representation* agar bisa menghasilkan nilai evaluasi berupa *anomaly score*. Alur pemrosesan pada arsitektur ini terbagi menjadi lima tahapan utama seperti yang dapat dilihat pada Gambar 2.



Gambar 2. Flowchart Transformer Autoencoder

2.1.1 Pengumpulan dan Prapemrosesan Data

Pada penelitian ini data yang digunakan dikelompokkan menjadi 2 kelompok fitur utama, yaitu fitur kendaraan dan fitur pesanan. Fitur kendaraan meliputi tipe unit, merek tipe, usia kendaraan, dan kapasitas kendaraan. Sedangkan, untuk fitur pesanan terdiri dari jenis barang, berat muatan, hari pengiriman, serta koordinat lokasi penjemputan (latitude dan longitude).

Seluruh data yang digunakan merupakan data historis yang hanya merepresentasikan alokasi kendaraan yang berhasil dialokasikan, sehingga digunakan sebagai *positive only dataset* dalam proses pembelajaran model. Kondisi ini menyebabkan dataset tidak memiliki contoh data anomali sehingga tidak memungkinkan penerapan model klasifikasi (*supervised learning*) yang mana

memerlukan representasi kedua kelas. Selain itu, ketidakseimbangan distribusi data dapat menurunkan kemampuan model dalam melakukan generalisasi terhadap kondisi yang jarang terjadi [6].

Sebelum proses penelitian, dilakukan tahap pra-pemrosesan data yang meliputi data *cleaning*, transformasi fitur, *feature engineering*, dan pembagian data. Tahap pembersihan data dilakukan dengan cara menghapus data yang duplikat, menangani nilai yang hilang, serta menghilangkan data yang tidak konsisten, termasuk data dengan berat muatan yang melebihi kapasitas kendaraan.

Transformasi fitur dilakukan melalui *Label Encoding* pada fitur kategorikal dan normalisasi menggunakan *Standard Scaler* pada fitur numerik. *Standard Scaler* dilakukan menyamakan rentang nilai antar fitur sehingga dapat mempercepat proses konvergensi model serta meningkatkan stabilitas pelatihan. Secara matematis, persamaan Z-Score Normalization dapat dihitung menggunakan persamaan 1 [7] .

$$Z = \frac{X - \mu}{\sigma} \quad (1)$$

Selain itu, terdapat fitur tambahan *Load Ratio* yang merupakan perbandingan antara berat muatan dan kapasitas kendaraan sebagaimana yang ditunjukkan pada persamaan 2. Fitur ini digunakan untuk membantu model dalam memahami tingkat pemanfaatan kapasitas kendaraan.

$$Load\ Ratio = \frac{Berat}{Kapasitas} \quad (2)$$

Dataset dibagi menjadi 80% data pelatihan dan 20% data validasi. Data pelatihan digunakan untuk membangun model Transformer Autoencoder, sedangkan data validasi digunakan memantau proses pembelajaran serta untuk membantu dalam menentukan ambang batas (*threshold*) *anomaly score*. Rincian fitur yang digunakan dalam penelitian ini dapat dilihat pada Tabel 2.

Tabel 2. Fitur yang digunakan

Kelompok Fitur	Atribut
Fitur Kendaraan	Tipe Unit, Merek Tipe, Usia Kendaraan, Kapasitas Kendaraan

Fitur Pesanan	Nama Item, Berat Muatan, Hari Pengiriman, Latitude, Longitude
---------------	---

2.1.2 Embedding dan Transformer Encoder

Data yang telah melalui proses *preprocessing*, seperti standarisasi pada fitur numerik dan *label encoding* pada fitur kategorikal, terlebih dahulu diubah menjadi representasi vektor. Fitur kategorikal seperti tipe unit, merk tipe, serta nama item diproses menggunakan *categorical embedding*, sedangkan untuk fitur numerik seperti *load ratio*, kapasitas serta koordinat Lokasi diproses menggunakan *numerical embedding*. Seluruh representasi ini selanjutnya digabung serta diproses oleh Transformer Encoder menggunakan mekanisme *self-attention*. Menurut Min et al [8], arsitektur Transformer memanfaatkan mekanisme *self-attention* untuk memodelkan hubungan antar fitur tanpa bergantung pada pemrosesan data secara berurutan (*recurrent processing*). Encoder memetakan urutan input kedalam representasi *continue* sedangkan decoder menggunakan representasi ini bersama dengan urutan *output* [9]. Melalui mekanisme ini, setiap fitur dapat mempelajari dependensi global terhadap fitur lainnya sehingga mampu menghasilkan representasi yang lebih informatif [5]. Persamaan terkait mekanisme *self-attention* dapat dilihat pada persamaan 3 berikut ini:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (3)$$

Pada tahap ini model mempelajari hubungan antar fitur, seperti kesesuaian antara jenis kendaraan, kapasitas unit, dan berat muatan [10]. Hasil dari proses ini berupa *latent representation*, yaitu representasi yang menggambarkan karakteristik operasional logistik yang normal. Secara matematis, proses pemetaan fitur oleh *encoder* ini dapat dirumuskan seperti Persamaan 4:

$$z = f_0(x) \quad (4)$$

Dimana, x merupakan data masukan, z merupakan *latent representation*, serta f_0 merupakan fungsi *encoder*.

2.1.3 Rekonstruksi Data Menggunakan Dual Decoder

Pada tahap ini, proses rekonstruksi bertujuan untuk menghasilkan data keluaran yang sedekat mungkin dengan data aslinya. Representasi laten (*Latent representation*) yang telah diperoleh sebelumnya digunakan untuk merekonstruksi kembali data masukan melalui dua buah decoder. Dalam arsitektur *autoencoder*, *latent representation* berfungsi sebagai media penyimpanan informasi sebelum dilakukan proses rekonstruksi oleh *decoder* [10]. Secara spesifik, *numerical decoder* bertugas merekonstruksi fitur-fitur numerik, sedangkan untuk *categorical decoder* bertugas untuk merekonstruksi fitur kategorikal. Secara matematis untuk fungsi *decoder* dapat dilihat pada persamaan 5 berikut ini:

$$\hat{x} = g\phi(z) \quad (5)$$

Dimana, z merupakan latent representation, $\hat{x}$ merupakan hasil rekonstruksi dan untuk $g\phi$ merupakan fungsi *decoder*.

2.1.4 Pelatihan Model

Model Transformer Autoencoder digunakan untuk mempelajari pola operasional kendaraan yang normal berdasarkan data historis operasional logistik PT XYZ. Model ini menggabungkan mekanisme Transformer encoder untuk mempelajari representasi data tabular serta Autocoder untuk melakukan proses rekonstruksi data.

Pada penelitian ini, model dilatih menggunakan data riwayat order tahun 2023 yang telah melalui tahap *preprocessing* dan *feature engineering*. Dataset yang digunakan terdiri dari atribut kategorikal dan numerik yang merepresentasikan karakteristik kendaraan, karakteristik muatan, Lokasi penjemputan serta pengalaman pengemudi. Pada penelitian ini, dalam pelatihan model parameter yang digunakan dapat dilihat pada Tabel 2.1

Tabel 2.1 Parameter Pelatihan Model

No	Parameter	Nilai
1	Batch Size	256
2	Epoch	15
3	Optimizer	Adamw
4	Learning Rate	0.001
5	Loss Function	Mean Squared Error (MSE) & Cross-Entropy (CE)
6	Embedding Dimension	32

7	Transformer Layers	3
8	Attention Heads	4
9	Latent Dimension	16

2.1.5 Perhitungan *Reconstruction Error* dan *Anomaly Score*

Anomali detection merupakan sistem AI yang digunakan untuk mencari data yang tidak wajar atau menyimpang dari pola biasanya. Sistem ini banyak diterapkan di beberapa industri seperti manufaktur, keamanan siber, serta keuangan. Dalam dunia nyata penerapan deteksi *anomaly* tidaklah mudah, hal ini karena terdapat beberapa kondisi seperti ketidakseimbangan data yang tersedia, serta ketiadaan label (Unanntated data) [11].

Selama proses pelatihan, model menghitung *reconstruction error* sebagai ukuran perbedaan antara data asli dengan hasil rekonstruksi. Nilai ini diperoleh dari kombinasi antara *Mean Squared Error* (MSE) untuk fitur numerik dan *Cross Entrophy Loss* (CE) untuk fitur kategorikal. Kedua nilai *loss* ini digunakan untuk memperbaharui bobot jaringan sehingga kemampuan model dalam merekonstruksi data normal terus meningkat.

Pada tahap deteksi *anomaly*, suatu data dapat dikategorikan sebagai *anomaly* apabila nilai *reconstruction error* melebihi nilai ambang batas (*threshold*) yang telah ditentukan. Dalam menentukan *threshold* ini bisa menggunakan beberapa pendekatan seperti distribusi gaussian, metode berbasis persentil maupun penyesuaian dinamis berdasarkan data validasi. Persamaan 6 merupakan bentuk persamaan dari MSE :

$$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2 \quad (6)$$

Pada Persamaan 5, x_i merepresentasikan data operasional asli, sedangkan untuk $\hat{x}_i$ merupakan data hasil rekonstruksi yang dihasilkan oleh Transformer Autoencoder. Nilai MSE digunakan untuk mengukur *reconstruction error* antara data asli dan data hasil rekonstruksi tersebut. Semakin besar nilai *reconstruction error* yang didapat, maka semakin besar juga tingkat penyimpangan data yang terjadi terhadap pola operasional normal yang telah dipelajari model [12].

Setelah proses pelatihan selesai, model digunakan untuk mengevaluasi setiap kandidat kombinasi kendaraan dan pengiriman. Pada tahap ini, *reconstruction error* dari setiap data dijadikan sebagai *anomaly score*. Kombinasi yang memiliki karakteristik yang sama dengan pola operasional normal akan menghasilkan *anomaly score* yang rendah. Sedangkan, untuk kombinasi yang tidak sesuai seperti kapasitas kendaraan yang tidak sebanding dengan muatan atau karakteristik operasional yang menyimpang dari data historis, akan menghasilkan *anomaly score* yang lebih tinggi. *Reconstruction error* dapat dihitung menggunakan kuadrat frobenius norm antara data asli dan data hasil rekonstruksi, yang dapat dilihat pada persamaan 7 berikut ini:


$$L_{AE}(X, x') = \min(\|x - x'\|_F^2) \quad (7)$$

Dimana L_{AE} merupakan nilai *reconstruction loss*, x mewakili data masukan asli, dan x' Adalah data hasil rekonstruksi.

2.2. Perancangan Algoritma Genetika

Algoritma genetika merupakan algoritma yang digunakan untuk pencarian yang didasarkan pada teori evolusi dan seleksi alam. Algoritma genetika memiliki sifat mencari segala kemungkinan dari solusi agar bisa mendapatkan yang paling optimal untuk menyelesaikan masalah yang ada [13]. Selain itu algoritma genetika sangat efektif dalam pencarian global, karena algoritma genetika tidak banyak melakukan perhitungan matematis dalam menyelesaikan masalah[14].

Pada penelitian ini algoritma genetika digunakan sebagai optimasi dalam menentukan kendaraan yang paling sesuai dengan kebutuhan pengiriman muatan. Algoritma genetika memanfaatkan nilai *anomaly score* yang telah dihasilkan dari Transformer Autoencoder sebagai salah satu komponen utama pada fungsi *fitness*. Selain itu, proses evaluasi juga akan mempertimbangkan jarak kendaraan terhadap Lokasi pickup serta kesesuaian kapasitas kendaraan dengan berat muatan. Berikut ini Adalah beberapa tahapan atau proses yang dilakukan pada Algoritma Genetika yang dapat dilihat pada Gambar 2.1



Gambar 2.1 Flowchart Algoritma Genetika

2.2.1 Pembentukan Kandidat Solusi

Sistem dimulai dengan mengambil data pesanan barang serta daftar unit kendaraan yang akan digunakan. Selain itu terkait pencarian kombinasi terbaik antara pesanan dengan unit kendaraan, perlu adanya proses pengujian terhadap semua kemungkinan pasangan antara pesanan dan truk menggunakan model Transformer Autoencoder yang sudah dilatih sebelumnya.

2.2.2 Konfigurasi Parameter *Genetic Algorithm*

Sebelum proses optimasi dimulai, Algoritma Genetika memerlukan penetapan hyperparameter yang digunakan untuk mengatur jalannya proses pencarian Solusi. Pada penelitian ini, nilai hyperparameter ditentukan secara empiris agar

proses pencarian mampu menyeimbangkan eksplorasi Solusi baru serta pemanfaatan Solusi terbaik yang telah ditemukan, sehingga dapat mengurangi kemungkinan algoritma berhenti pada Solusi lokal (*local optimum*). Untuk konfigurasi parameter yang digunakan dapat dilihat pada Tabel 2.2

Tabel 2.2 *Parameter Genetic Algorithm*

Parameter	Nilai
Jumlah Generasi	50
Parent Mating	4
Solusi per populasi	20
Jumlah Gen	1
Crossover	Single point
Mutation	Random Mutation
Mutation rate	20%

Pada Tabel 2.2 hiperparameter yang digunakan meliputi ukuran populasi sebanyak 20 individu, probabilitas mutasi sebesar 20%, dan jumlah generasi maksimum sebanyak 50 generasi. Seluruh parameter tersebut ditetapkan sebelum pembentukan populasi awal dan digunakan sebagai konfigurasi dasar selama proses optimasi berlangsung.

2.2.3 Inisialisasi *Genetic Algorithm*

Pada tahap ini, Algoritma Genetika diinisialisasi dengan menentukan parameter optimasi, seperti ukuran populasi (*population size*), jumlah maksimum generasi (*maximum generation*), probabilitas *crossover* dan probabilitas *mutation*. Selanjutnya, populasi awal dibentuk secara acak yang terdiri atas sejumlah kromosom, di mana setiap kromosom merepresentasikan satu alternatif Solusi alokasi kendaraan untuk seluruh pesanan pada periode pengiriman tertentu [15]. Representasi kromosom yang digunakan dalam penelitian ini dapat dilihat pada persamaan 8.

$$V_i = [g_1, g_2, g_3 \dots g_N], 1 \leq i \leq P \quad (8)$$

Dimana V_i merupakan kromosom ke- i , g_j merupakan gen ke- j yang merepresentasikan kendaraan yang dialokasikan pada pesanan ke- j . N merupakan jumlah pesanan (order) yang akan dialokasikan serta P merupakan ukuran populasi (*population size*).

2.2.4 Tahap Perputaran Evolusi

Pada tahap ini merupakan proses *looping* yang digunakan untuk memperbaiki kualitas kombinasi muatan dengan unit kendaraan sampai batas putaran maksimal tercapai.

a. Evaluasi *Fitness*

Pada tahap ini setiap kombinasi muatan dan unit kendaraan dinilai melalui dua lapis filter, yaitu pemeriksaan syarat mutlak (hard constraint) serta perhitungan nilai *fitness*.

Pada tahap pertama, sistem memeriksa apakah kandidat memenuhi batas operasional yang telah ditentukan. Apabila nilai LoadRatio lebih dari 1.0 yang menunjukkan kondisi *overload*, atau *anomaly score* melebihi ambang batas 0.0897, maka kandidat tersebut langsung dianggap tidak layak dan diberikan penalty dengan nilai fitness sebesar -9999. Mekanisme ini dilakukan untuk mengelemenisi kandidat yang tidak memenuhi persyaratan operasional sebelum proses optimasi dilakukan.

Kandidat yang lolos tahap pertama selanjutnya dievaluasi pada tahap kedua menggunakan fungsi *fitness*. Pada tahap ini, nilai *fitness* dihitung dengan metode Weighted sum yang menggabungkan tiga kriteria utama, yaitu *anomaly score*, jarak kendaraan menuju Lokasi penjemputan, dan kapasitas kendaraan. Ketiga kriteria ini digunakan secara bersamaan untuk menilai kualitas setiap kandidat sehingga algoritma dapat memilih Solusi alokasi unit yang paling optimal. Persamaan fungsi *fitness* yang digunakan dapat dilihat pada persamaan 9.

$$Fitness = (w_1 * A') + (w_2 * J') + (w_3 * K') \quad (9)$$

Pada persamaan (7), variable A' , J' , dan K' merupakan nilai anomaly score, jarak penjemputan, dan Tingkat pemanfaatan kapasitas unit yang telah dinormalisasi sehingga seluruh variable berada pada skala yang sama.

Pada penelitian ini, bobot ditetapkan sebesar 0.6 untuk *anomaly score*, 0.2 untuk jarak penjemputan dan 0.2 untuk Tingkat pemanfaatan kapasitas unit. Komposisi ini mencerminkan prioritas utama penelitian, yaitu meminimalkan

risiko anomaly operasional tanpa mengabaikan efisiensi jarak tempuh dan pemanfaatan kapasitas kendaraan. Dengan demikian, algoritma genetika akan memilih kandidat unit yang memiliki nilai *fitness* terbaik berdasarkan keseimbangan ketiga kriteria tersebut.

b. Elitism (Jalur pintas untuk mendapatkan Solusi terbaik)

Kombinasi yang memiliki nilai paling tinggi atau paling efisien akan langsung diamankan dan dipindahkan ke genasi berikutnya tanpa diubah-ubah. Mekanisme ini dilakukan untuk mencegah hilangnya Solusi optimal yang telah ditemukan dan memastikan proses optimasi berlangsung dengan stabil.

c. *Selection*, *Crossover*, dan *Mutation*

Untuk sisa kombinasi lain yang kurang optimal akan masuk pada proses seleksi. Pada *selection* terdapat proses pemilihan kromosom-kromosom yang akan dipertahankan pada populasi selanjutnya [13]. *Crossover* merupakan salah satu operator utama dalam algoritma genetika yang digunakan untuk menghasilkan individu baru (*offspring*) yang dilakukan dengan cara menggabungkan informasi genetik dari dua individu (*parent*) [13]. Proses ini dilakukan bertujuan untuk melahirkan alternatif kombinasi baru yang lebih efektif dan efisien. Berikut ini adalah persamaan dari proses *crossover* yang dapat dilihat pada persamaan 10 [16]

$$x'_i = \text{crossover}(x_i, x_j) \quad (10)$$

Dimana x_i dan x_j merupakan individu induk (*parent*), sedangkan x'_i merupakan individu baru (*offspring*) yang dihasilkan dari proses *crossover*.

Mutation merupakan proses perubahan secara acak pada satu atau beberapa gen dalam individu untuk menjaga keberagaman populasi serta juga dapat mencegah algoritma terjebak pada Solusi lokal. Persamaan dari *mutation* dapat dilihat pada persamaan 11 [16]

$$x'_i \rightarrow \text{mutate}(x'_i) \quad (11)$$

d. Pembentukan Populasi Baru

Hasil dari jalur Elitism dan hasil pengecekan baru digabungkan kembali untuk diuji pada putaran selanjutnya.

2.2.5 Tahap Pengambilan Keputusan Akhir

Setelah proses evolusi selesai, kromosom dengan nilai fitness tertinggi dipilih sebagai rekomendasi alokasi kendaraan. Apabila tidak terdapat kromosom yang memenuhi batas minimum *fitness*, sistem menyatakan bahwa tidak tersedia kendaraan yang layak untuk melayani pesanan tersebut.

3. HASIL DAN PEMBAHASAN

3.1 Rekayasa Fitur dan Pemrosesan Data

Keberhasilan model Transformer Autoencoder dalam mengenali anomaly sangat bergantung pada kualitas dari representasi data. Oleh karena itu, tahapan pemrosesan difokuskan pada *feature engineering* melalui pembentukan *variable* turunan baru yang bernama LoadRatio. Nilai ini diperoleh dari pembagian antara parameter berat muatan actual dengan kapasitas unit kendaraan.

Untuk mengevaluasi tingkat efektivitas dari pengguna fitur Load_Ratio dalam operasional logistik, maka dilakukan simulasi alokasi kendaraan berupa pengiriman komoditas garam seberat 25.000 Kg pada hari senin. Pesanan ini nantinya akan dicocokkan dengan kandidat unit yang tersedia, berikut adalah hasilnya dapat dilihat pada Tabel 3.

Tabel 3. Rekayasa fitur rasio muatan

No.	IdUnit	KapasitasKG	LoadRatio	Anomaly Score
1	TRK-00005822	25000	1.000	0.014051
2	TRK-00001402	25000	1.000	0.016565
3	TRK-00002086	25000	1.000	0.035075
4	TRK-00005620	8000	3.125	8.253610


Dari Tabel 3. terlihat bahwa fitur LoadRatio terbukti secara signifikan memandu model Transformer Autoencoder dalam mengidentifikasi batasan kapasitas fisik unit kendaraan. Pada tiga kandidat kendaraan (TRK-00005822, TRK-00001402, TRK-00002086) memiliki kapasitas 25.000 Kg, dengan rasio muatan ideal yaitu 1.000. Sehingga jika dilihat pada nilai *anomaly score* yang muncul pada ketiga unit tersebut, menghasilkan nilai anomaly yang rendah.

Sebaliknya, sistem mendeteksi anomaly yang terjadi pada TRK-00005620. Yang mana truk yang berkapasitas 8.000 Kg disimulasikan untuk memuat pesanan 25.000 Kg, akan menghasilkan LoadRatio sebesar 3.125. Saat nilai ini diproses, akan menghasilkan

nilai anomaly yang tinggi. Nilai *anomaly* yang tinggi ini, menandakan bahwa model mampu mengenali kondisi ketika muatan melebihi kapasitas kendaraan. Kondisi tersebut ditandai dengan nilai LoadRatio yang lebih besar dari 1, sehingga model memberikan skor anomaly yang tinggi karena dianggap sebagai pelanggaran terhadap kapasitas kendaraan.

3.2 Evaluasi Kinerja Transformer Autoencoder

Berdasarkan grafik *training loss* dan *validation loss* yang ada pada Gambar 3, terlihat bahwa model mengalami penurunan *loss* yang signifikan pada beberapa *epoch* awal. Nilai *training loss* menurun dari sekitar 2.045 pada *epoch* pertama menjadi sekitar 0.03 pada *epoch* ke 15. Selain itu untuk nilai *validation loss* juga mengalami penurunan dari sekitar 0.4727 menjadi 0.0214.



Gambar 3. Grafik training loss dan validation loss

Penurunan nilai *loss* yang konsisten menandakan bahwa model telah berhasil mempelajari pola operasional normal yang terdapat pada data historis Perusahaan. Pada *epoch* awal, model mempelajari hubungan dasar antar fitur, sedangkan pada *epoch* selanjutnya model mulai menyempurnakan *latent representation* yang dihasilkan sehingga mampu merekonstruksi data dengan tingkat kesalahan yang semakin rendah.

Jarak antara *training loss* dan *validation loss* relatif kecil selama proses pelatihan. Kondisi ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting* terhadap data pelatihan. *Validation loss* cenderung lebih rendah dibandingkan *training loss* juga masih berada dalam batas yang

wajar karena penggunaan mekanisme *dropout* pada transformer *encoder* selama proses pelatihan.

Secara keseluruhan, dapat dilihat bahwa hasil pelatihan dari Transformer Autoencoder telah berhasil mengenali pola operasional dengan baik. Sehingga selanjutnya model bisa digunakan untuk tahap perhitungan *reconstruction error* dan *anomaly score*.

3.3 Deteksi Anomali dan Penentuan Ambang Batas (*Threshold*)

Setelah model Transformer Autoencoder mencapai kondisi yang stabil, tahap selanjutnya yaitu menghitung nilai *reconstruction error* dari setiap data. Nilai *reconstruction error* digunakan sebagai *anomaly score* untuk mengukur Tingkat kesesuaian suatu alokasi unit kendaraan terhadap pola operasional yang telah dipelajari oleh model. Semakin kecil nilai *anomaly score*, maka semakin sesuai alokasi unit dengan pola historis yang ada. Namun, sebaliknya nilai *anomaly score* yang tinggi menandakan bahwa terdapat adanya penyimpangan, seperti ketidaksesuaian kapasitas kendaraan terhadap muatan atau terdapat pemilihan tipe kendaraan yang belum tepat.

Distribusi dari *anomaly score* pada seluruh data latih dianalisis menggunakan nilai persentil untuk menentukan batas antar alokasi yang masih dianggap normal dan yang berpotensi anomaly. Hasil perhitungannya dapat dilihat pada Tabel 3.1

Tabel 3.1 Hasil perhitungan persentil

No.	Persentil	Nilai
1	P95	0.04042371
2	P99	0.08971217
3	P99.9	0.26611838

Berdasarkan hasil yang diperoleh pada Tabel 3.1, penelitian ini menetapkan persentil ke-99 (P99) sebesar 0.0897 sebagai *hard constraint threshold*. Pemelihan nilai ini didasarkan pada karakteristik dari distribusi anomaly score, yaitu adanya peningkatan yang cukup signifikan dari P99 (0.0897) ke P99.9 (0.2661). Kondisi ini menunjukkan bahwa sekitar 1% data dengan *anomaly score* tertinggi dengan memiliki Tingkat penyimpangan yang jauh lebih besar dibandingkan mayoritas data lainnya, sehingga dikategorikan sebagai kandidat *anomaly*.

3.4 Optimasi Alokasi Unit Kendaraan Menggunakan Algoritma Genetika

Pengujian dilakukan menggunakan data order baru dengan karakteristik sebagai berikut:

Tabel 3.2 Data Baru

Parameter	Nilai
Nama Barang	Solar
Berat Muatan	13280
Hari Pengiriman	Minggu

Pada Tabel 3.2 merupakan contoh data baru yang digunakan pada saat pengujian. Dimana terdapat muatan solar dengan berat 13280. Selanjutnya sistem melakukan evaluasi terhadap kandidat kendaraan yang tersedia. Untuk setiap kendaraan dihitung *anomaly score* menggunakan transformer autoencoder yang selanjutnya digunakan sebagai input pada proses optimasi di Algoritma Genetika. Untuk kandidat yang terdapat pada pesanan ini terdapat 6 buah unit kendaraan dengan spesifikasi sebagai berikut:

No	IdUnit	TipeUnit	MerkTipe	Kapasitas	Usia	Pengalaman Driver	Jarak
1	TRK-00002086	Wing Box	Hino Wings Box FL 235 JW + Karoseri (ACE)	25000	6	5	1
2	TRK-00005620	Tanker 8 kL	RENTAL Hino Dutro 130 HD	8000	4	3	1
3	TRK-00000612	Tanker 32 kL	Hino Ranger. FM 285 TH	32000	8	5	3
4	TRK-00005715	Tanker 16 kL	RENTAL Hino Ranger FL 235 JN	13280	2	4	3
5	TRK-00005822	Wing Box	Hino Wings Box FL 235 JW + Karoseri (Antika)	25000	3	5	2

Berdasarkan hasil optimasi yang diperoleh, Algoritma Genetika berhasil memilih kendaraan kendaraan yang memiliki kombinasi terbaik antara tingkat kesesuaian operasional, jarak kendaraan, dan kapasitas angkut.

Integrasi *anomaly score* dari Transformer Autoencoder dapat memungkinkan proses optimasi tidak hanya mempertimbangkan faktor jarak, tetapi juga mempertimbangkan kesesuaian kendaraan terhadap pola historis operasional Perusahaan. Dengan demikian kendaraan yang dipilih tidak hanya dekat dengan Lokasi

pickup, tetapi juga memiliki karakteristik yang paling sesuai dengan kebutuhan pengiriman. Hasil dari optimasi dapat dilihat pada Tabel 3.3

Tabel 3.3 Hasil Optimasi

Id Unit	Anomaly Score	Distance Km	Kapasitas	Fitness Score
TRK-00005715	0. 041116	1	25000	0. 826305

4. KESIMPULAN

Berdasarkan hasil perancangan, pengujian, dan analisis efektivitas sistem alokasi unit kendaraan logistik menggunakan pendekatan *hybrid* Transformer Autoencoder dan Algoritma Genetika, maka dapat ditarik kesimpulan utama untuk menjawab rumusan masalah yang ada dalam penelitian ini :

- Model Transformer Autoencoder terbukti mampu mengekstrak aturan operasional secara mandiri tanpa memerlukan pemograman konvensional atau yang sering disebut dengan rule-based. Melalui rekayasa load ratio serta ekstraksi Latent space, model berhasil mendeteksi ketidakwajaran operasional, seperti tipe unit yang tidak sesuai serta ketidaksesuaian berat muatan dengan kapasitas kendaraan.
- Berdasarkan distribusi anomaly score, telah diperoleh ambang batas (*threshold*) pada persentil ke-99 (P99) sebesar 0.0897. Nilai ini digunakan sebagai *hard constraint threshold* untuk bisa membedakan kendaraan yang masih sesuai dengan pola historis dan kendaraan yang memiliki tingkat anomali yang tinggi. Dengan adanya batas ini, proses penyaringan kandidat unit kendaraan dapat dilakukan dengan lebih objektif berdasarkan hasil pembelajaran model.
- Algoritma genetika berhasil digunakan untuk memilih kandidat unit kendaraan terbaik berdasarkan beberapa kriteria, yaitu *anomaly score*, jarak menuju lokasi pengambilan muatan, serta pemanfaatan kapasitas kendaraan. Melalui fungsi *fitness* yang telah dirancang, sistem mampu memberikan rekomendasi kendaraan yang tidak hanya efisien tetap juga mampu memenuhi persyaratan operasional.
- Integrasi antara Transformer Autoencoder dengan Algoritma genetika dapat menghasilkan sistem yang mampu menyaring kandidat unit kendaraan sebelum proses optimasi dilakukan. Selain itu penerapan *hard constraint* dan *fail safe* dapat memungkinkan sistem menolak kandidat unit kendaraan yang tidak

memenuhi persyaratan operasional. Apabila seluruh kendaraan tidak layak, maka sistem tidak memberikan rekomendasi unit kendaraan sehingga keputusan yang dihasilkan tetap memperhatikan aspek keamanan dan kelayakan operasional.

5. DAFTAR PUSTAKA

- [1] M. T. Sembiring, N. Zuya, M. R. A. Laksmiana, and M. Z. Hadi, "Optimization of Delivery Allocation for Enhanced Fleet Utilization and Trip Minimization: A Case Study from an Indonesian Manufacturing Company," MDPI AG, Jun. 2025, p. 37. doi: 10.3390/engproc2025097037.
- [2] Q. S. Nur and S. Tedjo, "Analisa Optimalisasi Rute Distribusi Untuk Mengefisiensikan Logistik Menggunakan Algoritma Genetika," *Jurnal Manajemen & Teknik Industri – Produksi*, vol. XXV, no. 1, pp. 67–78, Sep. 2024, doi: 10.350587/Matrik.
- [3] H. Luo, J. Wei, S. Zhao, A. Liang, Z. Xu, and R. Jiang, "Intelligent logistics management robot path planning algorithm integrating transformer and GCN network," *ArXiv*, pp. 1–21, Jan. 2025, doi: 10.48550.
- [4] G. Somepalli, M. Goldblum, A. Schwarzschild, C. B. Bruss, and T. Goldstein, "SAINT: Improved Neural Networks for Tabular Data via Row Attention and Contrastive Pre-Training," Jun. 2021, [Online]. Available: <http://arxiv.org/abs/2106.01342>
- [5] D. Huang, "Design of an Anomaly Detection Model for Logistics Orders Based on Transformer Algorithms," in *Proceedings - 2025 3rd International Conference on Logistics Engineering, Supply Chain and Digital Transformation, LESCDT 2025*, Institute of Electrical and Electronics Engineers Inc., 2025, pp. 46–50. doi: 10.1109/LESCDT66758.2025.00017.
- [6] S. Parekh, H. Nemlekar, and D. P. Losey, "Towards balanced behavior cloning from imbalanced datasets," *Auton. Robots*, vol. 50, no. 1, Mar. 2026, doi: 10.1007/s10514-025-10237-0.
- [7] S. Prakash, "Hybrid Ensemble Learning for Anomaly Detection in Metaverse Transactions Using Isolation Forest, Autoencoder, and XGBoost," *International Journal Research on Metaverse*, vol. 3, no. 1, pp. 64–80, Jan. 2026, doi: 10.47738/ijrm.v3i1.46.

- [8] E. Min *et al.*, “Transformer for Graphs: An Overview from Architecture Perspective,” *ArXiv*, Feb. 2022, [Online]. Available: <http://arxiv.org/abs/2202.08455>
- [9] P. Singh and B. Raman, “Transformer Architectures,” in *Deep Learning Through the Prism of Tensors*, P. Singh and B. Raman, Eds., Singapore: Springer Nature Singapore, 2024, pp. 303–367. doi: 10.1007/978-981-97-8019-8_6.
- [10] K. Berahmand, F. Daneshfar, E. S. Salehi, Y. Li, and Y. Xu, “Autoencoders and their applications in machine learning: a survey,” *Artif. Intell. Rev.*, vol. 57, no. 2, Feb. 2024, doi: 10.1007/s10462-023-10662-6.
- [11] J. C. Huskisson, J. Grobler, and A. H. Basson, “Feature Tokeniser-Transformer Autoencoders for Interpretable Tabular Anomaly Detection,” in *Lecture Notes in Computer Science*, Springer Science and Business Media Deutschland GmbH, 2026, pp. 256–268. doi: 10.1007/978-3-032-05176-9_20.
- [12] M. F. Hasan, M. J. Hasan, M. Sayem, M. Z. Alam, and T. Ahmed, “A transformer autoencoder-based anomaly detection system for intra-vehicular networks,” *SPIE-Intl Soc Optical Eng*, Jan. 2026, p. 9. doi: 10.1117/12.3095232.
- [13] A. Tohari and Y. P. Astuti, “PENERAPAN ALGORITMA GENETIKA DALAM MENENTUKAN RUTE TERPENDEK PT. POS CABANG LAMONGAN,” 2023.
- [14] A. S. Fauziah, I. Cholissodin, and B. Rahayudi, “Optimasi Pendistribusian Air Mineral menggunakan Algoritma Genetika,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 2, pp. 966–972, Feb. 2022, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [15] E. Yulia Sari, T. Rahmawati, and Vr. Bayu Kurniawan, “Pemodelan Sistem Cerdas untuk Pemetaan dan Pendistribusian Bantuan dengan Algoritma Genetika,” vol. 18, no. 1, pp. 123–133, Jul. 2025, [Online]. Available: <https://journal.stekom.ac.id/index.php/elkom>
- [16] G. Li, L. Zhang, F. Zhang, and W. Xu, “VLGA: A Chaos-Enhanced Genetic Algorithm for Optimizing Transformer-Based Prediction of Infectious Diseases,” *Mathematics*, vol. 13, no. 24, Dec. 2025, doi: 10.3390/math13243908.