

Sistem Prediksi Tingkat Keamanan Objek pada Area *Blind spot* Unit *Forklift* Menggunakan *Artificial Neural Networks* dengan Dua Skenario

M Rifqi Setiawan¹, Tegar Prasetyo², Agustinus Winarno³, Harjono¹, Irfan Bahiuddin^{4*}

^{1,2,3,4}Departemen Teknik Mesin, Sekolah Vokasi, Universitas Gadjah Mada, Yogyakarta, 55281, Indonesia
irfan.bahiuddin@ugm.ac.id

Abstrak

Forklift merupakan peralatan yang digunakan di sektor konstruksi dan industri, namun pengoperasiannya memiliki risiko kecelakaan yang tinggi, terutama pada area *blind spot* yang tidak dapat dijangkau oleh pandangan operator. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem prediksi tingkat keamanan objek pada area *blind spot* guna meningkatkan keselamatan operasional. Metode yang digunakan menggabungkan pendekatan logika *fuzzy* dan *machine learning* berbasis *Artificial Neural Networks* (ANN). Dataset dibuat menggunakan program Python dengan logika *fuzzy* dan sistem berbasis sensor, dengan parameter input berupa jarak (0–300 cm), sudut (0°–180°), dan posisi kemudi (0°–180°). Tingkat keamanan diklasifikasikan menjadi tiga kategori, yaitu aman, waspada, dan bahaya. Model ANN yang digunakan adalah arsitektur *feed-forward* dengan variasi parameter pelatihan. Hasil penelitian menunjukkan bahwa konfigurasi optimal diperoleh pada 4 *hidden layer*, 100 *hidden node*, 1500 *epoch*, dengan algoritma pelatihan Adam. Model yang dihasilkan mampu memberikan performa yang baik berdasarkan metrik evaluasi *precision*, *recall*, dan *F1-score*. Temuan ini menunjukkan bahwa integrasi logika *fuzzy* dan ANN efektif dalam memprediksi tingkat keamanan pada area *blind spot forklift*. Pendekatan ini berpotensi untuk dikembangkan lebih lanjut dalam sistem pemantauan keselamatan berbasis *real-time* pada kendaraan industri.

Kata kunci: *Blind spot*, *fuzzy*, jaringan saraf tiruan, klasifikasi keamanan, *forklift*.

Abstract

Forklifts are widely used in the construction and industrial sectors; however, their operation involves a high risk of accidents, particularly in *blind spot* areas that are not visible to the operator. Therefore, this study aims to develop a safety level prediction system for objects in *forklift blind spot* areas to improve operational safety. The proposed method integrates a fuzzy logic approach with machine learning based on *Artificial Neural Networks* (ANN). The dataset was generated using a Python program with fuzzy logic and a sensor based-system, with input parameters including distance (0–300 cm), angle (0°–180°), and steering position (0°–180°). The safety level is classified into three categories: safe, caution, and danger. The ANN model employs a *feed-forward* architecture with variations in training parameters. The results indicate that the optimal configuration is achieved with 4 hidden layers, 100 hidden nodes, 1500 epochs, and the Adam optimization algorithm. The developed model demonstrates strong performance based on *precision*, *recall*, and *F1-score* evaluation metrics. These findings indicate that the integration of fuzzy logic and ANN is effective in predicting safety levels in *forklift blind spot* areas. This approach has the potential to be further developed into a *real-time* safety monitoring system for industrial vehicles.

Keywords: *Blind spot*, *fuzzy*, artificial neural network, safety classification, *forklift*.

I. PENDAHULUAN

Forklift merupakan salah satu alat bantu penanganan material yang banyak digunakan untuk mengangkat serta memindahkan barang di gudang,

pusat distribusi, maupun fasilitas manufaktur, sehingga dapat mengurangi beban kerja manusia [1]. Penggunaan *forklift* juga berperan dalam meningkatkan efisiensi operasional pada proses pemindahan material [2]. Namun demikian, dalam

pengoperasiannya terdapat area tertentu yang tidak berada dalam jangkauan pandangan operator, yang dikenal sebagai *blind spot*. Menurut [3], [4], *blind spot* merupakan wilayah yang berada di luar bidang pandang pengemudi. Penelitian [5] yang dilakukan pada forklift berukuran panjang 2,5 m, lebar 1,1 m, dan tinggi 2,0 m mengkaji area yang tidak terlihat oleh operator melalui pemindaian laser pada posisi sejajar dengan mata operator. Dalam pengujian tersebut, manusia dengan tinggi 1,8 m ditempatkan pada jarak 1 m di bagian depan dan belakang unit forklift. Hasil pemindaian menunjukkan bahwa visibilitas pada bagian depan hanya mencapai 57%, sedangkan pada bagian belakang sebesar 33%. Kondisi ini menunjukkan bahwa keterbatasan area pandang operator berpengaruh terhadap keselamatan operator maupun keamanan area pengoperasian. *The Bureau of Labor Statistics* (BLS) dan *Occupational Safety and Health Administration* (OSHA) menyatakan bahwa salah satu jenis kecelakaan *forklift* yang paling sering terjadi adalah tabrakan dengan material atau barang. Di Amerika Serikat, satu dari enam kecelakaan kerja berkaitan dengan *forklift*, dan hampir 80% kecelakaan *forklift* melibatkan pejalan kaki [1]. Data tersebut mengindikasikan bahwa kurangnya informasi operator terhadap keberadaan objek pada area *blind spot* dapat menimbulkan risiko serius terhadap keselamatan operasi *forklift* dan keamanan operator.

Perkembangan sistem deteksi *blind spot* pada kendaraan telah mengalami kemajuan melalui pemanfaatan berbagai teknologi sensor seperti radar, kamera, LiDAR, dan ultrasonik yang terintegrasi dalam sistem *Advanced Driver Assistance Systems* (ADAS). Sistem berbasis radar banyak digunakan karena mampu mendeteksi objek secara andal dalam berbagai kondisi cuaca serta memiliki kemampuan pengukuran kecepatan yang akurat, sehingga efektif untuk aplikasi *blind spot* monitoring pada kendaraan modern [6]. Di sisi lain, pendekatan berbasis kamera yang dikombinasikan dengan *deep learning* menawarkan kemampuan klasifikasi objek yang lebih kompleks dan kontekstual, seperti identifikasi pejalan kaki atau kendaraan, meskipun performanya sangat bergantung pada kondisi pencahayaan dan kualitas citra [7]. Teknologi LiDAR memberikan akurasi spasial tinggi hingga tingkat sentimeter, namun memiliki keterbatasan dari sisi biaya dan kompleksitas sistem, sehingga kurang ekonomis untuk aplikasi kendaraan konvensional.

Secara umum, pendekatan modern cenderung mengarah pada sensor fusion untuk meningkatkan keandalan sistem, namun hal ini meningkatkan kompleksitas komputasi dan biaya implementasi [8]. Sehingga, sensor ultrasonik tetap menjadi pilihan yang relevan, terutama untuk aplikasi jarak dekat,

karena memiliki keunggulan berupa biaya rendah, konsumsi daya kecil, serta kemampuan deteksi yang stabil pada kecepatan rendah dan lingkungan terbatas. Meskipun memiliki keterbatasan pada resolusi dan jangkauan deteksi dibandingkan radar atau LiDAR, ultrasonik tetap banyak digunakan dalam sistem keselamatan kendaraan, khususnya untuk area *blind spot* dan parking assistance, karena menawarkan *trade-off* yang optimal antara kinerja, biaya, dan kemudahan implementasi [9]. Oleh karena itu, pemanfaatan sensor ultrasonik yang dikombinasikan dengan pendekatan cerdas seperti *machine learning* menjadi solusi yang menarik untuk meningkatkan akurasi prediksi risiko dengan tetap mempertahankan efisiensi sistem.

Meskipun berbagai penelitian telah mengkaji sistem deteksi *blind spot* menggunakan sensor, sebagian besar pendekatan masih berfokus pada deteksi keberadaan objek tanpa memberikan informasi tingkat risiko secara kuantitatif. Selain itu, parameter yang digunakan umumnya terbatas pada jarak dan sudut objek terhadap kendaraan. Padahal, kondisi operasional *forklift* bersifat dinamis dan dipengaruhi oleh faktor lain, seperti posisi kemudi (*steering*), yang dapat memengaruhi arah pergerakan dan potensi bahaya.

Dengan demikian, terdapat kebutuhan untuk mengembangkan sistem yang tidak hanya mampu mendeteksi objek, tetapi juga dapat memprediksi tingkat keamanan secara lebih komprehensif dengan mempertimbangkan parameter tambahan yang relevan.

Berdasarkan permasalahan tersebut, penelitian ini mempunyai tujuan untuk mengembangkan sistem prediksi level keamanan objek pada area belakang, kanan, dan kiri atau titik *blind spot forklift* menggunakan pendekatan *Artificial Neural Networks* (ANN) [10]. Sistem yang diusulkan mengklasifikasikan tingkat keamanan menjadi beberapa klasifikasi yang terdiri dari aman (*safe*), waspada (*cautious*), dan berbahaya (*dangerous*), berdasarkan parameter jarak, sudut, dan posisi kemudi (*steering*).

Untuk mengevaluasi pengaruh variabel input terhadap kinerja model, penelitian ini menggunakan dua skenario, yaitu: (1) skenario dengan dua variabel input (jarak dan sudut), dan (2) skenario dengan tiga variabel input (jarak, sudut, dan posisi kemudi). Data diperoleh melalui sistem berbasis sensor ultrasonik dan aktuator servo sebagaimana telah digunakan pada penelitian sebelumnya [11].

Kontribusi utama penelitian ini terletak pada integrasi variabel posisi kemudi sebagai parameter tambahan dalam prediksi tingkat keamanan, yang diharapkan dapat meningkatkan akurasi prediksi serta memberikan informasi yang lebih representatif

terhadap kondisi operasional *forklift* pada area *blind spot*.

II. METODE PENELITIAN


Metode yang diusulkan terdiri dari alat deteksi *blind spot* dan *machine learning*. Pada penelitian ini deteksi *blind spot* terdiri dari dua komponen yaitu *controller box* dan *sensor box* yang digunakan untuk mencatat jarak dan sudut seperti yang sudah dilakukan [12], untuk alat deteksi *blind spot* dapat dilihat pada Gambar 1. *Machine learning* digunakan untuk menganalisis tingkat keamanan pada area *blind spot*. Data yang digunakan untuk machine learning terdiri dari dua skenario (S) seperti yang tertera pada Tabel 1.



Gambar 1. Sistem Deteksi *Blind spot*

Tabel 1. Skenario

S	Input	Output
S1	Jarak dan Sudut	Tingkat keamanan
S2	Jarak, sudut dan Posisi kemudi (<i>steering</i>)	Tingkat keamanan




Gambar 2. Ilustrasi Area Deteksi Objek

Mengacu pada penelitian yang telah dilakukan, parameter yang digunakan mencakup jarak dengan rentang 0–300 cm, sudut pengamatan 0°–180°, serta tingkat keamanan ditentukan berdasarkan nilai risiko dalam rentang 0–300 cm. Kategori jarak dibagi menjadi tiga kelompok, yaitu dekat pada rentang 0–100 cm, sedang pada rentang 101–200 cm, dan jauh pada rentang 201–300 cm. Sementara itu, sudut pengamatan diklasifikasikan menjadi tiga bagian,

yaitu sisi kiri dengan rentang 0°–30°, area belakang pada rentang 31°–149°, serta sisi kanan pada rentang 150°–180°. Tingkat keamanan kemudian dikelompokkan menjadi aman untuk rentang 0–100 cm, waspada untuk rentang 101–200 cm, dan bahaya untuk rentang 201–300 cm. Visualisasi area pendeteksian objek berdasarkan posisi dan tingkat kriteria bahaya disajikan pada Gambar 2.

A. Artificial Neural Networks (ANN)

Sistem prediksi tingkat keamanan objek pada area titik buta *forklift* dikembangkan dengan menggunakan metode *Artificial Neural Networks* (ANN). Tahap pelatihan dilakukan melalui pengaturan beberapa parameter, meliputi jumlah pengaturan beberapa parameter, meliputi jumlah *hidden layer*, jumlah *hidden node*, *epoch*, serta pemilihan algoritma pelatihan, seperti *Stochastic Gradient Descent* (SGD), RMSProp, Adagrad, Adadelta, Adamax, Nadam, dan Adam, untuk memperoleh akurasi terbaik [13]. Pada penelitian ini, ANN diimplementasikan dengan arsitektur *Feed Forward Neural Network* (FFNN). Rancangan arsitektur yang digunakan ditampilkan pada Gambar 3.



Gambar 3. Arsitektur (FFNN) S1

B. Data Training dan Data Testing

Data input untuk *machine learning* terdiri dari variasi jarak, sudut, posisi kemudi, dan tingkat keamanan. Dalam analisis tingkat keamanan ini, data perlu dibagi untuk keperluan analisis *machine learning*. Sebanyak 400 data digunakan dalam analisis ini, yang dibagi menjadi data latih, data validasi, dan data uji [14]. Rincian pembagian data dapat dilihat pada Tabel 2.

Tabel 2. Rasio Data

Jenis Data	Jumlah Data
Data Latih	70%
Data Uji	15%
Data validasi	15%

C. Evaluasi Sistem

Evaluasi sistem dilakukan untuk menilai kinerja model *machine learning*. Kinerja *machine learning* dievaluasi dengan menghitung metrik *precision*, *recall*, dan *F1-score* [15]. Rincian perhitungan dapat dilihat pada persamaan berikut:

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (3)$$

Dengan menggunakan metrik ini, dapat dinilai berbagai aspek kinerja model klasifikasi, termasuk kemampuan model dalam mengidentifikasi dengan tepat kelas positif dan negatif, serta seberapa efektif model dalam mengurangi kesalahan saat mengklasifikasikan data.

III. HASIL DAN PEMBAHASAN

Data untuk *machine learning* dalam penelitian ini menggunakan dua skenario. Skenario pertama dua variabel input, yaitu jarak dan sudut, skenario kedua menggunakan tiga variabel input, yaitu jarak, sudut, dan posisi kemudi (*steering*). Data yang digunakan untuk setiap skenario berjumlah 400 data. Dalam penelitian ini, dilakukan evaluasi ANN dengan melakukan perubahan jumlah *hidden layer*, *hidden node*, *epoch*, dan algoritma pelatihan untuk menentukan kombinasi yang memberikan akurasi terbaik dalam memprediksi tingkat keamanan.

A. Hidden Node

Variasi *hidden node* (HN) menghasilkan nilai *Mean Squared Error* (MSE) yang berbeda. Pengujian dengan algoritma pelatihan *Adam* pada dua skenario: jarak dan sudut (S1), jarak, sudut dan posisi kemudi (*steering*) (S2) dapat dilihat pada Gambar 4 dan 5. Gambar tersebut menunjukkan bahwa kenaikan jumlah *hidden node* cenderung menurunkan nilai MSE pada training dan testing. Hal ini menunjukkan bahwa semakin rendah jumlah *hidden node*, semakin rendah akurasi model ANN, dan sebaliknya, semakin tinggi jumlah *hidden node*, semakin tinggi akurasi model dalam memprediksi tingkat keamanan.

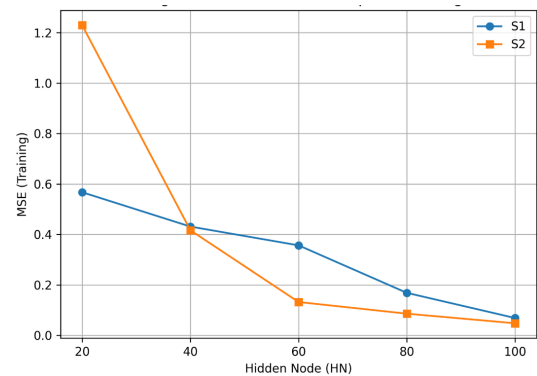
Gambar 4 dan 5 menunjukkan bahwa akurasi terbaik dicapai dengan 100 *hidden node*. Pada pelatihan, nilai MSE untuk tingkat keamanan adalah 0,0689 (jarak dan sudut) dan 0,480 (jarak, sudut, dan *steering*). Pada pengujian, nilai MSE adalah 0,9863

Tabel 3. F1- Score S1 dan S2 Berbagai Algoritma Pelatihan

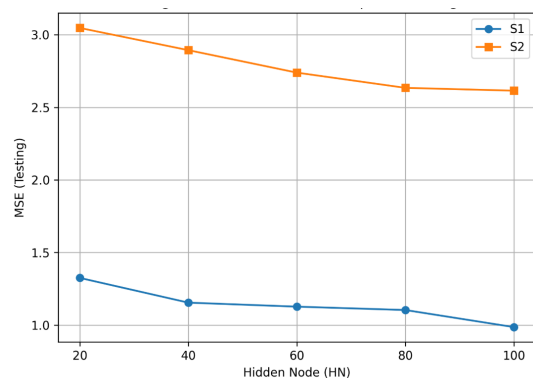
M	F1-score S1		F1-score S2	
	Train	Test	Train	Test
1	0,53	0,55	0,49	0,42
2	0,78	0,71	0,47	0,52
3	0,52	0,48	0,32	0,36
4	0,11	0,13	0,08	0,10
5	0,56	0,62	0,57	0,47
6	0,64	0,57	0,77	0,56
7	0,85	0,73	0,79	0,71

Tabel 4. Klasifikasi Kategori Tingkat Keamanan S1 dan S2

Skenario	Severity	Precision	Recall	f1-score
S1	Aman	0.75	1	0.88
	waspada	0.45	0.71	0.56
	Bahaya	1	0.62	0.77
S2	Aman	0.53	1	0.69
	waspada	0.75	0.73	0.74
	Bahaya	1	0.53	0.69



Gambar 4. Akurasi pada variasi *Hidden Node* untuk Training



Gambar 5. Akurasi pada variasi *Hidden Node* untuk Testing

(jarak dan sudut) dan 2,6148 (jarak, sudut, dan *steering*).

B. Evaluasi Algoritma Pelatihan

Setelah diperoleh akurasi terbaik pada penggunaan 100 *hidden node*, pengujian dilanjutkan dengan menerapkan beberapa algoritma pelatihan lainnya (M), yaitu *Stochastic Gradient Descent* (SGD) (1), *Root Mean Square Propagation* (RMSProp) (2), *Adagrad* (3), *Adadelta* (4), *Adamax* (5), *Nadam* (6), dan *Adam* (7). Hasil pengujian berupa nilai *F1-Score* untuk masing-masing algoritma pelatihan disajikan pada Tabel 3.

Dari penelitian ini tingkat akurasi tertinggi tercapai dengan menggunakan algoritma pelatihan *Adam* [13]. Sedangkan untuk akurasi terendah menggunakan algoritma pelatihan *Adadelta*.

Perbandingan *F1-Score* untuk pelatihan dan pengujian tingkat severity menggunakan algoritma *Stochastic Gradient Descent* (SGD) (1), *Root Mean Square Propagation* (RMSProp) (2), *Adagrad* (3), *Adadelta* (4), *Adamax* (5), *Nadam* (6), dan *Adam* (7) dapat dilihat pada Tabel 4. Dari hasil pengujian ini, algoritma pelatihan *Adam* mencapai *F1-Score* terbaik.

Kinerja sistem dievaluasi lebih lanjut dalam dua skenario menggunakan metrik *precision*, *recall*, dan *F1-score*, seperti yang dirangkum dalam Tabel 6. Hasil ini menunjukkan pentingnya pemilihan algoritma yang tepat untuk mengoptimalkan kemampuan model dalam memprediksi tingkat keamanan dengan akurat. Namun, hasil ini juga menunjukkan adanya keterbatasan dalam skenario tertentu yang memerlukan penelitian lebih lanjut.

IV. KESIMPULAN

Berdasarkan hasil penelitian, pendekatan machine learning berbasis ANN terbukti efektif dalam memprediksi tingkat keamanan pada area *blind spot forklift*. Model yang dikembangkan mampu mengklasifikasikan tingkat keamanan menjadi tiga kategori, yaitu aman, waspada, dan bahaya, dengan kinerja yang baik berdasarkan metrik evaluasi *precision*, *recall*, dan *F1-score*. Hasil uji coba mengindikasikan bahwa konfigurasi optimal diperoleh pada 4 layer tersembunyi (*hidden layer*), 100 *hidden node*, dan 1500 *epoch* dengan algoritma pelatihan Adam. Selain itu, analisis terhadap dua skenario input menunjukkan bahwa penambahan variabel posisi kemudi memberikan pengaruh terhadap kinerja model, meskipun masih diperlukan evaluasi lebih lanjut untuk meningkatkan kemampuan generalisasi pada data uji.

Secara keseluruhan, penelitian ini menunjukkan bahwa integrasi parameter geometrik dan kondisi operasional kendaraan dalam model ANN dapat meningkatkan akurasi prediksi tingkat keamanan

pada area *blind spot*. Untuk pengembangan selanjutnya, sistem ini berpotensi diimplementasikan dalam sistem pemantauan keselamatan berbasis *real-time* guna memberikan peringatan dini kepada operator serta meningkatkan keselamatan operasional forklift.

UCAPAN TERIMA KASIH

Studi ini telah didukung oleh hibah penelitian kompetitif dari Sekolah Vokasi UGM tahun 2024.

REFERENSI

- [1] lie Cao, T. Depner, H. Borstell, and K. Richter, *Discussions on sensor-based Assistance Systems for Forklifts*. VDE, 2019.
- [2] R. Firdaus, "Rancang Bangun Prototipe Forklift Manual Dengan Kapasitas Angkat 200 Kg (Proses Pembuatan)," 2021.
- [3] A. Kumar, J. Jaiswal, and N. Tiwari, "Blind Spot Monitoring System Using Ultrasonic Sensor," in *2023 International Conference on Disruptive Technologies (ICDT)*, IEEE, May 2023, pp. 30–35. doi: 10.1109/ICDT57929.2023.10150838.
- [4] T. T. Sari, M. K. Assoy, and G. Seçinti, "Utilizing Smartphones for Blind Spot Detection," in *2023 IEEE 20th Consumer Communications & Networking Conference (CCNC)*, IEEE, Jan. 2023, pp. 911–912. doi: 10.1109/CCNC51644.2023.10060770.
- [5] X. Shen, "Forklift Operator Visibility Evaluation in a Manufacturing Environment," 2016. [Online]. Available: <https://www.researchgate.net/publication/311680065>
- [6] A. Y. Ramteke, P. Ramteke, A. Dhongade, U. Modak, and L. P. Thakre, "Blind Spot Detection for Autonomous Driving Using RADAR Technique," *J. Phys. Conf. Ser.*, vol. 2763, no. 1, p. 012015, May 2024, doi: 10.1088/1742-6596/2763/1/012015.
- [7] Y. Lee and M. Park, "Rearview Camera-Based Blind-Spot Detection and Lane Change Assistance System for Autonomous Vehicles," *Applied Sciences*, vol. 15, no. 1, p. 419, Jan. 2025, doi: 10.3390/app15010419.
- [8] M. Zhang, X. Zhang, J. Mo, Z. Xiang, and P. Zheng, "Brake uneven wear of high-speed train intelligent monitoring using an ensemble model based on multi-sensor feature fusion and deep learning," *Eng. Fail. Anal.*, vol. 137, 2022, doi: 10.1016/j.engfailanal.2022.106219.
- [9] Q. Liu, Z. Li, S. Yuan, Y. Zhu, and X. Li, "Review on Vehicle Detection Technology for Unmanned Ground Vehicles," *Sensors*, vol. 21, no. 4, p. 1354, Feb. 2021, doi: 10.3390/s21041354.
- [10] K. D. Saharuddin *et al.*, "A Comparative Study on Various ANN Optimization Algorithms for Magnetorheological Elastomer Carbonyl Iron

- Particle Concentration Estimation,” *Journal of Advanced Research in Micro and Nano Engineering*, vol. 16, no. 1, pp. 124–133, Mar. 2024, doi: 10.37934/armne.16.1.124133.
- [11] T. Prasetyo, I. Bahiuddin, D. Rezy Pratama, Surojo, and M. H. M. Ariff, “Fuzzy Logic Based-Assistance System for Detecting Forklift Blind Spot Area Using Radar-Like-Ultrasonic Sensors,” in *Proceedings of 2023 IEEE International Conference on Internet of Things and Intelligence Systems, IoTaIS 2023*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 152–157. doi: 10.1109/IoTaIS60147.2023.10346076.
- [12] T. Prasetyo *et al.*, “Predicting the Risk Level and Position of Objects in the Forklift’s Blind Spot Area Using Artificial Neural Network,” in *2023 1st International Conference on Advanced Engineering and Technologies, ICONNIC 2023 - Proceeding*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 43–48. doi: 10.1109/ICONNIC59854.2023.10467780.
- [13] A. Srivastava, B. S. Rawat, G. Singh, V. Bhatnagar, P. K. Saini, and S. A. Dhondiyal, “A Review of Optimization Algorithms for Training Neural Networks,” in *2023 International Conference on Sustainable Emerging Innovations in Engineering and Technology, ICSEIET 2023*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 886–890. doi: 10.1109/ICSEIET58677.2023.10303287.
- [14] C. Teke, I. Akkurt, S. Arslankaya, I. Ekmekci, and K. Gunoglu, “Prediction of gamma ray spectrum for ^{22}Na source by feed forward back propagation ANN model,” *Radiation Physics and Chemistry*, vol. 202, Jan. 2023, doi: 10.1016/j.radphyschem.2022.110558.
- [15] S. I. Imtiaz, S. ur Rehman, A. R. Javed, Z. Jalil, X. Liu, and W. S. Alnumay, “DeepAMD: Detection and identification of Android malware using high-efficient Deep Artificial Neural Network,” *Future Generation Computer Systems*, vol. 115, pp. 844–856, Feb. 2021, doi: 10.1016/j.future.2020.10.008.