



Potensi Transformasi Deep Learning dalam Berbagai Domain: Studi Literatur pada Manufaktur dan Layanan Kesehatan

Yesi Nurul Mutia ¹, Syaiful Bachri Mustamin ², Wa Ode Saktilawati ³, Nurhikmah Fajar ¹, Sahriani ², Sri Kurniyan Sari ⁴

¹ Program Studi Teknik Komputer, Komputer, Universitas Muhammadiyah Kolaka Utara, Indonesia

² Program studi Teknologi Informasi, Fakultas Sains Teknologi dan Kesehatan, Institut Sains Teknologi dan Kesehatan 'Aisyiyah Kendari, Indonesia

³ Program Studi Kesehatan Masyarakat, Fakultas Kesehatan Masyarakat, Universitas Halu Oleo, Indonesia

⁴ Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Indonesia Timur, Indonesia

*Email (corresponding author): syaifulbachrimustamin@gmail.com

Abstrak. Penerapan deep learning di sektor manufaktur dan layanan kesehatan untuk meningkatkan efisiensi, akurasi, dan otomatisasi. Di sektor manufaktur, kolaborasi manusia-robot menghadapi tantangan dalam merencanakan tugas dan mengendalikan gerakan robot di lingkungan tak terstruktur, sementara deteksi cacat geometris pada produk menggunakan data awan titik 3D membutuhkan teknologi yang mampu menangani data kompleks. Di sektor layanan kesehatan, deep learning memainkan peran penting dalam segmentasi citra medis dan triage departemen gawat darurat untuk meningkatkan kecepatan dan akurasi pengambilan keputusan medis. Penelitian ini menggunakan studi literatur untuk mengeksplorasi berbagai aplikasi deep learning dalam kedua sektor tersebut, seperti penggunaan mixed reality head-mounted display (MR-HMD), deep reinforcement learning (DRL), dan model PointNet++ dalam manufaktur, serta aplikasi deep learning dalam segmentasi citra medis dan analisis data rekam medis elektronik di layanan kesehatan. Hasil penelitian menunjukkan bahwa deep learning meningkatkan efisiensi kolaborasi manusia-robot, memperbaiki deteksi cacat geometris, serta meningkatkan akurasi dan kecepatan proses triage di layanan kesehatan. Kesimpulannya, deep learning memiliki potensi transformasi besar di berbagai sektor dan membuka peluang untuk otomatisasi serta pengambilan keputusan berbasis data yang lebih canggih.

Kata kunci: Deep learning, kolaborasi manusia-robot, deteksi cacat geometris, segmentasi citra medis, triage departemen gawat

Abstract. The application of deep learning in the manufacturing and healthcare sectors aims to improve efficiency, accuracy, and automation. In the manufacturing sector, human-robot collaboration faces challenges in task planning and controlling robot movements in unstructured environments, while geometric defect detection in products using 3D point cloud data requires technology capable of handling complex data. In the healthcare sector, deep learning plays a significant role in medical image segmentation and emergency department (ED) triage to enhance the speed and accuracy of medical decision-making. This study uses a literature review to explore various deep learning applications in both sectors, such as the use of mixed reality head-mounted displays (MR-HMD), deep reinforcement learning (DRL), and PointNet++ models in manufacturing, as well as deep learning applications in medical image segmentation and electronic health record (EHR) data analysis in healthcare. The research findings indicate that deep learning improves human-robot collaboration efficiency, enhances geometric defect detection, and increases the accuracy and speed of triage processes in healthcare. In conclusion, deep learning has significant

transformative potential across various sectors and opens up opportunities for automation and more advanced data-driven decision-making.

Keywords: Deep learning, human-robot collaboration, geometric defect detection, medical image segmentation, emergency department

1. Pendahuluan

Dalam sektor manufaktur, salah satu tantangan besar adalah kolaborasi manusia-robot (HRC) di lingkungan yang tidak terstruktur (Y. Liu et al., 2021). Kolaborasi ini, meskipun sangat berpotensi meningkatkan efisiensi operasional, seringkali menghadapi kesulitan dalam merencanakan tugas dan mengendalikan gerakan robot secara efektif (Y. Liu et al., 2021). Hal ini dikarenakan lingkungan manufaktur yang dinamis dan tidak selalu dapat diprediksi. Untuk mengatasi masalah ini, penelitian-penelitian terbaru mengusulkan pendekatan yang menggabungkan pemahaman multimodal –khususnya penglihatan dan bahasa alami – untuk meningkatkan koordinasi antara manusia dan robot (Chang et al., 2021). Dengan memanfaatkan deep learning, sistem dapat merencanakan dan menyesuaikan gerakan robot dengan lebih fleksibel dan adaptif, memungkinkan kolaborasi yang lebih efisien dan produktif. Ini menjadi sangat penting dalam manufaktur modern yang membutuhkan fleksibilitas tinggi dan kemampuan untuk beradaptasi dengan berbagai skenario (Q. Liu et al., 2021a; Ying et al., 2021).

Selain itu, dalam bidang deteksi cacat geometris pada produk manufaktur, terutama di industri yang memanfaatkan teknologi metrologi 3D, deep learning juga berperan penting (Tsai et al., 2021; Xue et al., 2022). Proses inspeksi yang menggunakan data awan titik 3D memiliki tantangan besar dalam hal presisi pengukuran, serta kesulitan dalam memproses data dengan dimensi yang tinggi dan sifat yang tidak terstruktur. Penggunaan teknologi deep learning, seperti model PointNet++, memungkinkan analisis data awan titik 3D secara otomatis dan end-to-end (Yin et al., 2021). Model ini mengatasi tantangan tersebut dengan mengidentifikasi cacat yang mungkin terjadi pada bagian produk manufaktur dengan akurasi yang lebih tinggi, serta memperbaiki kelemahan pada metode konvensional yang terbatas oleh kompleksitas data dan keterbatasan dalam presisi pengukuran.

Dalam sektor layanan kesehatan, penerapan deep learning menunjukkan potensi yang luar biasa dalam meningkatkan kualitas perawatan dan efisiensi operasional. Sebagai contoh, dalam segmentasi citra medis, terutama dalam pencitraan otak tikus, deep learning digunakan untuk meningkatkan kemampuan dalam membedakan materi putih dan abu-abu pada citra MRI (Basha et al., 2021). Teknik ini tidak hanya meningkatkan akurasi dalam segmentasi, tetapi juga memungkinkan penggunaan label yang tidak sempurna namun lebih murah untuk pelatihan model dengan dataset besar. Hal ini membuka peluang untuk mengatasi keterbatasan biaya dalam pelatihan model, sambil tetap mempertahankan akurasi dan reliabilitas dalam analisis medis.

Di sisi lain, dalam konteks triage departemen gawat darurat (ED), deep learning juga berpotensi besar dalam meningkatkan kecepatan dan akurasi dalam mengelola pasien. Triage yang efisien sangat penting untuk memprioritaskan pasien yang membutuhkan perawatan segera (Sharafat & Bayati, 2021a). Dengan menggabungkan data rekam medis elektronik dan analitik prediktif berbasis deep learning, penelitian ini menunjukkan bagaimana teknologi ini dapat digunakan untuk meningkatkan akurasi dalam memprediksi kebutuhan perawatan dan rawat inap (Rough et al., 2020). Dengan menganalisis catatan klinis dalam bentuk teks

bebas, deep learning memungkinkan sistem untuk mengevaluasi kondisi pasien secara lebih cepat dan lebih tepat, yang pada akhirnya dapat mengurangi beban pada staf medis dan meningkatkan kualitas perawatan.

Secara keseluruhan, penelitian ini menyoroti bagaimana teknologi deep learning tidak hanya meningkatkan efisiensi dan akurasi dalam sektor manufaktur dan layanan kesehatan, tetapi juga membuka peluang baru untuk otomatisasi dan pengambilan keputusan berbasis data yang lebih canggih. Penerapan deep learning dalam berbagai domain ini memiliki potensi untuk merombak cara kita bekerja, baik di pabrik maupun di rumah sakit, dengan meningkatkan produktivitas, mengurangi kesalahan manusia, dan memberikan solusi yang lebih cepat dan lebih tepat untuk masalah yang kompleks (Anggriani et al., 2024). Oleh karena itu, penting untuk terus mengembangkan dan mengoptimalkan teknologi ini agar dapat menjawab tantangan masa depan dalam kedua sektor tersebut.

2. Metode

Metode penelitian yang digunakan dalam studi ini adalah literatur review, yang bertujuan untuk mengkaji berbagai penelitian yang telah ada dan mengidentifikasi tren serta temuan penting terkait penerapan teknologi deep learning di berbagai bidang. Penelitian-penelitian yang dibahas mencakup aplikasi deep learning di sektor manufaktur dan layanan kesehatan, dengan fokus pada kolaborasi manusia-robot, segmentasi citra medis, deteksi cacat geometris, serta peningkatan triage di departemen gawat darurat. Dalam penelitian-penelitian tersebut, berbagai metode digunakan, seperti penggunaan model pembelajaran mendalam dengan berbagai jenis data (misalnya data visual, data struktur, dan data citra), serta teknik pembelajaran tanpa pengawasan, segmentasi menggunakan arsitektur deep learning seperti U-Net, dan deep reinforcement learning untuk perencanaan tugas. Penelitian ini mengandalkan analisis kritis terhadap sumber-sumber yang ada untuk merangkum temuan-temuan tersebut, dan untuk memberikan wawasan mengenai penerapan deep learning dalam mengatasi tantangan yang ada di sektor-sektor tersebut, serta potensi dan aplikasi yang lebih luas.

Dalam konteks kolaborasi manusia-robot (HRC), penelitian ini diperlukan karena HRC dalam lingkungan manufaktur yang tidak terstruktur menghadirkan tantangan yang signifikan¹. Diperlukan pendekatan yang lebih canggih yang menggabungkan pemahaman multimodal, khususnya penglihatan dan bahasa alami, untuk merencanakan tugas dan mengendalikan gerakan robot dengan efektif¹. Ini mendorong pengembangan metode yang dipandu oleh visi-bahasa dan didukung oleh pembelajaran penguatan mendalam untuk HRC.

Penelitian tentang struktur data dalam pembelajaran mendalam muncul dari pengamatan bahwa data empiris memiliki struktur internal yang tidak dapat diabaikan. Teori yang ada sering mengabaikan struktur ini, padahal struktur data berperan penting dalam kemampuan jaringan saraf untuk mempelajari fitur-fitur bermakna dan mencapai generalisasi yang baik. Penelitian ini bertujuan untuk memahami bagaimana struktur data memengaruhi kemampuan jaringan untuk memproses informasi dan membedakan pola.

Dalam bidang segmentasi citra medis, khususnya segmentasi otak tikus, penelitian didorong oleh kebutuhan untuk mengatasi tantangan dalam membedakan materi putih dan abu-abu. Tujuan penelitian ini adalah untuk menguji kinerja berbagai arsitektur pembelajaran mendalam dan mengidentifikasi mode kegagalan yang mungkin terjadi. Penelitian ini juga

berupaya memanfaatkan label yang tidak sempurna namun murah untuk pelatihan model dengan dataset besar, serta memperkenalkan estimasi ketidakpastian dan ukuran penjelasan untuk meningkatkan keandalan.

Penelitian tentang deteksi cacat geometris pada gigi didorong oleh pentingnya integritas geometris untuk fungsionalitas, keandalan, dan keamanan produk manufaktur. Meskipun teknologi metrologi 3D memungkinkan inspeksi skala halus, penggunaan luasnya dibatasi oleh kompleksitas data awan titik 3D, seperti dimensi tinggi, sifat tidak terstruktur, dan sifat jarang pada area yang cacat. Penelitian ini bertujuan untuk mengembangkan model pembelajaran mendalam yang dapat menganalisis data awan titik 3D secara otomatis dan *end-to-end*, serta menyelidiki dampak resolusi dan presisi pengukuran pada kinerja klasifikasi (Bachri et al., 2024).

Terakhir, penelitian tentang peningkatan triage departemen gawat darurat (ED) dilatarbelakangi oleh kebutuhan untuk mengatasi masalah kepadatan dan kualitas perawatan di ED. Triage yang akurat dan efisien sangat penting untuk memprioritaskan pasien yang paling sakit dan mengelola alur departemen. Penelitian ini mengeksplorasi penggunaan data rekam medis elektronik dan analitik prediktif tingkat lanjut, termasuk pembelajaran mendalam, untuk meningkatkan kinerja triage dengan tujuan mengoptimalkan akurasi prediktif melalui penggabungan penilaian klinis perawat triage.

Berikut adalah rincian data dan metode yang digunakan dalam masing-masing penelitian:

a. Kolaborasi Manusia-Robot (HRC):

Data: Data visual dari *mixed reality head-mounted display* (MR-HMD), vektor keadaan termasuk informasi robot, manusia, lingkungan, dan properti relatif; informasi temporal dari vektor keadaan sebelumnya; dan dataset 463 pasang gambar-teks.

Metode: Perencanaan tugas HRC dengan bimbingan visi-bahasa dan *large language model* (LLM); model segmentasi objek target menggunakan ResNet-50, BERT, dan *transformer decoder*; kontrol gerakan manipulator *mobile* dengan *deep reinforcement learning* (DRL); evaluasi empiris dengan ahli manusia; dan eksperimen di lingkungan laboratorium.

b. Pembelajaran Mendalam Tanpa Pengawasan dengan Data Terstruktur:

Data: Data pasangan pola berkorelasi dengan parameter *overlap* ρ ; set pelatihan diorganisasikan dalam pasangan $\{\xi\mu, \bar{\xi}\mu\}$, dengan distribusi probabilitas marginal seragam pada $\{-1, 1\}$.

Metode: Model pembelajaran tanpa pengawasan dengan representasi internal yang tetap; model jaringan *fully-connected* dengan aturan Hebb; solusi *mean field* untuk persamaan rekursi *layer-wise*; analisis diagram bifurkasi; dan analisis limit termodinamika.

c. Segmentasi Otak Tikus:

Data: 11.150 volume MRI *T2-weighted* dari 9.660 tikus dengan berbagai strain; delapan bidang gambar koronal per tikus; dan label *ground truth* berbasis registrasi dengan 29 dan 58 *region of interest* (ROI).

Metode: Tiga arsitektur *deep learning* (U-Net, Attention U-Net, DeepLabv3+); pelatihan dengan *loss* Dice dan *cross-entropy*; evaluasi dengan *Dice score*; estimasi ketidakpastian dengan *Monte Carlo dropout*; *dropout feature ranking* untuk penjelasan; *ensemble* dari tujuh Attention U-Net; dan jarak Hausdorff.

d. Deteksi Cacat Geometris pada Gigi:

Data: Dataset "MFGNet-gear" dengan 12 desain *part* dan empat kelas kualitas, menghasilkan 24.000 *part*; awan titik 3D dari model CAD gigi; variabilitas desain ± 0.0254 mm; dan data cacat dengan variasi ukuran dan lokasi.

Metode: Model *deep learning* PointNet++; klasifikasi desain dan deteksi cacat *multi-class*; *Adam optimizer*; studi kasus dengan resolusi dan presisi pengukuran yang bervariasi; dan analisis *confusion matrices*.

e. Triage Departemen Gawat Darurat (ED):

Data: Lebih dari 5 juta kunjungan ED; variabel triage termasuk usia, jenis kelamin, tanda vital; catatan klinis perawat triage dalam bentuk teks bebas; keluhan utama pasien; dan disposisi akhir ED.

Metode: Penggunaan *multilayer perceptron* (MLP) untuk data terstruktur dan *long short-term memory* (LSTM) untuk data tidak terstruktur; penggabungan *output* lapisan terakhir; fungsi aktivasi sigmoid; dan evaluasi dengan *area under the receiver operating characteristic curve* (AUC).

Secara keseluruhan, penelitian-penelitian ini memanfaatkan berbagai jenis data dan metode pembelajaran mendalam untuk mengatasi tantangan di berbagai bidang.

3. Hasil dan Pembahasan

Dalam bidang manufaktur, penelitian pertama berfokus pada kolaborasi manusia-robot (HRC) dalam lingkungan tak terstruktur (Bae et al., 2020). Penelitian ini menggunakan *mixed reality head-mounted display* (MR-HMD) untuk mengumpulkan data dan berinteraksi dengan robot, serta menggunakan model *large language model* (LLM) dan *deep reinforcement learning* (DRL) untuk perencanaan tugas dan kontrol gerakan robot (Park et al., 2021). Sementara itu, penelitian lain di bidang manufaktur menginvestigasi deteksi cacat geometris pada gigi menggunakan data awan titik 3D. Penelitian ini mengembangkan dataset "MFGNet-gear" dan menggunakan arsitektur PointNet++ yang dimodifikasi untuk mengklasifikasikan desain gigi dan mendeteksi cacat (Qian et al., 2021).

Beberapa penelitian yang dibahas dalam sumber ini menunjukkan bagaimana *deep learning* (pembelajaran mendalam) dapat digunakan untuk memecahkan masalah kompleks di berbagai bidang. Penelitian-penelitian ini tidak hanya berfokus pada peningkatan kinerja, tetapi juga pada otomatisasi dan pemahaman mendalam tentang proses yang terlibat.

Di bidang ilmu komputer dan matematika, satu penelitian menganalisis efek struktur data pada *deep learning* tanpa pengawasan (N. Wang et al., 2021). Penelitian ini menggunakan model matematika untuk menunjukkan bagaimana struktur data dapat memengaruhi kemampuan jaringan saraf untuk mempelajari dan membedakan pola. Hasilnya menunjukkan bahwa struktur data memainkan peran penting dalam kinerja jaringan.

Dalam pencitraan medis, sebuah penelitian berfokus pada segmentasi otak tikus dari gambar MRI (McDougall et al., 2020). Penelitian ini membandingkan berbagai arsitektur *deep learning*, termasuk U-Net, Attention U-Net, dan DeepLabV3+, dan juga mengeksplorasi cara untuk mengatasi ketidaksempurnaan dalam data pelatihan. Tujuannya adalah untuk mengotomatiskan dan meningkatkan akurasi proses segmentasi.

Terakhir, dalam bidang layanan kesehatan, satu penelitian membahas penggunaan *deep learning* untuk meningkatkan triage di departemen gawat darurat (ED) (Sharafat & Bayati, 2021b). Penelitian ini menganalisis catatan klinis perawat triage dalam teks bebas,

bersama dengan data rekam medis lainnya, untuk memprediksi rawat inap dan kelayakan *fast-track*. Hasil penelitian menunjukkan bahwa penggabungan data teks tak terstruktur meningkatkan kinerja prediksi secara signifikan.

Secara keseluruhan, penelitian-penelitian ini menunjukkan berbagai aplikasi *deep learning* dan bagaimana teknologi ini dapat digunakan untuk meningkatkan efisiensi, akurasi, dan otomatisasi di berbagai bidang. Masing-masing studi menyoroti pentingnya data berkualitas tinggi, desain model yang sesuai, dan analisis yang mendalam untuk mencapai hasil yang andal dan bermakna.

3.1. Diskusi Sub Bagian

Berbagai penelitian yang telah diulas menunjukkan potensi transformatif *deep learning* di berbagai sektor, mulai dari manufaktur hingga layanan kesehatan, dengan fokus pada otomatisasi, peningkatan akurasi, dan efisiensi (Sheu et al., 2020). Penelitian-penelitian ini, meskipun berfokus pada domain yang berbeda, memberikan wawasan berharga tentang bagaimana *deep learning* dapat digunakan untuk memecahkan masalah kompleks dan meningkatkan proses yang ada. Dalam manufaktur, integrasi data multimodal melalui *mixed reality head-mounted display* (MR-HMD), *large language model* (LLM), dan *deep reinforcement learning* (DRL) memungkinkan kolaborasi manusia-robot yang lebih adaptif dan fleksibel (W. Wang et al., 2022). Sementara itu, studi tentang struktur data dalam *deep learning* mengungkapkan bahwa struktur data memengaruhi kemampuan jaringan saraf dalam membedakan pola, yang memiliki implikasi signifikan pada bagaimana data diproses dan diinterpretasi (Bai et al., 2021). Penelitian tentang segmentasi otak tikus dengan MRI menunjukkan bahwa model *deep learning* dapat belajar dari data yang kurang sempurna, di mana dataset besar dengan variasi yang beragam dapat mengkompensasi kekurangan label individual (Di Ieva et al., 2021). Dalam konteks manufaktur, deteksi cacat geometris pada gigi menggunakan data awan titik 3D dan model PointNet++ memperlihatkan bahwa *deep learning* dapat menangani data kompleks dan tidak terstruktur, tetapi juga menyoroti pentingnya resolusi dan presisi pengukuran serta kebutuhan untuk model yang lebih sensitif terhadap cacat lokal (Hong et al., 2020). Terakhir, dalam layanan kesehatan, analisis teks tak terstruktur dari catatan klinis perawat triage menunjukkan bagaimana *deep learning* dapat meningkatkan efisiensi dan akurasi triage dengan memproses data teks bebas yang kaya informasi (Yao et al., 2021). Secara keseluruhan, penelitian-penelitian ini memberikan bukti kuat tentang kemampuan *deep learning* untuk mentransformasikan berbagai sektor, sambil menekankan perlunya pemahaman yang lebih dalam tentang data, model, dan domain aplikasi spesifik.

Tabel 1. Ringkasan penelitian

Judul Penelitian	Ringkasan Umum Penelitian
Pendekatan Terpandu Visi-Bahasa dan Diaktifkan Pembelajaran Penguatan Mendalam untuk Pemenuhan Tugas Manufaktur Kolaboratif Manusia-Robot Tak Terstruktur	Penelitian ini mengusulkan pendekatan baru untuk kolaborasi manusia-robot (HRC) dalam manufaktur yang tidak terstruktur. Metode ini menggabungkan <i>mixed reality head-mounted display</i> (MR-HMD) untuk pengumpulan data, komunikasi, dan representasi keadaan. Pendekatan ini melibatkan perencanaan tugas HRC dengan bimbingan visi-bahasa dan <i>large language model</i> (LLM), serta kontrol gerakan manipulator <i>mobile</i> berbasis

Judul Penelitian	Ringkasan Umum Penelitian
	<i>deep reinforcement learning</i> (DRL). Tujuannya adalah untuk meningkatkan efisiensi dan fleksibilitas dalam tugas manufaktur kolaboratif (Q. Liu et al., 2021b).
Resolusi Pola Serupa dalam Model yang Dapat Dipecahkan dari Pembelajaran Mendalam Tanpa Pengawasan dengan Data Terstruktur	Penelitian ini menganalisis efek struktur data pada pembelajaran mendalam tanpa pengawasan. Menggunakan model matematika, penelitian ini mengeksplorasi bagaimana jaringan saraf memproses data dengan pola berkorelasi. Hasil penelitian menunjukkan bahwa struktur data memengaruhi kemampuan jaringan untuk membedakan pola dan bahwa ada transisi fase antara rezim di mana struktur data membantu atau menghambat identifikasi pola (Tan et al., 2024).
Segmentasi Otak Tikus dengan Pembelajaran Mendalam dari Label Berbasis Registrasi yang Tidak Sempurna	Penelitian ini mengeksplorasi penggunaan model <i>deep learning</i> untuk segmentasi otak tikus dari gambar MRI. Penelitian ini berfokus pada penggunaan label pelatihan berbasis registrasi yang mungkin tidak sempurna tetapi lebih murah dan tersedia dalam jumlah besar. Model-model yang dievaluasi termasuk U-Net, Attention U-Net, dan DeepLabV3+, dengan tujuan mengidentifikasi arsitektur yang paling efektif untuk tugas ini. Selain itu, penelitian ini juga menyelidiki estimasi ketidakpastian dan interpretasi keputusan untuk meningkatkan keandalan model (Li et al., 2021).
Deteksi Cacat Geometris Berbasis Pembelajaran Mendalam untuk Kualitas Gigi yang Efisien	Penelitian ini memperkenalkan dataset "MFGNet-gear" untuk deteksi cacat geometris pada gigi menggunakan data awan titik 3D. Model PointNet++ yang dimodifikasi digunakan untuk klasifikasi desain dan deteksi cacat, dengan fokus pada efisiensi dan otomatisasi. Penelitian ini juga menganalisis dampak resolusi dan presisi pengukuran terhadap kinerja model, menunjukkan bahwa ada ambang resolusi optimal untuk deteksi cacat yang akurat (Sulzer et al., 2021).
Analisis Otomatis Penilaian Klinis Tak Terstruktur Meningkatkan Kinerja Triage Departemen Gawat Darurat: Analisis Pembelajaran Mendalam Retrospektif	Penelitian ini mengeksplorasi penggunaan pembelajaran mendalam untuk meningkatkan kinerja triage di departemen gawat darurat (ED). Model ini menggunakan data rekam medis elektronik, termasuk catatan klinis perawat triage dalam teks bebas, untuk memprediksi rawat inap dan kelayakan <i>fast-track</i> . Hasil penelitian menunjukkan bahwa penggabungan penilaian klinis tak terstruktur meningkatkan akurasi prediksi secara signifikan, menunjukkan potensi analitik prediktif tingkat lanjut untuk mengoptimalkan proses triage (Roquette et al., 2020).

Kesimpulan

Penelitian-penelitian yang diulas secara keseluruhan menunjukkan potensi transformatif *deep learning* di berbagai bidang, mulai dari manufaktur hingga layanan kesehatan. Meskipun berfokus pada domain yang berbeda, penelitian-penelitian ini memberikan wawasan berharga tentang bagaimana *deep learning* dapat digunakan untuk mengatasi tantangan kompleks dan meningkatkan efisiensi. Dalam manufaktur, integrasi data multimodal melalui *mixed reality head-mounted display* (MR-HMD) memungkinkan kolaborasi manusia-robot yang lebih adaptif, dengan *large language model* (LLM) untuk

perencanaan tugas dan *deep reinforcement learning* (DRL) untuk kontrol robot. Sementara itu, penelitian mengenai struktur data dalam *deep learning* mengungkapkan bahwa struktur data memengaruhi kemampuan jaringan saraf dalam membedakan pola, yang memiliki implikasi penting terhadap cara data diproses dan diinterpretasi.

Studi lain tentang segmentasi otak tikus menggunakan MRI menunjukkan bahwa model *deep learning* dapat belajar dari data yang kurang sempurna, di mana dataset besar dengan variasi yang beragam mampu mengkompensasi kekurangan label individual. Dalam konteks manufaktur, deteksi cacat geometris pada gigi menggunakan data awan titik 3D dan model PointNet++ memperlihatkan bahwa *deep learning* dapat menangani data yang kompleks. Namun, penelitian ini juga menyoroti pentingnya resolusi dan presisi pengukuran serta kebutuhan untuk model yang lebih sensitif terhadap cacat lokal. Di sisi lain, dalam layanan kesehatan, analisis teks tak terstruktur dari catatan klinis perawat triage menunjukkan bagaimana *deep learning* dapat meningkatkan efisiensi dan akurasi triage dengan memproses data teks bebas yang kaya informasi.

Secara keseluruhan, penelitian-penelitian ini memberikan bukti kuat tentang kemampuan *deep learning* untuk mentransformasikan berbagai sektor. Namun demikian, penelitian ini juga menekankan pentingnya pemahaman yang lebih mendalam mengenai data, model, dan aplikasi spesifik dalam masing-masing domain.

Ucapan Terima Kasih

Kami mengucapkan terima kasih kepada semua pihak yang telah memberikan dukungan teknis, administratif, dan material dalam penelitian ini. Terima kasih juga kepada rekan-rekan yang memberikan saran konstruktif dan kepada keluarga yang telah memberikan dukungan moral sepanjang proses penelitian.

Daftar Pustaka

- Anggriani, D., Bachri Mustamin, S., Atnang, M., Fatmah, S., Azaliah Mar, N., Fajar, N., dan Kesehatan, T., & Kendari, A. (2024). Transforming the Diabetes Mellitus Diagnosis and Treatment Using Data Technology: Comprehensive Analysis of Deep Learning and Machine Learning Methodologies. *Journal of Scientific Insights*, 1(1), 26–32. <https://doi.org/10.69930/JSI.V1I1.71>
- Bachri, S. M., Atnang, M., Hikmah, N., Studi Teknologi Informasi, P., Sains Teknologi dan Kesehatan, F., & Sains Teknologi dan Kesehatan Aisyiyah Kendari, I. (2024). Transparansi dan Auditabilitas Data Pribadi dalam Layanan Berbasis Cloud Pada Proyek PACE: Studi Literatur. *Jurnal Teknologi Dan Sains Modern*, 1(1), 1–8. <https://doi.org/10.69930/JTSM.V1I1.57>
- Bae, J., Kim, K., Huh, J., & Hong, D. (2020). Variable Admittance Control With Virtual Stiffness Guidance for Human–Robot Collaboration. *IEEE Access*, 8, 117335–117346. <https://doi.org/10.1109/ACCESS.2020.3004872>
- Bai, X., Wang, X., Liu, X., Liu, Q., Song, J., Sebe, N., & Kim, B. (2021). Explainable deep learning for efficient and robust pattern recognition: A survey of recent developments. *Pattern Recognition*, 120, 108102. <https://doi.org/10.1016/J.PATCOG.2021.108102>
- Basha, S., Marizzoni, M., Frisoni, G. B., Jovicich, J., & Miyapuram, K. P. (2021). Risk prediction of prodromal Alzheimer’s disease using deep learning of MRI scans. *Alzheimer’s & Dementia*, 17(S1), e054803. <https://doi.org/10.1002/ALZ.054803>

- Chang, P., Luo, R., Dorostian, M., & Padr, T. (2021). A Shared Control Method for Collaborative Human-Robot Plug Task. *IEEE Robotics and Automation Letters*, 6(4), 7429–7436. <https://doi.org/10.1109/LRA.2021.3098323>
- Di Ieva, A., Russo, C., Liu, S., Jian, A., Bai, M. Y., Qian, Y., & Magnussen, J. S. (2021). Application of deep learning for automatic segmentation of brain tumors on magnetic resonance imaging: a heuristic approach in the clinical scenario. *Neuroradiology*, 63(8), 1253–1262. <https://doi.org/10.1007/S00234-021-02649-3>
- Hong, J., Kim, K., & Lee, H. (2020). Faster Dynamic Graph CNN: Faster Deep Learning on 3D Point Cloud Data. *IEEE Access*, 8, 190529–190538. <https://doi.org/10.1109/ACCESS.2020.3023423>
- Li, B., Niessen, W. J., Klein, S., de Groot, M., Ikram, M. A., Vernooij, M. W., & Bron, E. E. (2021). Longitudinal diffusion MRI analysis using Segis-Net: A single-step deep-learning framework for simultaneous segmentation and registration. *NeuroImage*, 235. <https://doi.org/10.1016/J.NEUROIMAGE.2021.118004>
- Liu, Q., Liu, Z., Xiong, B., Xu, W., & Liu, Y. (2021a). Deep reinforcement learning-based safe interaction for industrial human-robot collaboration using intrinsic reward function. *Adv. Eng. Informatics*, 49. <https://doi.org/10.1016/J.AEI.2021.101360>
- Liu, Q., Liu, Z., Xiong, B., Xu, W., & Liu, Y. (2021b). Deep reinforcement learning-based safe interaction for industrial human-robot collaboration using intrinsic reward function. *Adv. Eng. Informatics*, 49. <https://doi.org/10.1016/J.AEI.2021.101360>
- Liu, Y., Habibnezhad, M., & Jebelli, H. (2021). Brainwave-driven human-robot collaboration in construction. *Automation in Construction*, 124. <https://doi.org/10.1016/J.AUTCON.2021.103556>
- McDougall, S. G., Delahanty, J. M., Sandoval, F., Knaack, A., Fletcher, E., & DeCarli, C. (2020). Towards a generalized deep learning framework for production scale segmentation of brain structures. *Alzheimer's & Dementia*, 16(S4). <https://doi.org/10.1002/ALZ.038010>
- Park, K. B., Choi, S. H., Lee, J. Y., Ghasemi, Y., Mohammed, M., & Jeong, H. (2021). Hands-free human-robot interaction using multimodal gestures and deep learning in wearable mixed reality. *IEEE Access*, 9, 55448–55464. <https://doi.org/10.1109/ACCESS.2021.3071364>
- Qian, J., Feng, S., Xu, M., Tao, T., Shang, Y., Chen, Q., & Zuo, C. (2021). High-resolution real-time 360° 3D surface defect inspection with fringe projection profilometry. *Optics and Lasers in Engineering*, 137, 106382. <https://doi.org/10.1016/J.OPTLASENG.2020.106382>
- Roquette, B. P., Nagano, H., Marujo, E. C., & Maiorano, A. C. (2020). Prediction of admission in pediatric emergency department with deep neural networks and triage textual data. *Neural Networks : The Official Journal of the International Neural Network Society*, 126, 170–177. <https://doi.org/10.1016/J.NEUNET.2020.03.012>
- Rough, K., Dai, A. M., Zhang, K., Xue, Y., Vardoulakis, L. M., Cui, C., Butte, A. J., Howell, M. D., & Rajkomar, A. (2020). Predicting Inpatient Medication Orders From Electronic Health Record Data. *Clinical Pharmacology and Therapeutics*, 108(1), 145–154. <https://doi.org/10.1002/CPT.1826>
- Sharafat, A. R., & Bayati, M. (2021a). PatientFlowNet: A Deep Learning Approach to Patient Flow Prediction in Emergency Departments. *IEEE Access*, 9, 45552–45561. <https://doi.org/10.1109/ACCESS.2021.3066164>

-
- Sharafat, A. R., & Bayati, M. (2021b). PatientFlowNet: A Deep Learning Approach to Patient Flow Prediction in Emergency Departments. *IEEE Access*, 9, 45552–45561. <https://doi.org/10.1109/ACCESS.2021.3066164>
- Sheu, R. K., Lin, Y. C., Huang, C. Y., Chen, L. C., Pardeshi, M. S., & Tseng, H. H. (2020). IDS-DLA: Sheet Metal Part Identification System for Process Automation Using Deep Learning Algorithms. *IEEE Access*, 8, 127329–127342. <https://doi.org/10.1109/ACCESS.2020.3007257>,
- Sulzer, R., Landrieu, L., Marlet, R., & Vallet, B. (2021). Scalable Surface Reconstruction with Delaunay-Graph Neural Networks. *Computer Graphics Forum*, 40(5), 157–167. <https://doi.org/10.1111/CGF.14364>
- Tan, D., Huang, Z., Peng, X., Zhong, W., & Mahalec, V. (2024). Deep Adaptive Fuzzy Clustering for Evolutionary Unsupervised Representation Learning. *IEEE Transactions on Neural Networks and Learning Systems*, 35(5), 6103–6117. <https://doi.org/10.1109/TNNLS.2023.3243666>
- Tsai, D. M., Fan, S. K. S., & Chou, Y. H. (2021). Auto-Annotated Deep Segmentation for Surface Defect Detection. *IEEE Transactions on Instrumentation and Measurement*, 70, 1–10. <https://doi.org/10.1109/TIM.2021.3087826>
- Wang, N., Zhou, W., Song, Y., Ma, C., Liu, W., & Li, H. (2021). Unsupervised Deep Representation Learning for Real-Time Tracking. *International Journal of Computer Vision*, 129(2), 400–418. <https://doi.org/10.1007/S11263-020-01357-4>
- Wang, W., Li, R., Chen, Y., Sun, Y., & Jia, Y. (2022). Predicting Human Intentions in Human-Robot Hand-Over Tasks Through Multimodal Learning. *IEEE Transactions on Automation Science and Engineering*, 19(3), 2339–2353. <https://doi.org/10.1109/TASE.2021.3074873>
- Xue, Y., Shi, P., Jia, F., & Huang, H. (2022). 3D reconstruction and automatic leakage defect quantification of metro tunnel based on SfM-Deep learning method. *Underground Space*, 7(3), 311–323. <https://doi.org/10.1016/J.UNDSP.2021.08.004>
- Yao, L. H., Leung, K. C., Tsai, C. L., Huang, C. H., & Fu, L. C. (2021). A Novel Deep Learning-Based System for Triage in the Emergency Department Using Electronic Medical Records: Retrospective Cohort Study. *Journal of Medical Internet Research*, 23(12). <https://doi.org/10.2196/27008>,
- Yin, C., Wang, B., Gan, V. J. L., Wang, M., & Cheng, J. C. P. (2021). Automated semantic segmentation of industrial point clouds using ResPointNet. *Automation in Construction*, 130. <https://doi.org/10.1016/J.AUTCON.2021.103874>
- Ying, K. C., Pourhejazy, P., Cheng, C. Y., & Cai, Z. Y. (2021). Deep learning-based optimization for motion planning of dual-arm assembly robots. *Comput. Ind. Eng.*, 160. <https://doi.org/10.1016/J.CIE.2021.107603>
-

CC BY-SA 4.0 (Attribution-ShareAlike 4.0 International).

This license allows users to share and adapt an article, even commercially, as long as appropriate credit is given and the distribution of derivative works is under the same license as the original. That is, this license lets others copy, distribute, modify and reproduce the Article, provided the original source and Authors are credited under the same license as the original.

