

IMPLEMENTASI JARINGAN SARAF TIRUAN DALAM SISTEM KLASIFIKASI SPERMA UNTUK MENDUKUNG DIAGNOSIS INFERTILITAS PRIA DI INDONESIA

Muhammad Nashif Farid ¹⁾, I Gede Susrama Mas Diyasa²⁾, Alfian Rizaldy Pratama³⁾

1) Program Studi Sains Data Fakultas Ilmu Komputer UPN “Veteran” Jawa Timur

E-mail: nashifrd@gmail.com¹⁾

2) Fakultas Ilmu Komputer UPN “Veteran” Jawa Timur

E-mail: igsusrama.if@upnjatim.ac.id

3) Program Studi Sains Data, Fakultas Ilmu Komputer UPN “Veteran” Jawa Timur

E-mail: alfan.fasilkom@upnjatim.ac.id

Abstrak

Infertilitas pria merupakan salah satu faktor utama penyebab ketidaksuburan pada pasangan, di mana motilitas sperma menjadi parameter penting dalam menentukan kualitas sperma. Evaluasi motilitas secara manual masih umum digunakan di laboratorium klinis Indonesia, namun memiliki keterbatasan dalam hal subjektivitas dan efisiensi waktu. Penelitian ini bertujuan mengembangkan sistem klasifikasi motilitas spermatozoa berbasis deep learning menggunakan arsitektur 2D Convolutional Neural Network (CNN) sebagai solusi otomatis yang objektif dan terjangkau. Data penelitian berupa video mikroskopis sperma yang diproses melalui tahapan konversi format, normalisasi, ekstraksi frame, serta pelabelan berdasarkan tiga kategori motilitas (Progressive, Non-Progressive, dan Immotile). Model CNN dibangun dengan beberapa lapisan konvolusi, batch normalization, ReLU activation, dan max pooling, serta dilatih menggunakan optimizer Adam dan CrossEntropyLoss. Hasil pengujian menunjukkan bahwa model mencapai akurasi keseluruhan sebesar 90%, menandakan performa yang stabil di ketiga kelas. Pendekatan ini menunjukkan potensi tinggi dalam mendukung analisis sperma otomatis di laboratorium diagnostik dengan biaya rendah, serta dapat dikembangkan lebih lanjut menggunakan arsitektur berbasis video seperti 3D-CNN untuk meningkatkan pemahaman pola temporal pergerakan sperma.

Kata kunci: Infertilitas Pria, Motilitas Sperma, Jaringan Saraf Tiruan, 2D-CNN, Diagnosis Klinis.

Pendahuluan

Infertilitas merupakan kondisi ketika sepasang suami istri belum berhasil mendapatkan kehamilan meskipun telah melakukan hubungan seksual secara rutin selama setahun atau lebih tanpa menggunakan alat kontrasepsi. [1]. Kondisi infertilitas tidak hanya berkaitan dengan aspek medis, tetapi juga dapat memengaruhi keadaan psikologis, sosial, dan kualitas hidup pasangan. Faktor dari pihak pria diketahui memiliki kontribusi yang cukup besar, yaitu sekitar setengah dari seluruh kasus infertilitas yang terjadi. [2]. Dalam sistem reproduksi pria, gangguan yang paling sering ditemukan meliputi kelainan pada jumlah, bentuk, dan pergerakan (motilitas) spermatozoa. Kondisi serupa juga terjadi di Indonesia, di mana data dari Kementerian Kesehatan menunjukkan bahwa sekitar 10–15% pasangan usia subur mengalami kesulitan untuk memperoleh keturunan, atau setara dengan sekitar 4–6 juta pasangan. [3]. Infertilitas pada pria dapat dipicu oleh berbagai faktor, seperti adanya penyumbatan pada saluran reproduksi, gangguan hormonal, kegagalan testis dalam memproduksi sperma, hingga gangguan pada fungsi dan kualitas sperma itu sendiri. Kelainan pada sperma ini dapat memengaruhi kemampuan pria untuk memperoleh keturunan secara alami. [4].

Menurut klasifikasi dari World Health Organization (WHO), motilitas sperma dikategorikan menjadi tiga jenis, yaitu progressive motility (PR), non-progressive motility (NP), dan immotility (IM). WHO juga menetapkan batas bawah nilai referensi untuk total motilitas (gabungan PR dan NP) sebesar 40%, dengan persentase motilitas progresif minimal 32% agar dapat dikategorikan dalam rentang normal [1]. Dalam praktik klinis di Indonesia, penilaian kualitas sperma umumnya masih dilakukan secara manual dengan menggunakan mikroskop sesuai dengan pedoman WHO 2010/2021. Namun, metode konvensional ini memiliki sejumlah keterbatasan, seperti ketergantungan tinggi pada keterampilan dan pengalaman analis, proses pemeriksaan yang memerlukan waktu cukup lama, serta potensi subjektivitas penilaian yang dapat menyebabkan

perbedaan hasil antar-pemeriksa [5]. Alternatif yang lebih modern adalah penggunaan *Computer-Aided Sperm Analysis* (CASA), yaitu sistem berbasis komputer yang mampu melakukan evaluasi sperma secara lebih cepat, objektif, dan konsisten dibandingkan metode manual. Meskipun teknologi ini menawarkan keunggulan signifikan, penerapannya di Indonesia masih relatif terbatas karena biaya perangkat yang tinggi serta sifat perangkat lunak yang umumnya tertutup (*proprietary*), sehingga sulit diakses maupun dikembangkan lebih lanjut di lingkungan penelitian lokal. [6]. Keterbatasan inilah yang membuka ruang bagi pengembangan metode berbasis komputasi yang lebih terjangkau, fleksibel, dan dapat disesuaikan dengan kebutuhan laboratorium lokal.

Salah satu pendekatan yang kini banyak digunakan dalam analisis biomedis adalah *deep learning*, cabang dari *machine learning* yang meniru cara kerja otak manusia melalui jaringan saraf tiruan berlapis-lapis. Teknologi ini mampu belajar otomatis dari data dalam jumlah besar dan mengenali pola kompleks tanpa perlu perancangan fitur manual, baik pada data spasial seperti gambar maupun data temporal seperti video. Dengan kemampuannya tersebut, *deep learning* menjadi metode yang sangat kuat untuk menganalisis data biomedis yang kompleks dan bervariasi. [7]. Sebagai tinjauan umum, Wang et al. (2024) melakukan kajian komprehensif mengenai penerapan *deep learning* dalam analisis citra medis. Studi tersebut membahas berbagai teknik populer, seperti CNN untuk klasifikasi citra, RNN untuk data sekuensial, serta model hibrida yang digunakan dalam segmentasi dan peningkatan kualitas visualisasi medis. Hasil tinjauan menunjukkan bahwa *deep learning* kini menjadi pendekatan dominan dalam penelitian dan praktik klinis karena mampu memberikan hasil yang lebih konsisten dan efisien dibandingkan metode konvensional. Relevansi temuan ini terhadap penelitian infertilitas pria terletak pada dukungan literatur yang kuat bahwa penerapan *deep learning* pada analisis sperma merupakan langkah logis dalam kemajuan *biomedical screening* modern [8].

Dapat disimpulkan bahwa pendekatan ini memiliki keunggulan signifikan dalam hal akurasi, objektivitas, serta potensi penerapan klinis yang lebih luas. Berdasarkan hal tersebut, penelitian ini berfokus pada judul “Implementasi Jaringan Saraf Tiruan dalam Sistem Klasifikasi Motilitas Sperma untuk Mendukung Diagnosis Infertilitas Pria di Indonesia.” Dalam penelitian ini, kerangka kerja *deep learning* dikembangkan menggunakan *Convolutional Neural Network* (CNN), dengan implementasi khusus melalui arsitektur 2D-CNN. Sistem yang dibangun bertujuan untuk melakukan klasifikasi motilitas sperma secara otomatis guna mengatasi keterbatasan yang terdapat pada analisis manual maupun sistem CASA konvensional. Proses implementasi dilakukan secara bertahap, dimulai dari akuisisi data video mikroskopis, pra-pemrosesan dan ekstraksi frame, hingga pelatihan serta evaluasi model CNN. Diharapkan, penelitian ini dapat memberikan kontribusi dalam pengembangan solusi otomatisasi analisis motilitas sperma yang bersifat objektif, efisien, dan terjangkau, serta memiliki potensi untuk diterapkan secara lebih luas di laboratorium diagnostik di Indonesia.

Studi Pustaka

Motilitas Sperma

Motilitas sperma adalah kemampuan sel sperma bergerak secara aktif menuju sel telur sebagai penentu utama keberhasilan fertilisasi. Menurut WHO (2021), motilitas dibagi menjadi tiga kategori, yaitu *progressive* (PR), *non-progressive* (NP), dan *immotile* (IM). WHO menetapkan ambang batas total motilitas (PR + NP) sebesar 40% dan motilitas progresif minimal 32% sebagai nilai normal [1]. Penurunan motilitas atau *asthenozoospermia* dapat mengindikasikan gangguan fungsi sperma. Dalam penelitian ini, analisis motilitas dilakukan otomatis melalui pengolahan citra video mikroskopis untuk mengidentifikasi pola pergerakan sperma.

Convolutional Neural Network (2D-CNN)

Convolutional Neural Network (CNN) merupakan arsitektur *deep learning* yang dirancang untuk mengenali pola spasial pada citra. CNN terdiri dari beberapa lapisan utama, yaitu *convolution*, *activation* (ReLU), *pooling*, dan *fully connected layer* untuk klasifikasi [7]. Model 2D-CNN


memproses tiap frame video sebagai masukan dua dimensi dan mengekstraksi fitur spasial yang relevan untuk membedakan tiga kelas motilitas. Arsitektur ini dipilih karena efisien, mudah dilatih, dan memiliki performa baik untuk data gambar berukuran terbatas.

Metrik Evaluasi Model

Evaluasi performa model dilakukan menggunakan beberapa metrik utama, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. *Accuracy* digunakan untuk mengukur proporsi prediksi yang benar terhadap seluruh data uji. *Precision* menggambarkan sejauh mana model mampu memberikan prediksi yang tepat pada kelas tertentu, sedangkan *recall* menilai kemampuan model dalam mendeteksi seluruh data positif yang sebenarnya. *F1-score* merupakan rata-rata harmonis antara *precision* dan *recall* yang memberikan keseimbangan antara keduanya [9]. Selain itu, *confusion matrix* digunakan untuk memvisualisasikan distribusi hasil prediksi model, termasuk kesalahan klasifikasi dan tingkat keberhasilan model pada setiap kelas motilitas sperma.

Metodologi Penelitian

Penelitian ini dilakukan untuk membangun sistem klasifikasi motilitas spermamenggunakan pendekatan *convolutional neural network* berbasis video. Proses penelitian terdiri atas lima tahapan utama seperti pada Gambar di bawah:



Gambar 1. Diagram alir penelitian

Data Acquisition

Tahapan ini bertujuan untuk memperoleh data video mikroskopis spermatozoa sebagai bahan pelatihan model. Data yang digunakan berasal dari hasil rekaman mikroskop digital yang telah disimpan dalam direktori Google Drive. Setiap video memiliki format .avi atau .mp4 dengan resolusi awal bervariasi. Pada tahap ini dilakukan proses pemetaan direktori serta pengumpulan informasi terkait nama file, jumlah frame, durasi, resolusi, dan *frame rate*. Informasi ini digunakan untuk memastikan keseragaman dan kualitas video yang akan diproses pada tahap berikutnya.

Data Pre-Processing

Data video yang digunakan memiliki format dan durasi yang bervariasi, sehingga dilakukan tahap pra-pemrosesan agar dapat diolah secara konsisten oleh model. Proses ini meliputi konversi seluruh video ke format .mp4 dengan resolusi seragam 110×110 piksel dan frame rate 30 FPS, diikuti dengan ekstraksi dan pemilihan sejumlah frame tetap (misalnya 90 frame) untuk menyamakan panjang input. Nilai piksel kemudian dinormalisasi ke rentang [0,1] guna menstabilkan pelatihan model. Hasil akhirnya berupa kumpulan frame video yang seragam dalam format, ukuran, dan jumlah frame.

Anotasi dan Data Labelling

Tahap selanjutnya adalah pelabelan video berdasarkan observasi terhadap pola pergerakan spermatozoa. Tiga kategori motilitas digunakan, yaitu PR (*Progressive*) untuk sperma yang bergerak maju secara aktif, NP (*Non-Progressive*) untuk sperma yang bergerak tanpa perpindahan berarti, dan IM (*Immotile*) untuk sperma yang tidak bergerak. Proses labeling dilakukan secara manual melalui pengamatan visual, kemudian hasilnya disimpan dalam *dataframe* berisi pasangan antara *path* video dan kelas labelnya. Tahap ini menjadi fondasi penting bagi model dalam mempelajari pola visual motilitas sperma pada proses pelatihan.

Data Modelling

Pada tahap ini dibangun model deep learning berbasis 2D *Convolutional Neural Network* (CNN) untuk klasifikasi motilitas spermatozoa. Pemilihan arsitektur 2D-CNN didasarkan pada representasi data yang berupa frame citra dari video. Dataset disusun dalam format tensor dengan struktur (jumlah_frame, tinggi, lebar, channel) dan diolah menggunakan *DataLoader* untuk efisiensi


pemrosesan. Arsitektur model terdiri dari beberapa lapisan konvolusi, batch normalization, aktivasi ReLU, dan max pooling guna mengekstraksi fitur spasial dari setiap frame. Lapisan akhir berupa *fully connected layer* dengan aktivasi Softmax untuk menghasilkan prediksi tiga kelas motilitas (PR, NP, IM). Proses pelatihan dilakukan menggunakan optimizer Adam dengan learning rate 0.001 dan *loss function CrossEntropyLoss*, sambil memantau nilai loss dan accuracy di setiap epoch untuk evaluasi performa model.

Data Evaluation

Tahap terakhir adalah evaluasi performa model. Dataset dibagi menjadi *train set* dan *validation set* dengan rasio tertentu. Kinerja model diukur berdasarkan beberapa metrik, yakni Akurasi (*Accuracy*), *Confusion Matrix* dan *Loss Curves*. Selain itu, dilakukan pengamatan terhadap *misclassification* untuk memahami kesalahan prediksi model pada kelas tertentu. Hasil evaluasi digunakan untuk menilai kemampuan model dalam membedakan tiga tipe motilitas spermatozoa secara visual.

Hasil dan Pembahasan

Bagian ini membahas hasil penelitian yang diperoleh dari penerapan model *Convolutional Neural Network (CNN) 2D* untuk mendeteksi tingkat motilitas sperma berdasarkan video mikroskopis. Pembahasan difokuskan pada hasil pengolahan data, arsitektur model yang digunakan, performa pelatihan, serta evaluasi prediksi akhir. Setiap hasil yang disajikan diinterpretasikan untuk menjelaskan efektivitas pendekatan yang diterapkan terhadap permasalahan klasifikasi motilitas sperma.




Gambar 2. Contoh 3 frame video spermatozoa

Gambar 2 menampilkan tiga contoh frame hasil ekstraksi dari video mikroskopis sperma pada penelitian ini. Setiap video memiliki resolusi 110×110 piksel dengan frame rate 30 fps. Berdasarkan pengamatan visual, pergerakan sperma terlihat bervariasi dari cepat, lambat, hingga tidak bergerak sama sekali, yang menggambarkan karakteristik tiga kategori utama yaitu *progressive motile (PR)*, *non-progressive motile (NP)*, dan *immotile (IM)*. Variasi pola gerak ini menjadi dasar bagi model untuk mempelajari fitur spasial dan temporal dari tiap frame video. Selain itu, untuk memastikan kemampuan generalisasi model, data video dibagi ke dalam tiga subset, yaitu data latih (training), data validasi (validation), dan data uji (testing) dengan rasio 70:20:10. Pembagian ini dilakukan secara acak pada tingkat video agar tidak terjadi *data leakage* antar subset. Dengan skema tersebut, model dapat mempelajari pola dari sebagian besar data, divalidasi menggunakan subset berbeda untuk memantau kinerja selama pelatihan, serta diuji pada data baru untuk mengukur performa generalisasi. Sebagai langkah selanjutnya, tahap ini digunakan untuk memastikan bahwa model yang dibangun dapat menangkap pola visual yang relevan dari data frame yang memiliki karakteristik berbeda.

Tabel 1. Arsitektur CNN

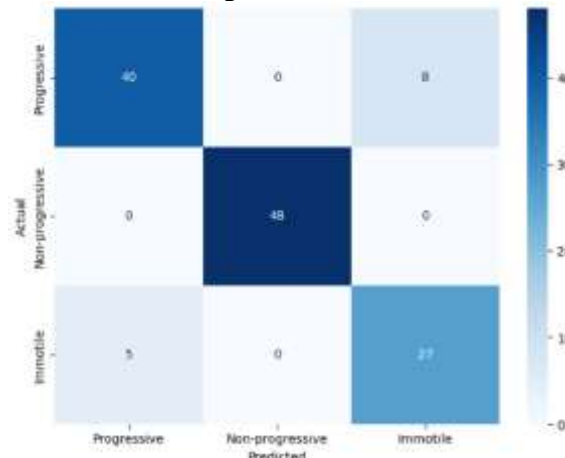
Layer (type)	Output Shape	Parameter
conv2d (Conv2D)	(None, 110, 110, 8)	224
max_pooling2d (MaxPooling2D)	(None, 55, 55, 8)	0
conv2d_1 (Conv2D)	(None, 53, 53, 16)	1,168
max_pooling2d_1 (MaxPooling2D)	(None, 26, 26, 16)	0
flatten_2 (Flatten)	(None, 10816)	0
dense_5 (Dense)	(None, 32)	346,144
dense_6 (Dense)	(None, 3)	99

Tabel 1 menunjukkan konfigurasi lapisan konvolusional dan kepadatan parameter pada model CNN 2D yang digunakan. Lapisan konvolusional pertama (Conv2D) dengan 8 filter berperan mengekstraksi fitur dasar seperti tepi dan pola tekstur dari setiap frame, kemudian diikuti oleh lapisan *pooling* untuk mereduksi dimensi. Lapisan konvolusional kedua memperdalam representasi fitur hingga membentuk 16 peta fitur yang lebih kompleks. Total parameter yang dilatih sebanyak 347.611, menunjukkan bahwa model masih tergolong ringan dan efisien untuk dataset berukuran kecil. Pemilihan dua lapisan konvolusi dianggap optimal untuk menyeimbangkan antara kapasitas model dan risiko *overfitting*.



Gambar 3. Grafik perbandingan training vs validation

Setelah arsitektur disusun, tahap berikutnya adalah mengevaluasi proses pelatihan model terhadap data latih dan validasi. Gambar 3 memperlihatkan grafik perbandingan antara nilai *training* dan *validation* untuk metrik akurasi dan loss. Pola grafik menunjukkan bahwa pada beberapa epoch awal, akurasi pelatihan meningkat secara signifikan sementara akurasi validasi sempat berfluktuasi sebelum akhirnya stabil. Kondisi ini menandakan adanya proses *fine-tuning* terhadap bobot model untuk menyesuaikan fitur yang relevan dengan data validasi. Penurunan *validation loss* yang tajam di awal pelatihan menunjukkan kemampuan model untuk mempelajari representasi yang baik dari data, meskipun setelah beberapa epoch terlihat indikasi *overfitting ringan* akibat ukuran data yang terbatas. Secara umum, hasil pelatihan menunjukkan bahwa model mampu melakukan generalisasi terhadap data validasi dengan akurasi yang cukup baik, walaupun masih terdapat peluang peningkatan melalui strategi augmentasi atau regularisasi tambahan seperti *dropout*.



Gambar 4. Confusion matrix hasil prediksi

Tahap akhir pembahasan ini berfokus pada analisis hasil prediksi menggunakan *confusion matrix* seperti ditampilkan pada Gambar 4. Matriks ini memberikan gambaran distribusi hasil klasifikasi antar kelas motilitas. Terlihat bahwa model memiliki performa terbaik dalam mengklasifikasikan kelas *progressive motile* (PR) dan *immotile* (IM), sementara sebagian kasus *non-progressive motile* (NP) masih keliru terklasifikasi sebagai PR. Hal ini dapat disebabkan oleh kemiripan pola gerak antara kedua kategori tersebut, terutama pada sperma yang bergerak lambat namun tetap menunjukkan arah tertentu. Selanjutnya, evaluasi performa model juga dianalisis menggunakan *classification report* untuk memperoleh metrik precision, recall, dan f1-score pada setiap kelas motilitas sperma. Berdasarkan tabel hasil pengujian pada tingkat frame, model CNN 2D menunjukkan kinerja yang cukup baik dengan akurasi keseluruhan sebesar 90%. Secara keseluruhan, nilai *macro average* dan *weighted average* yang berada di kisaran 0.89–0.90 memperlihatkan bahwa model memiliki kinerja yang stabil di ketiga kelas meskipun terdapat sedikit ketidakseimbangan antara performa kelas PR dan IM. Hasil ini sejalan dengan distribusi data dan karakteristik gerakan sperma, di mana pola gerak progresif dan immotil cenderung memiliki variasi yang lebih tinggi dibandingkan pola non-progresif yang relatif konsisten. Dengan demikian, hasil ini menunjukkan bahwa pendekatan berbasis CNN 2D mampu mengidentifikasi pola visual yang cukup baik untuk mendeteksi tingkat motilitas sperma. Namun demikian, untuk memperoleh akurasi yang lebih tinggi, diperlukan pengembangan model berbasis video (*3D-CNN* atau *Optical Flow*) agar informasi temporal pergerakan dapat dimanfaatkan secara lebih optimal.

Kesimpulan

Penelitian ini berhasil mengimplementasikan sistem klasifikasi motilitas sperma berbasis 2D *Convolutional Neural Network* (CNN) yang mampu mengidentifikasi tiga kategori motilitas (PR, NP, IM) secara otomatis dengan akurasi mencapai 90%. Hasil ini membuktikan bahwa pendekatan deep learning dapat menjadi alternatif efektif terhadap metode manual dan sistem CASA konvensional yang memiliki keterbatasan biaya serta aksesibilitas. Model CNN 2D yang dikembangkan mampu mengekstraksi fitur spasial dari frame video secara efisien dan memberikan hasil prediksi yang konsisten. Namun, tantangan masih ditemukan pada perbedaan pola gerak halus antara kelas NP dan PR, yang menyebabkan sebagian kesalahan klasifikasi. Untuk pengembangan selanjutnya, disarankan penerapan arsitektur berbasis 3D-CNN atau integrasi optical flow guna menangkap informasi temporal secara lebih mendalam. Dengan demikian, sistem ini berpotensi mendukung peningkatan akurasi, objektivitas, dan efisiensi analisis motilitas sperma di laboratorium diagnostik Indonesia.

Daftar Pustaka

- [1] WHO, *WHO Manual for the Laboratory Examination and Processing of Human Semen*, 6th Edition. World Health Organization, 2021.
- [2] WHO, “Infertility.” [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/infertility>
- [3] Safitriana, “Kemandulan (Infertil): Stigma Negatif Pada Wanita Indonesia,” *Direktorat Jenderal Kesehatan Lanjutan Kementerian Kesehatan*, Mei 2022. [Online]. Available: https://keslan.kemkes.go.id/view_artikel/12/kemandulan-infertil-stigma-negatif-pada-wanita-indonesia?
- [4] U. I. Ikatan Ahli, *Panduan Penanganan Infertilitas Pria*, 3rd ed. Ikatan Ahli Urologi Indonesia, 2022.
- [5] edy Priyanto, F. Arjadi, and N. Agatri, “PERBANDINGAN HASIL ANALISIS SPERMA DARI PROSES COITUS INTERRUPTUS DAN MASTURBASI PADA KASUS INFERTILITAS,” *Mandala Heart*, vol. 12, no. 2, Desember 2019, doi: <https://doi.org/10.20884/1.mandala.2019.12.2.1601>.
- [6] J. Yaniz, C. Alquézar-Baeta, and J. Yagüe-Martínez, “Expanding the Limits of Computer-Assisted Sperm Analysis through the Development of Open Software,” *Biology*, vol. 9, no. 8, p. 207, Agustus 2020, doi: <https://doi.org/10.3390/biology9080207>.
- [7] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [8] J. Wang *et al.*, “Testing the generalizability and effectiveness of deep learning models among clinics: sperm detection as a pilot study,” *Reprod. Biol. Endocrinol.*, vol. 22, no. 1, p. 59, May 2024, doi: 10.1186/s12958-024-01232-8.
- [9] S. Sathyanarayanan, “Confusion Matrix-Based Performance Evaluation Metrics,” *Afr. J. Biomed. Res.*, pp. 4023–4031, Nov. 2024, doi: 10.53555/AJBR.v27i4S.4345.