



Klasifikasi Motilitas Sperma dengan LSTM (*Long Short-Term Memory*) dan Menggunakan Optimasi SGD (*Stochastic Gradient Descent*)

Vaizal Asy'ari¹, Ani Dijah Rahajoe², I Gede Susrama Mas Diyasa^{*3}

^{1,2,3}Universitas Pembangunan Nasional "Veteran" Jawa Timur, Indonesia

E-mail: vaiz.asyari@gmail.com, anidijah.if@upnjatim.ac.id, anidijah.if@upnjatim.ac.id

Article Info	Abstract
Article History Received: 2025-08-05 Revised: 2025-09-12 Published: 2025-10-06	This study aims to develop a machine learning model based on the neural network architecture Long Short-Term Memory (LSTM) that is able to classify sperm movement abnormalities automatically. The dataset used consists of particle, mean velocity, linearity, and type features as normal and abnormal classification targets. The model training process was carried out by optimizing Stochastic Gradient Descent (SGD) using two scenarios, namely Aggressive SGD and SGD Nesterov, with a data sharing of 10% test data and 90% training-validation data (80%:20%). The results showed that the Aggressive SGD scenario provided the best performance with an accuracy of 87%, 100% precision, 78% recall, and an F1-score of 88%, compared to the SGD Nesterov scenario which only achieved an accuracy of 73%. These results indicate that the use of LSTM with SGD optimization is able to detect sperm motility abnormalities quite accurately, especially in recognizing normal sperm categories, although there are still challenges in detecting abnormal categories. This research is expected to contribute to the development of an automated machine learning-based system to support the diagnosis process of male infertility, especially related to sperm movement abnormalities, as well as become a basis for further research by comparing other machine learning methods.
Keywords: <i>Sperm Motility;</i> <i>LSTM;</i> <i>SGD Optimization.</i>	

Artikel Info	Abstrak
Sejarah Artikel Diterima: 2025-08-05 Direvisi: 2025-09-12 Dipublikasi: 2025-10-06	Penelitian ini bertujuan untuk mengembangkan sebuah model machine learning berbasis neural network arsitektur Long Short-Term Memory (LSTM) yang mampu mengklasifikasikan abnormalitas pergerakan sperma secara otomatis. Dataset yang digunakan terdiri dari fitur particle, mean velocity, linearity, dan type sebagai target klasifikasi normal dan abnormal. Proses pelatihan model dilakukan dengan optimasi Stochastic Gradient Descent (SGD) menggunakan dua skenario, yaitu Aggressive SGD dan SGD Nesterov, dengan pembagian data 10% data uji dan 90% data latih-validasi (80%:20%). Hasil penelitian menunjukkan bahwa skenario Aggressive SGD memberikan performa terbaik dengan akurasi 87%, presisi 100%, recall 78%, dan F1-score 88%, dibandingkan skenario SGD Nesterov yang hanya mencapai akurasi 73%. Hasil ini mengindikasikan bahwa penggunaan LSTM dengan optimasi SGD mampu mendeteksi abnormalitas motilitas sperma secara cukup akurat, khususnya dalam mengenali kategori sperma normal, meskipun masih memiliki tantangan dalam mendeteksi kategori abnormal. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem otomatis berbasis machine learning untuk mendukung proses diagnosis infertilitas pria, khususnya yang berkaitan dengan abnormalitas pergerakan sperma, serta menjadi landasan bagi penelitian lanjutan dengan membandingkan metode machine learning lainnya.
Kata kunci: <i>Motilitas Sperma;</i> <i>LSTM;</i> <i>Optimasi SGD.</i>	

I. PENDAHULUAN

Infertilitas merupakan gangguan pada sistem reproduksi, baik pada pria maupun wanita, yang ditandai dengan ketidakmampuan untuk mencapai kehamilan setelah melakukan hubungan seksual secara teratur tanpa kontrasepsi selama satu tahun atau lebih [1]. Infertilitas menjadi salah satu masalah kesehatan yang signifikan dan memengaruhi banyak pasangan di seluruh dunia. Berdasarkan laporan World Health Organization (WHO), sekitar 17,5% dari populasi dewasa, setara dengan satu dari

enam orang di seluruh dunia mengalami infertilitas [1]. Di Indonesia, sekitar 10-15% pasangan usia subur menghadapi masalah infertilitas [2]. Sebuah studi deskriptif dilakukan pada pasangan yang mengalami infertilitas di *University of Khartoum Fertility Center, Saad Abualila Teaching Hospital Sudan*, diketahui bahwa dari 800 pasangan yang diteliti, 342 wanita (42,8%) dan 284 pria (35,5%) mengalami infertilitas. Ini menunjukkan bahwa infertilitas dapat terjadi pada kedua jenis kelamin [3]. Infertilitas pada pria dapat disebabkan oleh

penyumbatan saluran reproduksi, gangguan hormonal, kegagalan testis menghasilkan sperma, fungsi dan kualitas sperma yang tidak normal. Di antara berbagai parameter sperma, morfologi dan motilitas dianggap sebagai prediktor kuat tingkat fertilitas pria [4]. Motilitas sperma yang rendah dapat menghambat kemampuan sperma untuk mencapai dan membuahi sel telur, sehingga analisis akurat terhadap parameter ini sangat penting.

Dalam menganalisis abnormalitas pergerakan sperma dapat diamati dengan metode konvensional melalui pengamatan mikroskopik, yang membutuhkan keahlian tinggi, rentan terhadap kesalahan subjektif, sehingga perlu memiliki penguji yang berpengalaman dengan keahlian dan keterampilan dalam menilai pergerakan spermatozoa untuk dapat memperoleh hasil tes akurat [5]. Untuk mengetahui hasil dengan pengamatan mikroskopik ini memerlukan waktu yang cukup lama. Selain metode konvensional tersebut, saat ini juga menggunakan teknologi yang bernama *Computer-Aided Sperm Analysis (CASA)* sebagai alat otomatis yang memanfaatkan kamera dan perangkat lunak dalam menganalisis data dari evaluasi mikroskop, akan tetapi produk CASA komersial terlalu mahal [6] dan tidak terbuka untuk umum [7]. Sebagai alternatif, menerapkan model pembelajaran mesin untuk mendeteksi dan mengklasifikasikan abnormalitas motilitas sperma secara otomatis, memberikan solusi yang lebih efektif dan akurat dalam analisis motilitas sperma.

Neural network adalah salah satu metode pembelajaran mesin yang telah terbukti efektif dalam klasifikasi dan deteksi pola pada data yang kompleks, termasuk citra dan lintasan pergerakan. Struktur *neural network* meliputi *input layer*, *hidden layer*, dan *output layer* [8]. Pada pembelajaran mesin ada beberapa jenis *neural network* yang digunakan untuk berbagai tugas, yaitu *Artificial Neural Network (ANN)*, *Convolutional Neural Network (CNN)*, dan *Recurrent Neural Network (RNN)* [9]. Pada penelitian ini jenis *neural network* yang digunakan dalam pengklasifikasian abnormalitas sperma adalah *Recurrent Neural Network (RNN)* dengan arsitektur *Long Short-Term Memory (LSTM)*. Dalam penelitian dengan judul *Prediction of Semen Quality Using Artificial Neural Network* [10], meneliti mengenai kualitas cairan semen dengan arsitektur MLP menggunakan dua *hidden layer* (11 *neuron* pada *hidden layer* pertama dan 8 *neuron* pada *hidden layer* kedua)

dan menghasilkan dua *output* yaitu, normal atau tidak, dengan hasil akurasi 90,78% untuk konsentrasi sperma. Arsitektur MLP juga digunakan pada klasifikasi kanker payudara dengan split data 80%:20% memperoleh nilai akurasi sebesar 97,7% [11]. Adapun penelitian terkait biomedis mengenai arsitektur LSTM digunakan pada penelitian klasifikasi kasus penyakit kanker yang benar dan kasus non-kanker, menghasilkan akurasi 84% [12]. Penelitian lainnya membandingkan CNN dengan LSTM dalam analisis deteksi penyakit paru-paru, menghasilkan akurasi sebesar 92,5% pada arsitektur CNN dan akurasi sebesar 94,1% pada arsitektur LSTM [13].

Neural network sering kali memerlukan optimisasi untuk mencapai akurasi yang lebih baik, untuk mengatasi hal tersebut, optimasi seperti *Adaptive Moment Estimation with Infinity Norm (Adamax)*, *Adaptive Gradient Algorithm (Adagrad)*, *Adaptive Delta (Adadelata)*, *Follow The Regularized Leader (FTRL)*, dan *Stochastic Gradient Descent (SGD)* dapat digunakan sebagai teknik optimasi dalam meningkatkan akurasi hasil klasifikasi dan deteksi pola dari *neural network*. Penelitian mengenai *neural network* untuk pengolahan citra medis [14] menggunakan menggunakan algoritma Adam dan RMSprop untuk menemukan kombinasi terbaik. Hasil penelitian menunjukkan bahwa algoritma Adam memberikan performa terbaik dengan akurasi sebesar 92%. Penelitian mengenai perbandingan optimasi SGD, Adadelata, dan Adam dalam klasifikasi hydrangea menggunakan *Convolutional Neural Network* [15], menunjukkan optimasi Adam menghasilkan akurasi tertinggi mencapai 83,5%. Dalam penelitian ini, kombinasi *neural network* dan optimasi akan diterapkan untuk mendeteksi dan mengklasifikasikan lintasan pergerakan sperma, serta mengidentifikasi abnormalitas yang dapat berkontribusi pada masalah infertilitas. Penelitian ini fokus pada prediksi abnormalitas motilitas sperma berdasarkan mean velocity dan lineritas sperma. Pada penelitian ini digunakan metode LSTM dengan optimasi *Stochastic Gradient Descent (SGD)* untuk mengklasifikasikan motilitas sperma. Hasil penelitian ini diharapkan dapat memberikan kontribusi pada pengembangan sistem otomatis yang lebih akurat dalam deteksi abnormalitas motilitas sperma, serta menjadi dasar bagi penelitian lebih lanjut dalam penerapan metode pembelajaran mesin pada analisis motilitas sperma.

II. METODE PENELITIAN

A. Motilitas Sperma

Motilitas sperma adalah kemampuan sperma untuk bergerak secara progresif agar dapat mencapai dan menembus sel telur (ovum) sehingga memungkinkan terjadinya pembuahan atau fertilisasi. Motilitas ini dianggap sebagai indikator penting dan faktor kunci dalam keberhasilan proses pembuahan. Berdasarkan manual laboratorium WHO [16] pria dengan ejakulasi yang mengandung kurang dari 42% sperma yang bergerak atau hanya 30% sperma dengan motilitas progresif diklasifikasikan mengalami Asthenozoospermia. Kondisi ini merupakan gangguan pada kemampuan gerak sperma yang sering menjadi penyebab utama ketidaksuburan pada pria.

Motilitas sperma dikendalikan oleh mekanisme sinyal molekuler dan struktural yang kompleks. Motilitas sperma dinyatakan dalam bentuk persentase dan diukur dengan menghitung jumlah sperma yang bergerak dan tidak bergerak melalui pengamatan mikroskopis. Untuk menilai adanya gangguan motilitas, setidaknya 300 sperma diamati dan diklasifikasi. Motilitas sperma dibagi ke dalam tiga kategori, yaitu: (1) Motilitas Progresif, di mana sperma bergerak aktif secara linear; (2) Motilitas Non-Progresif, di mana sperma bergerak dengan pola tidak linear seperti zig-zag atau bergetar di tempat; dan (3) Immotilitas, di mana sperma mati atau sama sekali tidak bergerak [17]. Penurunan motilitas sperma dapat memperpanjang waktu yang dibutuhkan untuk mencapai kehamilan dan memerlukan pemeriksaan lebih lanjut terkait masalah infertilitas pada pria.

B. Abnormalitas Motilitas Sperma

Abnormalitas pergerakan sperma adalah ketidaknormalan atau penurunan kemampuan spermatozoa untuk bergerak dengan baik, spermatozoa tidak mampu bergerak dengan baik atau tidak bergerak sama sekali. Abnormalitas pergerakan spermatozoa merupakan kelainan pada pergerakan sperma sehingga berdampak pada infertilitas pria (spermatozoa tidak dapat mencapai dan menembus sel telur). Menurut *World Health Organization* (2021) pergerakan spermatozoa dibagi menjadi beberapa kategori, yaitu:

1. Progresif cepat adalah spermatozoa bergerak aktif, baik secara linier maupun

dalam lingkaran besar, yang menempuh jarak dari titik awal hingga titik akhir, minimal 25 $\mu\text{m/s}$.

2. Progresif lambat adalah spermatozoa bergerak aktif, baik secara linier maupun dalam lingkaran besar, yang menempuh jarak dari titik awal hingga titik akhir, sebesar 5 hingga < 25 $\mu\text{m/s}$.

3. Non-progresif, semua pola gerakan ekor spermatozoa tanpa keberlanjutan, yaitu berenang dalam lingkaran kecil, gaya flagella menggeser kepala kurang dari 5 $\mu\text{m/s}$.

4. Imotil, tidak ada pergerakan ekor spermatozoa.

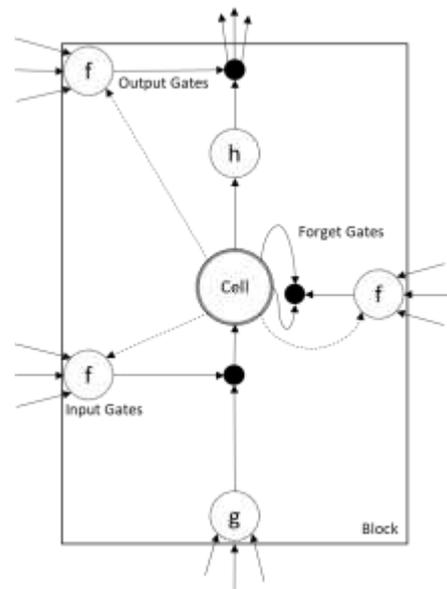
C. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah salah satu arsitektur *Recurrent Neural Network* (RNN) yang dimodifikasi dalam menangani masalah menghilangnya dan meledaknya gradien dan mengatasi masalah pelatihan pada urutan panjang dan mempertahankan memori [19]. Pada arsitektur LSTM terdiri dari tiga lapisan utama [12], yaitu:

1. *Forget gate layer*, menentukan informasi mana dari keadaan sebelumnya yang dapat diabaikan.

2. *Input gate layer*, mengidentifikasi informasi baru yang akan disimpan dan diteruskan ke lapisan berikutnya.

3. *Output gate layer*, memprediksi output berdasarkan keadaan saat ini.



Gambar 1. Arsitektur LSTM

LSTM memungkinkan model untuk mempelajari ketergantungan jangka panjang dalam data. LSTM mampu mempelajari lebih dari 1000 langkah sebelumnya tergantung kompleksitas jaringan. Gambar 5 menjelaskan arsitektur LSTM yang terdiri dari tiga *gate* (f), yaitu *input*, *forget*, dan *output*. Fungsi aktivasi pada *input gates* (g) yaitu *tanh*, dan *output gates* (h) yaitu *sigmoid*. Fungsi aktivasi *sigmoid* yang merupakan aktivasi untuk *gate* tertutup (inisialisasi 0 artinya informasinya diblok total yang mendakan untuk menyingkirkan informasi pembelajaran) dan *gate* terbuka (inisialisasi 1 artinya mengikutkan keseluruhan informasi yang menandakan untuk menjaga informasi pembelajaran). Koneksi bobot dari *cell* ke *gate* ditampilkan dengan garis putus-putus. Semua koneksi lain di dalam blok setara, yang memiliki bobot tetap bernilai 1.

III. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan dataset sperm motility dengan variabel *particle*, *mean velocity*, *linearity*, dan *type* sebagai target untuk memprediksi termasuk sperma normal atau abnormal. Dataset sperm motility ditunjukkan pada TABEL 1, variabel *particle* merujuk sebagai pengidentifikasi unik pada setiap sperma individu, variabel *mean velocity* dan variabel *linearity* merupakan fitur yang menggambarkan karakteristik pergerakan sperma, *mean velocity* menunjukkan kecepatan rata-rata sperma dalam $\mu\text{m/s}$, sedangkan *linearity* mengukur seberapa lurus jalur pergerakan sperma, variabel *type* yang merupakan variabel target menunjukkan klasifikasi motilitas sperma. Berdasarkan variabel *type* menunjukkan klasifikasi biner, nilai 0 mewakili sperma abnormal dan nilai 1 mewakili sperma normal. Dataset sperm motility tersebut kemudian diambil 10% untuk dijadikan data uji, kemudian data dipartisi menjadu dua untuk dijadikan data latih dan data validasi dengan ratio 80%:20%.

Tabel 1. Dataset sperm motility

Particle	Mean Velocity	Linearity	Type
0	38,29516	0,360177	0
1	53,56203	0,747693	1
2	63,35677	0,830854	1
3	12,43705	0,420411	0
5	23,79502	0,072762	0
...
783	20,87363198	0,525224797	0
784	10,18724439	0,526974918	0

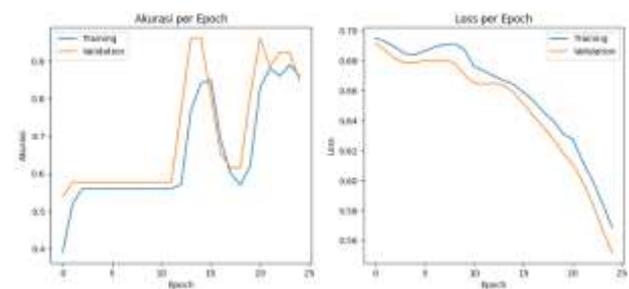
786	80,09160587	0,340016426	0
788	56,50635836	0,913971873	1
794	25,68930144	0,544817732	0

Pada tahap awal dilakukan pembuatan model menggunakan metode LSTM dengan menggunakan perbandingan parameter SGD yang terdiri dari dua skenario yang ditunjukkan pada TABEL 2. Pada skenario pertama (*Aggressive SGD*) laju pembelajaran yang lebih tinggi dan momentum untuk potensi konvergensi yang lebih cepat. Pada skenario kedua (*SGD nesterov*) menggunakan laju pembelajaran dan momentum sama seperti *aggressive SGD* dan mengaktifkan *Nesterov Accelerated Gradient* untuk konvergensi yang lebih stabil, sebagai upaya untuk memasukkan faktor korektif ke dalam bentuk momentum konvensional [20].

Tabel 2. Perbandingan Parameter Optimasi Sgd

No	Skenario Parameter	Learning Rate	Momentum	Nesterov
1	Aggressive SGD	0,05	0,9	False
2	SGD nesterov	0,05	0,9	True

Selanjutnya masing-masing skenario diuji sesuai dengan parameter masing-masing. Skenario pertama dengan pembagian data latih 80% dan data validasi 20% menggunakan 25 *epoch* menghasilkan perbandingan performa yang ditunjukkan pada Gambar 2.

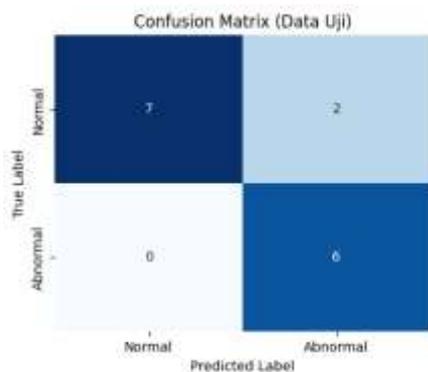


Gambar 2. Skenario *Aggressive SGD*

Gambar 2 menunjukkan hasil pelatihan model LSTM dengan skenario pembagian data 80% data latih, 20% validasi, dan 10% data uji menggunakan varian optimasi *Aggressive SGD* (learning rate 0.05, momentum 0.9, tanpa *Nesterov*). Grafik akurasi memperlihatkan adanya fluktuasi signifikan selama proses pelatihan. Pada awalnya, akurasi meningkat secara bertahap hingga mencapai sekitar 60%, kemudian melonjak tajam pada epoch ke-13 hingga mencapai akurasi sangat tinggi di atas

90% pada data validasi. Namun, setelahnya akurasi menurun drastis dan mengalami fluktuasi yang cukup tajam hingga mendekati akhir epoch. Meskipun demikian, akurasi model pada kedua data (latih dan validasi) tetap mampu mencapai lebih dari 85% di akhir proses pelatihan.

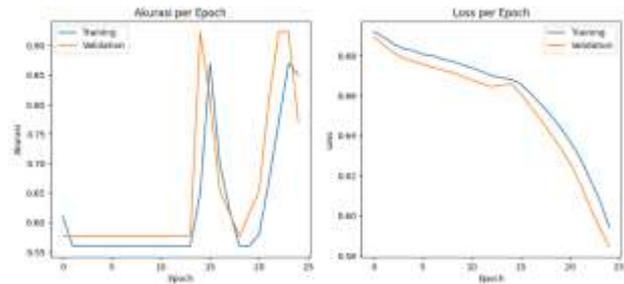
Pada grafik loss, terlihat bahwa penurunan loss berlangsung lebih stabil dan konsisten baik pada data latih maupun validasi. Loss terus menurun secara bertahap dari awal hingga akhir epoch, meskipun sempat mengalami sedikit kenaikan di pertengahan proses sebelum kembali turun lebih signifikan menjelang akhir epoch. Pola fluktuasi akurasi yang cukup tajam ini mengindikasikan bahwa model cukup sensitif terhadap perubahan bobot selama proses optimasi, namun tetap berhasil menemukan titik konvergensi yang lebih baik di akhir pelatihan. Hasil ini memperlihatkan bahwa parameter Aggressive SGD mampu mendorong model belajar dengan cepat, meskipun memerlukan perhatian lebih terkait kestabilan selama proses training.



Gambar 3. Confusion matrix skenario aggressive SGD

Berdasarkan confusion matrix pada Gambar 3, data dengan label asli "Normal" berjumlah total 9 sampel. Dari jumlah tersebut, 7 sampel berhasil diprediksi dengan benar sebagai "Normal", sedangkan 2 sampel lainnya salah diprediksi sebagai "Abnormal". Untuk data dengan label asli "Abnormal", terdapat total 6 sampel. Dari jumlah ini, 0 sampel berhasil diprediksi dengan benar sebagai "Abnormal", dan seluruh 6 sampel salah diprediksi sebagai "Normal". Ini menunjukkan bahwa model memiliki kinerja yang baik dalam mengidentifikasi kelas "Normal" namun gagal total dalam mengidentifikasi kelas "Abnormal". Akurasi keseluruhan model adalah 87%.

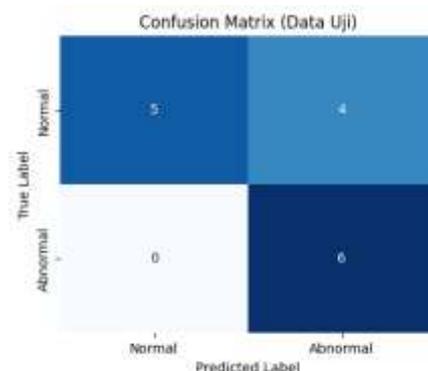
Skenario kedua dengan pembagian data latih 80% dan data validasi 20% menggunakan 25 epoch menghasilkan perbandingan performa yang ditunjukkan pada Gambar 4.



Gambar 4. Skenario SGD Nesterov

Gambar 4 menunjukkan hasil pelatihan model LSTM pada skenario kedua dengan optimasi SGD Nesterov. Pada grafik Akurasi per Epoch, terlihat fluktuasi yang signifikan untuk akurasi pelatihan (Training) maupun validasi (Validation). Akurasi awalnya berada di sekitar 0.60, kemudian stabil hingga epoch ke-12. Setelah itu, terjadi lonjakan akurasi yang tajam mencapai lebih dari 0.90 di sekitar epoch ke-14 untuk data validasi, namun diikuti penurunan drastis. Pola serupa terjadi lagi menjelang akhir epoch, di mana akurasi validasi melonjak kembali mendekati 0.90 sebelum akhirnya menurun.

Sementara itu, grafik Loss per Epoch menunjukkan penurunan yang lebih stabil dan konsisten untuk loss pelatihan dan validasi. Loss berawal dari sekitar 0.69 dan terus menurun secara bertahap hingga mendekati 0.585 di akhir epoch. Meskipun ada fluktuasi tajam pada akurasi, penurunan loss yang berkelanjutan mengindikasikan bahwa model masih dalam proses pembelajaran dan menemukan titik konvergensi.



Gambar 5. Confusion matrix skenario SGD nesterov

Berdasarkan *confusion matrix* pada gambar, data dengan label asli "Normal" berjumlah total 9 sampel. Dari jumlah tersebut, 5 sampel berhasil diprediksi dengan benar sebagai "Normal", sedangkan 4 sampel lainnya salah diprediksi sebagai "Abnormal". Untuk data dengan label asli "Abnormal", terdapat total 6 sampel. Dari jumlah ini, 0 sampel berhasil diprediksi dengan benar sebagai "Abnormal", dan seluruh 6 sampel salah diprediksi sebagai "Normal". Ini menunjukkan bahwa model memiliki kinerja dalam mengidentifikasi kelas "Normal", namun gagal total dalam mengidentifikasi kelas "Abnormal". Model tampaknya memprediksi semua sampel "Abnormal" sebagai "Normal". Akurasi keseluruhan model adalah 73%.

Dari model LSTM yang telah dibuat dan diterapkan pada data latih dan data validasi, kemudian dilakukan pengujian dengan data uji menghasilkan performa model yang ditunjukkan pada Table 3.

Tabel 3. Performance perbandingan skenario pertama dan kedua

Skenario	Optimizer Variant	Akurasi	Presisi	Recall	F1-score
Pertama	Aggressive SGD	87%	100%	78%	88%
Kedua	SGD Nesterov	73%	100%	56%	71%

Berdasarkan hasil eksperimen yang dilakukan, penggunaan dua varian optimasi *Stochastic Gradient Descent* (SGD), yaitu *aggressive SGD* dan *nesterov*, menunjukkan perbedaan performa dalam mendeteksi abnormalitas pergerakan sperma. *Aggressive SGD* menunjukkan keunggulannya dengan akurasi sebesar 87%, presisi 100%, *recall* 78%, dan F1-score 88%. Ini memperlihatkan kestabilan model meskipun proporsi data validasi lebih kecil. Sementara itu, varian *nesterov* memiliki akurasi 73% dengan presisi 100%, *recall* 56%, dan F1-score 71%. Meskipun presisi tinggi, nilai *recall* yang menurun menunjukkan adanya kecenderungan model lebih konservatif dalam memutuskan kategori positif, sehingga beberapa abnormalitas tidak terdeteksi. Secara keseluruhan, hasil ini mengindikasikan bahwa penggunaan *aggressive SGD* lebih sesuai diterapkan pada studi ini karena mampu memberikan keseimbangan yang lebih baik antara akurasi, presisi, *recall*, dan F1-score.

IV. SIMPULAN DAN SARAN

A. Simpulan

Penelitian dengan penerapan algoritma *Long Short-Term Memory* (LSTM) dengan menggunakan optimasi *Stochastic Gradient Descent* (SGD) untuk memprediksi abnormalitas motilitas sperma dengan fitur utama mean velocity dan linearitas dengan 10% data uji, dan partisi untuk data latih dan data validasi yaitu, 80%:20% menunjukkan akurasi optimal sebesar 87% pada skenario *aggressive SGD*. Penelitian ini memberikan bukti empiris bahwa algoritma LSTM dengan optimasi SGD dapat menjadi model prediksi untuk mendeteksi abnormalitas motilitas sperma. Hasil penelitian ini diharapkan dapat memberikan kontribusi bagi pengembangan sistem diagnostik otomatis khususnya dalam penilaian infertilitas pria yang berkaitan dengan motilitas sperma. Penelitian selanjutnya disarankan melakukan perbandingan dengan metode pembelajaran mesin lain guna memperluas kajian ilmiah di bidang ini.

B. Saran

Pembahasan terkait penelitian ini masih sangat terbatas dan membutuhkan banyak masukan, saran untuk penulis selanjutnya adalah mengkaji lebih dalam dan secara komprehensif tentang Klasifikasi Motilitas Sperma dengan LSTM (*Long Short-Term Memory*) dan Menggunakan Optimasi SGD (*Stochastic Gradient Descent*).

DAFTAR RUJUKAN

- A. Aristoteles, A. Syarif, and F. R. Lumbanraja, "Systematic Review: Perkembangan Machine Learning Pada Sperma Manusia," *Jurnal Teknoinfo*, vol. 17, no. 1, pp. 112–118, Jan. 2023, doi: 10.33365/jti.v17i1.2078.
- A. Badura *et al.*, "Prediction of Semen Quality Using Artificial Neural Network," *J Appl Biomed*, vol. 17, no. 3, pp. 167–174, Sep. 2019, doi: 10.32725/jab.2019.015.
- B. Raharjo, *Deep Learning dengan Python*. Semarang: Yayasan Prima Agus Teknik, 2022.
- D. Irfan, R. Rosnelly, M. Wahyuni, J. T. Samudra, and A. Rangga, "Perbandingan Optimasi SGD, Adadelta, dan Adam Dalam Klasifikasi Hydrangea Menggunakan CNN," *JOURNAL OF SCIENCE AND SOCIAL RESEARCH*, vol. 5,

no. 2, p. 244, Jun. 2022, doi:
10.54314/jssr.v5i2.789.

Industrial Automation (ICAMIMIA), IEEE,
Nov. 2023, pp. 347–351.

- I. Cahya, Ayuwati, and T. Ningsih, "Sistem Prediksi Berbasis Recurrent Neural Network Untuk Klasifikasi Penyakit Kanker," *Jurnal Ilmu Komputer dan Teknologi*, vol. 1, no. 1, pp. 7–11, Jan. 2025.
- I. D. Sudirman, *Data-Driven Entrepreneur: Bisnis Berdaya Saing dengan Data Science dan Rapid Miner*. Jakarta: Salemba Infotek, 2023.
- J. Yániz *et al.*, "Expanding the Limits of Computer-Assisted Sperm Analysis through the Development of Open Software," *Biology (Basel)*, vol. 9, no. 8, p. 207, Aug. 2020, doi: 10.3390/biology9080207.
- K. Anwar, R. Maruf, F. Susanto, and M. B. Ryando, "Analisis Performa Deteksi Penyakit Paru-Paru dengan Model Klasifikasi Gambar Menggunakan LSTM Deep Learning," *Jurnal Ilmiah Universitas Batanghari Jambi*, vol. 25, no. 1, p. 972, Feb. 2025, doi: 10.33087/jiubj.v25i1.5697.
- K. Jaka, B. H. Hayadi, Wanayumini, and R. Rosnelly, "Komparasi Metode Multi Layer Perceptron (MLP) dan Support Vector Machine (SVM) untuk Klasifikasi Kanker Payudara," *MIND Journal*, vol. 7, no. 1, pp. 51–60, Jun. 2022, doi: 10.26760/mindjournal.v7i1.51-60.
- M. Kraemer, C. Fillion, B. Martin-Pont, and J. Auger, "Factors influencing human sperm kinematic measurements by the Celltrak computer-assisted sperm analysis system," *Human Reproduction*, vol. 13, no. 3, pp. 611–619, Mar. 1998, doi: 10.1093/humrep/13.3.611.
- M. Rubessa *et al.*, "High-throughput sperm assay using label-free microscopy: morphometric comparison between different sperm structures of boar and stallion spermatozoa," *Anim Reprod Sci*, vol. 219, p. 106509, Aug. 2020, doi: 10.1016/j.anireprosci.2020.106509.
- M. Y. Anshori, V. Asy'Ari, T. Herlambang, and I. W. Farid, "Forecasting Occupancy Rate Using Neural Network at Hotel R," in *2023 International Conference on Advanced Mechatronics, Intelligent Manufacture and MediSage Indonesia*, "Trend Infertilitas yang Marak Terjadi di Negara Berkembang yang Juga Terjadi di Indonesia," MediSage. Accessed: Apr. 24, 2025. [Online]. Available: <https://mymedisage.com/newsletters/trend-infertilitas-yang-marak-terjadi-di-negara-berkembang-yang-juga-terjadi-di-indonesia?>
- O. G. Elhoussein, M. A. Ahmed, S. O. Suliman, I. Yahya, and I. Adam, "Epidemiology of infertility and characteristics of infertile couples requesting assisted reproduction in a low-resource setting in Africa, Sudan," *Fertil Res Pract*, vol. 5, no. 1, p. 7, Dec. 2019, doi: 10.1186/s40738-019-0060-1.
- R. Dcunha *et al.*, "Current Insights and Latest Updates in Sperm Motility and Associated Applications in Assisted Reproduction," *Reproductive Sciences*, vol. 29, no. 1, pp. 7–25, Jan. 2022, doi: 10.1007/s43032-020-00408-y.
- S. Fatimah, "Neural Network Optimization Optimization For Medical Image Processing," *Jurnal Komputer Indonesia*, vol. 2, no. 1, pp. 33–40, Jun. 2023, doi: 10.37676/jki.v2i1.566.
- S. H. Haji and A. M. Abdulazeez, "Comparison of Optimization Techniques Based on Gradient Descent Algorithm: A Review," *PalArch's Journal of Archaeology of Egypt / Egyptology*, vol. 18, no. 4, pp. 2715–2743, Feb. 2021.
- WHO, "Infertility," World Health Organization. Accessed: Dec. 23, 2024. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/infertility>
- World Health Organization (WHO) Department of Sexual and Reproductive Health and Research, "Infertility Prevalence Estimates, 1990–2021," Geneva, Apr. 2023.
- World Health Organization, *WHO laboratory manual for the examination and processing of human semen (Sixth Edition)*, 6th ed. World Health Organization, 2021.