

Teknologi Pose Estimation Untuk Model Klasifikasi Gerakan *Hammer-Curl*

^{1*}Galang Elang Perkasa, ²Patmi Kasih, ³Risa Helilintar

¹⁻³ Universitas Nusantara PGRI Kediri

E-mail: ¹galelang5656@gmail.com, ²fatkasihi@gmail.com, ³risa.helilintar@gmail.com

Penulis Korespondens : Galang Elang Perkasa

Abstrak—Penelitian ini bertujuan untuk mengembangkan sistem kecerdasan buatan berbasis perkiraan pose yang mampu mendeteksi dan mengevaluasi gerakan hammer-curl secara akurat. Sistem ini menganalisis pola gerakan tubuh dari video dengan memanfaatkan koordinat titik-titik tubuh (landmark), seperti bahu, siku, dan pergelangan tangan. Data landmark disusun dalam bentuk urutan berdimensi tetap sebanyak 30 frame untuk merepresentasikan satu unit gerakan, kemudian digunakan sebagai input untuk melatih model Long Short-Term Memory (LSTM). Model ini dikembangkan untuk mengklasifikasikan kualitas gerakan menjadi tiga kategori, yaitu gerakan sempurna, benar, dan salah. Hasil pengujian menunjukkan bahwa model mencapai akurasi sebesar 94% dari total 1579 data, dengan nilai macro average dan weighted average yang tinggi. Performa klasifikasi pada masing-masing kelas juga menunjukkan hasil yang baik, dengan nilai f1-score sebesar 90% untuk gerakan sempurna, 96% untuk gerakan benar, dan 95% untuk gerakan salah. Temuan ini menunjukkan bahwa sistem yang dibangun efektif dalam mengevaluasi kualitas gerakan hammer-curl dan berpotensi untuk diterapkan dalam pelatihan kebugaran secara otomatis dan real-time.

Kata Kunci— Pose Estimasi, LSTM, HammerCurl, Pose Manusia, Visi Komputer, Klasifikasi Gerakan

Abstract— *This research aims to develop a pose estimation-based artificial intelligence system that can accurately detect and evaluate hammer-curl movements. The system analyzes body movement patterns from videos by utilizing the coordinates of body points (landmarks), such as shoulders, elbows, and wrists. The landmark data is organized into a fixed-dimensional sequence of 30 frames to represent one unit of motion, and then used as input to train a Long Short-Term Memory (LSTM) model. The model was developed to classify movement quality into three categories, namely perfect, correct and incorrect movements. Test results showed that the model achieved an accuracy of 94% from a total of 1579 data, with high macro average and weighted average values. The classification performance of each class also showed good results, with f1-score values of 90% for perfect gestures, 96% for correct gestures, and 95% for incorrect gestures. These findings show that the system is effective in evaluating the quality of hammer-curl movements and has the potential to be applied in real-time, automated fitness training.*

Keywords— *Pose Estimation, LSTM, HammerCurl, Human Pose, ComputerVision, Motion Classification*

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Olahraga sangat penting untuk menjaga kesehatan fisik dan mental. Latihan otot tangan efektif untuk meningkatkan kekuatan lengan serta membantu pembesaran otot bicep [1][2]. Variasi seperti *hammer-curl* memberikan efek berbeda pada otot, sehingga penting untuk dipahami oleh olahragawan [3]. Sayangnya, kesalahan teknik dalam *hammer-curl* sering terjadi, mengurangi efektivitas latihan dan meningkatkan risiko cedera terutama bagi mereka yang berolahraga secara mandiri tanpa bimbingan ahli.

Penelitian sebelumnya menunjukkan teknologi dapat membantu analisis gerakan olahraga. Misalnya, [4] mengembangkan *AI Fitness Counter* menggunakan *webcam* dengan jarak optimal tiga meter. [5] menggunakan *LSTM* atau algoritma *Long-Short Term Memory* untuk menilai gerakan tari kesenian, dengan kinerja model yang dapat menghafal data perulangan gerakan dasar yang baik.

Penelitian ini bertujuan untuk mengembangkan model, dirancang untuk menganalisis pola gerakan tubuh berdasarkan koordinat titik-titik tubuh (*landmark*) yang diperoleh dari video, kemudian mengklasifikasikan kualitas gerakan berdasarkan sudut-sudut sendi tertentu, seperti siku dan bahu. Dengan pendekatan ini, diharapkan sistem mampu membedakan antara gerakan yang sempurna, benar, maupun salah.

II. METODE

Metode pengembangan yang digunakan dalam penelitian ini adalah metode *Waterfall*, yaitu pendekatan sekuensial di mana setiap tahap pengembangan dilakukan secara bertahap dan berurutan mulai dari analisis kebutuhan hingga implementasi dan evaluasi. Model ini dipilih karena memberikan alur kerja yang sistematis dan terdokumentasi dengan baik, sehingga memudahkan peneliti dalam merancang, membangun, dan menguji sistem klasifikasi gerakan berbasis teknologi pose estimation secara terstruktur dan terkontrol.

2.1 Pengumpulan Data Landmark Tubuh Dengan Algoritma Deteksi Pose

Hammer curl merupakan salah satu variasi latihan kekuatan yang secara khusus menargetkan otot bicep dan lengan bawah. Contoh gerakan *hammer-curl* ditampilkan pada Gambar 1 sebagai berikut.




Gambar 1. Contoh Gerakan Hammer-Curl

Gerakan ini dilakukan dengan memegang *dumbbell* secara vertikal mirip posisi memegang palu lalu mengangkat beban ke arah bahu tanpa memutar pergelangan tangan. Teknik

ini tidak hanya melatih otot brachialis yang berada di bawah bicep, tetapi juga memberikan tekanan tambahan pada otot brachioradialis di lengan bawah, sehingga menghasilkan perkembangan otot yang lebih seimbang. Karena melibatkan posisi pergelangan tangan yang lebih netral, hammer curl juga menjadi alternatif latihan yang relatif lebih aman dan mengurangi risiko cedera pada sendi dibandingkan dengan variasi curl lainnya.

Video yang diperoleh dari dataset kemudian diproses menggunakan algoritma pose estimation MediaPipe, yang berfungsi untuk mendeteksi titik-titik kunci (landmark) pada bagian tubuh manusia secara otomatis [6]. Fokus utama dalam proses ini adalah pada tiga titik penting, yaitu bahu (shoulder), siku (elbow), dan pergelangan tangan (wrist), karena ketiganya merepresentasikan pergerakan utama dalam aktivitas fisik yang dianalisis. MediaPipe menghasilkan koordinat dua dimensi (x, y) dari masing-masing titik dalam setiap frame video, sehingga tiap frame menghasilkan enam fitur numerik yang dapat digunakan sebagai input untuk proses pembelajaran model. Penjelasan titik landmark ditampilkan pada Gambar 2 sebagai berikut.



Gambar 2. Titik Tubuh Manusia Yang Dapat Dideteksi Oleh MediaPipe

Hasil dari proses deteksi pose ini kemudian diekstraksi dan disimpan dalam format Comma-Separated Values (CSV) agar memudahkan pengolahan lebih lanjut. Setiap baris dalam file CSV mewakili satu frame video dan berisi informasi tentang posisi koordinat keenam titik tubuh yang diamati, serta label kelas yang menunjukkan kualitas atau tingkat kesempurnaan gerakan pada frame tersebut. Format ini dipilih karena efisien untuk disimpan, dibaca, dan diolah menggunakan berbagai pustaka analisis data seperti Pandas dan NumPy pada tahap preprocessing sebelum digunakan dalam pelatihan model klasifikasi [7].

Penyimpanan dalam format ini bertujuan untuk mempermudah tahap pelatihan model klasifikasi, karena struktur data yang rapi dan terstandarisasi memungkinkan pemrosesan yang lebih efisien dan akurat. Format CSV memfasilitasi integrasi langsung dengan berbagai pustaka pemrograman seperti Pandas untuk manipulasi data dan TensorFlow atau Keras untuk proses pelatihan model. Dengan format ini, setiap baris data dapat dengan mudah diakses, dibaca ulang, atau diubah sesuai kebutuhan preprocessing, sehingga meminimalkan kesalahan dalam transformasi data dan meningkatkan reproduktibilitas eksperimen [8].

2.2 Penyusunan Data Sequence

Proses pembentukan *sequence* merupakan tahap penting dalam mempersiapkan data untuk pelatihan model Long Short-Term Memory (LSTM) yang dirancang untuk mengenali pola

gerakan dari urutan titik-titik pose tubuh. Data mentah berupa koordinat hasil ekstraksi titik kunci (landmark) seperti bahu (*shoulder*), siku (*elbow*), dan pergelangan tangan (*wrist*) yang telah dinormalisasi disusun dalam bentuk urutan berdimensi tetap. Dalam penelitian ini, digunakan panjang urutan (*sequence length*) sebanyak 30 frame secara berurutan untuk merepresentasikan satu unit gerakan.

Setiap *sequence* dibentuk dengan mengambil 30 baris data secara berurutan dari dataset, kemudian label kelas untuk urutan tersebut diambil dari frame terakhir sebagai representasi status akhir dari gerakan [9][10]. Pendekatan ini memungkinkan model *LSTM* untuk belajar dari konteks temporal gerakan secara keseluruhan. Setelah seluruh data urutan terbentuk, kumpulan *sequence* dan label disimpan dalam bentuk array numerik menggunakan NumPy agar dapat digunakan secara efisien dalam proses pelatihan model klasifikasi.

2.3 Strategi Penanganan Kelas Tidak Seimbang

Ketidakseimbangan kelas merupakan tantangan umum dalam pengembangan model klasifikasi, terutama ketika jumlah data untuk masing-masing kelas tidak proporsional. Pada kasus klasifikasi gerakan hammer curl ini, data dari beberapa kelas seperti "Salah", "Benar", dan "Sempurna" memiliki jumlah sampel yang berbeda secara signifikan. Jika tidak ditangani dengan tepat, hal ini dapat menyebabkan bias model terhadap kelas mayoritas, sehingga menurunkan akurasi dalam mengidentifikasi kelas minoritas yang justru penting dalam aplikasi nyata.

Untuk mengatasi hal ini, diterapkan pendekatan *class weighting*, yaitu dengan menghitung bobot kelas secara otomatis berdasarkan distribusi label dalam dataset. Bobot dihitung menggunakan fungsi *compute_class_weight* dari pustaka *Scikit-learn*, yang mempertimbangkan proporsi setiap kelas terhadap keseluruhan dataset [11]. Hasil bobot tersebut kemudian diterapkan selama proses pelatihan menggunakan parameter *class_weight* pada fungsi *model.fit()*. Dengan demikian, model akan memberikan penalti yang lebih besar ketika salah mengklasifikasikan kelas minoritas, sehingga memperbaiki performa klasifikasi secara menyeluruh dan meningkatkan sensitivitas model terhadap kelas yang lebih jarang muncul.


2.4 Arsitektur Model Klasifikasi dan Pelatihan Model

Model klasifikasi dirancang untuk mengenali pola gerakan berdasarkan urutan koordinat tubuh yang diekstraksi menggunakan algoritma pose estimation. Titik kunci yang digunakan meliputi bahu, siku, dan pergelangan tangan (masing-masing memiliki dua komponen: x dan y), menghasilkan enam fitur numerik per frame. Seluruh data dinormalisasi menggunakan skala global agar memiliki rentang nilai seragam, kemudian disusun menjadi sekuens berdimensi (30, 6) yang merepresentasikan satu unit gerakan. Label kelas diambil dari frame terakhir pada setiap sekuens dan dikonversi ke dalam bentuk one-hot encoding untuk keperluan klasifikasi multi-kelas. Dataset dibagi menjadi data latih dan uji dengan rasio 80:20 menggunakan stratifikasi agar distribusi kelas tetap seimbang. Berikut adalah alat dan pustaka yang digunakan oleh peneliti dalam membangun model klasifikasi.

1. *Tensorflow*
 - a. *Sequential*, digunakan dalam membangun arsitektur model *neural network*.
 - b. *LSTM Layer*, digunakan untuk mempelajari urutan data dalam model berbasis waktu ke waktu yang baik dalam mengenali gerakan tubuh yang terekam.
 - c. *Dropout*, digunakan untuk mencegah *overfitting* dengan mempercepat proses pelatihan model klasifikasi.

- d. *BatchNormalization*, digunakan dalam mempercepat dan menstabilkan pelatihan model dengan melakukan penormalan data yang masuk pada tiap lapisan.
- e. *EarlyStopping*, digunakan jika pada proses pelatihan model tidak adanya peningkatan hasil selama beberapa waktu.
- f. *ReduceLROnPlateau*, digunakan menurunkan kecepatan belajar (learning rate) jika hasil tidak membaik, agar model bisa lebih hati-hati dalam belajar.

Long Short-Term Memory (LSTM) merupakan salah satu jenis Recurrent Neural Network (RNN) yang dirancang untuk memproses dan mempelajari pola dari data sekuensial seperti gerakan tubuh dalam video.



Gambar 3. Arsitektur Memory Cells LSTM

LSTM mampu mempertahankan informasi dari waktu ke waktu melalui struktur internal yang disebut "cell state" dan tiga gerbang utama: input gate, forget gate, dan output gate. Mekanisme ini memungkinkan LSTM untuk menangani dependensi jangka panjang dengan lebih baik dibandingkan RNN konvensional, yang cenderung mengalami masalah vanishing gradient. Dalam penelitian ini, LSTM digunakan untuk menangkap pola pergerakan dari urutan frame pose tubuh, sehingga model dapat mengenali jenis gerakan hammer-curl berdasarkan urutan koordinat tubuh selama beberapa frame.

2.5 Implementasi Evaluasi Awal

Setelah proses pelatihan berakhir, tahap berikutnya adalah menguji kinerja awal model menggunakan data pengujian yang telah dipisahkan sebelumnya. Pengujian ini dilakukan melalui analisis *confusion matrix* dan *classification report*, yang menyajikan informasi mendalam mengenai kemampuan model dalam mengenali setiap kategori gerakan.

Langkah pertama dimulai dengan memprediksi data uji, di mana model menghasilkan nilai probabilitas untuk masing-masing kelas. Prediksi yang diperoleh selanjutnya dibandingkan dengan label sebenarnya, menghasilkan *confusion matrix* sebuah tabel yang menunjukkan jumlah klasifikasi yang tepat maupun keliru untuk setiap jenis gerakan. Representasi ini membantu mengidentifikasi pola kesalahan secara lebih terperinci, seperti ketika model kerap menilai gerakan "Sempurna" sebagai "Benar", atau sebaliknya.

Selain itu, *classification report* digunakan untuk menyampaikan sejumlah metrik evaluasi penting, seperti *precision*, *recall*, *f1-score*, dan *accuracy* pada masing-masing kelas. *Precision* mengukur ketepatan prediksi, *recall* menunjukkan sejauh mana model mampu menangkap seluruh instance dari suatu kategori, sedangkan *f1-score* merupakan rata-rata harmonis antara keduanya. Evaluasi ini menjadi sangat relevan ketika berhadapan dengan

distribusi kelas yang tidak merata. Dari sini, kelemahan model dapat diidentifikasi, seperti adanya kategori yang sering keliru dikenali atau memiliki recall yang rendah.

III. HASIL DAN PEMBAHASAN

3.1 Ekstraksi Fitur Titik Landmark Tubuh

Sistem ini menggunakan MediaPipe Pose untuk mengidentifikasi titik koordinat bahu, siku, dan pergelangan tangan dalam setiap bingkai video. Teknik ini menentukan sudut siku dengan menggunakan ketiga titik ini dan membaginya ke dalam tiga kategori: Sempurna, Benar, dan Salah. Hasil pendeteksian disimpan dalam file CSV yang menyertakan enam koordinat (x dan y untuk bahu, siku, dan pergelangan tangan) dan label kelas. Untuk mempercepat proses verifikasi visual, sebuah antarmuka diperkenalkan yang menampilkan sudut siku, label kategorisasi, dan bingkai tubuh pada layar saat video diproses. Metode ini memungkinkan para peneliti untuk membuat kumpulan data secara otomatis, efisien, dan dengan sedikit kesalahan.



Gambar 4. Tampilan Ekstraksi Fitur Landmark Tubuh

Pada Gambar 4, menampilkan bagaimana ekstraksi fitur titik landmark tubuh berlangsung dengan mendeteksi yang digunakan meliputi bahu (shoulder), siku (elbow), dan pergelangan tangan (wrist). Hasil ekstraksi berikut akan disimpan pada file berformat *CSV* yang nantinya digunakan untuk memudahkan proses pelatihan model *LSTM*.

3.2 Penanganan Dataset Tidak Seimbang

Salah satu tantangan yang dihadapi adalah ketidakseimbangan jumlah data antara kelas gerakan, *class_weight* dalam permasalahan ini berguna sebagai penyeimbang kontribusi antar kelas selama proses pelatihan model. Mengingat jumlah data gerakan hammer-curl yang sempurna dan benar jauh lebih sedikit dibandingkan data gerakan yang salah, tanpa penyesuaian

bobot, model cenderung lebih fokus pada kelas mayoritas. Hal ini berisiko menurunkan kemampuan model dalam mengenali gerakan yang benar, yang justru menjadi fokus utama penelitian ini. Oleh karena itu, diterapkan pendekatan *class weighting* untuk memberi bobot yang lebih tinggi pada kelas minoritas, sehingga model terdorong mempelajari karakteristik dari kedua kelas secara adil.

Pengaturan bobot kelas dilakukan dengan bantuan fungsi *compute_class_weight* dari pustaka Scikit-learn, yang secara otomatis menghitung bobot berdasarkan distribusi label dalam dataset. Bobot tersebut kemudian diterapkan pada parameter *class_weight* saat proses pelatihan model, sehingga model tidak hanya mengandalkan frekuensi data, tetapi juga mempertimbangkan pentingnya mengenali pola dari kelas yang kurang representatif. Hasil evaluasi menunjukkan bahwa pendekatan ini mampu meningkatkan performa klasifikasi, khususnya pada metrik *recall* dan *f1-score* untuk kelas gerakan sempurna dan benar.

3.3 Evaluasi Kinerja Model Long Short Term-Memory

Pada penelitian ini, model klasifikasi yang digunakan adalah Long Short Term Memory (LSTM), yang merupakan pengembangan dari algoritma Recurrent Neural Network (RNN). LSTM dipilih karena kemampuannya dalam mengolah data sekuensial, seperti data pose hasil ekstraksi dari MediaPipe, yang terdiri dari urutan koordinat titik-titik tubuh. Data pelatihan yang digunakan berasal dari file *dataset_bersih.csv*, yang berisi informasi landmark pose untuk tiga kategori kelas gerakan: salah, benar, dan sempurna.

Pada tahap pelatihan, peneliti membagi dataset menjadi dua bagian, yaitu data pelatihan dan data pengujian dengan rasio 80:20 menggunakan fungsi *train_test_split*. Pembagian ini dilakukan secara stratified berdasarkan label asli (sebelum one-hot encoding) agar distribusi kelas tetap seimbang di kedua subset data. Sebelum dibagi, data diformat dalam bentuk sekuens berdurasi 30 frame agar dapat digunakan sebagai input untuk arsitektur LSTM.

Untuk mengatasi permasalahan ketidakseimbangan kelas, peneliti menghitung *class weight* secara otomatis menggunakan fungsi *compute_class_weight* dari Scikit-learn. Bobot yang dihasilkan kemudian diterapkan pada saat pelatihan model melalui parameter *class_weight* pada fungsi *model.fit()*. Model LSTM yang dibangun terdiri dari satu lapisan LSTM berukuran 64 unit, diikuti oleh lapisan *dropout* dan beberapa lapisan *dense* dengan aktivasi *ReLU* dan *softmax* pada output. Proses pelatihan dilakukan selama maksimal 30 *epoch*, dengan penggunaan *EarlyStopping* untuk mencegah overfitting serta *Learning Rate Scheduler* untuk menurunkan laju pembelajaran secara bertahap setelah 10 *epoch*.

Tabel 1. Evaluasi Kinerja Model *Long Short-Term Memory*

<i>Model Report</i>			
Accuracy		96%	
Macro Avg	96%	96%	96%
Weigthed Avg	96%	96%	96%


Pada Tabel 1 ditampilkan hasil laporan model yang menunjukkan bahwa akurasi yang diperoleh dari total 1959 dataset pengujian landmark tubuh adalah sebesar 0.96. Selain itu, nilai *macro average* dari precision, recall, dan f1-score masing-masing sebesar 0.96 untuk label

sempurna, 0.96 untuk label benar, dan 0.96 untuk label salah , sedangkan *weighted average*-nya menunjukkan nilai sebesar 0.96 yang dapat dikatakan sangat baik jika dilihat dari hasil angka yang ditunjukkan.

Tabel 2. Evaluasi Kinerja Klasifikasi Model *Long Short-Term Memory*

Label	Clasification Report		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Sempurna	96%	96%	96%
Benar	94%	94%	94%
Salah	98%	97%	98%

Evaluasi kinerja model dilakukan terhadap data pengujian menggunakan metrik akurasi, precision, recall, dan f1-score. Peneliti menggunakan fungsi *classification_report* dari Scikit-learn untuk menghasilkan ringkasan performa klasifikasi. Hasil evaluasi tersebut ditampilkan dalam Tabel 1 sebagai *classification_report* yang menunjukkan performa model terhadap ketiga kelas. Selain itu, visualisasi *confusion matrix* juga digunakan untuk menggambarkan distribusi prediksi model terhadap data sebenarnya. Berdasarkan hasil evaluasi, pendekatan ini berhasil meningkatkan sensitivitas terhadap kelas minoritas dan menghasilkan klasifikasi yang lebih seimbang.



Gambar 5. Keluaran Dari Confusion Matrix

Gambar 5 menyajikan hasil keluaran dari confusion matrix terhadap model yang telah melalui proses pengujian. Confusion matrix ini digunakan untuk menggambarkan kinerja model dalam mengklasifikasikan tiga kategori gerakan, yaitu salah, benar, dan sempurna. Berdasarkan hasil pengujian, model menunjukkan performa yang sangat baik dalam mengenali gerakan salah, dengan jumlah prediksi yang tepat mencapai 185 dari total 198 data pengujian pada kelas tersebut. Untuk kategori gerakan benar, model berhasil melakukan klasifikasi secara akurat sebanyak 171 dari 199 data, sedangkan sisanya mengalami kesalahan klasifikasi ke dalam kelas salah maupun sempurna. Adapun untuk kategori gerakan sempurna, sebanyak 185 dari 198 data pengujian dapat dikenali secara tepat oleh model.

Ketidakseimbangan jumlah data antar kelas, khususnya antara kelas salah, benar, dan sempurna, terjadi karena kondisi nyata saat proses pengumpulan data. Gerakan salah cenderung lebih dominan karena secara alami lebih sering dilakukan oleh peserta yang tidak mendapatkan bimbingan langsung atau belum memiliki pengalaman yang memadai. Sebaliknya, gerakan sempurna relatif lebih sulit ditemukan karena memerlukan postur tubuh yang tepat serta konsistensi gerakan yang tinggi, yang umumnya hanya dapat dicapai oleh individu dengan keterampilan atau pengalaman tertentu. Ketidakseimbangan distribusi data ini mencerminkan kondisi riil dalam pelatihan gerakan dan menjadi aspek krusial yang perlu diperhitungkan dalam perancangan model, agar performa klasifikasi tidak terdistorsi oleh dominasi kelas mayoritas.

IV. KESIMPULAN

Penelitian ini menunjukkan bahwa pendekatan berbasis estimasi postur tubuh efektif digunakan dalam pengembangan model klasifikasi gerakan hammer curl. Meskipun demikian, masih terdapat beberapa kendala yang perlu diperhatikan, salah satunya adalah ketidakseimbangan jumlah data antar kelas yang berpotensi memengaruhi kinerja model secara keseluruhan. Hasil evaluasi menunjukkan bahwa model mampu mencapai tingkat akurasi sebesar 0,96 dari total 9.793 titik data, disertai dengan nilai *macro average* dan *weighted average* yang tinggi, menandakan performa yang konsisten di seluruh kelas.

Untuk meningkatkan kemampuan generalisasi model, penelitian selanjutnya disarankan untuk memperluas volume serta keragaman data pelatihan, termasuk variasi sudut pengambilan gambar dan partisipasi individu dengan karakteristik postur tubuh yang berbeda. Selain itu, pengembangan sistem evaluasi gerakan secara real-time menjadi arah penelitian potensial di masa mendatang, yang dapat mendukung penerapan langsung dalam konteks pelatihan kebugaran secara interaktif dan adaptif..

DAFTAR PUSTAKA

- [1] M. S. Husen and I. Anshory, "Rancang Bangun Alat Penghitung Repetisi Olahraga Biceps Arm Curl dengan Sensor Otot," *Innov. Technol. Methodical Res. J.*, vol. 3, no. 1, pp. 1–9, 2024, doi: 10.47134/innovative.v3i1.97.
- [2] A. Umi, I. Sugeng, and R. P. Herpandika, "Jurnal Kejaora : Jurnal Kesehatan Jasmani dan Olah Raga EVALUASI KONDISI FISIK PADA ATLET SELAM CLUB GALAXY AQUATIC PUTRA DALAM MENGHADAPI KEJURDA 2024," vol. 9, no. April, pp. 106–111, 2024.
- [3] T. Hidayat and R. A. Munandar, "Pengaruh Pelatihan Dumbbell Curl dan Shoulder Press terhadap Peningkatan Power Otot Lengan dan Kekuatan Otot Lengan," *Ainara J. (Jurnal Penelit. dan PKM Bid. Ilmu Pendidikan)*, vol. 3, no. 3, pp. 160–164, 2022, doi: 10.54371/ainj.v3i3.168.
- [4] M. Abdul muthalib, I. Irfan, K. Kartika, and S. M. Selamat Meliala, "Pengiraan Pose Model Manusia Pada Repetisi Kebugaran Ai Pemograman Python Berbasis Komputerisasi," *INFOTECH J.*, vol. 9, no. 1, pp. 11–19, 2023, doi: 10.31949/infotech.v9i1.4233.
- [5] L. Zaman, S. Sumpeno, and M. Hariadi, "Analisis Kinerja LSTM dan GRU sebagai Model Generatif untuk Tari Remo," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 8, no. 2, p. 142, 2019, doi: 10.22146/jnteti.v8i2.503.

- [6] A. S. Shandy Sadewa Asmoro, Resty Wulanningrum, “PENILAIAN GERAKAN BARIS-BERBARIS AI AND LSTM-BASED MARCHING MOVEMENT,” vol. 12, no. 2, pp. 41–52, 2024.
- [7] D. T. Hermanto, A. Setyanto, and E. T. Luthfi, “Algoritma LSTM-CNN untuk Binary Klasifikasi dengan Word2vec pada Media Online,” *Creat. Inf. Technol. J.*, vol. 8, no. 1, p. 64, 2021, doi: 10.24076/citec.2021v8i1.264.
- [8] D. I. Mulyana and S. F. Banase, “Jurnal JTIK (Jurnal Teknologi Informasi dan Komunikasi) Optimasi Deteksi Gerak Bahasa Isyarat dan Ekpresi Wajah Real,” vol. 9, no. March, pp. 277–284, 2025, doi: <https://doi.org/10.35870/jtik.v9i1.3188>.
- [9] R. Rosdiana Agustin, H. Maulana, and E. Prakarsa Mandyartha, “Detection of Actions Bisindo (Indonesian Sign Language) Into Text-To-Speech Using Long Short-Term Memory With Mediapipe Holistics,” *J. Tek. Inform.*, vol. 5, no. 4, pp. 1051–1061, 2024, [Online]. Available: <https://doi.org/10.52436/1.jutif.2024.5.4.1492>
- [10] R. Al Kiramy, I. Permana, and A. Marsal, “Comparison of RNN and LSTM Algorithm Performance in Predicting the Number of Umrah Pilgrims at PT . Hajar Aswad Perbandingan Performa Algoritma RNN dan LSTM dalam Prediksi Jumlah Jamaah Umrah pada PT . Hajar Aswad,” vol. 4, no. October, pp. 1224–1234, 2024, doi: <https://doi.org/10.57152/malcom.v4i4.1373>.
- [11] U. Jansri and S. Tretriluxana, “Effect of Class Weights on Imbalanced Classes in Bi-directional LSTM Training for Sleep Apnea Classification,” in *2024 12th International Electrical Engineering Congress (iEECON)*, 2024, pp. 1–6. doi: 10.1109/iEECON60677.2024.10537892.