

Klasifikasi Gerakan Olahraga Panahan Menggunakan YOLO dan Metode LSTM

Ahmad Rio Adriansyah¹, Edi Wibowo², Krisna Panji³

arasy@nurulfikri.ac.id¹, ediwibowo@nurulfikri.ac.id², panji@nurulfikri.ac.id³

^{1,2,3} Sekolah Tinggi Teknologi Terpadu Nurul Fikri

Informasi Artikel

Diterima : 24 Jan 2025
Direvisi : 6 May 2025
Disetujui : 9 Jun 2025

Kata Kunci

panahan, YOLO, LSTM,
klasifikasi gerakan,
deteksi pose

Abstrak

Klasifikasi gerakan olahraga panahan merupakan salah satu tantangan dalam pengembangan teknologi pendukung pelatihan atlet. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi gerakan panahan menggunakan YOLO untuk deteksi pose dan Long Short-Term Memory (LSTM) untuk klasifikasi temporal. Sistem ini memanfaatkan video rekaman pelatihan panahan yang diolah menjadi rangkaian gambar. Tujuannya adalah melatih model LSTM untuk mengenali pola dari 4 kelas gerakan panahan yang telah ditentukan yaitu *stand*, *extend*, *hold*, dan *release*. Hasil evaluasi menunjukkan bahwa sistem mampu mencapai akurasi sebesar 64,47%. Selain itu, analisis menggunakan metrik *precision*, *recall*, dan *F1-score* mengindikasikan performa yang beragam di antara kelas-kelas gerakan, dengan *F1-score* tertinggi sebesar 83,75% pada kelas *release*. Penelitian ini memberikan kontribusi terhadap pengembangan teknologi berbasis *machine learning* untuk mendukung pelatihan olahraga, khususnya panahan, dengan menawarkan pendekatan berbasis data yang mampu mengenali dan mengevaluasi gerakan atlet secara otomatis.

Keywords

archery, YOLO, LSTM,
movement classification,
pose detection

Abstract

*The classification of archery movements presents a significant challenge in the development of technology to support athlete training. This study aims to develop an archery movement classification system using a combination of YOLO for pose detection and Long Short-Term Memory (LSTM) for temporal classification. The system processes archery training videos into a sequence of images. The aim of this research is to train LSTM model to recognize patterns from four predefined archery movement classes: *stand*, *extend*, *hold*, and *release*. Evaluation results show that the system achieved an accuracy of 64.47%. Furthermore, analysis using *precision*, *recall*, and *F1-score* metrics indicates varying performance across the movement classes, with the highest *F1-score* of 83.75% achieved in the *release* class. This study contributes to the development of machine learning-based technology to support sports training, particularly in archery, by offering a data-driven approach capable of automatically recognizing and evaluating athletes' movements.*

A. Pendahuluan

Panahan merupakan salah satu olahraga tertua di dunia. Pada awalnya digunakan untuk berburu dan bertahan hidup, berkembang menjadi olahraga yang mengutamakan teknik dan konsistensi gerakan. Teknik memanah yang tepat dan benar sangat menunjang pencapaian prestasi yang optimal [1].

Menurut Harsono [2], ada 9 langkah teknik dalam panahan yang harus diperhatikan:

1. Sikap / cara berdiri (stand)
2. Memasang ekor panah (nocking)
3. Mengangkat lengan (extend)
4. Menarik tali busur (drawing)
5. Menjangkarkan tali busur (anchoring)
6. Menahan sikap (hold/tighten)
7. Membidik (aiming)
8. Melepas tali (release)
9. Menahan sikap memanah (after hold)

Pada setiap pertandingan, pemanah akan menggunakan kekuatan dan daya tahan otot lengan dalam menarik dan menahan busur untuk sekitar 200 anak panah [3]. Selain kekuatan, stabilitas postur dan teknik juga akan mempengaruhi hasil dari pertandingan.

Teknologi dapat digunakan untuk membantu dalam proses latihan dan pertandingan olahraga, baik untuk akses sumber daya pelatihan secara online melalui sistem [4], mendukung pertandingan dengan penggunaan sistem [5], manajemen data latihan dan pertandingan, termasuk dalam proses latihan.

Untuk olahraga panahan, telah tersedia beberapa teknologi pendukung latihan seperti penggunaan alat AccuBow, Neurotracker menggunakan Multiple Object Tracking [6], hingga virtual reality [7]. Tetapi teknologi tersebut membutuhkan alat tambahan dengan biaya tinggi sehingga tidak mudah diakses oleh pengguna umum.


Pada penelitian ini, peneliti akan mengembangkan sebuah alat bantu untuk latihan panahan dengan memanfaatkan teknologi yang sudah tersedia umum, yaitu smartphone, augmented reality, dan image detection yang berbiaya rendah dan mudah diakses oleh pengguna yang lebih luas. Model machine learning untuk dapat mengenali gerakan-gerakan dalam panahan tersebut dibuat memanfaatkan YOLO dengan metode LSTM dan transfer learning. Penelitian sejenis yang menggunakan pose estimation untuk olahraga panahan sudah dilakukan, diantaranya untuk menganalisis waktu menembak [8] dan sebagai alat bantu pelatihan untuk memperbaiki konsistensi postur [9] [10].

B. Teori dan Metode Penelitian

a. YOLO

YOLO, singkatan dari You Only Look Once, adalah algoritma deteksi objek berbasis deep learning yang terkenal karena kecepatan dan akurasi. Berbeda dengan pendekatan deteksi objek tradisional yang memerlukan proses berulang untuk memindai area gambar, YOLO melakukan deteksi secara langsung dalam satu proses, menjadikannya sangat efisien untuk aplikasi real-time [11].

YOLO membagi gambar menjadi grid dan memprediksi kotak pembatas (bounding boxes) serta kelas objek yang terdapat di setiap grid. Setiap sel grid bertanggung jawab untuk mendeteksi objek yang pusatnya berada dalam area grid tersebut. Selain deteksi objek, YOLO juga telah diadaptasi untuk mendeteksi titik-titik penting (keypoints) pada tubuh manusia, seperti sendi lutut, siku, bahu, dan lain-lain. Titik-titik ini dapat digunakan untuk merekonstruksi pose tubuh secara lengkap. Keypoints tersebut digambarkan pada **Gambar 1**.



Gambar 1. Tujuh Belas (17) Keypoints untuk Tubuh Manusia

Pendekatan YOLO untuk pose detection melibatkan penambahan luaran yang memprediksi koordinat keypoints pada tubuh manusia. Beberapa penelitian [12], [13] telah menunjukkan bahwa YOLO dapat dimodifikasi untuk mendeteksi hingga 17 keypoints yang sesuai dengan standar COCO (Common Objects in Context) [14]. Hal ini menjadikan YOLO alat yang sangat efektif untuk mengenali postur tubuh manusia dalam aplikasi olahraga, pengawasan, atau hiburan.

b. LSTM

LSTM (Long Short-Term Memory) [15] adalah sebuah arsitektur jaringan saraf tiruan yang termasuk dalam kategori Recurrent Neural Network (RNN). LSTM dirancang untuk mengatasi masalah vanishing gradient yang sering muncul dalam pelatihan RNN tradisional ketika menangani data sekuensial dengan ketergantungan jangka panjang. LSTM pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997 dan sejak itu menjadi salah satu algoritma yang paling populer untuk pemrosesan data sekuensial, seperti teks, audio, video, atau data time-series.

LSTM memiliki unit khusus yang disebut memory cell, yang mampu menyimpan informasi untuk jangka waktu yang lama. Setiap unit LSTM memiliki

tiga gerbang utama (forget gate, input gate, dan output gate) untuk meregulasi aliran informasi di dalam jaringannya. Arsitektur LSTM ditampilkan dalam **Gambar 2**.

Forget gate menentukan informasi mana yang perlu dihapus dari memory cell. Nilai yang tidak relevan akan dihapus untuk menghindari akumulasi informasi yang tidak diperlukan.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

Input gate menentukan informasi baru yang akan ditambahkan ke memory cell. Proses ini melibatkan pembaruan memori berdasarkan input baru.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$


$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (4)$$

Output gate menentukan informasi mana yang akan dikeluarkan berdasarkan memori terkini dan input saat ini.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (6)$$




Gambar 2. Arsitektur LSTM

c. Alur dan Metode Penelitian


Penelitian ini bertujuan untuk mengembangkan sistem pengenalan gerakan panahan menggunakan YOLO dan LSTM. Metode yang digunakan melibatkan beberapa tahap utama, yaitu pengumpulan data, pemrosesan video (segmentasi dan pelabelan), deteksi keypoints, pelatihan model, dan pengujian seperti ditampilkan pada **Gambar 3**.

Wawancara dan pengumpulan data dilakukan terhadap klub panahan SAI Archery yang berdomisili di Cipedak, Jakarta Selatan. Data awal yang diambil berupa rekaman video latihan panahan. Video ini berisi gerakan yang dilakukan oleh atlet atau pengguna selama latihan. Dari video tersebut, dilakukan segmentasi ke dalam gambar frame per frame dan diambil sampel gambar yang representatif terhadap pose tertentu.



Gambar 3. Alur Penelitian

Gerakan dasar panahan yang terdiri dari 9 gerakan, sebagaimana dijelaskan [2], disederhanakan menjadi 4 kelas karena perbedaan gerakan yang tidak terlalu terlihat secara visual. Keempat kelas tersebut ditunjukkan dalam **Gambar 4**: stand (a), extend (b), hold (c), dan release (d).



Gambar 4. Gerakan Panahan

Stand digunakan untuk mewakili stand dan nocking. Hold digunakan untuk mewakili anchoring, hold, dan aiming. Release digunakan untuk mewakili gerakan release dan afterhold. Draw yang merupakan gerakan dinamis tidak diproses dulu dalam penelitian ini.

Dari video latihan yang tersedia, didapatkan sejumlah gambar dan video yang dilabeli secara manual dengan tabulasi frekuensi seperti yang ditampilkan pada Tabel 1.

Tabel 1. Frekuensi Data Tiap Kelas

No	Kelas	Frekuensi
1	Stand	142
2	Extend	93
3	Hold	127
4	Release	129
<i>Total</i>		<i>491</i>

Setiap gambar dianalisis menggunakan YOLO untuk mengekstraksi 2 hal:

1. Bounding box yang menunjukkan area tubuh dari hasil deteksi manusia
2. Keypoints yang menunjukkan 17 buah titik-titik kunci pada tubuh manusia.

Struktur model yang digunakan adalah arsitektur sekuensial yang mengkombinasikan layer LSTM dengan regularisasi dropout dan layer padat (dense). Model ini didesain untuk mengklasifikasikan ke dalam 4 kategori output berdasarkan input fitur yang diberikan. Dari beberapa model yang dibuat dan diuji, model pada **Gambar 5** adalah yang menghasilkan performa terbaik.

Model: "sequential"

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 34, 50)	10400
dropout (Dropout)	(None, 34, 50)	0
dense (Dense)	(None, 34, 512)	26112
dense_1 (Dense)	(None, 34, 256)	131328
lstm_1 (LSTM)	(None, 50)	61400
dense_2 (Dense)	(None, 4)	204

=====
Total params: 229,444
Trainable params: 229,444
Non-trainable params: 0

Gambar 5. Model Terbaik yang Didapatkan


Model tersebut terdiri dari 6 buah lapisan (layer) sebagai berikut:

1. Layer LSTM yang pertama digunakan untuk mengekstraksi pola temporal dari input fitur.
2. Dropout digunakan untuk mencegah overfitting dengan mendeaktivasi sebagian neuron pada saat training.
3. Layer padat yang pertama digunakan untuk memetakan fitur dari LSTM ke dimensi yang lebih tinggi untuk representasi fitur yang lebih baik.
4. Layer padat yang kedua digunakan untuk mereduksi dimensi.
5. Layer LSTM yang kedua digunakan untuk membentuk pola tingkat tinggi yang lebih abstrak.
6. Layer padat terakhir dengan fungsi aktivasi softmax digunakan untuk mengklasifikasikan fitur ke dalam 4 kelas output.

Model dilatih menggunakan 80% dari keseluruhan data dan diuji menggunakan 20% lainnya secara random. Ukuran pengujian yang digunakan adalah akurasi, optimizer yang digunakan adalah adam optimizer, dan perhitungan loss menggunakan categorical cross entropy. Pelatihan dilakukan hingga maksimal 200 epoch dengan memanfaatkan early stopping.

C. Hasil dan Pembahasan

Dari proses training yang dilakukan, didapatkan hasil akurasi sebesar 64,47% pada data validasi. Meskipun performa ini belum optimal, terdapat pola-pola tertentu yang dapat dianalisis lebih lanjut untuk meningkatkan kinerja model. Pengujian terhadap data testing menghasilkan confusion matrix (yang dinormalisasi terhadap nilai prediksinya) seperti ditampilkan pada **Gambar 6**.



Gambar 6. Riwayat Akurasi dan Loss pada Training

		Prediction			
		stand	extend	hold	release
Actual	stand	60,51%	17,24%	11,93%	4,44%
	extend	12,10%	56,90%	30,73%	6,67%
	hold	14,65%	22,41%	55,96%	7,56%
	release	12,74%	3,45%	1,38%	81,33%

Gambar 7. Confusion Matrix

Riwayat dari proses training ditampilkan pada **Gambar 7**. Pada diagram tersebut, terlihat bahwa akurasi dan akurasi validasi tidak naik di atas 65% sampai training di epoch ke-80. Untuk analisis lebih lanjut, ditampilkan juga tabel precision, recall, dan f1-score masing-masing kelas dalam **Tabel 2**.

Tabel 2. Nilai Precision, Recall, dan F1-Score

No	Class	Precision	Recall	F1-Score
1	Stand	60,51%	59,01%	59,75%
2	Extend	56,90%	49,50%	52,94%
3	Hold	55,96%	60,70%	58,23%
4	Release	81,33%	86,32%	83,75%

Kelas release memiliki precision, recall, dan f1-score yang paling besar, yaitu sekitar 80%, menunjukkan bahwa model dapat mengenali kelas tersebut dengan baik. Sementara itu kelas stand, extend, dan hold sering salah diklasifikasikan dengan skor berkisar di 60%. Kelas extend paling sering disalahklasifikasikan ke hold dan sebaliknya, menunjukkan bahwa perlu ada pembeda lain yang lebih kuat diantara keduanya.

Analisis lanjutan menunjukkan bahwa beberapa gambar yang digunakan menampilkan lebih dari satu objek pemanah. Hal ini menyebabkan pelabelan awal yang tidak sesuai karena gerakan masing-masing pemanah bisa berbeda dalam satu waktu tertentu seperti dicontohkan pada **Gambar 8**.

Pada penelitian lanjutan, akan dilakukan penambahan variasi data, terutama pada kelas-kelas yang sulit didiskriminasikan seperti extend dan hold. Selain itu, akan dilakukan proses pembersihan data agar gambar atau video yang digunakan hanya berupa gerakan yang seragam atau mengandung objek tunggal. Proses training juga akan ditingkatkan dengan melakukan parameter tuning dan memberikan metode regularisasi tambahan.



Gambar 8. Data dengan Multiple Object

Hasil sementara, model sudah dapat mengenali dan mengklasifikasikan gerakan panahan dalam 4 kelas berbeda dengan akurasi yang masih terbatas. Hasil prediksi model terhadap salah satu data testing berbentuk video dapat dilihat pada **Gambar 9**.



Gambar 9. Hasil Prediksi Terhadap Video

D. Simpulan

Penelitian ini menunjukkan potensi penerapan machine learning, khususnya kombinasi YOLO dan LSTM, dalam mengenali dan mengklasifikasikan gerakan olahraga panahan ke dalam empat kelas utama. Meskipun akurasi model masih terbatas, hasil yang dicapai memberikan dasar kuat untuk pengembangan lebih lanjut di bidang teknologi pendukung pelatihan olahraga, terutama panahan. Sistem yang dirancang mampu memberikan gambaran awal tentang kemampuan model untuk mengenali pola gerakan secara otomatis, yang dapat diterapkan sebagai alat bantu analisis performa atlet dalam latihan.

Ke depannya, peningkatan performa model dapat dilakukan dengan memperbaiki proses pengambilan gerakan, memperbesar ukuran dataset, menambah variasi, serta menerapkan teknik augmentasi data dan parameter tuning.

E. Ucapan Terima Kasih

Terima kasih kepada LPPM STTNF yang telah mendanai penelitian ini dan kepada SAI Archery Cipedak yang telah mengizinkan peneliti mengambil dan menggunakan data latihannya untuk penelitian ini.

F. Referensi

- [1] M. Sasmarianto, *Mengenal Olahraga Panahan*, Bandung: Penerbit Widina Bhakti Persada, 2023.
- [2] Harsono, *Panahan: Untuk Pemula*, Bandung: UPI, 2004.
- [3] Y. Nurdin, *Hasil Memanah Jarak 30 Meter Dikaitkan Dengan Antropometri, Kekuatan Otot Lengan, Dan Daya Tahan Otot Lengan (Studi Deskriptif terhadap Atlet PPLP Panahan Jawa Barat)*, 2014.
- [4] M. S. F. F.D. Ramdani, "Pengaruh Aplikasi Senam E-Learning untuk Meningkatkan Teknik Dasar Senam Lantai Gerakan Roll Depan pada Siswa di SMAN 1 Surade," *Jurnal Kesehatan Jasmani dan Olahraga*, vol. 7, no. 2, pp. 133-137, November 2022.
- [5] D. L. J. Zhang, "The Application of Artificial Intelligence Technology in Sports Competition," *CETCE 2021, Journal of Physics: Conference Series*, 2021.
- [6] K. Komarudin, "Neurotracker Training to Improve The Archery Athlete Concentration," *Jurnal Pendidikan Jasmani dan Olahraga*, vol. 5, no. 2, 2020.
- [7] M. P. E. H. P. a. T. N. H. F. A. Purnomo, "Archery Training Simulation based on Virtual Reality," *2022 1st International Conference on Smart Technology, Applied Informatics, and Engineering (APICS)*, pp. 195-198, 2022.
- [8] J.-Y. M. J. K. E. C. L. Seungkeon Lee, "AI-Based Analysis of Archery Shooting Time from Anchoring to Release Using Pose Estimation and Computer Vision," *Applied Science*, 2024.
- [9] H. C. F. R. D. L. Zhaowei Lin, "Application of AI Motion Capture Technology in Archery Teaching," dalam *2nd International Conference on Health Big Data and Smart Sports*, Xiamen, China, 2022.

- [10] K. H. L. J. T. S. P. H. Z. Basil Andy Lease, "Deep Learning Posture Estimation for Archery Consistency Measurement," dalam *2024 International Conference on Image Processing, Computer Vision and Machine Learning (ICICML)*, Shenzhen, China, 2024.
- [11] J. Redmon, *You Only Look Once: Unified, Real-Time Object Detection*, 2016.
- [12] H. M. I. M. P. S. R. Miral Desai, "Evaluating the Performance of the YOLO Object Detection Framework on COCO Dataset and Real-World Scenarios," *Procedia Computer Science*, vol. 251, pp. 157-163, 2024.
- [13] M. Gao, "YOLO AND COCO DATASET DETECTIVE PORFERENCE," *World Journal of Information Technology*, vol. 2, no. 2, pp. 28-34, 2024.
- [14] M. M. S. B. J. H. P. P. D. R. P. D. & C. L. Z. Tsung-Yi Lin, "Microsoft COCO: Common Objects in Context," Cham, 2014.
- [15] J. S. S. Hochreiter, "Long Short-Term Memory," *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, 1997.
- [16] H. K. P. H. K. A. M. S. M. G. M. K. N. D.-T. Abhishek Samanta, "IMPECT-POSE: A Complete Front-end and Back-end Architecture for Pose Tracking and Feedback," dalam *The 32nd ACM Conference on User Modeling, Adaptation and Personalization*, Cagliari, Sardinia, Italy, 2024.