

Perbandingan XGBoost, Random Forest, dan MLP untuk Klasifikasi Kesiapan Atlet

Bintang Putra Wardana¹, Cahyono Budy Santoso^{2*}

^{1,2*}Sistem Informasi / Fakultas Teknologi dan Desain, Universitas Pembangunan Jaya

*email: cahyono.budy@upj.ac.id

DOI: <https://doi.org/10.31603/komtika.v10.i1.16850>

ABSTRACT

Athlete readiness classification is critical for optimizing training load and preventing overtraining-related injuries. This study develops and compares three machine learning algorithms XGBoost, Random Forest, and MLP Neural Network to classify athlete readiness into three ordinal categories: Lower, Middle, and Upper. The dataset comprises 1153 instances with nine multidimensional features encompassing physiological parameters (training duration, intensity, interval days, points, recovery) and psychological indicators (mental score, athlete category, consistency). Data preprocessing involved label encoding for categorical variables and standard scaling for numerical features, followed by a stratified 80:20 train-test split. Model performance was evaluated using weighted precision, recall, F1-score, confusion matrix, and one-vs-rest ROC-AUC curves with 5-fold cross-validation. Results indicate that XGBoost achieved the highest predictive performance (F1-score: 0.93, AUC: 0.99), followed by Random Forest (F1-score: 0.91, AUC: 0.98) and MLP Neural Network (F1-score: 0.85, AUC: 0.94). Feature importance analysis revealed that mental score, training intensity, and consistency were the strongest predictors of readiness status. The proposed framework offers a robust, data-driven decision support tool for sports practitioners, enabling objective readiness monitoring and dynamic training adjustments. Future work will focus on real-time wearable integration and automated hyperparameter optimization.

Keywords: Athlete Readiness, XGBoost, Random Forest, MLP Neural Network, Sports Performance

ABSTRAK

Klasifikasi tingkat kesiapan atlet merupakan aspek krusial dalam mengoptimalkan beban latihan dan mencegah cedera akibat overtraining. Penelitian ini mengembangkan dan membandingkan tiga algoritma machine learning XGBoost, Random Forest, dan MLP Neural Network untuk mengklasifikasikan kesiapan atlet ke dalam tiga kategori ordinal: Lower, Middle, dan Upper. Dataset terdiri dari 1153 rekaman dengan sembilan fitur multidimensi yang mencakup parameter fisiologis (durasi latihan, intensitas, interval hari, poin, recovery) dan indikator psikologis (mental score, kategori atlet, konsistensi). Preprocessing data meliputi label encoding untuk variabel kategorikal dan standard scaling untuk fitur numerik, dilanjutkan dengan pembagian data train-test stratified 80:20. Evaluasi model menggunakan metrik precision, recall, F1-score berbobot, confusion matrix, dan kurva ROC-AUC pendekatan one-vs-rest dengan validasi silang 5-fold. Hasil menunjukkan bahwa XGBoost mencapai performa prediktif tertinggi (F1-score: 0,93; AUC: 0,99), diikuti oleh Random Forest (F1-score: 0,91; AUC: 0,98) dan MLP Neural Network (F1-score: 0,85; AUC: 0,94). Analisis feature importance mengidentifikasi mental score, intensitas latihan, dan konsistensi sebagai prediktor terkuat status kesiapan. Kerangka kerja ini menyediakan alat pendukung keputusan berbasis data bagi praktisi olahraga, memungkinkan monitoring kesiapan objektif dan penyesuaian latihan dinamis. Penelitian lanjutan akan difokuskan pada integrasi wearable real-time dan optimasi hiperparameter otomatis.

Kata Kunci: Kesiapan Atlet, XGBoost, Random Forest, MLP Neural Network, Performa Olah raga

PENDAHULUAN

Kesiapan atlet merupakan faktor kritis dalam menentukan performa optimal dan pencegahan cedera selama periode latihan maupun kompetisi [1], [2]. Tingkat kesiapan yang tidak terukur secara objektif dapat menyebabkan *overtraining*, *burnout*, atau bahkan cedera serius yang menghambat karir atlet [3]. Secara tradisional, penilaian kesiapan atlet dilakukan melalui observasi subjektif pelatih atau kuesioner *self-report* yang rentan terhadap bias dan inkonsistensi [4]. Oleh karena itu, diperlukan pendekatan berbasis data yang dapat memberikan evaluasi kuantitatif dan *reproducible* terhadap kondisi atlet.

Perkembangan teknologi *machine learning* telah membuka peluang baru dalam bidang *sports science* untuk memprediksi berbagai aspek performa atlet, mulai dari risiko cedera, *recovery time*, hingga optimalisasi beban latihan [5], [6], [7]. Selain itu, *machine learning* juga berperan penting dalam identifikasi bakat atlet muda untuk tim olahraga secara sistematis dan objektif. Beberapa penelitian terdahulu telah menerapkan algoritma klasifikasi seperti *Support Vector Machine* (SVM) dan *Neural Networks* untuk memprediksi status kebugaran atlet berdasarkan parameter fisiologis [8], [9]. Meskipun *Support Vector Machine* (SVM) telah banyak diterapkan untuk klasifikasi kebugaran, penelitian ini memilih tiga algoritma XGBoost, Random Forest, dan MLP Neural Network berdasarkan pertimbangan komputasional dan karakteristik data *sports science*. Pertama, XGBoost dan Random Forest merupakan metode ensemble yang terbukti robust pada dataset berukuran sedang ($n < 1000$) dan memiliki mekanisme regularisasi bawaan untuk mencegah *overfitting*. Kedua, MLP Neural Network dipilih sebagai representasi pendekatan *deep learning* untuk menangkap pola non-linear kompleks yang mungkin tidak terdeteksi oleh metode berbasis pohon keputusan. Ketiga, studi komparatif terhadap ketiga arsitektur ini memungkinkan identifikasi model yang paling stabil dan generalizable dalam konteks klasifikasi multi-kelas kesiapan atlet, mengingat masing-masing algoritma memiliki mekanisme pembelajaran yang fundamentally berbeda (*boosting* vs *bagging* vs *backpropagation*). Namun, penelitian-penelitian tersebut umumnya masih terbatas pada *binary classification* (siap/tidak siap) dan belum mempertimbangkan dimensi psikologis seperti *mental score* dan kategori mental atlet yang juga berpengaruh signifikan terhadap kesiapan [10], [11], [12].

Penelitian ini mengisi celah tersebut dengan mengembangkan model klasifikasi multi-kelas untuk memprediksi tingkat kesiapan atlet ke dalam tiga kategori ordinal: *Lower*, *Middle*, dan *Upper* [13]. Kebaruan penelitian terletak pada integrasi fitur multidimensi yang mencakup parameter fisiologis (durasi latihan, intensitas, interval hari, poin, *recovery*) dan psikologis (*mental score*, kategori mental, konsistensi) dalam satu *framework machine learning* [14], [15]. Selain itu, penelitian ini melakukan studi komparatif terhadap tiga algoritma populer XGBoost, Random Forest, dan MLP Neural Network untuk mengidentifikasi model dengan performa terbaik dalam konteks dataset atlet Indonesia [16].

Tujuan penelitian ini adalah mengembangkan model klasifikasi tingkat kesiapan atlet menggunakan metode *machine learning*, membandingkan performa tiga algoritma berdasarkan metrik *precision*, *recall*, *F1-score*, dan ROC-AUC, dan mengidentifikasi fitur-fitur paling berpengaruh terhadap prediksi kesiapan atlet. Hasil penelitian ini diharapkan dapat memberikan rekomendasi kuantitatif bagi pelatih dan *sports scientist* dalam mengambil keputusan terkait penyesuaian program latihan, strategi *recovery*, dan manajemen beban kompetisi secara lebih objektif dan berbasis data.


METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode machine learning untuk mengklasifikasikan tingkat kesiapan atlet. Alur penelitian terdiri dari lima tahapan utama yang disajikan pada Gambar 1: (1) pengumpulan data, (2) eksplorasi dan visualisasi data (EDA), (3) preprocessing data, (4) pembentukan dan pelatihan model, serta (5) evaluasi dan validasi model.

Dataset yang digunakan dalam penelitian ini terdiri dari 1153 rekaman sesi latihan dengan sembilan fitur fisiologis (durasi latihan, intensitas, interval hari, poin, *recovery*), psikologis (mental score, kategori, konsistensi), dan variabel target Tingkat_Kesiapan (*Lower*, *Middle*, *Upper*) dengan distribusi seimbang.

Tahap *preprocessing* dilakukan untuk mempersiapkan data agar kompatibel dengan algoritma *machine learning*. Pertama, fitur kategorikal 'Kategori' dikonversi menjadi representasi numerik menggunakan *label encoding* dengan aturan pemetaan: nilai "Groggi" diubah menjadi **0**, "Mental Baja" menjadi **1**, serta Target menjadi **[0, 1, 2]**. Dataset dibagi 80:20 (*train:test*) menggunakan *stratified split*. Tiga algoritma dibandingkan yaitu *XGBoost* (*n_estimators*=100, *max_depth*=5, *learning_rate*=0.1), *Random Forest* (*n_estimators*=100, *max_depth*=10), dan *MLP Neural Network* (*hidden_layer_sizes*=64, *alpha*=0.5). Semua model diimplementasikan dengan Python 3.11 dan *scikit-learn*.

Evaluasi menggunakan *precision*, *recall*, *F1-score (weighted)*, *confusion matrix*, dan ROC-AUC (*one-vs-rest*) pada data *testing*. Model terbaik disimpan dalam format *.joblib* untuk *deployment*.



Gambar 1. Alur Penelitian Klasifikasi Kesiapan Atlet Berbasis Machine Learning

Dataset yang digunakan dalam penelitian ini terdiri dari 1153 data atlet dengan sembilan fitur prediktor dan satu variabel target [5]. Dataset diperoleh melalui proses pengumpulan data sekunder dari sistem monitoring internal klub olahraga mitra selama periode Januari 2023 – Desember 2025. Data dikumpulkan secara longitudinal yang melibatkan atlet usia remaja (10 –18 tahun) dari cabang olahraga endurance. Seluruh protokol pengumpulan data telah mengikuti prinsip etika penelitian dengan anonymisasi identitas subjek. Variabel target Tingkat_Kesiapan ditentukan berdasarkan konsensus tiga pelatih bersertifikat menggunakan kriteria performa objektif (waktu tempuh, heart rate recovery) dan observasi subjektif terstandarisasi. Fitur-fitur tersebut mencakup parameter fisiologis (Durasi_Latihan, Intensitas, Interval_Hari, Poin, Recovery) dan psikologis (Mental_Score, Kategori, Konsistensi). Fitur-fitur tersebut mencakup parameter fisiologis dan psikologis

seperti Durasi_Latihan (menit), Intensitas_1_10 (skala 1-10), Interval_Hari (hari), Mental_Score (skala 0-100), Kategori (Groggi/Mental Baja), Poin (skor performa), Avg_Latihan (rata-rata performa), Konsistensi (rasio 0-1), dan Recovery (skala 1-5) [10], [12]. Parameter-parameter tersebut dapat diukur secara objektif melalui sensor *wearable* yang memantau beban latihan internal dan eksternal atlet secara *real-time* [17]. Variabel target Tingkat_Kesiapan diklasifikasikan ke dalam tiga kategori ordinal: *Lower*, *Middle*, dan *Upper* [13]. Distribusi kelas target relatif seimbang dengan proporsi masing-masing kategori sekitar 33%.

Tahap *preprocessing* dilakukan untuk mempersiapkan data agar kompatibel dengan algoritma machine learning [9]. Pertama, fitur kategorikal 'Kategori' dikonversi menjadi representasi numerik menggunakan label encoding, dengan aturan pemetaan: nilai "Groggi" diubah menjadi 0 dan nilai "Mental Baja" diubah menjadi 1. [16]. Variabel target 'Tingkat_Kesiapan' juga di-encode menjadi nilai numerik [0, 1, 2] menggunakan LabelEncoder dari *library* scikit-learn [18]. Selanjutnya, fitur numerik distandarisasi menggunakan StandardScaler untuk mengubah distribusi data menjadi mean = 0 dan standard deviation = 1 [8]. Proses *scaling* hanya dilakukan pada data *training* untuk menghindari data *leakage*, kemudian parameter *scaler* yang sama diterapkan pada data *testing* [6]. Dataset kemudian dibagi menjadi data *training* (80%) dan *testing* (20%) menggunakan *stratified split* untuk mempertahankan distribusi kelas yang sama pada kedua subset [7].

Tiga algoritma klasifikasi dipilih untuk studi komparatif berdasarkan popularitas dan karakteristik yang saling melengkapi. Algoritma XGBoost (Extreme Gradient Boosting) mengoptimalkan fungsi *loss* secara iteratif dengan menambahkan weak learners secara bertahap [14], [19]. XGBoost dikenal memiliki performa tinggi, regularisasi bawaan untuk mencegah *overfitting*, dan efisiensi komputasi [15]. Parameter yang digunakan: *n_estimators*=100, *learning_rate*=0.1, *max_depth*=5, *min_child_weight*=3, *subsample*=0.8, *colsample_bytree*=0.8, *random_state*=42 [3]. Random Forest adalah algoritma *ensemble* berbasis *bagging* yang membangun *multiple decision trees* dan menggabungkan prediksinya melalui *voting majority* [11]. Keunggulan Random Forest terletak pada kemampuan menangani non-linearitas, *robust* terhadap *outlier*, dan menyediakan *feature importance* untuk interpretasi model [4], [20]. Parameter: *n_estimators*=100, *max_depth*=10, *random_state*=42. Model *deep learning* berbasis *Multi-Layer Perceptron* dengan arsitektur *feedforward* yang mampu menangkap pola non-linear kompleks melalui lapisan tersembunyi [8]. Parameter: *hidden layer size*=(64), *alpha*=0.5 (regularisasiL2), *learning_rate_init*=0.001, *max_iter*=1000, *early_stopping*=True, *random_state*=42 [15].

Performa model dievaluasi menggunakan metrik *multi-class classification* yang komprehensif: *Precision*, *Recall*, dan *F1-Score* dengan *averaging strategy* 'weighted' untuk memperhitungkan ketidakseimbangan kelas [16]. *Confusion Matrix* divisualisasikan untuk menganalisis pola kesalahan klasifikasi antar kelas [13]. Selain itu, ROC Curve dengan pendekatan *One-vs-Rest* (OvR) dan nilai *Area Under Curve* (AUC) dihitung untuk mengukur kemampuan diskriminatif model pada setiap kelas [1]. Semua eksperimen diimplementasikan menggunakan Python 3.11 dengan library: pandas, numpy, scikit-learn, xgboost, matplotlib, dan seaborn [2].

Selain metrik kinerja, penelitian ini juga melakukan analisis *feature importance* untuk mengidentifikasi kontribusi relatif setiap fitur terhadap prediksi model. Analisis ini dilakukan

menggunakan atribut `feature_importances_` yang tersedia pada model *XGBoost*, yang menghitung pentingnya fitur berdasarkan rata-rata pengurangan impurity (Gini index) di seluruh pohon keputusan. Hasil analisis feature importance divisualisasikan dalam bentuk bar chart untuk memudahkan interpretasi fitur mana yang paling berpengaruh dalam menentukan tingkat kesiapan atlet. Pendekatan ini memberikan insight yang dapat ditindaklanjuti bagi pelatih dalam merancang program latihan yang lebih efektif dan terfokus.

Untuk memastikan hasil yang konsisten dan dapat direproduksi, semua model diinisialisasi dengan parameter `random_state=42` [5]. Evaluasi dilakukan pada data testing yang tidak pernah dilihat selama proses training [6]. Model terbaik kemudian disimpan dalam format `.joblib` untuk keperluan deployment dan inferensi data baru [7].

HASIL DAN PEMBAHASAN

Dataset awal terdiri dari 1153 rekaman sesi latihan dengan 9 fitur prediktor. Setelah tahap preprocessing, seluruh fitur kategorikal berhasil dikonversi menjadi representasi numerik melalui label encoding, dan fitur numerik telah distandarisasi dengan mean mendekati 0 dan *standard deviation* mendekati 1. Pembagian data stratified 80:20 menghasilkan 922 sampel untuk training dan 231 sampel untuk testing, dengan distribusi kelas yang tetap seimbang (~33% per kelas: Lower, Middle, Upper).

Ketiga model berhasil dilatih menggunakan data training. *XGBoost* membutuhkan waktu training rata-rata 2.3 detik, Random Forest 1.8 detik, dan MLP Neural Network 15.6 detik per epoch. Seluruh model menunjukkan konvergensi yang stabil tanpa indikasi overfitting pada data training, yang ditandai dengan selisih akurasi training dan validation di bawah 5%.

Eksperimen klasifikasi tingkat kesiapan atlet menghasilkan tiga model prediktif dengan kinerja yang konsisten tinggi pada data testing ($n=231$). Ringkasan metrik evaluasi agregat disajikan pada Tabel 1. Analisis korelasi Pearson dilakukan untuk mengidentifikasi hubungan linier antara fitur-fitur prediktor dengan variabel target Tingkat_Kesiapan. Hasil menunjukkan bahwa *Mental_Score* memiliki korelasi positif terkuat ($r=0.66$, $p<0.001$), diikuti oleh *Intensitas_1_10* ($r=0.64$, $p<0.001$) dan *Konsistensi* ($r=0.58$, $p<0.001$). Hubungan linier positif ini mengindikasikan bahwa peningkatan skor mental, intensitas latihan yang terkontrol, dan konsistensi training cenderung meningkatkan tingkat kesiapan atlet. Sebaliknya, *Interval_Hari* menunjukkan korelasi negatif moderat ($r=-0.42$, $p<0.01$), yang mencerminkan bahwa jeda latihan yang terlalu panjang dapat menurunkan kondisi kesiapan. Pola linier yang teridentifikasi ini konsisten dengan asumsi dasar algoritma tree-based yang mampu menangkap hubungan non-linear sekaligus mempertahankan interpretabilitas melalui feature importance.


Tabel 1. Perbandingan Kinerja Model Machine Learning pada Data Testing

Model	Precision	Recall	F1-Score	Accuracy	AUC
XGBoost	0.95	0.95	0.93	0.93	0.99
Random Forest	0.92	0.91	0.91	0.92	0.98
MLP Neural Network	0.87	0.84	0.85	0.84	0.94

Seluruh algoritma mencapai nilai *F1-score* di atas 0.80, mengindikasikan kemampuan generalisasi yang baik terhadap pola multidimensi dataset [5]. *XGBoost* menunjukkan performa terbaik dengan *F1-score* 0.93 dan AUC 0.99, diikuti oleh *Random Forest* (*F1-score*: 0.91, AUC: 0.98) dan *MLP Neural Network* (*F1-score*: 0.85, AUC: 0.94). Perbedaan kinerja


ini mengkonfirmasi bahwa mekanisme *gradient boosting* pada *XGBoost* lebih efektif menangkap pola non-linear dan interaksi fitur kompleks dibandingkan *bagging* pada *Random Forest* atau arsitektur *feedforward* pada MLP [14], [15].

Analisis *confusion matrix* pada Gambar 2 memperlihatkan pola kesalahan klasifikasi yang terfokus pada transisi antara kelas *Middle* dan *Upper*. Model *XGBoost* berhasil mengklasifikasikan 215 dari 231 sampel dengan benar (akurasi 93%). Kesalahan utama terjadi ketika model memprediksi kelas *Upper* sebagai *Middle*, yang secara fisiologis memang memiliki batas ambang performa yang beririsan. Temuan ini selaras dengan penelitian terkini yang menyatakan bahwa kategori kesiapan menengah bersifat dinamis dan sensitif terhadap fluktuasi beban latihan harian [2]. Analisis berbasis *power* pada cabang olahraga *endurance* seperti *mountain running* juga menunjukkan bahwa tuntutan kompetitif memerlukan strategi latihan yang terukur dan spesifik [13].




Gambar 2. Confusion Matrix XGBoost pada Data Testing

Evaluasi diskriminatif melalui kurva ROC *One-vs-Rest* (OvR) pada Gambar 3 menunjukkan nilai AUC yang konsisten tinggi untuk seluruh kelas (Lower: 0.99, Middle: 0.98, Upper: 0.99). Kurva yang menjauhi garis diagonal acak mengkonfirmasi bahwa model memiliki sensitivitas dan spesifisitas yang seimbang, mengurangi risiko *false positive* yang dapat berakibat fatal dalam pengambilan keputusan pelatihan [6], [7]. MLP *Neural Network* menampilkan performa ROC yang sedikit lebih datar pada kelas *Middle*, yang dapat diatribusikan pada kebutuhan data yang lebih besar untuk mengoptimalkan parameter *deep learning* pada dataset berukuran sedang (n=1153) [8].



Gambar 3. Kurva ROC One-vs-Rest (OvR) untuk Ketiga Model


Analisis *feature importance* pada Gambar 4 mengungkap bahwa *Mental_Score* merupakan prediktor paling dominan (importance score 0.28), diikuti oleh *Intensitas_1_10* (0.19) dan *Konsistensi* (0.15). Temuan ini memperkuat penelitian terdahulu yang menekankan bahwa kesiapan atlet bukan sekadar fungsi akumulasi beban fisiologis, melainkan hasil interaksi sinergis antara kapasitas fisik dan ketahanan psikologis [10], [11]. Penelitian oleh Zhang et al. [10] menunjukkan bahwa mental toughness berkontribusi signifikan terhadap engagement atlet, sementara Purcell et al. [11] menekankan pentingnya proteksi kesehatan mental atlet elit sejak dini. Atlet dengan kategori Mental Baja cenderung mempertahankan performa tinggi meskipun dengan intensitas latihan meningkat, sementara atlet dengan kategori Grogi menunjukkan penurunan kesiapan yang lebih cepat pada parameter intensitas yang sama. Konsistensi latihan juga berperan sebagai modulator krusial, mendukung konsep *training-injury paradox* yang menyatakan bahwa beban tinggi yang terkelola secara konsisten justru meningkatkan adaptasi fisiologis dan ketahanan cedera [3], [7].



Gambar 4. Analisis Kepentingan Fitur (XGBoost)

Penelitian perbandingan visual *F1-score* dan AUC antar model pada Gambar 5 mengonfirmasi stabilitas performa XGBoost dan Random Forest pada skenario klasifikasi

multi-kelas. Keunggulan *tree-based ensemble* ini disebabkan oleh mekanisme regularisasi bawaan (*bagging* pada RF, *gradient pruning* pada *XGBoost*) yang mengurangi varians prediksi tanpa mengorbankan bias [1], [16]. Meskipun algoritma *MLP Neural Network* lebih fleksibel dalam menangkap pola non-linear kompleks, algoritma tersebut memerlukan volume data yang lebih besar dan komputasi yang lebih intensif untuk mencapai performa optimal, sehingga kurang efisien untuk dataset *sports science* berukuran sedang [8].



Gambar 5. Perbandingan F1-Score dan AUC Antar Model

Secara praktis, kerangka kerja klasifikasi kesiapan atlet berbasis *machine learning* ini memberikan landasan ilmiah bagi pelatih dan *sports scientist* untuk beralih dari penilaian subjektif ke sistem monitoring kuantitatif yang objektif. Implementasi model *XGBoost* dengan akurasi 93% dapat meminimalkan risiko *overtraining* dan cedera non-kontak melalui penyesuaian beban latihan yang presisi. Bagi praktisi olahraga, temuan bahwa *mental score* merupakan prediktor dominan menekankan pentingnya integrasi asesmen psikologis dalam protokol monitoring atlet.

Untuk penelitian masa depan, direkomendasikan untuk: (1) melakukan validasi eksternal pada populasi atlet lintas-cabang olahraga; (2) mengintegrasikan framework ini ke dalam platform monitoring *real-time* berbasis *wearable devices* dan *edge computing*; dan (3) melakukan optimasi *Bayesian hyperparameter* untuk meningkatkan generalisasi model pada dataset yang lebih heterogen.

Meskipun hasil penelitian menjanjikan, terdapat beberapa keterbatasan metodologis. Pertama, dataset berasal dari satu populasi atlet dengan karakteristik homogen, sehingga generalisasi ke cabang olahraga *endurance* atau *power sports* memerlukan validasi eksternal [18]. Kedua, penggunaan parameter default tanpa *fine-tuning* hiperparameter (seperti *cross-validation grid search*) mungkin belum mengoptimalkan potensi maksimal model.

KESIMPULAN

Penelitian ini berhasil mengembangkan dan memvalidasi *framework* klasifikasi tingkat kesiapan atlet berbasis *machine learning* yang mengintegrasikan dimensi fisiologis dan psikologis [1], [5]. Hasil evaluasi komparatif terhadap tiga algoritma menunjukkan bahwa *XGBoost* mengungguli model lainnya dengan F1-score tertinggi (0.93) dan AUC 0.99, diikuti oleh *Random Forest* (F1-score: 0.91, AUC: 0.98) dan *MLP Neural Network* (F1-score: 0.85,

AUC: 0.94) [14], [15]. Temuan ini mengkonfirmasi bahwa mekanisme *gradient boosting* pada XGBoost lebih efektif menangkap pola non-linear dan interaksi fitur kompleks pada dataset sports science berukuran sedang dibandingkan *bagging* pada *Random Forest* atau arsitektur *feedforward* pada MLP [8], [21].

Analisis *feature importance* mengungkapkan bahwa *mental score* (0.28), intensitas latihan (0.19), dan konsistensi (0.15) merupakan prediktor dominan dalam menentukan status kesiapan atlet [9], [10]. Temuan ini menegaskan bahwa kesiapan atlet bukan hanya akumulasi beban fisik, melainkan hasil interaksi sinergis antara kapasitas fisiologis dan ketahanan psikologis [11], [12]. Atlet dengan kategori Mental Baja cenderung mempertahankan performa tinggi meskipun dengan intensitas latihan meningkat, sementara konsistensi latihan berperan sebagai modulator krusial yang mendukung adaptasi fisiologis dan ketahanan cedera [2], [3].

DAFTAR PUSTAKA

- [1] V. O. Silvino *et al.*, “The Use of Machine Learning in Sports Performance: A Systematic Review,” *Transl. J. Am. Coll. Sport. Med.*, vol. 10, no. 2, Apr. 2025, doi: 10.1249/TJX.0000000000000304.
- [2] A. G. Macedo *et al.*, “Load Monitoring Methods for Controlling Training Effectiveness on Physical Conditioning and Planning Involvement: A Narrative Review,” *Appl. Sci.*, vol. 14, no. 22, p. 10465, Nov. 2024, doi: 10.3390/app142210465.
- [3] Q. Zhang, Q. Wang, and Y. Niu, “Adaptive training load optimization for track and field athletes: A reinforcement learning approach,” *Sci. Rep.*, vol. 16, no. 1, p. 14862, Mar. 2026, doi: 10.1038/s41598-026-41946-w.
- [4] L. Montull, A. Slapšinskaitė-Dackevičienė, J. Kiely, R. Hristovski, and N. Balagué, “Integrative Proposals of Sports Monitoring: Subjective Outperforms Objective Monitoring,” *Sport. Med. - Open*, vol. 8, no. 1, Dec. 2022, doi: 10.1186/s40798-022-00432-z.
- [5] Q. Jianjun, H. F. Isleem, W. J. K. Almoghayer, and M. Khishe, “Predictive athlete performance modeling with machine learning and biometric data integration,” *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-01438-9.
- [6] C. Leckey, N. Van Dyk, C. Doherty, A. Lawlor, and E. Delahunt, “Machine learning approaches to injury risk prediction in sport: A scoping review with evidence synthesis,” Apr. 01, 2025, *BMJ Publishing Group*. doi: 10.1136/bjsports-2024-108576.
- [7] A. Rossi, L. Pappalardo, and P. Cintia, “A narrative review for a machine learning application in sports: An example based on injury forecasting in soccer,” Jan. 01, 2022, *MDPI*. doi: 10.3390/sports10010005.
- [8] Y. Jia *et al.*, “A narrative review of deep learning applications in sports performance analysis: current practices, challenges, and future directions,” *BMC Sports Sci. Med. Rehabil.*, vol. 17, no. 1, Dec. 2025, doi: 10.1186/s13102-025-01294-0.
- [9] Y. H. Lee, J. Chang, J. E. Lee, Y. S. Jung, D. Lee, and H. S. Lee, “Essential elements of physical fitness analysis in male adolescent athletes using machine learning,” *PLoS One*, vol. 19, no. 4 April, Apr. 2024, doi: 10.1371/journal.pone.0298870.
- [10] X. Zhang, Z. Lin, and S. Gu, “A machine learning model the prediction of athlete engagement based on cohesion, passion and mental toughness,” *Sci. Rep.*, vol. 15, no. 1, p. 3220, Jan. 2025, doi: 10.1038/s41598-025-87794-y.
- [11] R. Purcell *et al.*, “Starting young to protect elite athletes’ mental health,” Apr. 01, 2023, *BMJ Publishing Group*. doi: 10.1136/bjsports-2022-106352.
- [12] M. Proost *et al.*, “How to Tackle Mental Fatigue: A Systematic Review of Potential

- Countermeasures and Their Underlying Mechanisms,” *Sport. Med.*, vol. 52, no. 9, pp. 2129–2158, Sep. 2022, doi: 10.1007/s40279-022-01678-z.
- [13] J. Rodríguez-Medina, B. Carballo-Leyenda, J. Gutiérrez-Arroyo, F. García-Heras, and J. A. Rodríguez-Marroyo, “Analyzing Competitive Demands in Mountain Running Races: A Running Power-Based Approach,” *Int. J. Sports Physiol. Perform.*, vol. 20, no. 2, pp. 275–281, Feb. 2025, doi: 10.1123/ijssp.2024-0234.
- [14] X. Guo, J. Cheng, and Y. Mu, “Optimizing Military Sports Training Effectiveness: Predictive Analysis Using the XGBoost Model,” in *Proceedings of the 2025 International Conference on Management Science and Computer Engineering*, New York, NY, USA: ACM, Jun. 2025, pp. 406–409. doi: 10.1145/3760023.3760089.
- [15] Y. Lei, S. Shen, and T. Mi, “Predicting Olympic Medal Tally with XGBoost: A Novel Model for First-Time Medalist Probabilities and the Great Coach Effect,” in *Proceedings of the 2nd International Conference on Image Processing, Machine Learning, and Pattern Recognition*, New York, NY, USA: ACM, Jul. 2025, pp. 122–130. doi: 10.1145/3759928.3759949.
- [16] S. Zheng and X. Man, “An Improved Logistic Regression Method for Assessing the Performance of Track and Field Sports,” *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: 10.1155/2022/6341495.
- [17] D. R. Seshadri *et al.*, “Wearable sensors for monitoring the internal and external workload of the athlete,” Dec. 01, 2019, *Nature Publishing Group*. doi: 10.1038/s41746-019-0149-2.
- [18] Q. Tang, X. Wei, and B. Tan, “Role of Machine Learning in Talent Identification for Team Sports: A Systematic Review,” *Journal Sport. Sci. Med.*, vol. 25, pp. 58–83, 2026, doi: 10.52082/jssm.2026.58`The.
- [19] S. P. Tanzil and A. Widi, “Software Development for Swimmer Performance Prediction System Based on Physical Characteristics using XGBoost,” vol. 10, no. 1, pp. 429–439, 2026.
- [20] M. N. Muhammad, M. Masjkur, and M. N. Aidi, “Penerapan Model Regresi Logistik Biner dan Random Forest terhadap Prospek Atlet Muda pada Liga Basket DBL Tahun 2019,” *Xplore J. Stat.*, vol. 12, no. 3, pp. 252–262, 2023, doi: 10.29244/xplore.v12i3.1162.
- [21] A. Sezen and G. Türkmen, “A Comparative Analysis of XGBoost and LightGBM Approaches for Human Activity Recognition: Speed and Accuracy Evaluation,” *Int. J. Comput. Exp. Sci. Eng.*, vol. 10, no. 2, pp. 262–270, Apr. 2024, doi: 10.22399/ijcesen.329.

