



Implementasi Algoritma Xgboost dengan Bayesian Optimization pada Sistem Rekomendasi Pemilihan Atlet Bola Voli Pantai Sulawesi Tenggara untuk Meningkatkan Efektivitas Keputusan

Muhammad Akbar Perdana Ramadhan¹, Laode Muhammad Golok Jaya², Adha Mashur Sajiah³, Bambang Pramono⁴, Sutardi⁵, Subardin⁶

¹²³⁴⁵⁶Jurusan Informatika, Fakultas Teknik, Universitas Halu Oleo, Kendari

^{1*}muhakbarpr.22113@gmail.com, ²laodemgj@uho.ac.id, ³adha.m.sajiah@uho.ac.id, ⁴bambangpramono09@gmail.com,
⁵sutardi_ft@uho.ac.id, ⁶subardin@uho.ac.id

Abstrak

Seleksi atlet bola voli pantai di Sulawesi Tenggara masih dilakukan secara konvensional dan bergantung pada penilaian subjektif pelatih, sehingga rentan menimbulkan inkonsistensi dan pengambilan keputusan yang kurang optimal di tengah meningkatnya jumlah calon atlet dan kompleksitas kriteria evaluasi. Kondisi ini berpotensi menghasilkan keputusan yang kurang tepat dan menghambat pengembangan atlet potensial. Penelitian ini mengimplementasikan algoritma Extreme Gradient Boosting (XGBoost) yang dioptimasi menggunakan Bayesian Optimization untuk membangun sistem rekomendasi pemilihan atlet yang objektif dan berbasis data. Dataset yang digunakan berjumlah 320 data atlet dengan 13 kriteria penilaian, dibagi menjadi 80% data pelatihan dan 20% data pengujian. Ketiga belas kriteria tersebut mencakup tinggi badan, kekuatan otot, kecepatan, kelincahan, teknik servis, smash, dan aspek psikologis. Evaluasi model dilakukan menggunakan metrik MAE, MSE, RMSE, R^2 , dan MAPE. Hasil penelitian menunjukkan bahwa Bayesian Optimization mampu meningkatkan performa model secara signifikan, dengan nilai MAE menurun dari 1,2878 menjadi 0,9074, MSE dari 2,3796 menjadi 1,2547, RMSE dari 1,5426 menjadi 1,1201, serta R^2 meningkat dari 0,9412 menjadi 0,9852. Model akhir mencapai MAPE sebesar 2,61%, yang tergolong kategori sangat akurat berdasarkan kriteria Lewis (1982). Nilai MAPE di bawah 10% menunjukkan akurasi peramalan yang sangat tinggi. Sistem berhasil diimplementasikan sebagai aplikasi web berbasis Flask dan telah divalidasi secara kualitatif oleh pakar bola voli pantai. Hasil pengujian black box menunjukkan seluruh fitur sistem berjalan sesuai fungsi yang dirancang. Dengan demikian, sistem ini dapat diandalkan untuk mendukung seleksi atlet yang lebih transparan dan akurat.

Kata Kunci: XGBoost, Bayesian Optimization, Sistem Rekomendasi, Bola Voli Pantai, Machine Learning

1. Latar Belakang

Bola voli pantai merupakan cabang olahraga yang menuntut kombinasi kemampuan fisik, teknis, dan mental yang tinggi dari setiap atletnya. Di Sulawesi Tenggara, pengembangan atlet bola voli pantai menghadapi tantangan utama berupa proses seleksi yang masih dilakukan secara konvensional dan bergantung pada penilaian subjektif pelatih. Pendekatan ini rentan menimbulkan inkonsistensi dan keputusan yang kurang optimal, terutama di tengah meningkatnya jumlah calon atlet dan semakin kompleksnya kriteria evaluasi yang harus dipertimbangkan [1].

Perkembangan teknologi machine learning membuka peluang untuk membangun sistem seleksi atlet yang lebih objektif dan berbasis data. Salah satu algoritma yang telah terbukti unggul dalam berbagai domain adalah Extreme Gradient Boosting (XGBoost), sebuah metode ensemble learning berbasis gradient boosting yang mampu menangani hubungan non-linier, memiliki mekanisme regularisasi bawaan untuk mengurangi overfitting, serta bekerja secara efisien pada dataset berskala besar [2].

Meskipun demikian, performa XGBoost sangat dipengaruhi oleh pemilihan hiperparameter yang tepat. Metode konvensional seperti grid search dan random search membutuhkan komputasi yang besar dan tidak selalu menghasilkan konfigurasi optimal. Bayesian Optimization menawarkan pendekatan probabilistik yang lebih efisien dalam menemukan kombinasi hiperparameter terbaik dengan jumlah evaluasi yang lebih sedikit [3].

Penelitian ini bertujuan untuk mengimplementasikan XGBoost yang dioptimasi dengan Bayesian Optimization dalam sistem rekomendasi pemilihan atlet bola voli pantai Sulawesi Tenggara, guna meningkatkan akurasi prediksi dan mendukung proses pengambilan keputusan yang lebih objektif dan terukur. Kontribusi utama penelitian ini adalah menghadirkan sistem rekomendasi atlet berbasis machine learning pertama yang berfokus pada bola voli pantai di Sulawesi Tenggara, lengkap dengan bukti empiris peningkatan performa melalui optimasi hiperparameter.

1.1 Sistem Rekomendasi Berbasis Machine Learning

Sistem rekomendasi berbasis machine learning memanfaatkan data historis untuk menghasilkan saran atau peringkat secara otomatis. Dalam konteks olahraga, pendekatan ini telah diterapkan pada prediksi hasil pertandingan, analisis performa atlet, dan seleksi pemain. Penelitian terdahulu menunjukkan bahwa algoritma berbasis boosting seperti XGBoost dan LightGBM secara konsisten menghasilkan akurasi tinggi pada data tabular olahraga, dengan keunggulan dalam menangkap pola non-linier antara kriteria performa atlet [4][5].

1.2 Extreme Gradient Boosting (XGBoost)

XGBoost adalah algoritma ensemble learning yang membangun model prediktif secara bertahap melalui akumulasi pohon keputusan yang saling mengoreksi kesalahan. Model akhir XGBoost regresi dirumuskan sebagai:

$$\hat{y}^l = \sum_{k=1}^K f_k(x_i) \quad (1)$$

di mana $\hat{y}^l$ adalah nilai prediksi atlet ke- i , K adalah jumlah pohon keputusan, dan f_k adalah fungsi pohon ke- k . Fungsi objektif yang diminimalkan selama pelatihan terdiri dari komponen loss dan regularisasi:

$$Obj = \sum \ell(\hat{y}^l, y_i) + \sum \Omega(f_k) \quad (2)$$

Fungsi regularisasi $\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum w_j^2$ mengontrol kompleksitas pohon dengan membatasi jumlah daun (T) dan bobot daun (w_j), sehingga mencegah overfitting [2].

1.3 Bayesian Optimization

Bayesian Optimization adalah metode optimasi berbasis probabilitas yang menggunakan Gaussian Process untuk memodelkan hubungan antara hiperparameter dan performa model. Metode ini menggunakan acquisition function untuk menentukan titik evaluasi berikutnya secara efisien, memungkinkan pencarian hiperparameter optimal dengan jumlah iterasi yang jauh lebih sedikit dibandingkan grid search atau random search [3][6].

2. Metode Penelitian

2.1 Dataset

Dataset yang digunakan terdiri dari 320 data atlet bola voli pantai Sulawesi Tenggara yang diperoleh dari Persatuan Bola Voli Seluruh Indonesia (PBVSI) tingkat daerah. Setiap atlet dinilai berdasarkan 13 kriteria yang mencakup aspek fisik, teknis, dan performa: (1) Tinggi Badan, (2) Berat Badan, (3) Posisi Pemain, (4) Akurasi Passing, (5) Akurasi Servis, (6) Akurasi Spike, (7) Akurasi Setting, (8) Akurasi Blocking, (9) Akurasi Defense, (10) Teamwork, (11) Tingkat Prestasi, (12) Durasi Latihan, dan (13) Ketahanan Fisik (Beep Test).

2.2 Preprocessing Data

Data atribut yang bersifat kategorikal dan numerik dikonversi ke skala pembobotan 1–5 menggunakan tabel konversi yang disusun berdasarkan masukan pakar. Nilai total skor setiap atlet dihitung sebagai penjumlahan seluruh bobot kriteria dan dijadikan variabel target (y). Data kemudian dibagi menjadi 80% data pelatihan (256 data) dan 20% data pengujian (64 data).

2.3 Implementasi Model

Model XGBoost dibangun menggunakan library xgboost pada Python di lingkungan Google Colaboratory. Proses Bayesian Optimization dilakukan menggunakan library scikit-optimize (skopt) untuk mencari kombinasi hiperparameter terbaik pada ruang pencarian yang telah ditentukan, meliputi `n_estimators` [50–500], `max_depth` [2–6], `learning_rate` [0,01–0,3], `subsample` [0,6–1,0], `colsample_bytree` [0,6–1,0], dan `gamma` [0–1,0]. Sistem akhir diimplementasikan sebagai aplikasi web menggunakan framework Flask.

2.4 Metrik Evaluasi

Performa model dievaluasi menggunakan lima metrik: Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), koefisien determinasi (R^2), dan Mean Absolute Percentage Error (MAPE). Interpretasi MAPE mengacu pada kriteria Lewis (1982): sangat akurat (<10%), akurat (10–20%), cukup akurat (20–50%), dan tidak akurat (>50%).

3. Hasil dan Pembahasan

3.1 Hiperparameter Optimal Hasil Bayesian Optimization

Setelah proses optimasi Bayesian Optimization dengan 50 iterasi, diperoleh kombinasi hiperparameter optimal sebagaimana ditampilkan pada Tabel 1.

Tabel 1. Parameter Optimal Hasil Bayesian Optimization

Parameter	Nilai Optimal
<code>n_estimators</code>	247
<code>max_depth</code>	2
<code>learning_rate</code>	0,1627
<code>subsample</code>	0,8169
<code>colsample_bytree</code>	0,7845
<code>gamma</code>	0,9144

3.2 Perbandingan Performa Sebelum dan Sesudah Optimasi

Tabel 2 menyajikan perbandingan metrik evaluasi model XGBoost sebelum dan sesudah dilakukan optimasi hiperparameter menggunakan Bayesian Optimization.


Tabel 2. Perbandingan Metrik Evaluasi Sebelum dan Sesudah Bayesian Optimization

Metrik	Sebelum Optimasi	Sesudah Optimasi	Peningkatan
MAE	1,2878	0,9074	↓ 29,6%
MSE	2,3796	1,2547	↓ 47,3%
RMSE	1,5426	1,1201	↓ 27,4%
R^2	0,9412	0,9852	↑ 4,7%
MAPE	4,21%	2,61%	↓ 38,0%

Hasil pada Tabel 2 menunjukkan bahwa Bayesian Optimization memberikan peningkatan signifikan pada seluruh metrik evaluasi. Nilai MAE turun sebesar 29,6%, MSE turun 47,3%, dan RMSE turun 27,4%. Nilai R^2 meningkat dari 0,9412 menjadi 0,9852, yang berarti model akhir mampu menjelaskan 98,52% variasi data target. Nilai MAPE sebesar 2,61% berada jauh di bawah ambang 10% menurut Lewis (1982), mengkategorikan model sebagai sangat akurat.

3.3 Analisis Grafik Evaluasi Model


Gambar 1 menampilkan grafik perbandingan nilai aktual dan nilai prediksi model XGBoost teroptimasi pada data pengujian. Sumbu horizontal mewakili indeks data atlet, sedangkan sumbu vertikal mewakili nilai skor. Garis biru menunjukkan nilai aktual dan garis oranye menunjukkan nilai prediksi model.



Gambar 1. Perbandingan Nilai Prediksi dan Nilai Aktual ($R^2 = 0,9852$)

Terlihat bahwa garis prediksi mengikuti pola garis aktual dengan sangat rapat di sepanjang seluruh rentang data pengujian. Kedekatan antara kedua garis ini secara visual mengkonfirmasi nilai $R^2 = 0,9852$ yang diperoleh secara matematis, membuktikan bahwa model mampu menggeneralisasi pola data dengan sangat baik meskipun hanya diuji pada data yang belum pernah dilihat selama pelatihan.


Gambar 2 menampilkan distribusi residual (selisih antara nilai aktual dan nilai prediksi) pada data pengujian. Distribusi yang mendekati normal dan terpusat di sekitar nol mengindikasikan tidak adanya bias sistematis dalam prediksi model.



Gambar 2. Distribusi Residual Model XGBoost Teroptimasi

Distribusi error yang simetris dan sempit mengindikasikan bahwa model tidak cenderung secara konsisten melebihkan (overestimate) maupun meremehkan (underestimate) skor atlet. Hal ini sejalan dengan nilai MAE yang rendah (0,9074), di mana sebagian besar prediksi hanya memiliki selisih kurang dari 1 poin dari skor aktual pada skala 0–65.

Gambar 3 menyajikan perbandingan visual metrik evaluasi sebelum dan sesudah diterapkan Bayesian Optimization. Visualisasi ini memperjelas magnitude peningkatan performa yang diperoleh melalui proses optimasi hiperparameter.



Gambar 3. Perbandingan Performa Model Sebelum dan Sesudah Bayesian Optimization

Grafik ini secara jelas menunjukkan penurunan konsisten pada semua metrik error (MAE, MSE, RMSE) dan peningkatan pada R^2 setelah optimasi. Penurunan terbesar terjadi pada MSE sebesar 47,3%, yang mengindikasikan bahwa Bayesian Optimization berhasil secara signifikan mengurangi prediksi yang meleset jauh dari nilai aktual.

3.4 Implementasi Antarmuka Sistem

Sistem rekomendasi diimplementasikan sebagai aplikasi web berbasis Flask yang dapat diakses melalui browser. Gambar 4 menampilkan halaman utama dashboard sistem yang menyajikan ringkasan statistik dataset atlet, termasuk jumlah total atlet terdaftar, distribusi posisi pemain, dan rata-rata skor per kriteria. Dashboard dirancang untuk memberikan gambaran umum kondisi data atlet kepada pengguna sistem sebelum melakukan proses rekomendasi.



Gambar 4. Tampilan Halaman Dashboard Sistem

Gambar 5 menampilkan halaman kelola data atlet yang memungkinkan pengguna melihat, menambah, mengubah, dan menghapus data atlet secara langsung melalui antarmuka tabel interaktif. Setiap baris data menampilkan identitas atlet beserta nilai 13 kriteria yang telah dikonversi ke skala bobot. Fitur pencarian dan filter tersedia untuk memudahkan pengelolaan data atlet dalam jumlah besar.

No	Nama Atlet	Posisi	Tim	Posisi Pemain	Posisi Pemain	Posisi Pemain	Posisi Pemain	Posisi Pemain	Posisi Pemain	Posisi Pemain	Posisi Pemain	Posisi Pemain	Posisi Pemain
1	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero
2	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero
3	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero
4	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero
5	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero
6	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero
7	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero
8	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero
9	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero
10	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero
11	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero
12	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero
13	Adi	Libero	Tim	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero	Libero

Gambar 5. Tampilan Halaman Kelola Data Atlet


Gambar 6 menampilkan halaman input data atlet baru yang menyediakan formulir terstruktur untuk memasukkan data atlet. Setiap field input dilengkapi dengan dropdown pilihan yang telah dikalibrasi sesuai tabel pembobotan, sehingga pengguna tidak perlu mengetahui nilai bobot secara langsung. Sistem secara otomatis mengonversi nilai input ke skala 1–5 sebelum diproses oleh model prediksi.

Gambar 6. Tampilan Halaman Input Data Atlet Baru

Gambar 7 menampilkan halaman hasil rekomendasi atlet yang merupakan output utama sistem. Halaman ini menampilkan peringkat atlet secara otomatis berdasarkan skor prediksi model XGBoost, dilengkapi dengan keterangan status rekomendasi (Sangat Direkomendasikan, Direkomendasikan, atau Tidak Direkomendasikan) sesuai rentang skor yang telah ditentukan. Pelatih dapat menggunakan halaman ini sebagai dasar pengambilan keputusan dalam proses seleksi atlet secara objektif.

Gambar 7. Tampilan Halaman Hasil Rekomendasi Atlet

Gambar 8 menampilkan halaman informasi model yang menyajikan detail teknis model XGBoost yang sedang aktif digunakan, meliputi hiperparameter optimal hasil Bayesian Optimization, metrik evaluasi model, dan tanggal terakhir model diperbarui. Halaman ini memberikan transparansi kepada pengguna mengenai performa dan konfigurasi model yang mendasari sistem rekomendasi.



Gambar 8. Tampilan Halaman Informasi Model

3.5 Analisis Performa Model

Nilai MAE sebesar 0,9074 menunjukkan bahwa rata-rata prediksi model hanya meleset kurang dari 1 poin dari skor aktual atlet, pada skala skor 0 hingga 65 poin. Nilai RMSE sebesar 1,1201 yang hanya sedikit lebih tinggi dari MAE mengindikasikan bahwa tidak terdapat outlier prediksi yang signifikan, sehingga model cenderung konsisten di seluruh rentang data.

Nilai $R^2 = 0,9852$ menunjukkan kekuatan prediktif yang sangat tinggi. Berdasarkan panduan Cohen (1988), nilai R^2 di atas 0,90 tergolong sangat kuat, yang berarti hampir seluruh variasi skor antar atlet dapat dijelaskan oleh 13 kriteria yang digunakan. Nilai gamma hasil optimasi yang cukup besar (0,9144) berperan sebagai regularisasi efektif yang mencegah overfitting, terbukti dari selisih MAPE antara data latih dan data uji yang hanya sebesar 0,30%.

Perbandingan dengan penelitian terdahulu menunjukkan bahwa kombinasi XGBoost dan Bayesian Optimization dalam penelitian ini menghasilkan performa yang kompetitif. Penelitian pada prediksi harga Ethereum menggunakan metode serupa mencapai R^2 sebesar 0,9777 [7], sedangkan penelitian ini mencapai $R^2 = 0,9852$ pada domain yang berbeda yaitu seleksi atlet olahraga.

3.6 Pengujian Black Box

Pengujian black box dilakukan terhadap seluruh fitur sistem menggunakan 12 skenario uji. Seluruh skenario menunjukkan hasil sesuai yang diharapkan (pass rate 100%), meliputi fungsi autentikasi pengguna, kelola data atlet, input data atlet baru, proses rekomendasi otomatis, tampilan hasil peringkat, dan fitur informasi model. Hasil ini membuktikan bahwa sistem berjalan secara fungsional sesuai kebutuhan pengguna yang telah didefinisikan.

3.7 Validasi Kualitatif oleh Pakar

Validasi kualitatif dilakukan oleh seorang pakar bola voli pantai dengan pengalaman lebih dari 10 tahun melatih atlet di Sulawesi Tenggara. Hasil rekomendasi sistem dinilai sesuai dengan pertimbangan empiris pelatih, terutama dalam mengidentifikasi atlet dengan kombinasi kemampuan teknis dan fisik yang seimbang. Pakar menyatakan bahwa sistem dapat menjadi alat bantu yang berharga dalam proses seleksi atlet secara objektif dan terstandarisasi.

4. Kesimpulan

Penelitian ini berhasil mengimplementasikan algoritma XGBoost yang dioptimasi menggunakan Bayesian Optimization pada sistem rekomendasi pemilihan atlet bola voli pantai Sulawesi Tenggara. Tiga kesimpulan utama dapat ditarik dari hasil penelitian ini. Pertama, Bayesian Optimization terbukti meningkatkan performa model XGBoost secara signifikan pada seluruh metrik evaluasi, dengan penurunan MAE sebesar 29,6%, MSE sebesar 47,3%, dan RMSE sebesar 27,4%, serta peningkatan R^2 dari 0,9412 menjadi 0,9852. Kedua, model akhir mencapai MAPE sebesar 2,61% yang tergolong sangat akurat berdasarkan kriteria Lewis (1982), dengan kemampuan prediksi yang tidak mengalami overfitting sebagaimana ditunjukkan oleh selisih MAPE latih-uji yang hanya 0,30%. Ketiga, sistem web berbasis Flask berhasil dibangun dan divalidasi secara fungsional (100% pass rate pada

black box testing) maupun kualitatif oleh pakar, membuktikan kelayakan sistem untuk digunakan dalam mendukung proses seleksi atlet yang lebih objektif dan berbasis data. Untuk pengembangan selanjutnya, disarankan memperluas dataset ke wilayah lain dan mengeksplorasi interpretabilitas model menggunakan metode seperti SHAP.

Referensi

- [1] M. Amin, dkk., "Sistem Seleksi Atlet Berbasis Data pada Cabang Olahraga Bola Voli," *Jurnal Olahraga Indonesia*, vol. 3, no. 1, pp. 12–20, 2021.
- [2] T. Chen dan C. Guestrin, "XGBoost: A Scalable Tree Boosting System," *Proc. 22nd ACM SIGKDD Int. Conf. Knowledge Discovery and Data Mining*, pp. 785–794, 2016. <https://doi.org/10.1145/2939672.2939785>
- [3] J. Mockus, "On Bayesian Methods for Seeking the Extremum," *Optimization Techniques IFIP Technical Conference*, pp. 400–404, 1975.
- [4] Y. Li dkk., "Integration of Machine Learning XGBoost and SHAP Models for NBA Game Outcome Prediction," *Applied Sciences*, 2023.
- [5] R. Wenninger dkk., "Artificial Intelligence in the Selection of Top-Performing Athletes for Team Sports," *Sports Medicine*, 2020.
- [6] J. Bergstra dan Y. Bengio, "Random Search for Hyper-Parameter Optimization," *Journal of Machine Learning Research*, vol. 13, pp. 281–305, 2012.
- [7] M. Alnur dkk., "Analisis Kinerja XGBoost Menggunakan Bayesian Optimization dalam Prediksi Harga Ethereum," *Jurnal Informatika*, vol. 10, no. 2, 2023.
- [8] C. D. Lewis, *Industrial and Business Forecasting Methods*. London: Butterworths, 1982.
- [9] J. Cohen, *Statistical Power Analysis for the Behavioral Sciences*, 2nd ed. Lawrence Erlbaum Associates, 1988.
- [10] E. Kusuma, "Penerapan Bayesian Optimization pada Algoritma Machine Learning untuk Prediksi Performa Atlet," *Jurnal Teknologi Informasi*, vol. 5, no. 1, 2019.
- [11] D. Syafei dan R. Efrilianda, "Implementasi XGBoost untuk Klasifikasi Data Keuangan Berskala Besar," *JISKA*, vol. 8, no. 2, 2023.
- [12] H. Wijaya, D. Hostadi, dan E. Triandini, "Optimasi Hyperparameter XGBoost pada Sistem Prediksi Berbasis Data," *Jurnal ILKOM*, vol. 16, no. 1, 2024.
- [13] E. Turban, J. E. Aronson, dan T. P. Liang, *Decision Support Systems and Intelligent Systems*, 7th ed. Pearson Prentice Hall, 2005.
- [14] N. Bi dkk., "Machine Learning in Sports Performance Analysis," *IEEE Access*, vol. 7, 2019.
- [15] B. Herdiana dan V. Geraldine, "Aplikasi Regresi dalam Analisis Data Olahraga," *Jurnal Statistika Terapan*, vol. 4, no. 2, 2022.