

Prediksi Kemampuan Squat Atlet Powerlifting Pria Menggunakan XGBoost dan LightGBM

Justin Salim ¹⁾ Jonathan ²⁾ Devin Saputra Wijaya ³⁾

¹⁾²⁾³⁾ Teknik Informatika, FTI, Universitas Tarumanagara

Jl. Letjen S. Parman No.1, RT.6/RW.16, Tomang, Kec. Grogol Petamburan,
Kota Jakarta Barat, Daerah Khusus Ibukota Jakarta 11440

¹⁾ email: justin.535220017@stu.untar.ac.id, ²⁾ email: jonathan.535220026@stu.untar.ac.id, ³⁾ email: devin.53220011@stu.untar.ac.id

ABSTRAK

Machine learning semakin penting di era modern karena kemampuannya menghasilkan prediksi hanya dengan mengolah data. Penelitian ini bertujuan untuk memprediksi kemampuan squat atlet powerlifting pria menggunakan dua algoritma pembelajaran mesin, yaitu XGBoost dan LightGBM. Kedua algoritma dipilih karena keduanya mampu menangani data berukuran besar dengan variabel prediktor yang kompleks. Data yang digunakan mencakup informasi fisik atlet, catatan performa squat, bench press, deadlift, serta variabel terkait kompetisi. Metode penelitian meliputi tahap prapemrosesan data, pembagian data ke dalam set pelatihan dan pengujian, penerapan algoritma XGBoost dan LightGBM, serta evaluasi performa model. Evaluasi dilakukan menggunakan metrik root mean square error (RMSE), koefisien determinasi (R^2), dan mean absolute error (MAE). Hasil penelitian menunjukkan bahwa kedua algoritma mampu memberikan performa prediksi yang baik, dengan XGBoost lebih unggul dalam tingkat kinerja prediksi yang lebih tinggi dibandingkan dengan LightGBM.

Key words

Machine Learning, Algoritma, Data, XGBoost, LightGBM

1. Pendahuluan

Powerlifting adalah cabang olahraga kekuatan yang terdiri dari tiga jenis angkatan, *squat*, *bench press*, dan *deadlift*, dengan tujuan untuk mengangkat beban seberat mungkin pada setiap gerakan. Sejak pertama kali dipertandingkan di *World Games* 1981, *squat* telah menjadi tolak ukur penting untuk menentukan kekuatan keseluruhan seorang atlet. Kemampuan untuk memprediksi performa *squat* secara akurat dapat membantu pelatih dalam menyusun program latihan yang lebih berfokus pada individu dan efektif sesuai kapasitas atlet sebagai individu.

Manfaat dari model prediksi ini tidak hanya terbatas pada perancangan program latihan. Secara praktis prediksi yang akurat dapat membantu atlet dan pelatih dalam menetapkan target kompetisi yang lebih realistik,

mengelola ekspektasi, dan menyusun strategi dalam mengangkat selama kompetisi. Misalnya, dengan mengetahui potensi kekuatan maksimal seorang atlet, pelatih dapat menentukan berat angkatan pembuka yang lebih strategis untuk memaksimalkan peluang keberhasilan dan membangun kepercayaan diri atlet di platform. Selain itu, dari perspektif ilmu keolahragaan, model ini dapat memberikan wawasan baru mengenai faktor-faktor antropometri dan demografis yang paling berpengaruh terhadap performa angkat beban yang dapat memandu penelitian lebih lanjut di bidang fisiologi olahraga. Seiring dengan kemajuan teknologi, *machine learning* menawarkan solusi menjanjikan untuk memprediksi kemampuan *squat* berdasarkan data historis atlet [1].

Oleh karena itu, penelitian ini berfokus pada penerapan dan perbandingan performa dua algoritma *machine learning* yaitu, XGBoost dan LightGBM untuk membangun *model* dengan kemampuan prediksi *squat* yang maksimal [2].

Pemilihan XGBoost dan LightGBM sebagai fokus utama penelitian ini didasarkan pada reputasi keduanya sebagai algoritma *state-of-the-art* dalam berbagai kompetisi *machine learning* yang melibatkan data *tabular*. Keduanya merupakan implementasi dari *gradient boosting*, sebuah teknik yang dikenal mampu menghasilkan akurasi tinggi. Namun keduanya memiliki perbedaan fundamental dalam pendekatan pembangunan *decision tree* di mana XGBoost menggunakan *level-wise growth* sementara LightGBM menggunakan *leaf-wise growth*. Perbedaan ini berpotensi menghasilkan model dengan karakteristik performa yang berbeda, baik dari segi akurasi maupun efisiensi komputasi. Oleh karena itu membandingkan keduanya secara langsung pada *dataset powerlifting* akan memberikan pemahaman komprehensif mengenai algoritma mana yang lebih cocok pada konteks spesifik ini [3].

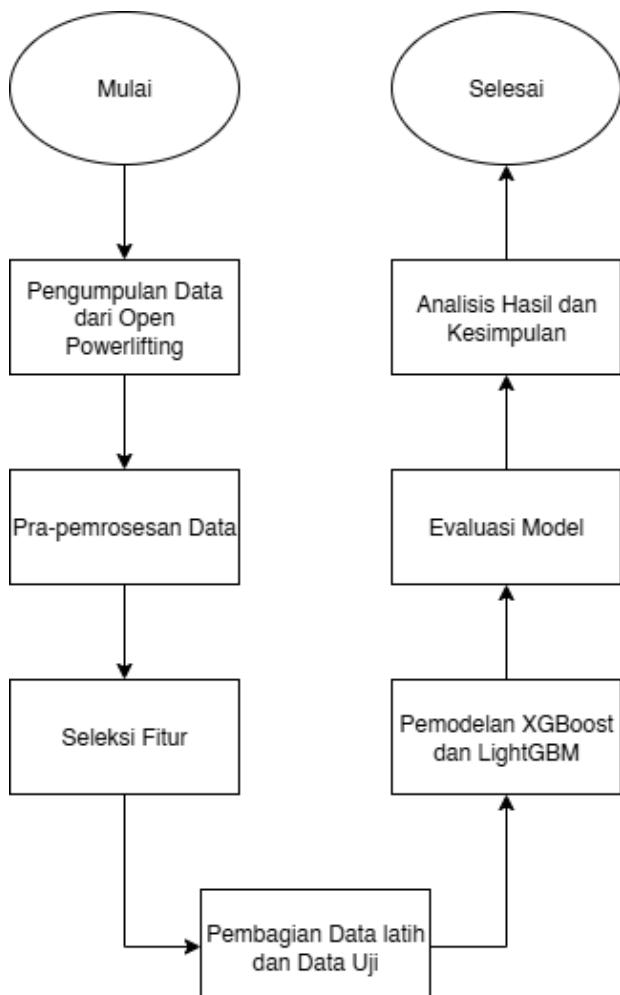
Tujuan utama dari membandingkan kedua model tersebut adalah untuk menentukan model mana yang menghasilkan ketepatan prediksi tertinggi serta mengidentifikasi variabel-variabel atlet yang paling signifikan dalam memengaruhi kekuatan angkatan *squat*. Data atlet *powerlifting* yang digunakan khusus pada jenis kelamin pria dengan target prediksi spesifik pada

angkatan *squat*. Model yang dikembangkan hanya menggunakan algoritma XGBoost dan LightGBM [4], [5], dengan variabel input terbatas pada data demografis, dan riwayat performa yang tersedia dalam *dataset* yang digunakan [6].

2. Landasan Teori

2.1. Metode Penelitian

Alur penelitian ini dirancang secara sistematis yang mencakup beberapa tahapan utama, mulai dari pengumpulan data hingga evaluasi model. Diagram alur kerja sistem prediksi berikut dapat mengilustrasikan proses penelitian secara keseluruhan.



Gambar 1 Diagram Alur Kerja Sistem Prediksi

2.2. Powerlifting

Powerlifting adalah cabang olahraga yang menguji kekuatan seorang atlet, cabang olahraga ini terbagi menjadi tiga gerakan, yaitu *squat*, *benchpress*, dan *deadlift* [7]. Skor atlet ditentukan dari total beban terbaik

yang berhasil diangkat oleh atlet. Di antara ketiga gerakan tersebut salah satunya *squat* memiliki peranan penting dalam menentukan skor akhir atlet karena menggunakan keseluruhan otot tubuh bagian bawah mulai dari paha depan, paha belakang, pinggul, dan punggung bawah [8].

Secara teknis, angkatan *squat* dalam kompetisi *powerlifting* memiliki standar yang ketat. Seorang atlet harus menurunkan pinggul hingga bagian atas paha di sendi pinggul berada di bawah bagian atas lutut, sebelum kembali ke posisi berdiri tegak [9]. Faktor seperti jenis peralatan yang digunakan seperti *belt*, *knee sleeves*, atau bahkan *squat suit* pada kategori *equipped powerlifting* dapat secara signifikan memengaruhi jumlah beban yang bisa diangkat [10]. Variabel-variabel inilah yang membuat prediksi performa menjadi tantangan yang kompleks, karena model harus dapat menangkap interaksi antara kapabilitas fisik atlet dengan faktor-faktor eksternal seperti regulasi federasi dan peralatan yang diizinkan.

2.3. Penelitian Terdahulu

Penerapan *machine learning* untuk menganalisis dan memprediksi performa dalam olahraga angkat beban telah menjadi fokus dalam berbagai penelitian. Sejumlah studi telah berhasil mengembangkan model untuk prediksi performa [1] dan memprediksi skor total atlet dalam kompetisi menggunakan berbagai metode *machine learning* [11]. Pendekatan ini sering kali bertujuan untuk memproyeksikan kemampuan atlet di masa depan, yang dapat membantu dalam perancangan program latihan yang lebih efektif dan khusus per individu [12].

Selain itu, metode yang lebih canggih juga telah dilakukan, seperti penggunaan *Extreme Learning Machine* (ELM) yang dimodifikasi untuk analisis data *powerlifting* [13]. Di sisi lain, beberapa penelitian mengambil pendekatan yang berbeda dengan tidak berfokus pada prediksi nilai melainkan pada klasifikasi gerakan angkatan itu sendiri. Contohnya adalah penggunaan teknik *deep learning* dan *computer vision* untuk mengklasifikasikan jenis angkatan *powerlifting* secara otomatis dari data visual [14]. Hal ini menunjukkan luasnya penerapan kecerdasan buatan dalam konteks ini, mulai dari analisis video hingga prediksi performa berbasis data *tabular*.

Dengan mempertimbangkan berbagai pendekatan tersebut, penelitian ini akan berfokus pada masalah regresi untuk prediksi performa *squat* atlet [15]. Secara spesifik, studi ini akan membandingkan efektivitas dua algoritma *gradient boosting* yang populer, yaitu XGBoost dan LightGBM yang telah terbukti andal dalam menangani data *tabular* yang kompleks untuk berbagai masalah prediksi [16].

2.4. Machine Learning

Machine learning adalah cabang dari kecerdasan buatan (*Artificial Intelligence*) yang memungkinkan sebuah sistem komputer untuk belajar langsung dari data untuk membuat sebuah prediksi atau keputusan tanpa

diprogram secara eksplisit [17]. Dalam penelitian ini, pendekatan yang digunakan adalah *supervised learning*, di mana model dilatih menggunakan kumpulan data yang telah memiliki label atau hasil yang diketahui [18]. Model akan belajar dengan memetakan pola dari data input seperti *Event*, *Equipment*, *Age*, *AgeClass*, *Division*, *BodyweightKg*, *WeightClassKg*, dan *Federation* untuk memahami hubungan antara fitur-fitur tersebut dengan hasil yang ingin diprediksi.

Pendekatan *supervised learning* ini kontras dengan *unsupervised learning*, di mana algoritma bekerja pada data tanpa label dan mencoba menemukan struktur atau pola tersembunyi secara mandiri, contohnya seperti *clustering* atlet berdasarkan profil performa. Tujuan dalam penelitian ini adalah memprediksi nilai spesifik *Best3SquatKg* berdasarkan serangkaian fitur input yang telah diketahui, maka *supervised learning* adalah pendekatan paling tepat. Model akan belajar dari data historis di mana hasil angkatan *squat* setiap atlet sudah tercatat, sehingga memungkinkannya untuk menggeneralisasi pola dan membuat prediksi pada data baru yang belum pernah dilihat sebelumnya.

Secara lebih spesifik jenis *supervised learning* yang diterapkan adalah regresi. Regresi merupakan teknik yang bertujuan untuk memprediksi nilai numerik yang bersifat kontinu [19]. Pendekatan ini sangat sesuai dengan tujuan penelitian, yaitu memprediksi kekuatan angkatan *squat* dalam satuan kilogram yang merupakan sebuah nilai kontinu sehingga menjadikan permasalahan ini menjadi masalah regresi.

2.5. Algoritma Gradient Boosting

Gradient Boosting adalah metode *ensemble learning* yang sangat efektif dalam membangun model prediksi. Teknik *ensemble learning* bekerja dengan cara membangun serangkaian model yang biasanya adalah *decision trees* secara sekuensial [20]. Setiap model baru yang ditambahkan akan berfokus untuk memperbaiki kesalahan atau residu dari prediksi yang dibuat oleh model-model sebelumnya. Dengan cara ini, model secara bertahap akan terus belajar dan meningkatkan ketepatannya secara keseluruhan.

Dua implementasi dari algoritma *gradient boosting* yang akan digunakan dalam penelitian ini adalah XGBoost dan LightGBM.

Extreme Gradient Boosting (XGBoost) adalah implementasi yang telah dioptimalkan untuk performa komputasi dan kecepatan. XGBoost dikenal luas karena kinerjanya yang unggul di berbagai kompetisi *machine learning*. Kelebihan utamanya terletak pada fitur regularisasi yang efektif untuk mencegah *overfitting* serta kemampuannya menangani data yang hilang [21].

Fitur regularisasi pada XGBoost, khususnya regularisasi L1 dan L2 memainkan peran krusial dalam mencegah *overfitting*. *Overfitting* terjadi ketika model menjadi terlalu kompleks dan “menghafal” data pelatihan, sehingga kinerjanya menjadi buruk pada data baru. Regularisasi bekerja dengan memberikan *penalty* pada kompleksitas model, mendorongnya membangun

decision trees yang lebih sederhana dan lebih mampu menggeneralisasi pola data [20]. Kemampuan ini menjadikan XGBoost sangat andal, terutama pada *dataset* dengan banyak fitur atau relasi antar fitur yang kompleks.

Pembentukan nilai prediksi menggunakan metode XGBoost dapat dibuat dalam bentuk persamaan sebagai berikut:

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

Dimana f_k adalah model *decision tree* ke-k. Untuk persamaan y_i dapat dihitung dengan persamaan berikut:

$$\hat{y}_i^t = \sum_{k=1}^t f_k(x_i) = \hat{y}_i^{t-1} + f_i(x_i) \quad (2)$$

Di mana \hat{y}_i^t adalah hasil akhir dari model *tree*, \hat{y}_i^{t-1} adalah model *tree* yang dihasilkan sebelumnya, $f_k(x_i)$ adalah model baru yang dibangun, dan t adalah jumlah total model dari model *base tree* [21].

Light Gradient Boosting Machine (LightGBM) adalah kerangka kerja *gradient boosting* lain yang dirancang khusus untuk kecepatan komputasi dan efisiensi memori yang lebih tinggi. Perbedaan utamanya dengan XGBoost terletak pada cara membangun *decision tree*. LightGBM menggunakan strategi *leaf-wise growth*, yang membuatnya lebih cepat pada *dataset* berukuran besar tanpa mengorbankan ketepatan secara signifikan [22].

Strategi *leaf-wise growth* akan membuat LightGBM akan menumbuhkan *tree* dengan memilih *leaf* yang akan memberikan pengurangan *loss* terbesar. Ini berbeda dari strategi *level-wise growth* milik XGBoost yang menumbuhkan pohon secara simetris lapis demi lapis.. Pendekatan *leaf-wise* ini membuat konvergensi model menjadi lebih cepat. Namun, pada *dataset* yang lebih kecil, pendekatan ini berisiko menghasilkan pohon yang terlalu dalam dan kompleks yang dapat menyebabkan *overfitting*. Oleh karena itu dapat dilakukan penyesuaian *hyperparameter* seperti *num_leaves* atau *max_depth* menjadi sangat penting saat menggunakan LightGBM [5].

LightGBM menggabungkan model *tree* untuk mendapatkan hasil prediksi, persamaan dapat dilihat sebagai berikut:

$$f(x) = \sum_{m=0}^M f_m(x) \quad (3)$$

Model *tree* akan dioptimasi dengan mengurangi error, persamaan dapat dilihat sebagai berikut:

$$L = \sum_i^n (y_i - \hat{y}_i)^2 \quad (4)$$

L adalah *loss function* untuk menghitung selisih antara nilai sebenarnya dan nilai prediksi [23].

2.6. Metode Evaluasi

Untuk mengukur seberapa baik kinerja model regresi, digunakan beberapa metrik evaluasi. Metrik yang akan digunakan adalah MAE, RMSE< dan R².

Mean Absolute Error (MAE) adalah rata-rata dari selisih absolut antara nilai prediksi dan nilai sebenarnya. Metrik ini memberikan gambaran besaran kesalahan rata-rata dalam satuan yang sama dengan target. Persamaan untuk mendapatkan nilai MAE dapat dilihat sebagai berikut:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (5)$$

Dimana \hat{y}_i adalah hasil prediksi dari y .

Root Mean Squared Error (RMSE) adalah akar kuadrat dari rata-rata selisih kuadrat antara nilai prediksi dan nilai sebenarnya. RMSE memberikan bobot lebih besar pada kesalahan yang besar. Persamaan untuk mendapatkan nilai RMSE dapat dilihat sebagai berikut:

$$MSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (6)$$

R-squared (R²) adalah koefisien determinasi yang mengukur seberapa besar proporsi varians dari variabel target yang dapat dijelaskan oleh model. Nilainya dapat dimulai dari 0 hingga 1, di mana nilai yang lebih tinggi menunjukkan model yang lebih baik. Persamaan untuk mendapatkan nilai R² dapat dilihat sebagai berikut:

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (7)$$

Kombinasi dari metrik-metrik ini akan menjadi dasar untuk membandingkan performa model secara objektif [24].

Pemilihan kombinasi metrik ini bertujuan untuk mendapatkan evaluasi yang menyeluruh. MAE memberikan interpretasi yang paling intuitif mengenai rata-rata kesalahan dalam satuan kilogram. Di sisi lain, RMSE sangat berguna karena memberikan bobot yang lebih besar pada kesalahan prediksi yang besar akibat proses pengkuadratan. Hal ini membuat RMSE menjadi metrik yang sensitif terhadap adanya prediksi yang sangat melenceng, hal ini sangat penting untuk diidentifikasi dalam konteks prediksi performa. Sementara itu, R² melengkapi analisis dengan memberikan informasi tentang seberapa baik model dapat menangkap variabilitas dalam data, yang tidak dapat diukur hanya dari nilai kesalahan saja.

3. Hasil Percobaan

3.1. Data dan Pra-pemrosesan

Penelitian ini menggunakan *dataset* publik yang diambil dari sebuah organisasi independen yang mencatat dan mengumpulkan data hasil dari kompetisi *powerlifting* seluruh dunia. *Dataset* ini berisikan data historis dari ribuan atlet dengan berbagai fitur-fitur seperti *Age*, *Bodyweight*, *Weightclass*, *Equipment*, serta *Best3Squat* yang dicatat dan dikumpulkan oleh sebuah organisasi bernama *Open Powerlifting* dengan total 42 kolom [6]. Data yang akan diprediksi dalam penelitian ini adalah capaian beban maksimal pada angkatan *squat*. Fitur-fitur dari *dataset* dapat dilihat pada tabel berikut:

Tabel 1 Informasi Dataset

Nama Fitur	Deskripsi	Tipe
<i>Name</i>	Nama atlet	<i>Object</i>
<i>Sex</i>	Jenis kelamin atlet	<i>Object</i>
<i>Event</i>	Jenis kompetisi yang diikuti	<i>Object</i>
<i>Equipment</i>	Peralatan yang dipakai	<i>Object</i>
<i>Age</i>	Umur atlet	<i>Float</i>
<i>AgeClass</i>	Kategori Umur atlet	<i>Object</i>
<i>BirthYearClass</i>	Kategori tahun kelahiran atlet	<i>Object</i>
<i>Division</i>	Divisi atlet	<i>Object</i>
<i>BodyweightKg</i>	Berat badan atlet	<i>Float</i>
<i>WeightClassKg</i>	Kelas berat badan atlet	<i>Object</i>
<i>Squat1Kg</i>	Percobaan pertama <i>squat</i> atlet	<i>Float</i>
<i>Squat2Kg</i>	Percobaan kedua <i>squat</i> atlet	<i>Float</i>
<i>Squat3Kg</i>	Percobaan ketiga <i>squat</i> atlet	<i>Float</i>
<i>Squat4Kg</i>	Percobaan keempat <i>squat</i> atlet	<i>Float</i>
<i>Best3SquatKg</i>	Hasil terbaik <i>squat</i> dari 3 kali angkatan	<i>Float</i>
<i>Bench1Kg</i>	Percobaan pertama <i>bench</i> atlet	<i>Float</i>
<i>Bench2Kg</i>	Percobaan kedua <i>bench</i> atlet	<i>Float</i>
<i>Bench3Kg</i>	Percobaan ketiga <i>bench</i> atlet	<i>Float</i>
<i>Bench4Kg</i>	Percobaan keempat <i>bench</i> atlet	<i>Float</i>
<i>Best3BenchKg</i>	Hasil terbaik <i>bench</i> dari 3 kali angkatan	<i>Float</i>
<i>Deadlift1Kg</i>	Percobaan pertama <i>deadlift</i> atlet	<i>Float</i>
<i>Deadlift2Kg</i>	Percobaan kedua <i>deadlift</i> atlet	<i>Float</i>
<i>Deadlift3Kg</i>	Percobaan ketiga <i>deadlift</i> atlet	<i>Float</i>

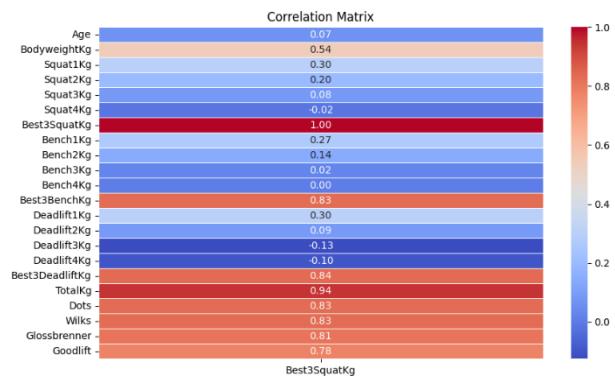
<i>Deadlift4Kg</i>	Percobaan keempat <i>deadlift</i> atlet	<i>Float</i>
<i>Best3DeadliftKg</i>	Hasil terbaik <i>deadlift</i> dari 3 kali angkatan	<i>Float</i>
<i>TotalKg</i>	Total angkatan atlet	<i>Float</i>
<i>Place</i>	Posisi atlet dalam kompetisi	<i>Object</i>
<i>Dots</i>	Sebuah nilai untuk menentukan kemampuan atlet	<i>Float</i>
<i>Wilks</i>	Sebuah nilai untuk menentukan kemampuan atlet	<i>Float</i>
<i>Glossbrenner</i>	Sebuah nilai untuk menentukan kemampuan atlet	<i>Float</i>
<i>Goodlift</i>	Sebuah nilai untuk menentukan kemampuan atlet	<i>Float</i>
<i>Tested</i>	Tes obat-obatan terlarang pada atlet	<i>Object</i>
<i>Country</i>	Negara asal atlet	<i>Object</i>
<i>State</i>	Provinsi atau negara bagian asal atlet	<i>Object</i>
<i>Federation</i>	Federasi yang menyelenggarakan kompetisi	<i>Object</i>
<i>ParentFederation</i>	Federasi tertinggi dari federasi yang menyelenggarakan kompetisi	<i>Object</i>
<i>Date</i>	Tanggal dimulainya kompetisi	<i>Object</i>
<i>MeetCountry</i>	Negara di mana kompetisi diselenggarakan	<i>Object</i>
<i>MeetState</i>	Provinsi atau negara bagian di mana kompetisi diselenggarakan	<i>Object</i>
<i>MeetTown</i>	Kota di mana kompetisi diselenggarakan	<i>Object</i>
<i>MeetName</i>	Nama kompetisi	<i>Object</i>
<i>Sanctioned</i>	Kompetisi di akui oleh federasi	<i>Object</i>

Sebelum tahap pemodelan, serangkaian langkah dilakukan untuk membersihkan dan mentransformasi data yang penting dilakukan untuk memastikan kualitas dan integritas *dataset*. Pertama-tama data akan disaring untuk hanya menyertakan data atlet pria yang mengurangi jumlah data menjadi sekitar 2,6 juta baris. Selanjutnya fitur yang ditangani adalah variabel target yakni *Best3SquatKg*, di mana nilai negatif yang merepresentasikan angkatan gagal dan nilai *null* akan diubah menjadi 0. Untuk fitur prediktor *BodyweightKg* akan menggunakan nilai median, sementara fitur *Age* dan *Division* yang kosong akan dihapus. Selain itu fitur *AgeClass* dan *WeightClassKg* akan diisi secara logis

berdasarkan nilai pada kolom *Age* dan *BodyweightKg*. Baris yang masih memiliki nilai kosong setelah semua proses ini kemudian dihapus. Sebagai langkah akhir, semua fitur kategorikal yang tersisa ditransformasikan menjadi representasi numerik menggunakan *LabelEncoder* agar sesuai untuk diproses oleh model *machine learning*.

Pada tahap preparasi data, proses seleksi fitur dilakukan untuk memastikan model prediksi dibangun hanya menggunakan atribut yang relevan dan tersedia sebelum kompetisi berlangsung, serta untuk mencegah *data leakage*.

Analisis korelasi menunjukkan adanya korelasi yang sangat tinggi antara variabel target dengan fitur seperti *TotalKg*, *Dots*, *Wilks*, dan *Glossbrenner*. Fitur-fitur ini merupakan hasil perhitungan yang baru ada setelah kompetisi selesai, sehingga penggunaannya akan menyebabkan *data leakage*. Oleh karena itu semua kolom tersebut dihilangkan.



Gambar 2 Heatmap Korelasi Fitur Numerik Terhadap Best3SquatKg

Selain itu, fitur-fitur yang bersifat identitas seperti *Name*, *MeetName*, *Date*, dan *Country* dihilangkan karena tidak memiliki nilai prediktif sama sekali. Seluruh kolom yang berkaitan dengan angkatan *bench press* dan juga *deadlift* dihapus untuk menjaga fokus penelitian hanya pada *squat*. Kolom-kolom percobaan angkatan *squat* seperti *Squat1Kg*, *Squat2Kg*, *Squat3Kg*, dan *Squat4Kg* juga dihilangkan karena menjadi penentuan variabel target.

Setelah proses pembersihan dan seleksi, fitur-fitur yang digunakan untuk pemodelan adalah: *Event*, *Equipment*, *Age*, *AgeClass*, *Division*, *BodyweightKg*, *WeightClassKg*, dan *Federation*.

Variabel target dari penelitian ini adalah *Best3SquatKg* maka kolom-kolom percobaan angkatan yang menjadi dasar penentuan variabel target juga ikut dihilangkan. Hal ini memastikan bahwa model akan memprediksi kekuatan *squat* berdasarkan atribut intrinsik atlet, bukan berdasarkan hasil parsial dari angkatan itu sendiri.

3.2. Skenario Pengujian

Selanjutnya akan berfokus pada apa yang menjadi utama dalam penelitian ini, yaitu keterkaitan antara

variabel y (*BestSquat3Kg*), X (*Event*, *Equipment*, *Age*, *AgeClass*, *Division*, *BodyweightKg*, *WeightClassKg*, *Federation*). Pembagian data dilakukan dalam bentuk tiga rasio, yaitu 80:20, 70:30, dan 60:40. Masing-masing pembagian data diuji dengan dua model regresi, dan diukur dengan menggunakan tiga metode evaluasi yang berbeda. Penelitian ini diharapkan dapat menemukan model yang lebih efektif dalam memprediksi kemampuan *squat* atlet.

Kedua model XGBoost dan LightGBM menggunakan beberapa parameter. Untuk XGBoost menggunakan XGBRegressor dengan parameter *n_estimators*=400, *max_depth*=5, dan *learning_rate*=0.1. untuk LightGBM, digunakan LGBMRegressor dengan *n_estimators*=250, *max_depth*=5, dan *learning_rate*=0.1.

Pembagian data dilakukan dalam tiga rasio data latih dan data uji, yaitu 80:20, 70:30, dan 60:40. Kinerja setiap model dievaluasi menggunakan tiga metrik: koefisien determinasi (R^2), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Error* (MAE).

Dalam hasil evaluasi, perlu memperhatikan nilai tiap metrik evaluasi. Dalam kasus ini, perlu dicari nilai yang terkecil untuk MAE dan RMSE, sementara untuk skor R^2 , perlu mencari nilai yang mendekati 1 atau jauh dari 0, yang menandakan hasil estimasi yang paling baik.

3.3. Hasil Evaluasi Model

Untuk pengujian pertama, pembagian datasetnya adalah 60:40, yang berisi 60% data latih dan 40% data uji.

Tabel 2 Rasio pengujian data latih dan uji 60:40

Model	R^2	RMSE	MAE
XGBoost	0.8517	43.2484	23.0239
LightGBM	0.8510	43.3528	23.0725

Pada rasio pengujian ini, kedua model menunjukkan performa yang rendah, meskipun tidak sepenuhnya buruk. Dari hasil ini dapat diambil kesimpulan bahwa jumlah data latih yang lebih sedikit dapat memengaruhi kemampuan prediksi model dan membuatnya kurang optimal dalam mempelajari pola data. Namun, dalam rasio pengujian ini, model XGBoost menunjukkan hasil yang sedikit lebih baik daripada LightGBM.

Untuk pengujian kedua, pembagian datasetnya adalah 70:30, yang berisi 70% data latih dan 30% data uji.

Tabel 3 Rasio pengujian data latih dan uji 70:30

Model	R^2	RMSE	MAE
XGBoost	0.8520	43.2320	23.0032
LightGBM	0.8512	43.3558	23.0837

Di rasio data ini, dapat terlihat peningkatan performa yang terjadi di kedua model dibandingkan rasio data 60:40 karena nilai R^2 pada kedua model sedikit meningkat, walaupun pada nilai RMSE dan MAE ada perbedaan, yaitu sedikit menurun untuk model XGBoost, namun LightGBM mengalami sedikit peningkatan yang berarti LightGBM masih kurang optimal dalam rasio pembagian data ini. Maka sama seperti sebelumnya, XGBoost

berhasil mempertahankan keunggulannya di pembagian data ini.

Untuk pengujian terakhir, pembagian datasetnya adalah 80:20, di mana 80% data latih dan 20% data uji.

Tabel 4 Rasio pengujian data latih dan uji 80:20

Model	R^2	RMSE	MAE
XGBoost	0.8527	43.1460	22.9975
LightGBM	0.8520	43.2547	23.0349

Pada pengujian ini, kedua model menghasilkan performa paling optimal di pembagian data ini karena XGBoost mencapai nilai ketepatan tertingginya di sini, dengan R^2 sebesar 0.8527. Selain itu, nilai MAE juga yang terendah, menunjukkan rata-rata kesalahan prediksi yang paling kecil di antara semua pembagian data.

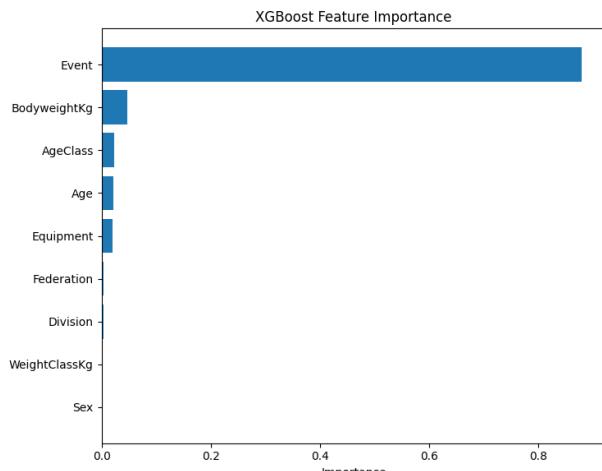
Pada pengujian ketiga rasio pembagian data dapat dilihat bahwa pembagian rasio data sangat berpengaruh dalam mempelajari pola data, dan dengan semakin besar proporsi data latih, maka semakin baik performa modelnya. Hal ini menunjukkan model memerlukan data latih yang cukup agar menghasilkan prediksi yang lebih akurat.

Selain itu, di semua pembagian rasio data, XGBoost konsisten menunjukkan kinerja yang lebih baik daripada LightGBM. Meskipun selisihnya tipis, keunggulan yang konsisten di setiap rasio data menandakan bahwa model XGBoost lebih efektif untuk *dataset* dan masalah ini.

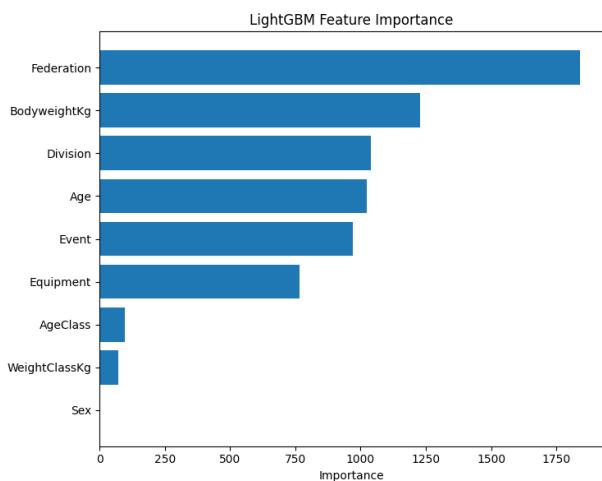
Keunggulan konsisten XGBoost yang tipis dapat diatribusikan pada beberapa faktor. Algoritma XGBoost secara alami memiliki mekanisme regularisasi yang lebih canggih, yang mungkin lebih efektif dalam mengontrol kompleksitas model pada *dataset* ini dan mencegah *overfitting* dibandingkan dengan LightGBM. Perbedaan dalam cara kedua algoritma membangun *tree* juga berperan penting. Strategi *level-wise growth* XGBoost yang lebih konservatif mungkin terbukti lebih stabil dan menghasilkan model yang lebih dapat diandalkan pada struktur data spesifik dari kompetisi *powerlifting*. Sebaliknya, kecepatan LightGBM yang berasal dari *leaf-wise growth* mungkin tidak memberikan keuntungan akurasi yang signifikan pada *dataset* ini, dan bahkan menjadi sedikit kurang optimal dalam menemukan pola yang paling umum.

3.4. Analisis

Selanjutnya adalah memberikan hasil analisis dari *feature importance* pada kedua model. Ini bertujuan untuk mengidentifikasi variabel mana yang paling signifikan dalam proses prediksi kedua model.



Gambar 3 Grafik Feature Importance XGBoost



Gambar 4 Grafik Feature Importance LightGBM

Berdasarkan grafik di atas, dapat dilihat bahwa *feature importance* pada masing-masing model berbeda. Pada XGBoost, model ini menempatkan fitur *Event* sebagai faktor dominan dengan selisih yang sangat jauh dengan fitur lainnya. Model ini menganggap bahwa jenis perlombaan yang diikuti atlet menjadi variabel yang digunakan sebagai prediksi utama dalam memprediksi kekuatan *squat* atlet. Fitur lain yang berpengaruh adalah *BodyweightKg*, *AgeClass*, *Age*, dan *Equipment*.

Sedangkan, LightGBM menunjukkan fitur yang berbeda dengan XGBoost, dan lebih merata pada beberapa fiturnya. Fitur *Federation* menjadi yang paling penting, diikuti oleh *BodyweightKg*, *Division*, *Age*, dan *Event*. Ini menunjukkan model LightGBM lebih mempertimbangkan faktor penyelenggara kompetisi dan kelas divisi atlet.

Namun, terdapat fitur yang ditunjukkan sama pentingnya pada kedua model, yaitu *BodyweightKg* dan *Age* yang memang secara umum sangat relevan dalam menentukan kekuatan seorang atlet.

Perbedaan ini mungkin mengindikasikan bahwa struktur internal XGBoost lebih sensitif terhadap variasi dalam jenis *Event*, yang mungkin berkorelasi dengan

tingkat spesialisasi atlet. Di sisi lain, LightGBM yang memberikan bobot lebih pada *Federation* dan *Division* bisa jadi lebih baik dalam menangkap pola yang terkait dengan standar kompetisi dan demografi peserta yang diatur oleh federasi tertentu.

Interpretasi dari perbedaan ini sangat menarik dari sudut pandang olahraga. Dominasi fitur *Event* pada model XGBoost menunjukkan bahwa model ini sangat bergantung pada konteks kompetisi, apakah kompetisi *Squat Bench Deadlift* atau hanya *Squat*. Dikarenakan atlet yang berspesialisasi hanya pada *squat* mungkin memiliki profil kekuatan yang berbeda dari atlet *powerlifting* tiga angkatan. Di sisi lain, penekanan LightGBM pada *Federation* menyoroti pentingnya faktor regulasi. Federasi yang berbeda memiliki standar penjurian yang berbeda, aturan peralatan yang bervariasi, dan kumpulan atlet yang berbeda pula. Fakta bahwa *BodyweightKg* dan *Age* menjadi penting pada kedua model mengonfirmasi prinsip-prinsip biomekanik dasar seperti berat badan berkorelasi positif dengan kekuatan angkatan atlet, dan usia memengaruhi puncak performa atlet.

4. Kesimpulan

Hasil penelitian ini menunjukkan bahwa algoritma XGBoost memberikan performa sedikit lebih baik dibandingkan dengan LightGBM dalam memprediksi kemampuan *squat* para atlet *powerlifting* pria. Berdasarkan hasil evaluasi menggunakan metrik RMSE, R^2 , dan MAE, XGBoost menunjukkan nilai kesalahan prediksi yang lebih kecil serta nilai koefisien determinasi yang sedikit lebih tinggi. Hal ini menunjukkan bahwa XGBoost mampu menjelaskan variasi data dengan lebih baik dibandingkan LightGBM. Dengan ketepatan yang konsisten pada berbagai rasio pembagian data pelatihan dan pengujian, dapat disimpulkan bahwa XGBoost memiliki keunggulan dalam stabilitas dan ketelitian model. Performa yang lebih baik ini menjadikan XGBoost lebih sesuai untuk digunakan dalam analisis kemampuan *squat* atlet, karena dapat memberikan hasil prediksi yang lebih mendekati nilai sebenarnya dan membantu pelatih dalam menentukan strategi peningkatan performa atlet secara lebih akurat.

Penelitian ini memiliki keterbatasan karena hanya menggunakan data yang tersedia secara publik tanpa menyertakan variabel fisiologis atau data program latihan individu atlet yang lebih detail. Untuk penelitian selanjutnya, model dapat diperkaya dengan data seperti volume latihan, riwayat cedera, atau data biomekanika untuk meningkatkan kemampuan prediksi model.

REFERENSI

- [1] L. Ferrari, G. Bochicchio, A. Bottari, F. Lucertini, dan S. Pogliaghi, "Predicting Future Performance in Powerlifting: A Machine Learning Approach," *Sports Med Open*, vol. 11, no. 1, hlm. 112, Okt 2025, doi: 10.1186/S40798-025-00903-Z.

- [2] P. Septiana, R. Haiban Hirzi, U. Hidayaturrohman, U. Hamzanwadi Selong Jl TGKH Muhammad Zainuddin Abdul Madjid Pancor, dan L. Timur, "Perbandingan Metode LightGBM dan XGBoost dalam Menangani Data dengan Kelas Tidak Seimbang," 2022. [Daring]. Tersedia pada: www.unipasby.ac.id
- [3] G. Türkmen dan A. Sezen, "A Comparative Analysis of XGBoost and LightGBM Approaches for Human Activity Recognition: Speed and Accuracy Evaluation," *International Journal of Computational and Experimental Science and Engineering*, vol. 10, no. 2, Jun 2024, doi: 10.22399/ijcesen.329.
- [4] X. Guo, J. Cheng, dan Y. Mu, "Optimizing Military Sports Training Effectiveness: Predictive Analysis Using the XGBoost Model," dalam *Proceedings of the 2025 International Conference on Management Science and Computer Engineering*, New York, NY, USA: ACM, Jun 2025, hlm. 406–409. doi: 10.1145/3760023.3760089.
- [5] W. Liu, X. Xu, Y. Cui, dan D. Bai, "A Method Based on LightGBM for Analyzing and Predicting the Outcomes of Tennis Matches," dalam *Proceedings of the 2024 International Academic Conference on Edge Computing, Parallel and Distributed Computing*, New York, NY, USA: ACM, Apr 2024, hlm. 90–95. doi: 10.1145/3677404.3677420.
- [6] "Powerlifting Rankings." Diakses: 6 Oktober 2025. [Daring]. Tersedia pada: <https://www.openpowerlifting.org/>
- [7] H. Abd El-Maksoud El-Gazzar JASS dan H. Abd El-Maksoud El-Gazzar, "Scientific debate between two main athletic training methods: Powerlifting and Olympic lifting," *Journal of Applied Sports Science*, vol. 14, no. 1, 2024, Diakses: 6 Oktober 2025. [Daring]. Tersedia pada: www.jass.alexu.edu.eg
- [8] D. J. van den Hoek dkk., "What are the odds? Identifying factors related to competitive success in powerlifting," *BMC Sports Sci Med Rehabil*, vol. 14, no. 1, hlm. 110, Des 2022, doi: 10.1186/s13102-022-00505-2.
- [9] D. J. van den Hoek dkk., "Normative data for the squat, bench press and deadlift exercises in powerlifting: Data from 809,986 competition entries," *J Sci Med Sport*, vol. 27, no. 10, hlm. 734–742, Okt 2024, doi: 10.1016/j.jsams.2024.07.005.
- [10] R. Hammami dkk., "Maturity Status as a Determinant of the Relationships Between Conditioning Qualities and Preplanned Agility in Young Handball Athletes," *J Strength Cond Res*, vol. 32, no. 8, hlm. 2302–2313, Agu 2018, doi: 10.1519/JSC.0000000000002390.
- [11] W. Rafajłowicz dan J. Marszałek, "Intelligent Performance Prediction for Powerlifting," 2021, hlm. 475–484. doi: 10.1007/978-3-030-87986-0_42.
- [12] V. Huy Chau, "Powerlifting score prediction using a machine learning method," *Mathematical Biosciences and Engineering*, vol. 18, no. 2, hlm. 1040–1050, 2021, doi: 10.3934/mbe.2021056.
- [13] V. H. Chau, A. T. Vo, dan B. T. Le, "A Gravitational-Double Layer Extreme Learning Machine and its Application in Powerlifting Analysis," *IEEE Access*, vol. 7, hlm. 143990–143998, 2019, doi: 10.1109/ACCESS.2019.2944877.
- [14] A. ÇELİKEL dan I. A. OZKAN, "Deep Learning-Based Classification of Powerlifting Movements Using Mediapipe," *International Journal of Applied Methods in Electronics and Computers*, Sep 2024, doi: 10.58190/ijamec.2024.107.
- [15] T. Horvat dan J. Job, "The use of machine learning in sport outcome prediction: A review," *WIREs Data Mining and Knowledge Discovery*, vol. 10, no. 5, Sep 2020, doi: 10.1002/widm.1380.
- [16] N. T. M. Sagala dan M. Amien Ibrahim, "A Comparative Study of Different Boosting Algorithms for Predicting Olympic Medal," dalam *2022 IEEE 8th International Conference on Computing, Engineering and Design (ICCED)*, IEEE, Jul 2022, hlm. 1–4. doi: 10.1109/ICCED56140.2022.10010351.
- [17] D. T. Ananto dkk., "Edukasi dan Pelatihan Pengenalan Machine Learning dan Computer Vision Untuk Mengeksplorasi Potensi Visual," *Jurnal UMJ*, no. PROSIDING SEMNASKAT LPPM UMJ 2023, Okt 2023, [Daring]. Tersedia pada: <http://jurnal.umj.ac.id/index.php/semnaskat>
- [18] Ahmad Nur Ihsan Purwanto, Muhammad Naufal Ammr Dzakwan, dan Fadillah Dani Prawoto, "Tren dan Perkembangan Supervised versus Unsupervised Learning," *Jurnal Teknik Informatika dan Teknologi Informasi*, vol. 5, no. 2, hlm. 619–625, Agu 2025, doi: 10.55606/jutiti.v5i2.5742.
- [19] H. Supriyanto, "A COMPARISON OF SUPERVISED LEARNING METHODS FOR FORECASTING TIME SERIES IN OUTSIDE PATIENT VISITS," vol. 10, no. 2, 2022.
- [20] A. Latif dan S. K. Wildah, "ANALISIS KINERJA ALGORITMA ENSEMBLE DALAM PREDIKSI PERILAKU PEMBELIAN PELANGGAN," 2025.
- [21] Hafiz Alda Cahyafitri, "IMPLEMENTASI METODE EXTREME GRADIENT BOOSTING DALAM PENENTUAN KLASIFIKASI INDEKS KETIMPANGAN GENDER DI INDONESIA," 2025.
- [22] C. G. L. Pringandana dan K. Kusnawi, "A Comparative Analysis of Hyperparameter-Tuned XGBoost and LightGBM for Multiclass Rainfall Classification in Jakarta," *Jurnal Teknik*

- Informatika (Jutif)*, vol. 6, no. 4, hlm. 2467–2483, Agu 2025, doi: 10.52436/1.jutif.2025.6.4.4965.
- [23] F. Alzamzami, M. Hoda, dan A. El Saddik, “Light Gradient Boosting Machine for General Sentiment Classification on Short Texts: A Comparative Evaluation,” *IEEE Access*, vol. 8, hlm. 101840–101858, 2020, doi: 10.1109/ACCESS.2020.2997330.
- [24] M. Ardiansyah Sembiring, F. Wulandari Sembiring, S. Informasi, dan S. Royal Kisaran, “ANALISA KINERJA MODEL REGRESI DALAM MACHINE LEARNING UNTUK MEMPREDIKSI HARGA BERAS,” *Journal Of Information Systems And Informatics Engineering*, vol. 8, no. 1, hlm. 144–152, 2024, doi: 10.35145/joisie.v8i1.3902.

Justin Salim, mahasiswa S1, program studi Teknik Informatika Universitas tarumanagara.

Jonathan, mahasiswa S1, program studi Teknik Informatika Universitas tarumanagara.

Devin Saputra Wijaya, mahasiswa S1, program studi Teknik Informatika Universitas tarumanagara.