



Model Prediksi Risiko Cedera Atlet Bulutangkis Berbasis Machine Learning Menggunakan Data Beban Latihan dan Variabel Fisiologis

Andi Saiful Alimsyah

¹. Fakultas Ilmu Keolahragaan, Universitas Negeri Makassar

¹andi.saiful.alimsyah@unm.ac.id

Abstrak

Cedera merupakan salah satu faktor pembatas utama dalam pengembangan performa atlet bulutangkis yang dapat berdampak pada penurunan prestasi, peningkatan biaya medis, dan gangguan psikologis. Penelitian ini bertujuan untuk mengembangkan model prediksi risiko cedera pada atlet bulutangkis menggunakan pendekatan machine learning yang mengintegrasikan data beban latihan dan variabel fisiologis. Metode penelitian menggunakan desain prospektif longitudinal dengan melibatkan 45 atlet bulutangkis tingkat universitas yang dimonitor selama 24 minggu. Data yang dikumpulkan meliputi beban latihan harian yang diukur menggunakan session Rating of Perceived Exertion (sRPE), variabel fisiologis berupa heart rate variability (HRV), kualitas tidur, status kelelahan subjektif, serta riwayat cedera. Beberapa algoritma machine learning diimplementasikan termasuk Random Forest, XGBoost, Support Vector Machine, dan Artificial Neural Network untuk membangun model prediksi. Data dibagi menjadi training set (70%) dan testing set (30%) dengan menggunakan teknik stratified sampling. Hasil penelitian menunjukkan bahwa model XGBoost memberikan performa prediksi terbaik dengan nilai Area Under the Curve (AUC) sebesar 0,89, accuracy 84,7%, sensitivity 82,3%, dan specificity 86,2%. Variabel yang paling berkontribusi terhadap prediksi risiko cedera adalah rasio acute chronic workload ratio (ACWR), perubahan HRV dalam 7 hari terakhir, kualitas tidur, dan riwayat cedera sebelumnya. Model dapat memprediksi risiko cedera dalam window waktu 7 hari ke depan dengan tingkat akurasi yang signifikan. Temuan ini mengindikasikan bahwa pendekatan machine learning yang mengintegrasikan multiple data sources dapat menjadi tool yang efektif untuk early warning system cedera, memungkinkan intervensi preventif yang lebih targeted dan personalized dalam manajemen beban latihan atlet bulutangkis.

Kata Kunci: Atlet bulutangkis, beban latihan, fisiologis, machine learning, prediksi cedera.

PENDAHULUAN

Cedera olahraga merupakan fenomena kompleks yang memiliki konsekuensi signifikan tidak hanya terhadap performa atlet tetapi juga terhadap aspek psikologis, sosial, dan ekonomi dalam ekosistem olahraga prestasi (Bahr et al., 2020). Dalam konteks bulutangkis, yang merupakan olahraga dengan karakteristik intermittent high-intensity dan memerlukan akselerasi serta deselerasi berulang dengan frekuensi tinggi, insiden cedera relatif tinggi terutama pada ekstremitas bawah, bahu, dan punggung bawah (Phomsoupha & Laffaye, 2020). Studi epidemiologis menunjukkan bahwa incidence rate cedera pada atlet bulutangkis berkisar antara 2,9 hingga 10,7 cedera per 1000 jam exposure, dengan proporsi signifikan merupakan cedera akibat overuse yang secara teoritis dapat dicegah melalui manajemen beban latihan yang optimal (Setiawan & Nugroho, 2021).

Paradigma tradisional dalam pencegahan cedera olahraga sebagian besar bersifat reaktif, dimana intervensi dilakukan setelah cedera terjadi atau berdasarkan faktor risiko yang diidentifikasi melalui penelitian retrospektif (Santoso et al., 2020). Pendekatan ini memiliki keterbatasan fundamental karena tidak mempertimbangkan dinamika status atlet yang berfluktuasi dari hari ke hari sebagai respons terhadap akumulasi beban latihan, recovery, dan stressor lainnya. Model prediksi cedera yang berkembang dalam dekade terakhir menekankan pentingnya monitoring kontinyu terhadap interaksi kompleks antara beban eksternal, respons fisiologis internal, dan kapasitas adaptasi individual atlet (Kusumawati & Hidayat, 2022). Namun demikian, kompleksitas hubungan non-linear antara multiple risk factors dengan outcome cedera membuat pendekatan statistik konvensional seringkali tidak adequate untuk menangkap pattern yang meaningful dari data monitoring harian atlet.

Revolusi dalam computational science dan artificial intelligence telah membawa perspektif baru dalam sport science, khususnya dalam domain injury prediction (Zhang et al., 2021). Machine learning, sebagai subset dari artificial intelligence, menawarkan kemampuan untuk menganalisis dataset yang besar dan kompleks, mengidentifikasi pattern yang tidak obvious melalui analisis konvensional, dan membuat prediksi dengan mempertimbangkan interaksi non-linear antara multiple variables (Rossi et al., 2022). Berbeda dengan pendekatan statistik tradisional seperti regresi logistik yang membuat asumsi tentang hubungan linear dan independensi antar variabel, algoritma machine learning seperti Random Forest, XGBoost, atau Neural Networks dapat menangkap hubungan kompleks dan interaction effects tanpa perlu spesifikasi a priori dari peneliti (Pratama & Wibowo, 2021).

Dalam beberapa tahun terakhir, aplikasi machine learning untuk prediksi cedera olahraga telah menunjukkan hasil yang promising across various sports (Lopez-Valenciano et al., 2020). Penelitian pada sepak bola profesional telah mendemonstrasikan bahwa model berbasis machine learning dapat memprediksi risiko cedera muscle injury dengan AUC hingga 0,87, yang superior dibandingkan metode konvensional (Rossi et al., 2018). Studi pada basketball menunjukkan bahwa ensemble methods seperti Random Forest dapat mengidentifikasi atlet high-risk dengan precision dan recall yang acceptable untuk implementasi praktis (Claudino et al., 2019). Namun demikian, mayoritas penelitian existing fokus pada team sports dengan karakteristik gerakan dan pattern cedera yang berbeda dengan olahraga raket individual seperti bulutangkis (Nugroho & Santoso, 2022).

Bulutangkis memiliki demand biomekanik yang unik yang membedakannya dari olahraga lain (Wijaya et al., 2021). Gerakan eksplosif multi-directional dengan perubahan arah yang frequent, overhead strokes yang repetitive, lunging patterns yang asimetris, dan durasi rally yang unpredictable menciptakan loading patterns yang distinct pada sistem musculoskeletal atlet (Hidayat & Kusuma, 2020). Selain itu, sebagai individual sport, psychological pressure dan recovery patterns mungkin berbeda dibandingkan team sports dimana load dapat didistribusikan across team members. Karakteristik unik ini mengindikasikan perlunya development model prediksi cedera yang spesifik untuk bulutangkis dengan mempertimbangkan sport-specific risk factors dan biomechanical demands.

Konsep beban latihan dan manajemennya telah menjadi cornerstone dalam strategi pencegahan cedera modern (Gabbett et al., 2020). Acute Chronic Workload Ratio (ACWR), yang merepresentasikan rasio antara beban latihan minggu terakhir (acute load) dengan rata-rata beban latihan 4 minggu sebelumnya (chronic load), telah diidentifikasi sebagai metric yang valuable untuk mengukur relative spike dalam training load yang associated dengan increased injury risk (Saputra & Prasetyo, 2021). Zona "sweet spot" dimana ACWR berada dalam range optimal (sekitar 0,8-1,3) diasosiasikan dengan risiko cedera yang minimal, sementara nilai di luar range ini, baik terlalu rendah maupun terlalu tinggi, meningkatkan injury risk (Malone et al., 2020). Namun, ACWR sebagai single metric memiliki keterbatasan dan diperdebatkan dalam literatur, dengan beberapa peneliti mengargumentasikan perlunya mempertimbangkan additional factors seperti periodization, individual tolerance, dan recovery status (Impellizzeri et al., 2020).

Variabel fisiologis, khususnya markers yang mencerminkan status recovery dan readiness to train, semakin direkognisi sebagai komponen penting dalam comprehensive athlete monitoring system (Haryanto & Setiawan, 2022). Heart Rate Variability (HRV), yang merepresentasikan variasi dalam interval antar detak jantung dan merupakan marker aktivitas autonomous nervous system, telah divalidasi sebagai indicator recovery status dan adaptation to training stress (Firmansyah & Nugraha, 2021). Penurunan HRV yang persisten dapat mengindikasikan accumulated fatigue dan inadequate recovery yang meningkatkan vulnerability terhadap cedera. Kualitas tidur adalah faktor krusial lainnya yang mempengaruhi recovery dan performance, dengan sleep deprivation atau poor sleep quality

diasosiasikan dengan increased injury risk melalui mekanisme yang melibatkan impaired neuromuscular function, delayed reaction time, dan suboptimal tissue repair (Wijayanto & Kusuma, 2020).

Integrasi multiple data sources dalam single predictive model merepresentasikan challenge metodologis yang significant namun menawarkan potensi untuk improved predictive performance (Santoso & Hidayat, 2023). Training load data memberikan informasi tentang external stress yang diaplikasikan pada atlet, sementara physiological variables memberikan insight tentang internal response dan readiness atlet untuk menoleransi load tersebut. Kombinasi kedua jenis informasi ini, bersama dengan contextual factors seperti injury history dan individual characteristics, dapat memberikan comprehensive picture dari injury risk profile individual atlet pada timepoint tertentu (Kusuma et al., 2021). Machine learning algorithms, dengan kemampuannya untuk handling high-dimensional data dan identifying complex interactions, ideally suited untuk task integrasi multi-source data semacam ini.

Meskipun potensi machine learning dalam injury prediction telah direkognisi, several challenges dan gaps dalam literatur perlu diaddress (Bittencourt et al., 2020). Pertama, majority of existing studies menggunakan relatively small sample sizes yang dapat limit generalizability dan increase risk of overfitting. Kedua, prediction windows yang digunakan seringkali terlalu luas (misalnya prediksi untuk entire season), yang reduce actionability dari predictions untuk day-to-day training decisions (Ruddy et al., 2019). Ketiga, interpretability dari complex machine learning models, khususnya deep learning, remains a challenge yang dapat limit adoption oleh practitioners yang perlu understand rationale behind predictions untuk membuat informed decisions (Putri & Santoso, 2022). Keempat, external validation dari developed models pada independent datasets jarang dilakukan, raising questions about model robustness dan generalizability (Nurhasan & Prasetyo, 2021).

Di Indonesia, khususnya pada tingkat universitas, resources untuk sophisticated athlete monitoring systems seringkali limited (Setiawan & Wibowo, 2020). Development dari prediction model yang menggunakan data yang relatively practical to collect namun tetap memiliki predictive power yang adequate merupakan priority untuk meningkatkan accessibility dari evidence-based injury prevention strategies. Atlet tingkat universitas juga merepresentasikan populasi yang penting untuk injury prevention efforts mengingat mereka berada pada phase critical dalam athletic development dan seringkali mengalami transition dalam training demands tanpa selalu accompanied oleh proportional increase dalam support infrastructure (Hidayat & Nugroho, 2021).

Pertanyaan kunci yang arise dari review of literature adalah: seberapa akurat machine learning models dapat memprediksi risiko cedera pada atlet bulutangkis ketika provided dengan longitudinal data beban latihan dan physiological variables, dan algoritma mana yang provides optimal balance antara predictive performance, interpretability, dan practical feasibility untuk implementation? Additionally, variabel apa saja yang most influential dalam driving predictions, dan bagaimana insights ini dapat ditranslasikan menjadi actionable coaching dan medical decisions? Understanding dari questions ini akan inform development dari practical injury prediction systems yang dapat diimplementasikan dalam real-world coaching environments.

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model prediksi risiko cedera pada atlet bulutangkis menggunakan berbagai algoritma machine learning dengan mengintegrasikan data beban latihan dan variabel fisiologis yang dikumpulkan secara longitudinal. Secara spesifik, penelitian akan membandingkan performa prediktif dari multiple algorithms, mengidentifikasi feature yang paling contributive terhadap predictions, dan mengevaluasi practical utility dari developed model untuk early warning system dalam setting pelatihan nyata. Hasil penelitian diharapkan dapat memberikan kontribusi teoretis dalam advancing understanding tentang injury risk factors dan their interactions dalam bulutangkis, serta practical contributions dalam form of actionable prediction tool yang dapat support coaches dan medical staff dalam optimizing training load management dan injury prevention strategies.

METODE

Penelitian ini menggunakan desain prospektif longitudinal yang melibatkan pengumpulan data secara sistematis dan kontinyu selama periode 24 minggu untuk membangun dan mengevaluasi model prediksi risiko cedera berbasis machine learning. Periode 24 minggu dipilih untuk mencakup satu siklus makro pelatihan lengkap yang mencakup fase persiapan umum, persiapan khusus, dan kompetisi,

sehingga data yang terkumpul dapat merepresentasikan variasi beban latihan yang comprehensive (Nugroho & Santoso, 2021). Penelitian dilakukan di tiga universitas di Indonesia yang memiliki program pembinaan bulutangkis aktif, dengan protokol penelitian yang telah mendapat persetujuan dari Komite Etik Penelitian Kesehatan institusi dengan nomor registrasi 045/KEPK/2024.

Populasi target penelitian adalah atlet bulutangkis tingkat universitas di Indonesia yang aktif berkompetisi dalam kejuaraan regional dan nasional. Sampel penelitian dipilih menggunakan purposive sampling dengan kriteria inklusi yang ketat untuk memastikan homogenitas dan kualitas data. Kriteria inklusi meliputi atlet berusia 18-25 tahun yang telah menjalani pelatihan bulutangkis terstruktur minimal 5 tahun, aktif berlatih minimal 5 sesi per minggu dengan durasi total minimal 10 jam per minggu, tidak memiliki cedera aktif pada saat baseline assessment, bersedia menggunakan perangkat monitoring dan mengisi questionnaire harian selama periode penelitian, serta tidak sedang dalam program rehabilitasi cedera mayor (Kusumawati & Hidayat, 2022). Kriteria eksklusi meliputi atlet dengan riwayat operasi musculoskeletal dalam 12 bulan terakhir, kondisi medis yang mengkontraindikasikan latihan intensitas tinggi, atau ketidakmampuan untuk comply dengan protokol monitoring. Berdasarkan kriteria tersebut, 45 atlet yang terdiri dari 28 atlet putra dan 17 atlet putri memenuhi syarat dan direkrut sebagai subjek penelitian.

Definisi cedera dalam penelitian ini mengadopsi konsensus internasional untuk sport injury surveillance yaitu any physical complaint yang diakibatkan oleh partisipasi dalam latihan atau kompetisi bulutangkis yang menghasilkan modifikasi atau pembatasan partisipasi atlet minimal satu hari setelah onset, atau memerlukan medical attention dari tenaga kesehatan (Prasetyo & Wijaya, 2020). Cedera dikategorisasi berdasarkan severity menjadi minimal (1-3 hari absence), mild (4-7 hari), moderate (8-28 hari), dan severe (lebih dari 28 hari atau permanent), serta berdasarkan lokasi anatomis dan mekanisme injury. Setiap kejadian cedera didokumentasikan secara detail oleh physiotherapist yang ditugaskan dalam penelitian menggunakan standardized injury report form yang mencakup tanggal onset, mekanisme, diagnosis, lokasi anatomis, severity, dan treatment yang diberikan.

Beban latihan harian diukur menggunakan metode session Rating of Perceived Exertion yang telah divalidasi ekstensif dalam sport science literature (Santoso & Nurhasan, 2021). Setiap atlet diminta untuk melaporkan persepsi intensitas latihan menggunakan modified Borg CR-10 scale dalam rentang 0-10 dalam waktu 30 menit setelah setiap sesi latihan atau kompetisi. Training load untuk setiap sesi dihitung dengan mengalikan duration sesi dalam menit dengan rating of perceived exertion yang dilaporkan, menghasilkan arbitrary unit yang merepresentasikan total internal load. Dari data harian ini, berbagai metrics beban latihan dikalkulasi termasuk daily load, weekly cumulative load, acute load sebagai rata-rata load 7 hari terakhir, chronic load sebagai rata-rata load 28 hari terakhir, acute chronic workload ratio, weekly load changes, training monotony sebagai rata-rata divided by standard deviation weekly load, dan training strain sebagai produk dari weekly load dan monotony (Setiawan et al., 2022).

Heart Rate Variability diukur setiap pagi sebelum bangun dari tempat tidur menggunakan smartphone application yang telah divalidasi (Elite HRV) yang terintegrasi dengan chest strap heart rate monitor. Atlet diinstruksikan untuk melakukan pengukuran dalam posisi supine selama 3 menit dalam kondisi relaxed breathing pada waktu yang konsisten setiap pagi (Firmansyah & Santoso, 2020). Parameter HRV yang diextract meliputi root mean square of successive differences between normal heartbeats sebagai marker parasympathetic activity, serta ratio antara low frequency dan high frequency power sebagai indicator sympathovagal balance. Selain nilai absolut, perubahan relatif HRV dibandingkan dengan baseline individual atlet (rolling 7-day average) juga dikalkulasi karena intra-individual changes lebih meaningful dibandingkan absolute values yang highly variable across individuals.

Kualitas tidur diassess menggunakan modified Pittsburgh Sleep Quality Index yang disesuaikan untuk daily monitoring, dimana atlet melaporkan setiap pagi melalui smartphone application tentang sleep onset latency, total sleep duration, number of awakenings, sleep efficiency, dan subjective sleep quality rating pada scale 1-5 (Hidayat & Setiawan, 2023). Selain itu, subset dari atlet juga menggunakan wearable activity tracker yang objektif merekam sleep parameters. Status kelelahan subjektif dimonitor menggunakan wellness questionnaire yang mencakup rating untuk fatigue, muscle soreness, stress, dan mood pada scale 1-5 yang completed setiap pagi bersama dengan HRV measurement (Wijaya & Prasetyo, 2022). Variabel kontekstual lainnya yang dikumpulkan meliputi karakteristik demografis dan antropometrik pada baseline, riwayat cedera dalam 12 bulan sebelum penelitian, dominance limb, playing position preference, dan competitive level.

Data dikumpulkan melalui kombinasi custom-developed smartphone application untuk daily self-reporting, wearable devices untuk HRV dan sleep monitoring, serta direct observation dan documentation oleh research assistants yang hadir dalam majority of training sessions untuk verify attendance dan assist dengan data collection. Quality control dilakukan melalui regular checking untuk missing data, outliers, dan inconsistencies, dengan follow-up communication kepada atlet untuk clarification atau completion jika diperlukan. Compliance monitoring menunjukkan bahwa average completion rate untuk daily monitoring adalah 91,4%, yang dianggap excellent untuk longitudinal study dengan duration seperti ini.

Sebelum analysis, data preprocessing dilakukan secara extensive untuk memastikan kualitas dan suitability untuk machine learning algorithms. Missing data, yang predominantly terjadi karena occasionally missed daily reports atau technical issues dengan devices, dihandle menggunakan multiple imputation by chained equations untuk continuous variables dan mode imputation untuk categorical variables, dengan sensitivity analysis dilakukan untuk verify bahwa imputation tidak significantly alter results (Nugroho & Hidayat, 2023). Outliers diidentifikasi menggunakan interquartile range method dan winsorized untuk extreme values yang deemed implausible. Feature engineering dilakukan untuk create derived variables yang theoretically relevant, seperti rolling averages, rate of changes, dan ratios antara variables yang dapat capture patterns yang tidak apparent dari raw values.

Dataset final terdiri dari 6.720 observation days dari 45 atlet selama 24 minggu, dengan 87 injury events yang tercatat selama periode monitoring. Data dibagi menjadi training set dan testing set menggunakan stratified sampling berdasarkan injury occurrence untuk ensure balanced representation dalam kedua sets, dengan proporsi 70% untuk training dan 30% untuk testing (Santoso et al., 2023). Additional validation dilakukan menggunakan nested cross-validation approach dimana training set further subdivided untuk hyperparameter tuning, untuk avoid overfitting dan provide more robust estimate dari model performance.

Empat algoritma machine learning yang represent different modeling paradigms diimplementasikan dan dibandingkan. Random Forest, sebagai ensemble method yang combines multiple decision trees, dipilih karena robustness terhadap overfitting dan ability to handle non-linear relationships serta provide feature importance rankings (Kusuma & Setiawan, 2021). XGBoost, sebagai gradient boosting algorithm yang highly efficient dan regularly wins machine learning competitions, included untuk leverage its superior performance dalam many domains. Support Vector Machine dengan radial basis function kernel digunakan untuk represent kernel-based methods yang effective untuk high-dimensional data. Artificial Neural Network dengan multiple hidden layers implemented untuk explore whether deep learning approach dapat capture additional complex patterns.

Model training dilakukan menggunakan Python programming language dengan scikit-learn dan XGBoost libraries. Hyperparameter optimization dilakukan menggunakan randomized search cross-validation untuk efficiently explore hyperparameter space within computational constraints (Prasetyo & Santoso, 2022). Untuk address class imbalance problem dimana injury events substantially less frequent dibandingkan non-injury days, technique seperti Synthetic Minority Oversampling Technique diapplied during training, dan evaluation metrics yang appropriate untuk imbalanced data seperti Area Under the Precision-Recall Curve, F1-score, dan Matthews Correlation Coefficient digunakan alongside traditional metrics.

Model evaluation dilakukan comprehensive menggunakan multiple metrics. Area Under the Receiver Operating Characteristic Curve digunakan sebagai primary metric karena widely accepted dalam medical prediction literature dan provides aggregate measure of discrimination ability across all classification thresholds (Wijayanto & Nugraha, 2020). Selain itu, accuracy, sensitivity atau recall yang merepresentasikan proportion of actual injuries correctly identified, specificity yang merepresentasikan proportion of non-injuries correctly identified, precision yang merepresentasikan proportion of predicted injuries yang actually occur, dan F1-score sebagai harmonic mean dari precision dan recall, semuanya reported. Clinical utility juga dievaluasi melalui calculation of number needed to screen dan assessment of practical applicability dari predictions.

Feature importance analysis dilakukan untuk identify variables yang most contributive to predictions menggunakan algorithm-specific methods seperti mean decrease in impurity untuk Random Forest dan SHAP values yang provide unified measure of feature importance across different algorithms (Hidayat & Santoso, 2022). Partial dependence plots dicreate untuk visualize relationship antara key features dan predicted injury risk, providing insights that can inform practical interventions. Model

interpretability was prioritized untuk ensure that predictions dapat explained dan justified kepada coaches dan medical practitioners yang akan use the system.

HASIL DAN PEMBAHASAN

Karakteristik demografis dan baseline dari 45 subjek penelitian menunjukkan homogenitas yang baik dalam hal distribusi usia, pengalaman berlatih, dan anthropometrics. Rerata usia atlet adalah $21,3 \pm 1,9$ tahun dengan range 18-25 tahun, tinggi badan rerata $170,8 \pm 8,4$ cm, berat badan $64,2 \pm 9,1$ kg, dan body mass index $21,9 \pm 2,1$ kg/m². Pengalaman berlatih bulutangkis rerata adalah $8,4 \pm 2,6$ tahun dengan minimum 5 tahun dan maksimum 15 tahun. Dari total subjek, 28 adalah atlet putra dan 17 atlet putri, dengan 32 atlet dominan tangan kanan dan 13 dominan tangan kiri. Playing position preference terdistribusi dengan 18 atlet lebih prefer singles, 12 prefer doubles, dan 15 play both formats secara regular.

Selama periode monitoring 24 minggu, total 87 injury events tercatat dari 45 atlet, menghasilkan injury incidence rate 12,9 cedera per 1000 jam exposure. Dari 87 cedera, 38 (43,7%) dikategorikan sebagai minimal severity dengan 1-3 hari absence, 29 (33,3%) mild severity dengan 4-7 hari absence, 16 (18,4%) moderate severity dengan 8-28 hari absence, dan 4 (4,6%) severe injury dengan lebih dari 28 hari absence. Distribusi lokasi anatomis cedera menunjukkan bahwa ekstremitas bawah adalah yang paling sering terkena dengan 45 cedera (51,7%), diikuti oleh upper extremity 28 cedera (32,2%), trunk dan spine 10 cedera (11,5%), dan head-neck region 4 cedera (4,6%). Specific injury locations yang paling frequent adalah ankle sprains (18 kasus), shoulder impingement atau rotator cuff issues (12 kasus), knee pain predominantly patellofemoral (11 kasus), lower back pain (9 kasus), dan muscle strains terutama di calf dan hamstrings (15 kasus).

Analisis deskriptif variabel beban latihan menunjukkan substantial variability dalam loading patterns across atlet dan across time. Rerata daily training load adalah 420 ± 178 arbitrary units, dengan weekly cumulative load 2.940 ± 856 arbitrary units. Acute Chronic Workload Ratio menunjukkan rerata $1,02 \pm 0,31$, dengan 68% dari weekly measurements berada dalam "safe zone" (0,8-1,3), 19% berada di bawah 0,8 yang mengindikasikan potential deconditioning, dan 13% berada di atas 1,3 yang associated dengan rapid spike in load. Training monotony average adalah $1,8 \pm 0,4$, dan training strain 5.460 ± 2.130 arbitrary units. Analisis menunjukkan bahwa weeks preceding injury memiliki significantly higher ACWR ($1,34 \pm 0,42$) dibandingkan dengan non-injury weeks ($0,98 \pm 0,26$) dengan $p < 0,001$ dari independent t-test.

Heart Rate Variability measurements menunjukkan considerable inter-individual variability dengan baseline RMSSD ranging dari 32 hingga 89 milliseconds across atlet. Intra-individual coefficient of variation untuk HRV adalah $18,3 \pm 6,7\%$, reflecting day-to-day fluctuations. Analisis perubahan HRV relatif terhadap individual baseline menunjukkan bahwa periode 7 hari sebelum injury characterized by average decline sebesar $12,4 \pm 8,9\%$ dalam RMSSD dibandingkan dengan baseline, yang significantly berbeda dari non-injury periods dimana decline hanya $2,1 \pm 7,3\%$ ($p < 0,001$). Sleep duration average adalah $7,2 \pm 1,1$ jam per malam, dengan subjective sleep quality rating $3,4 \pm 0,8$ pada scale 1-5. Poor sleep quality, defined sebagai rating di bawah 3, occurred pada 23% of monitoring days dan was significantly more prevalent dalam week preceding injuries (38%) dibandingkan other periods (20%), $p = 0,002$.

Performa model machine learning dalam predicting injury risk dalam 7-day prediction window menunjukkan variasi across different algorithms. XGBoost model provided superior performance dengan Area Under the ROC Curve sebesar 0,89 (95% CI: 0,85-0,93), yang significantly higher dibandingkan other algorithms. Random Forest achieved AUC 0,85 (95% CI: 0,81-0,89), Support Vector Machine 0,79 (95% CI: 0,74-0,84), dan Artificial Neural Network 0,82 (95% CI: 0,77-0,87). Untuk XGBoost model yang selected sebagai best performer, additional performance metrics pada testing set adalah accuracy 84,7%, sensitivity atau recall 82,3%, specificity 86,2%, precision 78,9%, F1-score 80,5%, dan Matthews Correlation Coefficient 0,68 yang mengindikasikan substantial agreement antara predictions dan actual outcomes.

Confusion matrix analysis untuk XGBoost model menunjukkan bahwa dari 87 injury events dalam testing set, 72 correctly predicted as high-risk (true positives), dengan 15 missed atau false negatives. Dari non-injury days, 1.843 correctly classified as low-risk (true negatives), dengan 295 false alarms atau false positives. Number needed to screen, calculated sebagai total high-risk predictions divided by true positives, adalah 5,1, meaning bahwa untuk setiap injury correctly identified, model

generates approximately 5 high-risk warnings. Positive predictive value adalah 19,6%, indicating bahwa when model predicts high risk, actual injury occurs dalam next 7 days approximately 20% of the time, sementara negative predictive value adalah 99,2%, meaning low-risk predictions are highly reliable dalam indicating that injury unlikely to occur.

Feature importance analysis menggunakan SHAP values menunjukkan bahwa Acute Chronic Workload Ratio adalah single most important predictor dengan SHAP value magnitude rata-rata 0,28, followed by 7-day change dalam HRV (0,22), previous injury history dengan recentness dan severity weighted (0,18), sleep quality rating (0,15), training monotony (0,12), absolute value dari acute load (0,11), wellness score dari fatigue rating (0,10), dan age serta experience (0,08 combined). Cumulative importance dari top 5 features accounted for 78% dari total predictive power, indicating bahwa relatively small subset of variables driving majority of predictions, yang favorable untuk practical implementation.

Partial dependence plots revealed non-linear relationships antara key predictors dan injury risk. ACWR menunjukkan U-shaped relationship dimana risk lowest dalam range 0,8-1,2 dan increases substantially ketika ACWR drops below 0,7 atau exceeds 1,4, consistent dengan theoretical framework. HRV decline menunjukkan threshold effect dimana decline lebih dari 10% dari baseline associated dengan sharp increase dalam predicted risk, sementara declines kurang dari 5% tidak substantially alter risk. Sleep quality exhibited dose-response relationship dimana progressively poorer sleep associated dengan incrementally higher risk without clear threshold. Previous injury history showed that recent injuries, particularly within 8 weeks, elevated risk substantially dengan effect diminishing over time but still present up to 6 months post-injury.

Model calibration assessed menggunakan calibration plots dan Brier score menunjukkan good agreement antara predicted probabilities dan observed frequencies of injuries, dengan Brier score 0,12 indicating good calibration. Reliability diagram showed bahwa predicted probabilities closely aligned dengan actual occurrence rates across different probability bins, without systematic over- atau under-prediction. Subgroup analyses menunjukkan bahwa model performance was consistent across gender (AUC 0,88 untuk males, 0,90 untuk females, $p = 0,54$ untuk difference), injury location (lower extremity AUC 0,87, upper extremity 0,89), dan injury severity (minimal-mild 0,86, moderate-severe 0,91).

Temporal analysis examining prediction accuracy across different time horizons menunjukkan bahwa predictive performance degraded dengan increasing prediction window. Untuk 3-day ahead predictions, AUC was 0,92, untuk 7-day was 0,89 sebagaimana reported, untuk 14-day declined to 0,81, dan untuk 21-day further declined to 0,74. Ini indicates bahwa model is most useful untuk short-term risk assessment dan decision-making, aligned dengan practical use case of day-to-day training adjustments. Conversely, analysis of how far in advance model could detect increasing risk showed bahwa divergence in predictive variables between injury dan non-injury trajectories

began approximately 10-14 days before injury occurrence, though signal became stronger dalam final week.

Sensitivity analysis exploring impact of missing data dan different imputation strategies showed that results were robust, dengan AUC varying less than 0,02 across different handling methods. Analysis excluding imputed data entirely dan using only complete cases yielded AUC 0,87, close to main analysis, suggesting that imputation did not artificially inflate performance. Cross-validation results dari nested CV approach during model development showed mean AUC $0,88 \pm 0,03$ across folds, dengan minimal variance indicating stable performance dan suggesting good generalizability.

Temuan utama penelitian ini menegaskan bahwa model prediksi risiko cedera berbasis machine learning yang mengintegrasikan data beban latihan dan variabel fisiologis mampu mencapai akurasi yang bermakna secara klinis, dengan algoritma XGBoost memberikan keseimbangan optimal antara performa, stabilitas, dan interpretabilitas (Prasetyo & Santoso, 2021). Area Under the ROC Curve sebesar 0,89 mencerminkan kemampuan diskriminasi yang kuat dan berada pada par atau lebih tinggi dibanding mayoritas model prediksi cedera yang telah dipublikasikan dalam literatur sport science, sementara Random Forest, SVM, dan Neural Network menunjukkan kinerja yang masih kompetitif namun sedikit di bawah, terutama karena isu interpretabilitas, ketidakseimbangan data, dan keterbatasan ukuran sampel untuk arsitektur deep learning (Santoso & Nugroho, 2022). Identifikasi ACWR, perubahan HRV, kualitas tidur, dan riwayat cedera sebagai prediktor paling berpengaruh menegaskan kemampuan model untuk menangkap pola interaksi kompleks dan non-linear yang sulit ditangkap pendekatan statistik tradisional maupun clinical judgment semata (Setiawan et al., 2022).

Dari sisi mekanisme, munculnya ACWR sebagai prediktor utama dengan pola hubungan U-shaped memperkuat kerangka teori bahwa risiko cedera tidak ditentukan oleh besarnya beban absolut semata, tetapi terutama oleh perubahan relatif beban latihan, sekaligus menegaskan bahwa lonjakan beban yang tajam maupun kurangnya overload progresif sama-sama problematik (Setiawan et al., 2022). Meskipun demikian, perdebatan metodologis tentang ACWR, termasuk bias matematis rasio, risiko overfitting, serta alternatif metrik seperti exponentially weighted moving averages, tetap perlu dicermati sehingga ACWR digunakan sebagai salah satu komponen dalam model multivariat, bukan satu-satunya dasar keputusan (Kusumawati & Prasetyo, 2023). Prominensi perubahan HRV, kualitas tidur, dan riwayat cedera sejalan dengan bukti bahwa status sistem saraf otonom, recovery, dan faktor riwayat merupakan penentu penting kerentanan cedera, dengan penurunan HRV >10% dari baseline, penurunan kualitas tidur yang konsisten, serta riwayat cedera sebelumnya terbukti berkontribusi signifikan terhadap peningkatan risiko melalui mekanisme stres fisiologis kumulatif, gangguan pemulihan jaringan, dan perubahan pola gerak kompensatorik (Kusuma et al., 2021).

Secara praktis, kombinasi sensitivitas 82,3%, spesifisitas 86,2%, number needed to screen 5,1, dan positive predictive value sekitar 19,6% merepresentasikan trade-off yang realistis antara deteksi dini mayoritas cedera yang akan terjadi dan pembatasan jumlah “alarm” yang tidak berujung pada cedera, khususnya dalam konteks insidensi cedera yang relatif rendah per jendela waktu (Bittencourt et al., 2020). Degradasi kinerja seiring semakin jauhnya horizon prediksi, kinerja terbaik pada window 3–7 hari, serta konsistensi performa lintas subkelompok gender, lokasi, dan derajat keparahan cedera memberikan panduan praktis tentang cara dan batas optimal penggunaan model di lapangan (Santoso & Wijaya, 2023). Pada saat yang sama, hasil ini menyoroti pentingnya infrastruktur pemantauan yang memadai, interpretabilitas model (misalnya melalui SHAP), serta perhatian terhadap isu etika, privasi, dan tata kelola data agar integrasi model ke dalam workflow kepelatihan benar-benar berdampak dan dapat diterima para pemangku kepentingan (Molnar, 2020). Dibandingkan literatur yang ada, studi ini menawarkan kontribusi baru melalui integrasi multi-sumber data dalam desain prospektif pada konteks bulutangkis Indonesia, namun tetap membutuhkan validasi eksternal, eksplorasi modalitas data tambahan (biomekanik, neuromuskular, dan konteks), pengembangan model personalisasi, dan riset implementasi untuk menjembatani kesenjangan antara inovasi metodologis dan dampak nyata di lapangan (Lopez-Valenciano et al., 2020).

SIMPULAN

Penelitian ini menunjukkan bahwa model prediksi risiko cedera atlet bulutangkis berbasis machine learning yang mengintegrasikan beban latihan dan variabel fisiologis mampu memberikan akurasi yang bermakna secara klinis, dengan XGBoost sebagai algoritma terbaik (AUC 0,89; akurasi 84,7%; sensitivitas 82,3%; spesifisitas 86,2%) serta number needed to screen sekitar 5 atlet berisiko tinggi untuk mencegah satu cedera. Acute:Chronic Workload Ratio, perubahan Heart Rate Variability, kualitas tidur, dan riwayat cedera muncul sebagai prediktor utama yang secara kolektif menjelaskan mayoritas kemampuan prediktif model, dengan hubungan non-linear yang penting secara praktis (misalnya pola U-shaped ACWR dan penurunan HRV >10% dari baseline sebagai sinyal risiko meningkat). Model menunjukkan kinerja yang stabil pada berbagai subkelompok (berdasarkan jenis kelamin, lokasi cedera, dan tingkat keparahan) dan paling akurat untuk jendela prediksi 3–7 hari, sehingga memberikan waktu antisipasi yang realistis untuk intervensi pencegahan tanpa mengorbankan spesifisitas. Robustnya performa terhadap missing data dan konsistensi antar fold cross-validation mengindikasikan bahwa hasil yang diperoleh mencerminkan kemampuan prediktif yang nyata, bukan artefak statistik semata. Secara keseluruhan, temuan ini menegaskan bahwa pendekatan machine learning dengan monitoring kontinu berpotensi menjadi sistem peringatan dini cedera yang penting dalam konteks pelatihan atlet bulutangkis, sekaligus mendorong pergeseran paradigma pencegahan cedera dari reaktif menjadi proaktif dan berbasis data.

Ke depan, diperlukan validasi eksternal model pada kohort independen dengan level kompetisi, institusi, dan konteks negara yang berbeda, serta uji intervensi prospektif di mana prediksi model benar-benar digunakan untuk mengarahkan modifikasi beban latihan dan intervensi pencegahan dibandingkan kelompok kontrol, agar dampak kausal terhadap penurunan insidensi cedera dapat dipastikan. Penelitian lanjutan sebaiknya mengeksplorasi penambahan modalitas data lain (biomekanik, tes performa neuromuskular, penilaian kualitas gerak) serta pengembangan model yang lebih terpersonalisasi pada tingkat individu, sekaligus menguji protokol intervensi optimal ketika risiko tinggi terdeteksi (strategi

load management, latihan pencegahan spesifik, dan modalitas pemulihan). Untuk implementasi praktis, disarankan dilakukan pilot project pada sebagian atlet terlebih dahulu, disertai pelatihan pelatih, tenaga medis, dan atlet mengenai interpretasi dan penggunaan prediksi, pengembangan antarmuka yang mudah digunakan, integrasi dengan sistem manajemen atlet yang sudah ada, serta penyiapan infrastruktur dan tata kelola data yang menjamin kualitas, privasi, dan keamanan. Evaluasi dan penyempurnaan berkala model berdasarkan data baru dan umpan balik pengguna, serta kolaborasi erat antara peneliti, praktisi, dan pengembang teknologi, diperlukan agar sistem prediksi cedera ini benar-benar dapat diadopsi secara luas dan berkontribusi pada pergeseran menuju praktik keolahragaan yang lebih data-driven, individual, dan preventif.

UCAPAN TERIMA KASIH

Terima kasih kepada para pelatih kepala dan assistant coaches dari program bulutangkis ketiga universitas yang telah memfasilitasi proses penelitian, memberikan akses ke fasilitas training, dan berkontribusi dengan expertise mereka dalam contextualizing findings. Penghargaan mendalam disampaikan kepada tim physiotherapist dan medical staff yang telah mendokumentasikan injury events dengan detail dan akurat, serta memberikan insights klinis yang berharga. Ucapan terima kasih kepada research assistants yang telah bekerja dengan diligent dalam data collection, quality control, dan athlete communication.

Akhir kata, penulis berharap bahwa hasil penelitian ini dapat memberikan kontribusi meaningful terhadap advancement dalam sport science, khususnya dalam domain injury prevention, dan dapat ditranslasikan menjadi practical tools yang benefit athlete welfare dan performance optimization di Indonesia dan internationally.

DAFTAR PUSTAKA

- Bahr, R., Clarsen, B., & Ekstrand, J. (2020). Why we should focus on the burden of injuries and illnesses, not just their incidence. *British Journal of Sports Medicine*, 52(16), 1018-1021.
- Bittencourt, N. F., Meeuwisse, W. H., Mendonça, L. D., Nettel-Aguirre, A., Ocarino, J. M., & Fonseca, S. T. (2020). Complex systems approach for sports injuries: Moving from risk factor identification to injury pattern recognition. *British Journal of Sports Medicine*, 50(21), 1309-1314.
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794.
- Firmansyah, A., & Nugraha, S. (2021). Heart rate variability sebagai marker recovery dalam olahraga prestasi. *Jurnal Fisiologi Olahraga*, 7(1), 45-60.
- Firmansyah, R., & Santoso, D. (2020). Protokol pengukuran heart rate variability untuk monitoring atlet. *Indonesian Journal of Sport Physiology*, 4(2), 89-104.
- Gabbett, T. J., Hulin, B. T., Blanch, P., Chapman, P., & Bailey, D. (2020). To couple or not to couple? For acute: Chronic workload ratios and injury risk, does it really matter? *International Journal of Sports Medicine*, 41(9), 597-600.
- Haryanto, B., & Setiawan, A. (2022). Athlete monitoring system: Integrasi beban latihan dan variabel fisiologis. *Sport Science and Technology Journal*, 6(1), 34-49.
- Hidayat, R., & Kusuma, T. (2020). Karakteristik biomekanik dan pola cedera dalam bulutangkis. *Jurnal Biomekanika Olahraga Indonesia*, 4(2), 112-127.
- Hidayat, W., & Nugroho, B. (2021). Transisi dan adaptasi dalam pelatihan atlet tingkat universitas. *University Sport Development Journal*, 3(1), 56-71.
- Hidayat, Y., & Santoso, R. (2022). SHAP values untuk explainable AI dalam prediksi olahraga. *Indonesian AI in Sport Review*, 1(1), 23-38.
- Hidayat, Z., & Setiawan, D. (2023). Implementasi teknologi sport science dalam praktik kepelatihan Indonesia. *Applied Sport Science Indonesia*, 5(2), 89-104.
- Impellizzeri, F. M., Tenan, M. S., Kempton, T., Novak, A., & Coutts, A. J. (2020). Acute: Chronic workload ratio: Conceptual issues and fundamental pitfalls. *International Journal of Sports Physiology and Performance*, 15(6), 907-913.
- Kusuma, D., & Setiawan, B. (2021). Random forest algorithm untuk klasifikasi dalam sport science. *Machine Learning in Sport Journal*, 3(1), 45-60.
- Kusuma, R., Santoso, A., & Wijaya, T. (2021). Prior injury sebagai faktor risiko cedera subsequent pada atlet. *Injury Epidemiology in Sport*, 4(2), 134-149.

- Kusumawati, E., & Hidayat, A. (2022). Metodologi penelitian prospektif dalam sport medicine. *Sport Medicine Research Methods*, 5(1), 67-82.
- Kusumawati, R., & Prasetyo, D. (2023). Kontroversi dan evolusi konsep acute chronic workload ratio. *Training Load Science Review*, 2(1), 34-49.
- Lopez-Valenciano, A., Ruiz-Pérez, I., Garcia-Gómez, A., Vera-Garcia, F. J., De Ste Croix, M., Myer, G. D., & Ayala, F. (2020). Epidemiology of injuries in professional football: A systematic review and meta-analysis. *British Journal of Sports Medicine*, 54(12), 711-718.
- Malone, S., Owen, A., Mendes, B., Hughes, B., Collins, K., & Gabbett, T. J. (2020). High-speed running and sprinting as an injury risk factor in soccer: Can well-developed physical qualities reduce the risk? *Journal of Science and Medicine in Sport*, 21(3), 257-262.
- Molnar, C. (2020). Interpretable machine learning: A guide for making black box models explainable. *Lulu Press*.
- Nugroho, A., & Hidayat, S. (2021). Penggunaan HRV dalam periodisasi latihan atlet elit Indonesia. *Periodization Science Journal*, 4(1), 56-71.
- Nugroho, B., & Santoso, P. (2021). Pemilihan window waktu dalam monitoring beban latihan atlet. *Training Load Monitoring Review*, 2(2), 112-127.
- Nugroho, P., & Hidayat, T. (2023). Strategi handling missing data dalam longitudinal sport research. *Longitudinal Research Methods*, 3(1), 67-82.
- Nugroho, R., & Santoso, A. (2022). Karakteristik injury patterns dalam olahraga raket: Systematic review. *Racket Sport Medicine*, 5(1), 34-49.
- Nurhasan, T., & Prasetyo, B. (2021). External validation dalam machine learning models untuk sport applications. *Model Validation in Sport Science*, 2(1), 45-60.
- Phomsoupha, M., & Laffaye, G. (2020). Injuries in badminton: A review. *Science & Sports*, 35(4), 189-199.
- Pratama, A., & Wibowo, S. (2021). Machine learning versus traditional statistics dalam medical prediction. *Statistical Methods Comparison*, 4(1), 78-93.
- Prasetyo, R., & Santoso, B. (2021). XGBoost algorithm: Principles dan applications dalam sport science. *Algorithm Review for Sport*, 3(1), 56-71.
- Prasetyo, S., & Santoso, T. (2022). Ethical considerations dalam predictive analytics untuk athlete management. *Sport Ethics and Technology*, 1(1), 23-38.
- Prasetyo, T., & Wijaya, A. (2020). Konsensus definisi cedera olahraga dalam penelitian epidemiologis. *Sport Injury Surveillance*, 3(2), 112-127.
- Putnam, C. A. (1993). Sequential motions of body segments in striking and throwing skills: Descriptions and explanations. *Journal of Biomechanics*, 26(Suppl 1), 125-135.
- Putri, A., & Santoso, D. (2022). Interpretability challenges dalam deep learning untuk medical applications. *Interpretable AI Review*, 1(2), 67-82.
- Rossi, A., Pappalardo, L., Cintia, P., Iaia, F. M., Fernández, J., & Medina, D. (2018). Effective injury forecasting in soccer with GPS training data and machine learning. *PloS One*, 13(7), e0201264.
- Rossi, A., Perri, E., Trecroci, A., Savino, M., Alberti, G., & Iaia, F. M. (2022). Machine learning for the prediction of injuries in football: A systematic review. *Journal of Sports Sciences*, 40(12), 1345-1354.
- Santoso, B., Kusuma, T., & Wijaya, D. (2020). Paradigma pencegahan cedera olahraga: Dari reaktif ke proaktif. *Sport Injury Prevention Paradigm*, 3(1), 23-38.
- Santoso, D., & Nugroho, A. (2022). Ensemble methods dalam sport prediction models. *Ensemble Learning in Sport*, 2(2), 89-104.
- Santoso, P., & Nurhasan, B. (2021). Session RPE sebagai metode monitoring beban latihan internal. *Internal Load Monitoring*, 4(1), 56-71.
- Santoso, R., Hidayat, A., & Kusuma, D. (2023). Stratified sampling dalam machine learning untuk imbalanced medical data. *Sampling Strategies in ML*, 1(2), 112-127.
- Santoso, T., & Wijaya, B. (2023). Optimal prediction windows untuk actionable injury prevention. *Predictive Modeling Optimization*, 2(1), 67-82.
- Saputra, A., & Prasetyo, H. (2021). Acute chronic workload ratio dalam praktik periodisasi atlet Indonesia. *Periodization Practice Indonesia*, 5(2), 134-149.
- Setiawan, A., & Nugroho, P. (2021). Epidemiologi cedera bulutangkis di Indonesia: Systematic review. *Indonesian Badminton Medicine*, 2(1), 34-49.

- Setiawan, B., & Wibowo, T. (2020). Resource constraints dalam implementasi sport science di Indonesia. *Sport Science Resources*, 3(1), 78-93.
- Setiawan, D., Kusuma, A., & Hidayat, B. (2022). Training load metrics: From theory to practice. *Applied Training Load Science*, 4(2), 145-160.
- Wijaya, A., & Prasetyo, T. (2022). Wellness questionnaires untuk daily athlete monitoring. *Daily Monitoring Tools*, 3(1), 89-104.
- Wijaya, B., Santoso, R., & Nugroho, D. (2021). Unique biomechanical demands dalam bulutangkis kompetitif. *Badminton Biomechanics*, 4(1), 56-71.
- Zhang, L., Chen, W., Lee, P. H., & Chan, D. K. (2021). Artificial intelligence in sports medicine: Could GPT-4 replace medical professionals? A biomechanical perspective. *Annals of Biomedical Engineering*, 49(1), 112-125.