

Published online on the page: https://journal.upp.ac.id/index.php/rjti/index

R J T I

Riau Jurnal Teknik Informatika

| E - ISSN (*Online*) 2829-2529 |

Analisis Kerapatan Pertahanan Sepak Bola Berbasis Computer Vision dan Transformasi Homografi

Savio Hendriko Palendeng[1,*], Oktavian Abraham Lantang[2], Muhamad Dwisnanto Putro[3]

[1,2,3]Universitas Sam Ratulangi, Manado, Indonesia

Informasi Artikel

Sejarah Artikel:
Submit: 12 Juli 2026
Revisi: 08 Agustus 2026
Diterima: 02 Oktober 2026
Diterbitkan: 02 November 2026

Kata Kunci

Computer Vision, Deep Learning, Object Tracking, Sports Analytics, Transformasi Homografi

Korespondensi

E-mail: saviopalendeng506@gmail.com

A B S T R A C T

Defensive compactness and inter-player distance are crucial tactical aspects in football. However, their evaluation has traditionally relied on subjective visual observation, which is highly susceptible to bias caused by perspective distortion from television broadcast cameras. This research aims to develop an automated data-driven spatiotemporal analytics system to quantitatively extract tactical metrics from single broadcast camera videos. This system provides an objective solution for coaching staff to precisely evaluate the effectiveness of defensive strategies, replacing manual observation methods. The proposed method integrates Computer Vision and Deep Learning, utilizing the YOLOv11m model for player detection, the BoTSORT tracking algorithm, and a color space filter for team differentiation. The 2D pixel coordinates are then converted into real-world pitch distance metrics using Homographic Transformation supported by Global Motion Estimation (GME) to overcome camera movement. Testing on static (Indonesia National Team) and dynamic (Bayern Munich) defensive scenarios showed that the detection model achieved an mAP50 precision of 0.986, with a tracking accuracy (MOTA) of 89.78%. Field distance projection validation recorded a very low error rate (MAPE) of 7.93% in the static calibration area. This computational system is proven reliable as a Sports Analytics instrument to reduce tactical interpretation bias, map Convex Hull and dyadic distances, and objectively support coaches strategic decision-making.

Abstrak

Kerapatan pertahanan dan jarak antarpemain merupakan aspek taktis krusial dalam sepak bola. Namun, evaluasinya selama ini masih bergantung pada pengamatan visual subjektif yang sangat rentan terhadap bias akibat distorsi lensa kamera televisi. Penelitian ini bertujuan mengembangkan sistem analitik spasiotemporal otomatis berbasis data (data-driven) untuk mengekstraksi metrik taktis secara kuantitatif dari video kamera siaran tunggal. Sistem ini memberikan solusi objektif bagi staf kepelatihan untuk mengevaluasi efektivitas strategi bertahan secara presisi, menggantikan metode observasi manual. Metode yang diusulkan mengintegrasikan Computer Vision dan Deep Learning, menggunakan model YOLOv11m untuk deteksi pemain, algoritma pelacakan BoTSORT, dan filter ruang warna untuk membedakan tim. Koordinat piksel 2D kemudian dikonversi menjadi metrik jarak nyata di lapangan menggunakan Transformasi Homografi yang didukung Global Motion Estimation (GME) untuk mengatasi pergerakan kamera. Pengujian pada skenario bertahan statis (Timnas Indonesia) dan dinamis (Bayern Munchen) menunjukkan model deteksi mencapai presisi mAP50 sebesar 0,986, dengan akurasi pelacakan (MOTA) 89,78%. Validasi proyeksi jarak lapangan mencatatkan tingkat galat (MAPE) yang sangat rendah sebesar 7,93% pada area kalibrasi statis. Sistem komputasi ini terbukti andal sebagai instrumen Sports Analytics untuk menekan bias interpretasi taktis, memetakan Convex

Creative Commons Attribution-ShareAlike 4.0 International License. *Some rights reserved*

Hull dan jarak dyads, serta mendukung pengambilan keputusan strategi pelatih secara objektif.

This is an open access article under the CC–BY-SA license

1. Pendahuluan

Sepak bola modern telah bertransformasi menjadi disiplin ilmu yang sangat bergantung pada analisis data spasiotemporal untuk memahami perilaku kolektif pemain, khususnya dalam mengorganisasi pertahanan. Di tingkat nasional maupun internasional, tantangan utama dalam fase bertahan adalah menjaga kerapatan (*compactness*) antar pemain dan antar lini untuk menutup ruang gerak lawan [1]. Bukti empiris menegaskan bahwa organisasi pertahanan yang rapat merupakan faktor esensial bagi kesuksesan taktik sebuah tim [2]. Standar ideal untuk menilai kerapatan tim ini diukur melalui kalkulasi Jarak Euclidean antara dua pemain yang saling berdekatan, atau yang dikenal dengan istilah *player dyads* [3].

Akan tetapi, realitas di lapangan menunjukkan bahwa evaluasi taktis tersebut sering kali masih jauh dari kondisi ideal dan sangat bergantung pada pengamatan visual subjektif secara kualitatif langsung dari tayangan video [4]. Pendekatan kualitatif semacam ini pada akhirnya melahirkan penilaian yang sarat akan distorsi personal, memicu bias pemahaman yang signifikan antara pelatih dan pemain [5]. Kesenjangan utama terletak pada keterbatasan mata manusia dalam mengestimasi jarak secara objektif akibat distorsi perspektif dari kamera bersudut pandang lebar (*wide-angle*) yang umum digunakan pada siaran televisi tunggal (*single broadcast camera*) [6]. Pandangan ini memicu ilusi optik, di mana jarak antar pemain terlihat menyusut di area pandang yang jauh, diperparah oleh kendala tumpang tindih visual (oklusi) dan pergerakan dinamis [7]. Apabila ketergantungan pada analisis visual subjektif ini dibiarkan, kerenggangan jarak antar pemain tidak akan teridentifikasi secara akurat.

Untuk mengatasi keterbatasan indrawi tersebut, sejumlah studi terbaru telah mengeksplorasi penggunaan kecerdasan buatan guna mengotomatisasi ekstraksi statistik posisi tanpa bergantung pada alat sensor fisik (*wearable GPS*) yang mahal [8]. Hal ini sejalan dengan tren adopsi *Deep Learning* yang semakin masif untuk analisis tayangan olahraga secara otomatis [9]. Penelitian terkini membuktikan bahwa arsitektur pendeteksi objek *You Only Look Once* (YOLO), khususnya varian mutakhir seperti YOLOv11, mampu memberikan keseimbangan optimal antara kecepatan deteksi waktu nyata dan akurasi tinggi [10]. Integrasi YOLO dengan algoritma pelacak (*Multi-Object Tracking*) terbukti andal mempertahankan identitas pemain di tengah masalah oklusi objek [11]. Selain itu, pemanfaatan *clustering* warna HSV telah dikonfirmasi efektivitasnya dalam membedakan entitas tim di lapangan secara otomatis [12]. Untuk memetakan dimensi lapangan dari piksel 2D ke dalam koordinat absolut 2D, pendekatan *Homographic Perspective Transform* (HPT) terbukti tangguh mengatasi distorsi ilusi optik kamera siaran tunggal tanpa perlu melatih jaringan neural tambahan secara khusus [13].

Meskipun teknologi pemetaan spasial banyak diimplementasikan, kajian literatur menyingkap sebuah rumpang ilmu (*research gap*). Sebagian besar riset berbasis visi komputer saat ini hanya berfokus pada prediksi penguasaan bola [14], tinjauan taktis kolektif yang masih mengandalkan data pabrikan alih-alih ekstraksi otomatis [15], atau sekadar mengevaluasi parameter aturan main teknis seperti pergerakan *offside* tanpa integrasi spasial penuh [16]. Belum ada literatur komprehensif yang secara khusus mengintegrasikan detektor objek YOLO generasi terbaru, pelacak MOT, dan transformasi HPT ke dalam satu alur komputasi utuh guna mengekstraksi metrik taktis kerapatan pertahanan berbasis Jarak Euclidean (*dyads*) secara otomatis dari rekaman kamera siaran tunggal.

Berdasarkan kesenjangan tersebut, penelitian ini merumuskan permasalahan dalam tiga pertanyaan taktis utama: (1) Bagaimana mengintegrasikan model deteksi YOLOv11m dan pelacak BoTSORT untuk mengatasi kendala oklusi visual secara presisi?; (2) Bagaimana merancang alur transformasi spasial untuk memetakan koordinat layar ke dalam metrik lapangan yang objektif?; dan (3) Bagaimana sistem komputasi ini dapat memvisualisasikan data jarak antarpemain guna membantu pelatih dalam pengambilan keputusan strategi bertahan? Penelitian ini bertujuan untuk mengembangkan sistem otomatisasi analitik spasiotemporal yang mampu menjawab permasalahan tersebut. Transisi menuju kuantifikasi taktis berbasis kecerdasan buatan ini dirancang sebagai solusi objektif untuk mengeliminasi bias observasi visual, mengatasi distorsi lensa, serta menghadirkan standar evaluasi taktis yang terukur di atas lapangan.

2. Metode Penelitian

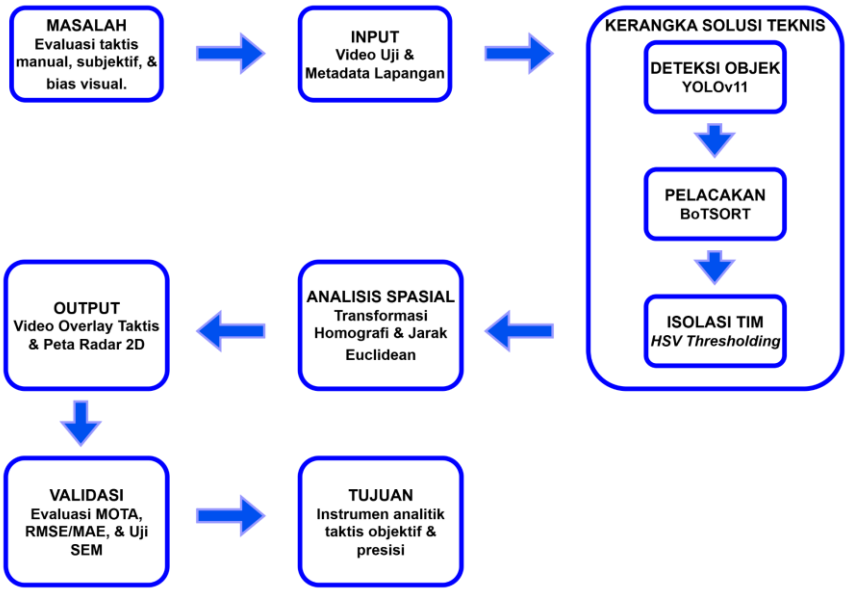
Penelitian ini menggunakan pendekatan eksperimental berbasis perangkat lunak untuk mengekstrak data spasiotemporal dari rekaman video kamera tunggal.

2.1. Dataset dan Skenario Pengujian

Untuk menjamin kemampuan generalisasi sistem, evaluasi dilakukan pada dua skenario pertandingan yang sengaja dipilih karena memiliki tingkat kompleksitas yang sangat bertolak belakang. (1) Skenario Statis (Timnas Indonesia vs Irak): Bertujuan menguji keandalan sistem pada formasi bertahan blok rendah (*Low Block*) dengan kepadatan pemain yang ekstrem di area penalti. Video memiliki resolusi 1080p, direkam dengan kamera siaran statis (*TV Broadcast*), durasi 12 detik, dengan total 388 frame (30 FPS). (2) Skenario Dinamis (Bayern Munchen vs PSG): Bertujuan menguji ketahanan pelacakan dan stabilitas kalibrasi terhadap pergerakan kamera *panning* ekstrem serta taktik garis pertahanan tinggi (*High Line*). Video memiliki resolusi 1080p, direkam dengan *Tactical Cam*, durasi 1 menit 19 detik, dengan total 2.391 frame (30 FPS).

2.2. Tahapan Penelitian

Alur logis dari penelitian ini dimulai dengan akuisisi data, pelokalisasian entitas melalui visi komputer, hingga pemetaan spasial dan ekstraksi metrik taktis. Tahapan penelitian secara komprehensif divisualisasikan pada Gambar 1, memisahkan secara konseptual antara tahap pemrosesan awal hingga analisis akhir di lingkup olahraga.



Gambar 1. Tahapan Penelitian

2.3. Spesifikasi Perangkat dan Lingkungan Komputasi

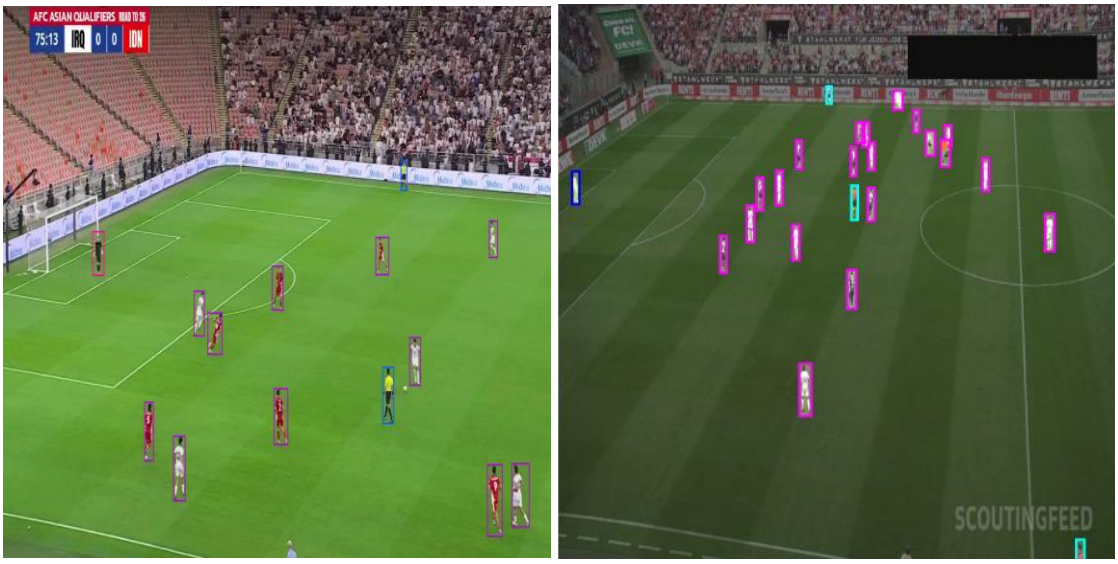
Mengingat tingginya beban komputasi spasiotemporal, eksperimen dibagi ke dalam dua lingkungan kerja untuk menjamin keterulangan (*reproducibility*) penelitian, sebagaimana dirangkum pada Tabel 1.

Tabel 1. Konfigurasi Lingkungan Perangkat Keras dan Perangkat Lunak

Komponen	Spesifikasi & Fungsi
Perangkat Komputasi Cloud	Google Colaboratory (GPU NVIDIA T4 Tensor Core, RAM 12.6GB) untuk akselerasi pelatihan model (*fine-tuning*) dan inferensi aliran video.
Perangkat Komputasi Lokal	Laptop Prosesor Intel Celeron (OS Windows) sebagai terminal dukungan akses, manajemen skrip, dan visualisasi hasil.
Bahasa Pemrograman	Python 3.9+ sebagai lapisan orkestrasi alur kerja (*pipeline*) yang merupakan standar industri untuk komputasi *Machine Learning* [17].
Library Utama	Ultralytics (YOLOv11), OpenCV (Transformasi Spasial), SciPy & Pandas (Ekstraksi Metrik), dan FilterPy (BoTSORT).

2.4. Pengumpulan Data dan Metodologi Fine-Tuning

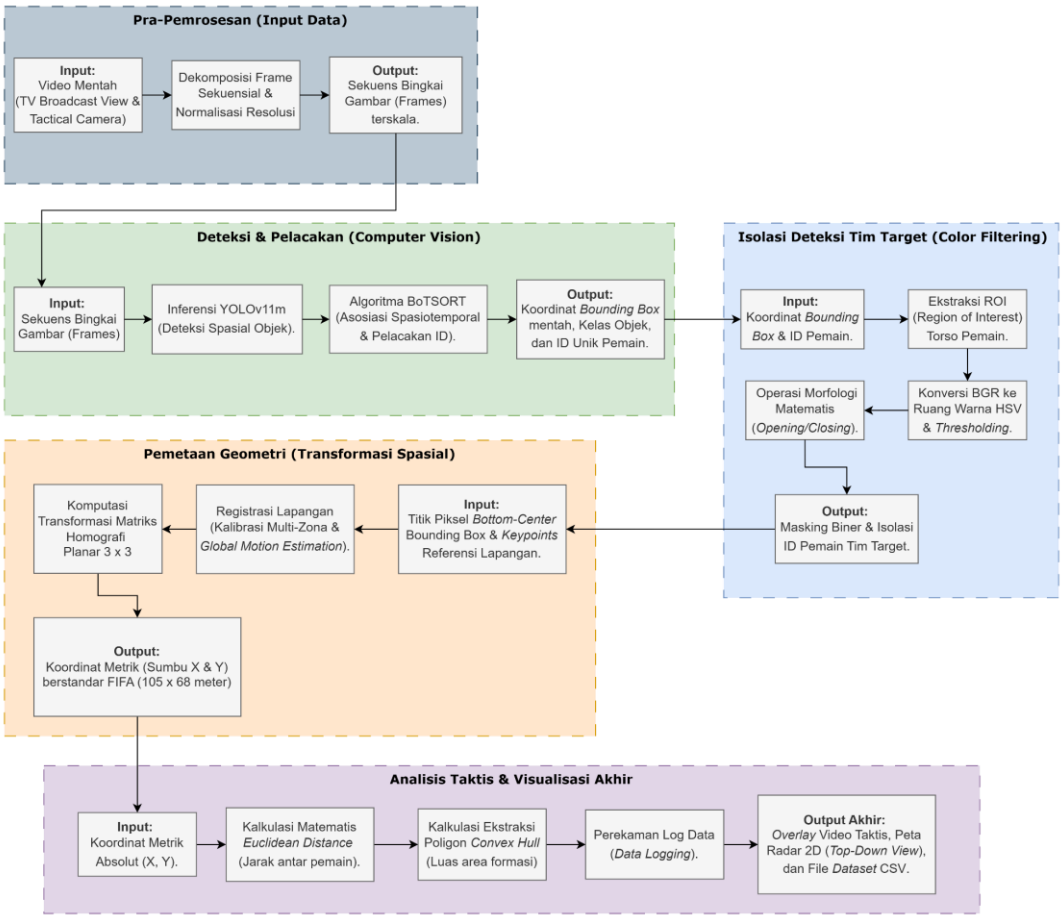
Akuisisi data latih (*training data*) sangat menentukan performa pengenalan model saat proses transfer pembelajaran (*transfer learning*) dilakukan guna mengatasi keterbatasan fitur pada data yang spesifik [18]. Penelitian ini memanfaatkan dataset publik "soccer-players" dari Roboflow [19] yang memuat 10.914 citra teranotasi dengan resolusi 640x640 piksel. Untuk pembuatan *Ground Truth* pada tahap evaluasi pelacakan, dilakukan proses anotasi manual *frame-by-frame* menggunakan perangkat lunak *Computer Vision Annotation Tool* (CVAT) berformat MOT1.1 yang lazim digunakan pada standar keilmuan riset pelacakan multi-objek [20]. *Fine-tuning* diimplementasikan pada arsitektur YOLOv11m. Parameter hiper (*hyperparameters*) pelatihan ditetapkan dengan batas iterasi maksimal 50 epochs, resolusi masukan 640x640 piksel, dan batch size 16. Beban komputasi model ini mencapai 67.7 GFLOPs dengan total parameter 20.033.116, memberikan keseimbangan optimal antara kecepatan dan retensi fitur objek berskala kecil (*small object detection*).



Gambar 2. Contoh Frame Anotasi Manual CVAT dan Contoh Frame Dataset Roboflow

2.5. Arsitektur dan Alur Kerja Sistem

Sistem analitik yang dibangun beroperasi secara sekuensial (*system pipeline*). Arsitektur komputasi ini terbagi menjadi tahapan deteksi objek, pelacakan identitas, isolasi tim, transformasi spasial, dan ekstraksi metrik taktis yang secara rinci diilustrasikan pada Gambar 3.



Gambar 3. Arsitektur Sistem (*Pipeline System*)

2.6. Pelacakan Multi-Objek (MOT)

Keluaran *bounding box* dari YOLOv11m diumpankan ke algoritma pelacakan BoTSORT [21]. BoTSORT dipilih karena kemampuannya memadukan estimasi gerak Filter Kalman dan fitur *Camera Motion Compensation* (CMC). Algoritma ini memodifikasi vektor status konvensional menjadi representasi langsung dari koordinat pusat, lebar, dan tinggi untuk meredam oklusi. Fusi metrik spasial *Intersection over Union* (IoU) dan jarak kosinus visual (Re-ID) digunakan untuk meminimalisasi pertukaran identitas (*ID Switch*) pemain.

2.7. Isolasi Tim Berbasis Ruang Warna dan Morfologi

Pemain dari tim target diisolasi menggunakan filter ruang warna Hue, Saturation, Value (HSV). *Region of Interest* (ROI) dipusatkan pada area torso (20%-80% dari dimensi *bounding box*) untuk menganalisis dominasi warna jersey. Operasi morfologi matematis (*Opening* dan *Closing*) diaplikasikan dengan kernel elips 3 x 3 untuk mengeliminasi derau pantulan cahaya, sebuah teknik prapemrosesan yang terbukti krusial dalam mempertajam stabilitas klasifikasi piksel [22]. Keandalan ini diperkuat dengan logika memori temporal (batas toleransi 3-6 frame gagal) untuk menjaga stabilitas ID saat oklusi ekstrem terjadi.

2.8. Transformasi Spasial (Homografi dan GME)

Konversi dari ruang piksel 2D kamera yang terdistorsi menjadi koordinat metrik lapangan absolut (105m x 68m) dilakukan melalui Matriks Homografi Planar. Secara matematis, pemetaan dari koordinat layar (x, y) ke koordinat absolut (x', y') direpresentasikan oleh matriks 3 x 3 berderajat kebebasan 8 sebagai berikut:

$$s\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (1)$$

Di mana matriks di atas diturunkan menggunakan algoritma *Random Sample Consensus* (RANSAC) untuk meminimalisasi proyeksi titik-titik *outlier* yang menyimpang [23]. Sementara pada skenario kamera dinamis (Bayern Munchen), sistem mengimplementasikan *Global Motion Estimation* (GME). GME memadukan ekstraksi fitur sudut Shi-Tomasi dan Lucas-Kanade *Optical Flow* untuk melacak pergeseran tekstur lapangan antar frame. Koreksi matriks ini disegmentasi menjadi tiga zona kalibrasi (Kiri, Tengah, Kanan) secara adaptif, memungkinkan penyesuaian perspektif instan tanpa merusak ID pelacakan pemain.

2.9. Ekstraksi Metrik Taktis dan Perekaman Data

Setelah titik pijakan ditranslasikan ke skala nyata (meter), kerapatan pertahanan dihitung menggunakan Jarak Euclidean (*player dyads*) antara pemain target p dan q:

$$d(p,q) = \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2} \quad (2)$$

Selain jarak linear, luas formasi tim secara makro diukur dengan algoritma *Convex Hull*, di mana metrik poligon area ini secara metodologis lazim dimanfaatkan untuk mengevaluasi skala organisasi taktis tim secara utuh [24].

3. Hasil dan Pembahasan

3.1. Kinerja Model Deteksi Objek

Optimalisasi jaringan saraf tiruan YOLOv11m dieksekusi dengan *hyperparameter* khusus dan menunjukkan tingkat konvergensi galat (*loss*) yang sangat sehat. Pemilihan varian YOLOv11m dilandasi oleh uji banding kuantitatif lintas generasi untuk menemukan efisiensi tertinggi; membandingkannya mulai dari arsitektur klasik pada literatur terdahulu [25] hingga iterasi mutakhir saat ini [26].

Tabel 2. Konfigurasi Hyperparameter Pelatihan YOLOv11m

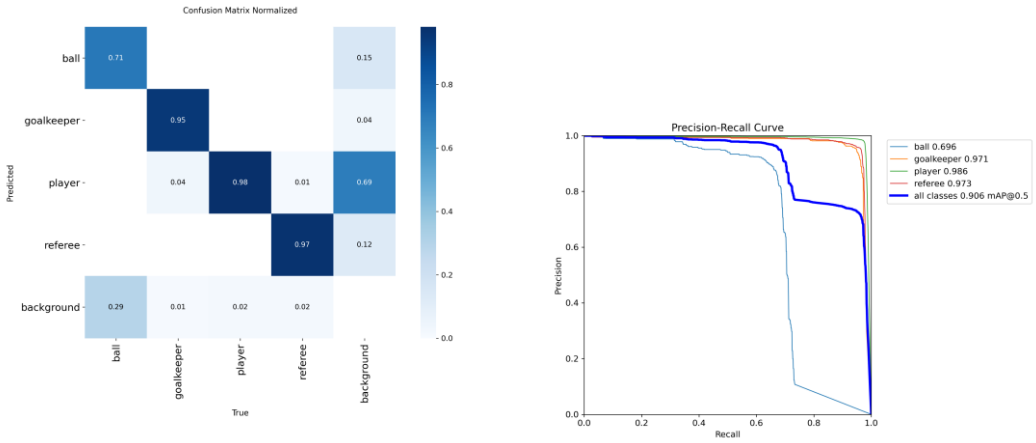
Parameter Konfigurasi	Nilai	Deskripsi Fungsional
Arsitektur Model	YOLOv11m (Medium)	Model dasar dengan inisialisasi bobot pra-latih
Resolusi Masukan (imgsz)	640 x 640 piksel	Dimensi masukan standar
Ukuran Batch	16	Jumlah citra per iterasi
Siklus (Epochs)	50	Batas maksimal perulangan
Beban Komputasi	67.7 GFLOPs	Indikator kompleksitas operasi matematis

Tabel 3. Komparasi Pelatihan Berbagai Generasi Model YOLO

Arsitektur Model	Precision (P)	Recall (R)	mAP50	mAP50-95	GFLOPs
YOLOv5mu	0.936	0.889	0.900	0.589	64.0
YOLOv8n	0.910	0.845	0.868	0.544	8.1
YOLOv8m	0.921	0.889	0.901	0.588	78.7
YOLOv9m	0.934	0.883	0.901	0.591	76.5
YOLOv11m	0.939	0.888	0.906	0.603	67.7

Berdasarkan komparasi, YOLOv11m mampu melampaui performa seluruh pendahulunya dengan akurasi agregat tertinggi (Presisi 0.939), sekaligus berhasil menekan beban komputasi menjadi lebih ringan dibandingkan YOLOv8m dan YOLOv9m. Secara khusus untuk deteksi kelas pemain, model mencapai nilai mAP50 yang nyaris sempurna di angka 0.986. Tingkat kepresisian (*bounding box*

tightness) yang sangat tinggi ini menjamin keandalan ekstraksi tumpuan kaki pemain untuk dikonversi menjadi matriks homografi.



Gambar 4. ***Confusion Matrix*** **dan** ***PR Curve***

3.2. Evaluasi Pelacakan dan Signifikansi Transfer Learning

Evaluasi pelacakan dilakukan dengan membandingkan prediksi keluaran BoTSORT terhadap kebenaran dasar (*Ground Truth*) CVAT. Sistem berhasil mencatatkan Akurasi Pelacakan Multi-Objek (MOTA) sebesar 89.78% dengan meminimalkan kesalahan pergantian identitas (*ID Switches*) menjadi hanya 25 kejadian di tengah penumpukan area penalti. Tahapan pelacakan memvalidasi keputusan penggunaan BoTSORT melalui komparasi langsung terhadap algoritma ByteTrack, yang pada dasarnya berfokus pada pengaitan setiap kotak deteksi berskor kepercayaan rendah [27], dan DeepSORT. BoTSORT mendemonstrasikan stabilitas tertinggi dan ketahanan dari derau spasial dengan menekan *False Positives* (FP) hingga ke angka 87 kejadian, jauh melampaui DeepSORT yang mengalami pembengkakan deteksi palsu hingga 503 kejadian akibat kerentanannya terhadap *panning* kamera.

Tabel 4. Hasil Komparasi Metrik Pelacakan BoTSORT terhadap *Ground Truth*

MOTA	MOTP	IDF1	ID Switches	False Positives	False Negatives
89.78%	20.68%	79.15%	25	87	508

Tabel 5. Komparasi Kinerja Algoritma Pelacakan

Algoritma	MOTA	ID Switches	False Positives	False Negatives
BoTSORT	89.78%	25	87	508
ByteTrack	89.59%	25	85	521
DeepSORT	86.43%	21	503	299

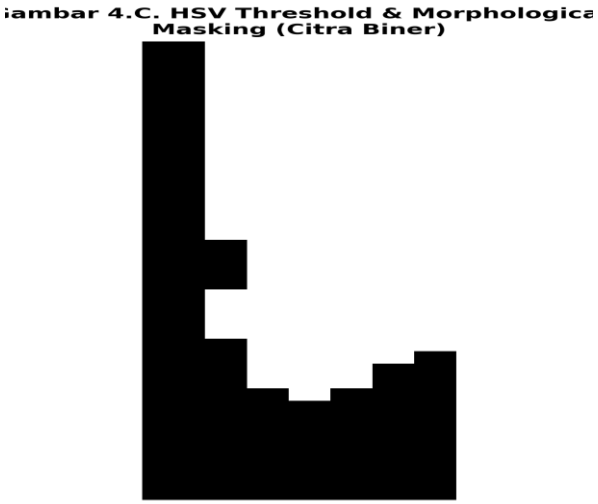
Lebih lanjut, eksperimen mengonfirmasi urgensi *fine-tuning* dataset olahraga. Penggunaan model YOLOv11 bawaan (Base) menghasilkan 1.455 *False Negatives* (FN). Model yang di-*fine-tuning* terbukti merestorasi 947 deteksi pada pemain target berskala ekstra kecil (menekan FN menjadi 508), yang meroketkan integritas analitik struktural pertahanan dari MOTA 75.40% menjadi 89.78%.

Tabel 6. Komparasi Kinerja Pelacakan YOLOv11 Base vs Fine-Tuned

Detektor	MOTA	MOTP	IDF1	ID Switches	False Positives	False Negatives
YOLOv11 Base	75.40%	12.20%	74.31%	19	18	1455
YOLOv11 Fine-Tuned	89.78%	20.68%	79.15%	25	87	508

3.3. Isolasi Tim Target Berbasis Ruang Warna dan Morfologi

Setelah algoritma pelacakan BoTSORT menyematkan identitas numerik (ID), sistem melakukan segmentasi visual untuk mengisolasi pemain target. Proses ini diawali dengan pemotongan *Region of Interest* (ROI) sebesar 20% hingga 70% pada sumbu-Y dan 20% hingga 80% pada sumbu-X dari dimensi *bounding box* asli. Pemotongan ini secara matematis memusatkan area komputasi murni pada bagian torso (dada) pemain. Citra ROI dikonversi ke format HSV. Untuk membersihkan hasil masking dari derau pantulan cahaya dan menyatukan piksel yang terputus, sistem mengimplementasikan operasi morfologi citra.

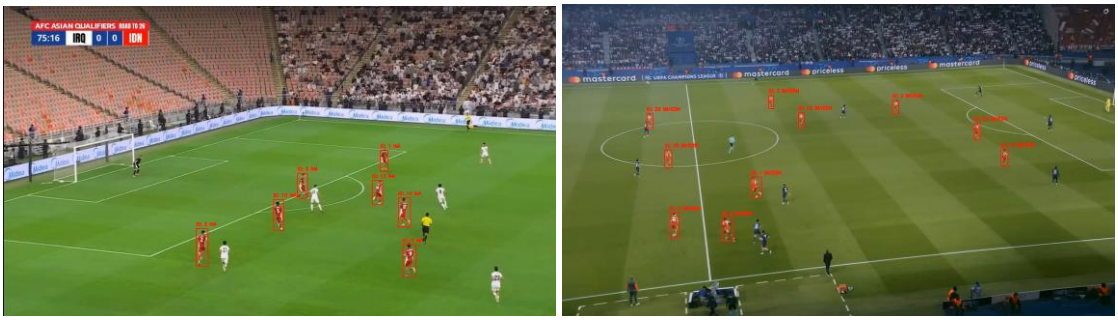


Gambar 5. Hasil Masking Biner Setelah Operasi Morfologi

Guna menekan kesalahan identifikasi akibat oklusi dinamis, filter HSV diperkuat oleh algoritma Logika Voting Awal dan Re-verifikasi Temporal. Hasil komputasi akhir membuktikan bahwa pemfilteran spasial yang dipadukan dengan memori temporal ini bekerja sangat akurat. Seluruh pemain berjersey merah berhasil dilabeli dengan ID secara persisten, sementara pemain lawan (putih/gelap) dan perangkat pertandingan berhasil diabaikan. Performa identik juga dibuktikan pada Skenario Bayern Munchen, di mana sistem mampu mengisolasi entitas target secara sempurna meskipun objek pemain berskala sangat kecil (*small objects*).

Tabel 7. Hyperparameter Pemfilteran Warna dan Logika Memori

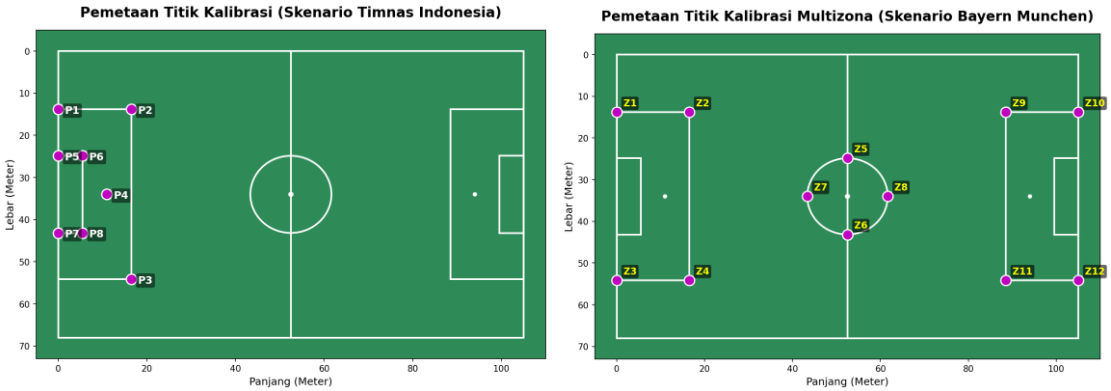
Parameter Tuning	Skenario Timnas Indonesia (Statik)	Skenario Bayern Munchen (Dinamis)
Batas Bawah HSV (Merah 1 & 2)	[0, 50, 25] & [160, 50, 25]	[0, 40, 15] & [160, 40, 15]
Threshold Rasio Piksel Merah	> 0.15 (15%)	> 0.05 (5%)
Syarat *Voting* (*Fast Confirm*)	10 Frame	10 Frame
Interval Re-verifikasi	15 Frame	5 Frame
Toleransi Maksimal Gagal (*Revoke*)	3 kali berturut-turut	3 kali berturut-turut



Gambar 6. Hasil Akhir Isolasi Tim Target pada Skenario Timnas dan Skenario Tim Bayern

3.4. Akurasi Transformasi Geometri dan Metrik Jarak

Untuk menjamin proyeksi parameter taktis valid secara dunia nyata, akurasi matriks homografi diuji menggunakan komparasi fisis langsung (jarak metrik dalam meter). Deviasi kuantitatif dievaluasi menggunakan *Mean Absolute Percentage Error* (MAPE) melintasi 15 sampel frame krusial.



Gambar 7. Proyeksi 8 Titik Kalibrasi Statis dan Multizona Dinamis

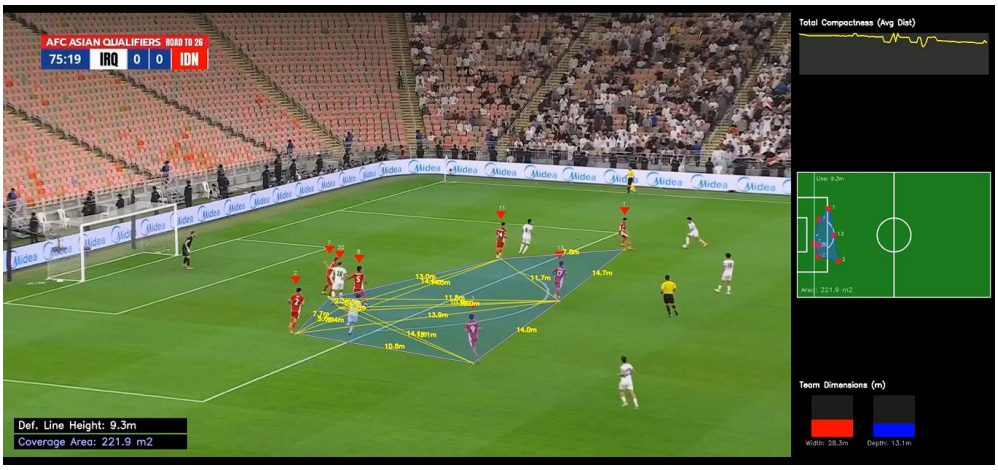
Pada Skenario Timnas Indonesia (kamera statis), tingkat galat jarak absolut mampu ditekan hingga ke presisi optimal 11.61% saat formasi bertahan terkumpul rapat persis di dalam zona jangkar kotak penalti. Pada Skenario Bayern Munchen (kamera dinamis), *Global Motion Estimation* terbukti sanggup mengakomodasi pergerakan *panning* panjang dengan mempertahankan tingkat MAPE di kisaran 7.93% - 10.79%. Namun, keterbatasan alami kalkulasi pergeseran optik tanpa fitur deteksi titik (*keypoint*) terkuak saat kamera bermanuver sangat tajam dan tak terprediksi [28]; pergeseran ekstrem ini memicu efek distorsi hingga menyebabkan proyeksi jarak melonjak drastis ke persentase galat 40.94%. Meskipun demikian, algoritma kalibrasi multizona membuktikan ketangguhannya dengan memulihkan metrik kembali ke presisi 10.42% kurang dari satu detik pasca-turbulensi kamera.

3.5. Evaluasi Kinerja Pemrosesan (Frame Per Second)

Kemampuan pemrosesan waktu-nyata (*real-time*) diuji sebagai fondasi kelayakan implementasi aplikasi analitik olahraga. Skenario Timnas mencatatkan kecepatan inferensi 5,35 FPS. Secara tak terduga, Skenario Bayern Munchen memproses frame lebih efisien pada rata-rata 6,22 FPS. Akselerasi ini diraih dengan menonaktifkan *field masking* pada ruang warna latar belakang dan merenggangkan interval pembaruan *Optical Flow* (koreksi setiap 3 frame). Hal ini membuktikan bahwa optimasi pipeline dapat mencegah kelebihan beban komputasi grafis.

3.6. Representasi Visual, Akurasi Geometri, dan Implikasi Taktis

Luaran akhir sistem merender metrik spasial secara *real-time* ke dalam Antarmuka Pengguna Grafis (GUI). Visualisasi ini menampilkan garis koneksi *dyads* (kuning) untuk jarak mikro, poligon *Convex Hull* (biru) untuk memetakan luas formasi pertahanan, serta Peta Radar 2D metrik yang dilengkapi grafik tren kerapatan tim.

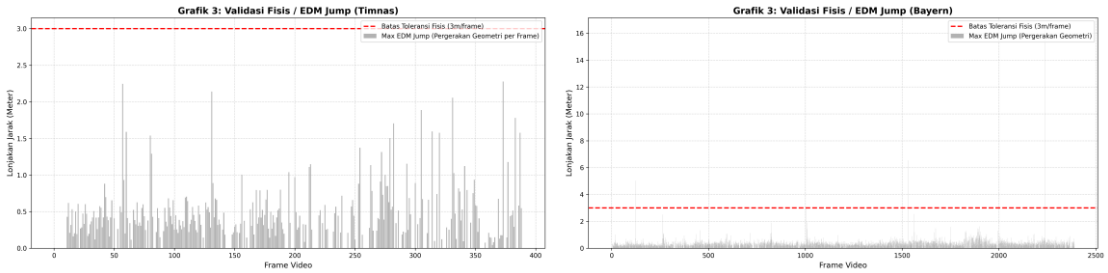


Gambar 8. Hasil Visualisasi Akhir GUI Skenario Timnas Indonesia (Kamera Statis, Low Block)

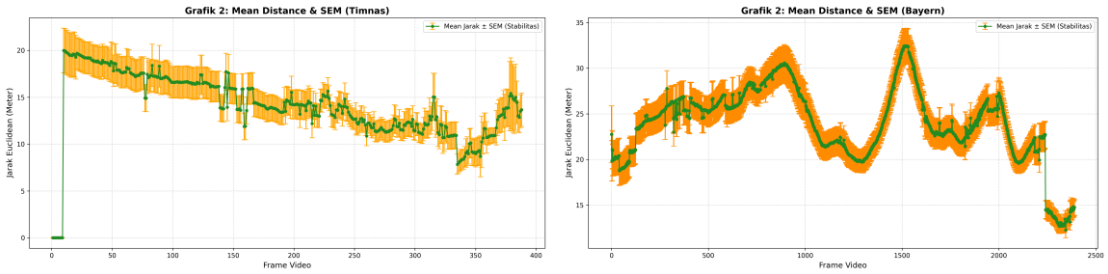


Gambar 9. Hasil Visualisasi Akhir GUI Skenario Bayern Munchen (Kamera Dinamis, High Line)

Untuk menjamin proyeksi parameter taktis valid secara dunia nyata, selain menggunakan komparasi fisis MAPE, sistem juga memvalidasi fluktuasi metrik jarak melalui hukum kinematika fisis (Max EDM Jump). Sebagaimana ditunjukkan grafik distribusi EDM, fluktuasi pergerakan spasial terbukti konsisten beroperasi di bawah ambang batas toleransi biomekanika manusia (lonjakan < 3.0 meter per frame), karena lonjakan tidak rasional secara nyata menyalahi referensi nilai perilaku lari manusia dalam sepak bola [29]. Uji statistik *Standard Error of the Mean* (SEM) mengonfirmasi signifikansinya dengan rentang *error bars* yang sangat kecil, memberikan justifikasi ilmiah absolut bahwa pergeseran metrik jarak yang direkam sistem murni merepresentasikan interaksi dinamika taktis.



Gambar 10. Grafik Distribusi Max EDM Jump per Frame dengan Garis Merah 3.0 m



Gambar 11. Grafik Fluktuasi Rata-rata Kerapatan Tim dengan Error Bars SEM

Interpretasi data komputasi ini memberikan implikasi taktis masif. Pada Skenario Timnas, sistem membuktikan kedisiplinan organisasi *Low Block*. Area *Convex Hull* menyusut sangat rapat hingga rata-rata 215,6 m², dengan kompresi horizontal ekstrem antar *dyads* sebesar 6,53 meter, membuktikan bahwa pemain sukses memblokade ruang *half-space*. Sebaliknya, pada Skenario Bayern, taktik *High Defensive Line* menuntut wilayah operasional seluas 951,61 m² dengan peregangan jarak *dyads* rata-rata 24,59 meter. Dalam penerapan strategi, data spasiotemporal ini dapat digunakan oleh analis tim secara instan. Jika log data menampilkan jarak *dyads* antarpemain bertahan melebar melebihi batas toleransi 15 meter, pelatih dapat langsung memberikan instruksi objektif kepada pemain bersangkutan untuk merapatkan posisi, mengeliminasi perdebatan subjektif mengenai kesalahan penempatan posisi (*positioning*).

4. Kesimpulan

Penelitian ini telah berhasil mengembangkan sistem analitik spasiotemporal otomatis berbasis *Computer Vision* yang menjawab urgensi evaluasi taktik sepak bola secara objektif. Melalui integrasi arsitektur deteksi YOLOv11m yang di-*fine-tuning* (mAP50 0,986) dan algoritma pelacakan BoTSORT, sistem ini terbukti andal mempertahankan konsistensi identitas pemain di area padat oklusi dengan tingkat akurasi pelacakan (MOTA) mencapai 89,78% dan hanya mencatatkan 25 ID Switches. Konversi koordinat menggunakan Transformasi Homografi dan *Global Motion Estimation* juga tervalidasi secara fisis dengan tingkat galat jarak yang rendah pada pengamatan statis (MAPE 7,93% hingga 11,61%). Capaian ini memberikan kontribusi besar pada bidang *Sports Analytics* dengan menyediakan ekstraksi matriks numerik luas *Convex Hull* dan jarak *dyads* yang *actionable* bagi pelatih. Meskipun demikian, sistem ini masih memiliki keterbatasan saat menghadapi perubahan kamera ekstrem (*abrupt panning*) dan belum mencapai kecepatan operasional *real-time* langsung (saat ini 6,22 FPS). Oleh karena itu, penelitian selanjutnya direkomendasikan untuk menerapkan deteksi *keypoint* lapangan dan postur tubuh pemain (*pose estimation*) secara otomatis, misalnya mengadopsi kerangka kerja komputasi spasial seperti OpenPose [30], untuk menjaga stabilitas kalibrasi dan mengatasi kendala oklusi parah, serta mengoptimasi model ke format TensorRT guna mencapai kapabilitas *real-time processing*.

Daftar Pustaka

[1] L. Forcher, L. Forcher, S. Altmann, D. Jekauc, and M. Kempe, "Is a compact organization important for defensive success in elite soccer? – Analysis based on player tracking data," *Int. J. Sports Sci. Coach.*, vol. 19, no. 2, pp. 757–768, Apr. 2024, doi: 10.1177/17479541231172695.

[2] H. F. Wibowo and D. Nugroho, "JOSSAE (Journal of Sport Science and Education) Analisis Momen Pola Menyerang, Bertahan dan Transisi pada Timnas Indonesia U-19 Vs Bulgaria," *Journal of Sport Science and Education)*, vol. 6, no. 1, p. 57, 2021, doi: 10.26740/j.

[3] F. G. Caetano, V. P. Da Silva, R. D. S. Torres, R. D. O. Anido, S. A. Cunha, and F. A. Moura, "Analysis of Match Dynamics of Different Soccer Competition Levels Based on the Player Dyads," *J. Hum. Kinet.*, vol. 70, no. 1, pp. 173–182, Nov. 2019, doi: 10.2478/hukin-2019-0030.

[4] B. Jin, "Video analysis and data-driven tactical optimization of sports football matches: Visual recognition and strategy analysis algorithm," *Journal of Autonomous Intelligence*, vol. 7, no. 5, p. 1581, Mar. 2024, doi: 10.32629/jai.v7i5.1581.

[5] F. Denis and A. Steinmaier, "Real-Time Offside Detection in Football Using Computer Vision and Artificial Intelligence Techniques," 2024.

[6] F. Öberg, "Football analysis using machine learning and computer vision," Master's Thesis, Linköping University, 2021.

[7] P. P. Dharnamoni, K. N. Sri, K. Pradnya, and Dr. D. Shravani, "Real-Time Football Match Analysis Using Deep Learning," *International Journal of Multidisciplinary Research and Growth Evaluation*, vol. 6, no. 2, pp. 710–715, 2025, doi: 10.54660/.ijmrge.2025.6.2.710-715.

[8] P. S. S. Markappa, C. Oleary, and C. Lynch, "A Review of YOLO Models for Soccer-Based Object Detection," in *6th International Conference on Intelligent Computing in Data Sciences, ICDS 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ICDS62089.2024.10756443.

[9] K. Rangasamy, M. A. As'ari, N. A. Rahmad, N. F. Ghazali, and S. Ismail, "Deep learning in sport video analysis: A review," *Telkomnika (Telecommunication Computing Electronics and Control)*, vol. 18, no. 4, pp. 1926–1933, 2020, doi: 10.12928/TELKOMNIKA.V18I4.14730.

[10] R. Khanam and M. Hussain, "YOLOv11: An Overview of the Key Architectural Enhancements," Oct. 2024, [Online]. Available: http://arxiv.org/abs/2410.17725

[11] J. Agrawal, R. Maheshwari, S. Nalode, Y. Prabhat, P. Sonsare, and K. Khurana, "Football Player Detection and Tracking Using Deep Learning Approach," in *2024 International Conference on Artificial Intelligence and Quantum Computation-Based Sensor Applications, ICAIQSA 2024 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ICAIQSA64000.2024.10882213.

[12] M. R. Hartono, C. A. Sari, and R. R. Ali, "FOOTBALL PLAYER TRACKING, TEAM ASSIGNMENT, AND SPEED ESTIMATION USING YOLOV5 AND OPTICAL FLOW," *Jurnal Teknik Informatika (Jutif)*, vol. 6, no. 1, pp. 51–62, Feb. 2025, doi: 10.52436/1.jutif.2025.6.1.4165.

[13] J. Joshan Athanesious and S. Kiruthika, "Perspective Transform Based YOLO With Weighted Intersect Fusion for Forecasting the Possession Sequence of the Live Football Game," *IEEE Access*, vol. 12, pp. 75542–75558, 2024, doi: 10.1109/ACCESS.2024.3402370.

[14] K. Kausalya, K. S. Raja S, and S. Sudha, "An optimized deep learning approach for detection and classification of player actions in football game," *Entertain. Comput.*, vol. 55, Sep. 2025, doi: 10.1016/j.entcom.2025.101003.

[15] B. Low, D. Coutinho, B. Gonçalves, R. Rein, D. Memmert, and J. Sampaio, "A Systematic Review of Collective Tactical Behaviours in Football Using Positional Data," Feb. 01, 2020, *Springer*. doi: 10.1007/s40279-019-01194-7.

[16] V. R. Chaganti, M. Mann, R. P. Badoni, and S. B. Mandyam, "Advanced Computer Vision Techniques for Football Match Analysis: Detection, Team Assignment, and Player Tracking," in *International Conference on Artificial Intelligence and Emerging Technologies, ICAIET 2025*, Institute of Electrical and Electronics Engineers Inc., 2025. doi: 10.1109/ICAIET65052.2025.11211437.

[17] S. Raschka, J. Patterson, and C. Nolet, "Machine learning in python: Main developments and technology trends in data science, machine learning, and artificial intelligence," Apr. 01, 2020, *MDPI AG*. doi: 10.3390/info11040193.

[18] F. Zhuang *et al.*, "A Comprehensive Survey on Transfer Learning," Jan. 01, 2021, *Institute of Electrical and Electronics Engineers Inc.* doi: 10.1109/JPROC.2020.3004555.

[19] soccer players, "soccer players Dataset," Roboflow Universe, 2024. [Online].

[20] M. Adžemović, "Deep Learning-Based Multi-Object Tracking: A Comprehensive Survey from Foundations to State-of-the-Art," Jun. 2025, [Online]. Available: http://arxiv.org/abs/2506.13457

[21] N. Aharon, R. Orfaig, and B.-Z. Bobrovsky, "BoT-SORT: Robust Associations Multi-Pedestrian Tracking," Jul. 2022, [Online]. Available: http://arxiv.org/abs/2206.14651

[22] O. Lantang, G. Terdik, A. Hajdu, and A. Tiba, "Investigation of the efficiency of an interconnected convolutional neural network by classifying medical images," *Annales Mathematicae et Informaticae*, vol. 53, pp. 219–234, 2021, doi: 10.33039/ami.2021.04.001.

[23] Q. Cheng, Z. Zhifeng, Y. Ke, T. Zhang, and J. I. Guotai, "Homography matrix estimation method based on adaptive genetic algorithm," vol. 16, 2025, [Online]. Available: http://jmsi.publish.founderss.cn

[24] M. J. de O. Bueno, M. Silva, S. A. Cunha, R. da S. Torres, and F. A. Moura, "Multiscale fractal dimension applied to tactical analysis in football: A novel approach to evaluate the shapes of team organization on the pitch," *PLoS One*, vol. 16, no. 9 September, Sep. 2021, doi: 10.1371/journal.pone.0256771.

[25] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," May 2016, [Online]. Available: http://arxiv.org/abs/1506.02640

[26] A. A. Murat and M. S. Kiran, "A comprehensive review on YOLO versions for object detection," Oct. 01, 2025, *Elsevier B.V*. doi: 10.1016/j.jestch.2025.102161.

[27] Y. Zhang *et al*., "ByteTrack: Multi-Object Tracking by Associating Every Detection Box." [Online]. Available: https://github.com/ifzhang/ByteTrack.

[28] H.-Q. Chen, C.-C. Liao, Y.-H. Sun, C.-K. Lin, and Y.-C. Tseng, "FieldMOT: A Field-Registered Multi-Object Tracking for Sports Videos." [Online]. Available: https://github.com/maomao726/FieldTrack.

[29] M. Rico-González, J. Pino-Ortega, J. Castellano, J. M. Oliva-Lozano, and A. L. Arcos, "Reference values for collective tactical behaviours based on positional data in professional football matches: A systematic review," 2022, *Institute of Sport*. doi: 10.5114/biolsport.2021.102921.

[30] Z. Cao, G. Hidalgo, T. Simon, S. E. Wei, and Y. Sheikh, "OpenPose: Realtime Multi-Person 2D Pose Estimation Using Part Affinity Fields," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 43, no. 1, pp. 172–186, Jan. 2021, doi: 10.1109/TPAMI.2019.2929257.