

BAB 2 LANDASAN TEORI

2.1 Bisbol

Bisbol merupakan sebuah permainan olahraga beregu yang dimainkan oleh dua tim, di mana masing-masing tim terdiri dari sembilan pemain utama yang beroperasi di lapangan tertutup bawah yurisdiksi satu atau lebih wasit (*umpire*). Tujuan utama dari tim penyerang (*offense*) adalah menjadikan pemukulnya sebagai pelari (*runner*) dan memajukan pelari tersebut mengelilingi rangkaian empat marka (*bases*). Sebaliknya, tim bertahan (*defense*) memiliki objektif untuk mencegah pemain lawan menjadi pelari serta menghentikan kemajuan mereka di sepanjang marka tersebut. Skor atau poin (*run*) dihasilkan ketika seorang pelari berhasil menyentuh semua marka secara legal mulai dari marka pertama, kedua, ketiga, dan kembali ke marka utama (*home base*) sebelum tiga mati (*outs*) tercapai untuk mengakhiri paruh babak (*inning*) tersebut [22].

Dalam dinamika permainan, setiap pemain bertahan memiliki peran spesifik berdasarkan posisinya di lapangan, yang secara garis besar terbagi menjadi pemain lapangan dalam (*infielder*), pemain lapangan luar (*outfielder*), dan baterai (*battery*). Unit baterai terdiri dari penangkap (*catcher*) yang berposisi di belakang marka utama dan pelempar (*pitcher*) yang bertugas mengirimkan bola ke arah pemukul. Pelempar (*pitcher*) merupakan poros utama pertahanan yang memulai setiap permainan dengan mengirimkan bola menggunakan mekanisme lemparan (*pitch*) dari atas papan pelempar (*pitcher's plate*) menuju zona pemukul (*strike zone*) [22].

Penelitian ini memfokuskan analisis secara eksklusif pada peran pelempar (*pitcher*). Fokus tersebut didasarkan pada fakta bahwa pelempar memiliki beban kerja biomekanik yang paling intens dibandingkan posisi lainnya di lapangan. Mekanisme lemparan yang dilakukan secara repetitif dengan kecepatan dan rotasi tinggi menciptakan stres valgus yang ekstrem pada sendi siku. Akumulasi dari beban kerja ini secara langsung menempatkan pelempar pada risiko tinggi mengalami degradasi jaringan lunak, khususnya cedera pada *Ulnar Collateral Ligament* (UCL), yang memerlukan intervensi bedah rekonstruktif *Tommy John Surgery* untuk pemulihannya.

2.2 Cedera *Ulnar Collateral Ligament* (UCL) pada *Pitcher*

Ulnar Collateral Ligament (UCL) merupakan struktur utama yang menjaga stabilitas sisi medial siku terhadap gaya valgus selama gerakan melempar. UCL terdiri atas tiga bundel, yaitu *anterior*, *posterior*, dan *oblique*, di mana bundel *anterior* berperan paling penting dalam mempertahankan kestabilan saat fase percepatan *pitching* [23]. Bundel ini mulai pada *medial epicondyle humerus* dan berinsersi pada *sublime tubercle ulna*, membentuk jaringan kolagen padat yang menahan peregangan berulang akibat gerakan *pitching* kecepatan tinggi.

Selain stabilisator statis seperti UCL, sisi medial siku juga diperkuat oleh stabilisator dinamis yang terdiri atas otot *flexor-pronator mass*, termasuk *flexor carpi ulnaris* (FCU) dan *flexor digitorum superficialis* (FDS). Aktivasi kedua otot ini membantu menurunkan beban pada UCL selama fase akselerasi, khususnya pada sudut fleksi 30°–60°, sehingga berperan sebagai kompensasi terhadap tekanan valgus yang tinggi [23].

Cedera UCL pada *pitcher* umumnya disebabkan oleh kombinasi gaya valgus dan gaya geser ekstrem yang terjadi berulang kali pada fase *late cocking* hingga *acceleration*. Kondisi ini dikenal sebagai *Valgus Extension Overload* (VEO), yaitu ketika rotasi internal bahu dan ekstensi siku menghasilkan tekanan maksimum pada sisi medial siku [24]. Beban torsi yang tinggi pada fase ini menimbulkan mikrotrauma kumulatif pada bundel *anterior* UCL, yang seiring waktu dapat berkembang menjadi cedera parsial atau total.

Dalam konteks *pitching* modern, tekanan ini diperburuk oleh peningkatan kecepatan lemparan (*velocity*) dan rotasi bola (*spin rate*), dua faktor biomekanik yang terbukti meningkatkan stres pada jaringan ligamentum. Pemahaman mengenai anatomi dan biomekanika cedera ini menjadi landasan bagi penelitian ini, karena variasi halus dalam parameter biomekanik seperti *release speed*, *extension*, dan *release position* yang terekam oleh sistem *Statcast* dapat merepresentasikan perubahan mekanis yang berpotensi menandakan risiko cedera UCL pada *pitcher* profesional.

2.3 Kinematika dan Biomekanika pada Gerakan *Pitching*

Gerakan melempar bola dalam bisbol merupakan aktivitas kompleks yang melibatkan koordinasi dinamis antara berbagai bagian tubuh, mulai dari tungkai bawah hingga lengan atas. Kinematika adalah studi pergerakan yang berfokus

pada deskripsi gerakan tubuh seperti kecepatan, percepatan, sudut, dan rotasi, tanpa mempertimbangkan gaya yang menyebabkannya, sedangkan biomekanika menelaah gaya internal dan eksternal yang bekerja pada struktur tubuh selama gerakan tersebut [25]. Dalam *pitching*, kedua studi ini saling berkaitan di mana kinematika menjelaskan bagaimana gerakan terjadi, sementara biomekanika menjelaskan mengapa pola tertentu dapat menimbulkan stres atau cedera.

Efisiensi mekanika lemparan bergantung pada urutan gerak berantai (*kinetic chain*) yang dimulai dari kaki, panggul, dan batang tubuh sebelum diteruskan ke bahu, lengan bawah, dan tangan. Rotasi batang tubuh yang terjadi terlalu dini dapat meningkatkan torsi internal pada sendi bahu, sedangkan rotasi yang terjadi secara optimal membantu mengurangi beban sendi tanpa menurunkan kecepatan bola [11]. Sinkronisasi antarsegmen tubuh merupakan faktor penting dalam menghasilkan kecepatan tinggi secara efisien sekaligus mengurangi beban berulang yang berpotensi menyebabkan cedera.

Faktor risiko cedera UCL sebagian besar muncul pada fase *late cocking* dan *acceleration*, ketika gaya valgus ekstrem dan torsi rotasi internal mencapai puncaknya. Peningkatan kecepatan bola serta rotasi eksternal bahu yang berlebihan terbukti meningkatkan tekanan pada ligamen kolateral ulnaris, yang berfungsi menahan gaya valgus pada siku [26]. Parameter biomekanik seperti torsi bahu, sudut rotasi batang tubuh, dan momen siku menjadi indikator penting untuk menilai risiko cedera, terutama pada pelempar dengan beban mekanis kumulatif tinggi.

Perubahan metrik pelacakan lemparan seperti kecepatan (*velocity*), laju putaran (*spin rate*), dan sudut pendekatan bola memiliki hubungan signifikan dengan kejadian cedera UCL [16]. Meskipun metrik tersebut bersifat kinematik secara definisi, variabel-variabel ini merupakan ekspresi terukur dari hasil biomekanik, yakni gaya dan torsi yang dihasilkan oleh sistem muskuloskeletal selama lemparan. Pemahaman integratif antara kinematika dan biomekanika diperlukan untuk mendeteksi serta memprediksi beban stres kumulatif yang dapat menyebabkan cedera pada pelempar.

Kombinasi analisis kinematik dan biomekanik memungkinkan penilaian kuantitatif terhadap efisiensi gerak dan risiko cedera. Penggunaan teknologi pelacakan modern seperti *Statcast* memungkinkan pengukuran parameter ini secara langsung dalam kondisi pertandingan, sehingga menjadi dasar bagi integrasi data berbasis sensor dan analisis visual dalam penelitian ini.

2.4 Sistem Pelacakan *Statcast*

Statcast merupakan sistem pelacakan optik berfrekuensi tinggi yang dikembangkan oleh *Major League Baseball (MLB) Advanced Media* dan diperkenalkan secara resmi pada tahun 2015. Sistem ini menggabungkan teknologi radar Doppler dan kamera stereoskopik untuk mengukur posisi, kecepatan, rotasi, serta lintasan bola dan pemain dalam tiga dimensi dengan presisi tinggi [14]. Tujuan utama *Statcast* adalah menyediakan data kuantitatif mengenai dinamika permainan secara *real-time*, termasuk pergerakan bola, kecepatan lemparan, jarak lari pemain, dan metrik pergerakan defensif [13].

Dalam konteks *pitching*, *Statcast* menghasilkan berbagai metrik kinematik yang menggambarkan karakteristik biomekanik setiap lemparan. Variabel utama yang digunakan dalam penelitian mencakup kecepatan pelepasan (*release speed*), laju putaran bola (*spin rate*), ekstensi (*extension*), posisi pelepasan (*release point*), dan pergerakan horizontal serta vertikal bola (*movement*). Parameter-parameter ini mencerminkan hasil akhir dari koordinasi biomekanik tubuh pelempar, sehingga dapat digunakan sebagai proksi untuk menilai efisiensi gerak dan potensi stres mekanis pada sendi [16].

Keunggulan *Statcast* dibandingkan sistem laboratorium konvensional seperti *motion capture* terletak pada kemampuannya untuk merekam data biomekanik dalam kondisi pertandingan yang sebenarnya. Hal ini memungkinkan analisis longitudinal terhadap ribuan lemparan dari setiap pemain tanpa perlu pengaturan eksperimental yang kompleks. Selain itu, data *Statcast* juga bersifat objektif, terstandarisasi di seluruh stadion MLB, dan tersedia secara publik melalui antarmuka data seperti *pybaseball*, yang memudahkan integrasi dengan kerangka analisis berbasis pembelajaran mesin (*machine learning*) [15].

Sejak tahun 2023, cakupan *Statcast* diperluas ke seluruh stadion *Triple-A (AAA)*, menjadikannya satu-satunya level *Minor League* dengan pelacakan penuh untuk seluruh tim. Ekspansi ini membuka peluang untuk penelitian lintas level kompetisi yang lebih representatif, sekaligus memperluas jumlah sampel pelempar dengan karakteristik mekanika yang beragam [20]. Integrasi data MLB dan AAA memperkuat validitas model prediksi dengan meningkatkan variasi individu dan stabilitas performa model [19].

Statcast tidak hanya berfungsi sebagai alat pengumpulan data, tetapi juga sebagai infrastruktur utama dalam ekosistem analitik modern MLB. Sistem ini memungkinkan eksplorasi hubungan antara perubahan mekanis, performa, dan

risiko cedera dengan tingkat resolusi yang belum pernah dicapai sebelumnya, menjadikannya fondasi penting bagi pendekatan pembelajaran mesin dan *multimodal* yang digunakan dalam penelitian ini.

2.5 Faktor Biometrik dan BMI dalam Beban Kerja Pitching

Berat badan, tinggi badan, dan *Body Mass Index* (BMI), memainkan peran dalam menentukan besarnya beban kinetik yang diterima oleh ekstremitas atas selama gerakan *pitching*. Peningkatan dimensi fisik tubuh secara signifikan berkorelasi dengan peningkatan torsi varus pada siku, yang merupakan beban mekanis utama yang harus ditahan oleh *ulnar collateral ligament* (UCL) untuk menjaga stabilitas sendi.

Berat badan diidentifikasi sebagai parameter antropometrik dengan kontribusi terkuat terhadap variansi torsi varus pada siku pelempar (*pitcher*) bisbol dewasa. Secara mekanis, pelempar dengan massa tubuh yang lebih besar menghasilkan beban torsi yang lebih tinggi selama fase *cocking* hingga sesaat sebelum rotasi internal bahu maksimal. Hal ini disebabkan oleh peningkatan properti inersia pada segmen-segmen tubuh, di mana massa segmen distal seperti lengan bawah memberikan pengaruh besar terhadap kebutuhan torsi varus untuk melawan beban valgus yang dihasilkan saat melempar. Kondisi ini menempatkan pelempar dengan berat badan lebih tinggi pada risiko cedera yang lebih besar karena mereka memberikan beban yang lebih berat pada jaringan yang tidak memiliki kapasitas kekuatan tambahan secara proporsional [27].

Selain pengaruh langsung terhadap torsi, BMI juga memengaruhi karakteristik fungsional pelempar melalui keterbatasan jangkauan gerak (*Range of Motion* atau ROM) dan akumulasi kelelahan. Peningkatan BMI sering kali dikaitkan dengan penurunan ROM pada sendi-sendi utama dalam rantai kinetik (*kinetic chain*), khususnya rotasi internal panggul baik pada sisi lempar (*throwing side*) maupun sisi sarung tangan (*glove side*). Keterbatasan ROM pada panggul ini dapat mengganggu mekanisme lemparan yang efisien, memaksa tubuh untuk melakukan kompensasi mekanis yang meningkatkan stres pada sendi bahu dan siku demi mempertahankan kecepatan lemparan maksimal.

Lebih lanjut, pelempar dengan BMI yang lebih tinggi cenderung lebih rentan terhadap kelelahan otot, yang dapat memperburuk degradasi mekanika selama sesi pertandingan yang panjang. *Strain* relatif yang lebih tinggi pada sistem muskuloskeletal selama tugas repetitif seperti *pitching* meningkatkan risiko

terjadinya cedera beban berlebih (*overuse injuries*). Oleh karena itu, BMI tidak hanya berfungsi sebagai indikator massa, tetapi juga sebagai variabel yang menentukan efisiensi biomekanik dan ketahanan fisik pelempar dalam menghadapi beban kerja *pitching* yang repetitif [28].

2.6 Logika Integrasi Data Lintas Liga (MLB dan AAA)

Integrasi data antara *Major League Baseball* (MLB) dan *Triple-A* (AAA) dilakukan untuk memperluas cakupan variasi mekanika pelempar dan meningkatkan kemampuan generalisasi model. Proses penggabungan ini didasarkan pada beberapa parameter teknis untuk menjaga konsistensi kualitas data:

A Kesetaraan Alat dan Metrik

Meskipun berasal dari level kompetisi yang berbeda, data kinematik diambil menggunakan sistem pelacakan optik *Statcast* yang identik.

1. Fitur-fitur yang tersedia pada level AAA, seperti *release speed*, *spin rate*, *extension*, dan koordinat pelepasan, memiliki struktur dan unit pengukuran yang sama dengan data MLB.
2. Pengambilan data kinematik dilakukan secara paralel untuk dua level kompetisi dengan metode ekstraksi yang berbeda namun tetap menghasilkan struktur data yang seragam.
 - (a) MLB: Data diekstraksi menggunakan fungsi `statcast` dari pustaka `pybaseball` yang mengakses langsung pangkalan data *Statcast* dari *Baseball Savant*.
 - (b) AAA: Mengingat keterbatasan akses data liga minor pada pustaka standar, pengambilan data AAA dilakukan menggunakan mesin kustom berbasis *Python* yang dikembangkan oleh Robert Frey. Metode ini memanfaatkan skrip *scraper* yang secara spesifik dirancang untuk menarik data *Statcast* level minor melalui repositori *GitHub* "*Minor League Statcast Data in Python*". Implementasi metode Frey memungkinkan penelitian ini untuk mendapatkan 25 kolom kinematik yang identik dengan standar MLB sejak ketersediaannya di tahun 2023 [29].

B Sinkronisasi Biometrik

Data kinematik dari *Statcast* disinkronkan secara real-time dengan data biometrik (tinggi badan, berat badan) melalui *MLB Stats API*. Hal ini memastikan bahwa fitur fisik seperti BMI dihitung dengan standar yang sama baik untuk pelempar MLB maupun AAA.

C Deviasi Biomekanik

Untuk mengatasi perbedaan intensitas performa antar liga, penelitian ini tidak menggunakan nilai absolut mentah sebagai *input* akhir.

1. Fitur akhir dihitung berdasarkan selisih (*difference*) antara metrik pertandingan saat ini terhadap rata-rata karier individu pelempar tersebut.
2. Pendekatan ini memungkinkan model untuk fokus pada anomali mekanis relatif terhadap standar performa masing-masing pemain, sehingga perbedaan *baseline* seperti kecepatan atau laju putaran bola antara pemain MLB dan AAA tidak menjadi bias dalam deteksi risiko cedera.

2.7 Vision Transformer (ViT)

Vision Transformer (ViT) adalah sebuah arsitektur *deep learning* yang mengadaptasi mekanisme *self-attention* dari model *Transformer*, yang awalnya dirancang untuk *Natural Language Processing* (NLP), ke domain *computer vision*. Berbeda dengan *Convolutional Neural Networks* (CNN) yang memproses data secara hierarkis melalui filter lokal, ViT membagi gambar *input* menjadi serangkaian *patch* (potongan gambar) berukuran tetap. Setiap *patch* ini kemudian di-"datarkan" (*flattened*) dan dipetakan ke dalam *embedding* dimensi-tetap, yang dikenal sebagai *patch embeddings*.

Positional embeddings ditambahkan ke *patch embeddings* ini untuk mempertahankan informasi lokasi spasial, karena arsitektur *self-attention* murni bersifat *permutation-invariant*. Rangkaian *patch* ini kemudian diproses oleh *Transformer encoder* standar. Mekanisme *self-attention* di dalam *encoder* memungkinkan model untuk menimbang hubungan antara semua *patch* secara bersamaan, memungkinkannya menangkap dependensi global dan konteks jangka panjang dalam data visual [30]. Tahapan proses bekerjanya model ViT diuraikan

secara detil berdasarkan landasan arsitektur yang sudah ditetapkan dalam makalah Dosovitsky et al. (2021), yang sebagai berikut:

A Dekomposisi *Patch* dan *Linear Projection*

Tahap pertama dalam proses ViT adalah membagi gambar *input* $x \in \mathbb{R}^{H \times W \times C}$ menjadi urutan *patch* 2D yang rata (*flattened*) $x_p \in \mathbb{R}^{N \times (P^2 \cdot C)}$.

1. H, W adalah resolusi gambar asli dan C adalah jumlah saluran (*channels*).
2. P, P adalah resolusi dari setiap *patch* gambar.
3. $N = HW/P^2$ adalah jumlah total *patch* yang dihasilkan, yang juga menjadi panjang urutan *input* bagi *Transformer*.

Setiap *patch* ini kemudian dipetakan ke dalam dimensi D yang konstan menggunakan sebuah proyeksi linear yang dapat dilatih, menghasilkan apa yang disebut sebagai *patch embeddings*.

B *Class Token* dan *Positional Embedding*

Untuk melakukan tugas klasifikasi, ViT menggunakan pendekatan standar dengan menyisipkan sebuah *learnable [class] token* ($z_0^0 = x_{class}$) di awal urutan *patch* yang telah di-embed. Status keluaran dari token ini pada lapisan terakhir berfungsi sebagai representasi gambar untuk klasifikasi.

Karena arsitektur *self-attention* murni bersifat *permutation-invariant* (tidak peka terhadap urutan), *positional embeddings* ditambahkan ke dalam *patch embeddings* untuk mempertahankan informasi lokasi spasial antar *patch* di dalam gambar. Persamaan untuk *input* awal ke dalam *encoder* adalah sebagai berikut:

Rumus 2.1 menunjukkan representasi *input* awal yang terdiri dari *class token*, *patch embeddings*, dan *positional embeddings*.

$$z_0 = [x_{class}; x_p^1 E; \dots; x_p^N E] + E_{pos} \quad (2.1)$$

C *Transformer Encoder*

Transformer Encoder terdiri dari lapisan-lapisan yang berulang, di mana setiap lapisan memiliki dua komponen utama yaitu *Multi-Head Self-Attention*

(MSA) dan *Multi-Layer Perceptron* (MLP). Sebelum masuk ke setiap blok, diterapkan *Layer Normalization* (LN) untuk menstabilkan distribusi aktivitas neuron dan mempercepat konvergensi pelatihan.

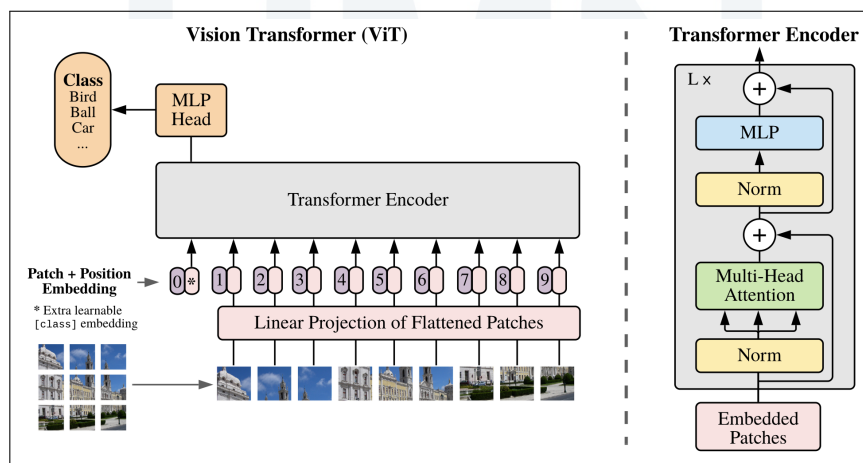
Rumus 2.2 menunjukkan bagaimana normalisasi diterapkan pada *input* z dengan menghitung rata-rata (μ) dan varians (σ) dari semua fitur pada satu langkah waktu tertentu.

$$LN(z) = \gamma \frac{z - \mu}{\sigma} + \beta \quad (2.2)$$

Setelah proses normalisasi, data diteruskan ke mekanisme *Self-Attention* yang secara matematis dihitung menggunakan vektor *Query* (Q), *Key* (K), dan *Value* (V) sesuai dengan Rumus 2.3.

$$Attention(Q, K, V) = softmax \left(\frac{QK^T}{\sqrt{d_k}} \right) V \quad (2.3)$$

Di mana d_k merupakan dimensi dari vektor *key* yang berfungsi sebagai faktor penskalaan (*scaling factor*) untuk mencegah nilai *dot-product* yang terlalu besar sebelum masuk ke fungsi *softmax*. Representasi visual dari aliran data di dalam *Transformer Encoder* dapat dilihat pada Gambar 2.1.



Gambar 2.1. Arsitektur *Vision Transformer* (ViT) yang berdasarkan Dosovitsky et al. (2021).

Dalam konteks data *spatial-temporal* atau *time-series*, ViT dapat diadaptasi dengan merepresentasikan data runut waktu sebagai gambar *single-channel*, di mana satu sumbu mewakili waktu dan sumbu lainnya mewakili berbagai fitur

(metrik). Pendekatan ini berhasil diterapkan oleh Kang et al. [19] untuk memprediksi risiko TJS menggunakan data *in-game*. Studi mereka menemukan bahwa ViT mengungguli model sekuensial tradisional (seperti LSTM) karena kemampuannya menangkap interaksi kompleks lintas-fitur dan pola temporal dalam data *pitching* yang diambil secara tidak teratur (*irregularly sampled*). Oleh karena itu, arsitektur ViT diadopsi dalam penelitian ini untuk menganalisis data kinematik yang diambil dari *Statcast*, dengan hipotesis bahwa mekanisme *self-attention* mampu mengidentifikasi pola pergerakan halus dan dependensi *spatial-temporal* jarak jauh yang berpotensi menjadi prekursor cedera UCL.

Implementasi spesifik mengenai transformasi data *Statcast* menjadi *input* visual serta konfigurasi *hyperparameter* ViT yang digunakan dalam penelitian ini akan dibahas lebih mendalam pada Bab 3.

2.8 Transformasi Data Tabular Menjadi Representasi Gambar

Transformasi data *pitching* yang bersifat tabular menjadi representasi gambar merupakan langkah krusial untuk mengeksplorasi kemampuan *Vision Transformer* (ViT) dalam menangkap korelasi lintas fitur (*spatial*) dan pola temporal secara simultan. Proses ini dimulai dengan menyusun metrik mekanika *Statcast* ke dalam sebuah matriks dua dimensi, di mana sumbu-Y merepresentasikan berbagai fitur *pitching* dan sumbu-X merepresentasikan langkah waktu (*time steps*), sehingga membentuk sebuah "citra" tanda tangan biomekanik pelempar [19].

Keputusan teknis dalam pembentukan matriks ini sangat dipengaruhi oleh persyaratan arsitektur model visi yang digunakan. Penggunaan dimensi 224×224 ditentukan secara spesifik oleh arsitektur `vit_base_patch16_224` yang telah dilatih sebelumnya (*pre-trained*) pada *dataset ImageNet*, sehingga data mekanika harus disesuaikan agar kompatibel dengan bobot awal model tersebut. Mengingat data *pitching* asli tidak selalu memenuhi dimensi standar ini, matriks yang telah dinormalisasi ke rentang $[0, 1]$ dipadatkan (*padding*) menggunakan nilai konstan -5. Pemilihan angka -5 ini berfungsi sebagai penanda matematis yang kontras untuk membantu mekanisme *self-attention* membedakan secara tegas antara informasi biomekanik asli dan area kosong hasil *padding* [19].

Selain itu, data numerik yang awalnya bersifat satu saluran (*single-channel*) diperluas secara artifisial menjadi tiga saluran (RGB) agar dapat diproses oleh lapisan-lapisan model yang mengharapkan *input* berwarna, yang pada akhirnya memungkinkan proses pelatihan mencapai konvergensi yang lebih cepat dan stabil.

Melalui strategi adaptasi ini, ViT dapat membagi citra menjadi potongan-potongan (*patches*) berukuran 16×16 untuk mendeteksi sinyal biomekanik halus serta ketergantungan jangka panjang yang sering kali sulit diidentifikasi oleh arsitektur sekuensial tradisional.

2.9 Analisis Sensitivitas Temporal

Analisis sensitivitas merupakan sebuah instrumen evaluasi yang digunakan untuk menentukan bagaimana variasi dalam *input* suatu model memengaruhi *output* atau hasil akhir secara keseluruhan [31]. Dalam penelitian ini, prinsip tersebut dikembangkan menjadi Analisis Sensitivitas Temporal untuk mengidentifikasi ambang batas waktu (*time-horizon*) paling prediktif dalam menangkap sinyal degradasi biomekanik sebelum terjadinya cedera.

Secara teknis, analisis ini berfokus pada manipulasi jarak antara titik observasi terakhir dengan titik kejadian (*event*) cedera. Proses ini melibatkan pemotongan data (*data truncation*) secara sistematis untuk mensimulasikan skenario peringatan dini. Jendela waktu (20, 40, 60, 80, dan 100 hari) merepresentasikan "cakrawala prediksi" yang berbeda, di mana model dilatih untuk melakukan inferensi risiko berdasarkan akumulasi data historis yang berhenti tepat pada batas jendela yang ditentukan. Pendekatan ini memungkinkan evaluasi terhadap konsistensi dan kekuatan sinyal prekursor yang muncul pada berbagai jarak waktu sebelum cedera, sekaligus mengidentifikasi keseimbangan optimal antara kekuatan prediktif jangka pendek yang lebih akut dan stabilitas informasi jangka panjang yang berpotensi mengalami pengenceran informasi (*information dilution*).

Penentuan parameter jendela waktu (20, 40, 60, 80, dan 100 hari) diselaraskan dengan standar durasi pemulihan biomekanik yang dikembangkan oleh Reinold (2026). Secara klinis, jendela 40 dan 60 hari mencerminkan fase "*Acute Return-to-Play*" (standar program 6 minggu) yang bertujuan menangkap sinyal cedera pada intensitas kompetisi yang sedang berjalan. Jendela 80 hari selaras dengan fase "*Stable Progression*" (standar program 12 minggu) yang dirancang untuk menjaga stabilitas beban kerja optimal 98% dari waktu pengamatan [32]. Sementara itu, jendela 20 hari difungsikan untuk mengidentifikasi anomali pada ambang batas "*Sub-Chronic*", untuk mendeteksi lonjakan beban (*spikes*) sebelum pola tersebut melekat pada rata-rata kronis 28 hari yang menjadi standar industri dalam memantau risiko cedera [32]. Terakhir, selain untuk memastikan

selaras dengan pengujian pada penelitian yang dilakukan oleh Kang, jendela 100 hari merepresentasikan fase "*Structural Remodeling*" yang diperlukan untuk menangkap transisi dari intensitas rehabilitasi menuju beban kerja kompetitif penuh. Melalui pendekatan ini, penelitian bertujuan mengidentifikasi titik optimal di mana sinyal degradasi fisik paling jernih sebelum terjadi *information dilution* akibat penggunaan data historis yang terlalu lampau.

2.10 Penanganan *Dataset* Tidak Seimbang

Dalam tugas klasifikasi biner seperti prediksi cedera, sering terjadi *dataset* bersifat tidak seimbang (*imbalanced*)—yaitu, satu kelas (misalnya, *pitcher* sehat) jauh lebih banyak daripada kelas lainnya (*pitcher* cedera). Melatih model pada data semacam itu dapat menyebabkannya menjadi bias terhadap kelas mayoritas, yang mengakibatkan kinerja prediktif yang buruk pada kelas minoritas, yang sering kali merupakan kelas yang paling menarik.

Beberapa teknik tersedia untuk mengatasi hal ini. Metode *resampling*, seperti SMOTE (*Synthetic Minority Over-sampling Technique*), bekerja dengan menyeimbangkan *dataset* [33]. Pendekatan alternatif di tingkat algoritmik adalah penggunaan Fungsi Kerugian Tertimbang (*Weighted Loss Function*), seperti *Weighted Binary Cross-Entropy* [34].

Dalam penelitian ini, strategi penanganan ketidakseimbangan data mengadopsi metodologi yang dikembangkan oleh Kang (2025). Mengingat *dataset* cedera memiliki rasio ketidakseimbangan yang cukup tinggi—di mana kasus non-cedera jauh lebih banyak dibandingkan kasus cedera—Kang melakukan komparasi antara penggunaan teknik SMOTE dan *Weighted Binary Cross-Entropy* (*Weighted BCE*). Temuan dalam penelitian tersebut menunjukkan bahwa penggunaan *Weighted BCE* memberikan performa yang lebih unggul dibandingkan metode *upsampling*, dengan peningkatan skor F1 sebesar 0,03 pada kelas minoritas. Hal ini disebabkan karena pemberian bobot (`pos_weight`) secara langsung pada fungsi kerugian memungkinkan model untuk memberikan perhatian lebih (*attention*) pada fitur-fitur biomekanik yang langka tanpa menciptakan sampel artifisial yang berisiko menambah *noise* pada data. Oleh karena itu, penelitian ini menerapkan fungsi kerugian *BCEWithLogitsLoss* dengan parameter `pos_weight` untuk memastikan model tetap sensitif dalam mendeteksi risiko cedera meskipun berada di bawah dominasi data pelempar (*pitcher*) sehat.

2.11 Interpretabilitas Melalui *Attention Map*

Mekanisme *self-attention* pada arsitektur *Transformer* berfungsi sebagai instrumen interpretasi yang kuat dengan cara menimbang hubungan antar *patch input* secara simultan untuk menangkap dependensi global. Secara teknis, mekanisme ini menghasilkan bobot atensi (*attention weights*) yang merepresentasikan distribusi kepentingan relatif dari setiap segmen data biomekanik terhadap prediksi akhir model. Pemetaan atensi ini memberikan transparansi fungsional dengan cara memvisualisasikan "citra" tanda tangan pelempar (*pitcher*) ke dalam bentuk *heatmap*, yang memungkinkan identifikasi langsung terhadap fitur-fitur yang paling krusial bagi model.

Melalui pemetaan ini, model dapat melakukan seleksi fitur internal untuk mengidentifikasi *hotspots* atau area dengan kepadatan informasi tinggi pada *grid* biomekanik [35]. Analisis atensi pada *Vision Transformer* (ViT) memungkinkan pendeteksian pola pergerakan halus dan dependensi *spatial-temporal* jarak jauh yang sering kali menjadi prekursor terjadinya cedera UCL. Selain itu, teknik ini mampu mengungkapkan aliran informasi dari *input* menuju prediksi dengan mengekstrak dependensi paling menonjol pada setiap lapisan jaringan.

Penerapan visualisasi atensi dalam konteks klasifikasi biomekanik berfungsi sebagai alat diagnostik yang valid untuk menilai konsistensi model dalam membedakan sinyal risiko. Dengan merepresentasikan kepentingan fitur yang bersifat *model-agnostic*, mekanisme atensi menyediakan kerangka kerja *Explainable AI* (XAI) yang secara langsung menghubungkan deviasi teknis pelempar dengan keputusan prediksi model [36].

2.12 Korelasi *Pearson*

Koefisien korelasi *Pearson* (r) merupakan metrik statistik yang digunakan untuk mengukur hubungan linear antara dua variabel, yang secara teknis didefinisikan sebagai rasio antara kovarians kedua variabel terhadap perkalian standar deviasi masing-masing variabel tersebut. Dalam analisis data, koefisien ini berfungsi untuk menentukan sejauh mana dua sinyal atau variabel memiliki ketergantungan linear satu sama lain. Nilai r berada pada rentang -1 hingga 1 , di mana nilai yang mendekati ekstrem menunjukkan kekuatan hubungan yang tinggi, sedangkan nilai yang mendekati nol mengindikasikan bahwa variabel-variabel tersebut tidak berkorelasi secara linear atau hanya mengandung *noise* [37].

Untuk memvalidasi apakah korelasi yang ditemukan memiliki makna yang sah atau hanya terjadi secara kebetulan, digunakan nilai p (p -value) sebagai instrumen pengujian hipotesis. Nilai p memberikan ukuran probabilitas untuk memperoleh hasil pengamatan yang setidaknya sama ekstremnya dengan hasil yang diobservasi, dengan asumsi bahwa hipotesis nol adalah benar [38]. Dalam praktik statistik, nilai p berfungsi sebagai ambang batas keputusan untuk menolak atau mendukung sebuah hipotesis, di mana nilai yang kecil (umumnya $p < 0,05$) menunjukkan bahwa hubungan antar variabel tersebut signifikan secara statistik.

Penelitian ini menerapkan pendekatan analisis korelasi yang ditargetkan, di mana fitur-fitur biomekanik tidak dibandingkan satu sama lain dalam sebuah matriks besar, melainkan diuji secara spesifik terhadap variabel temporal sisa waktu menuju cedera. Pendekatan ini berfungsi untuk memitigasi *noise* data dan secara langsung memvalidasi hipotesis mengenai degradasi fisik pelempar (*pitcher*) seiring mendekatnya hari kejadian cedera.

