



**Politecnico
di Torino**

Politecnico di Torino

Corso di Laurea Magistrale in Ingegneria Biomedica
A.a. 2023/2024
Sessione di Laurea Luglio 2024

Tesi di Laurea Magistrale

**Evaluating Joint Kinematics with Deep Learning: A
Study on Pose Estimation Techniques**

Relatore:
Prof. Taian Martins Vieira

Candidato:
Manco Sandro

INDICE

1	INTRODUZIONE	1
2	METODI TRADIZIONALI	2
2.1	Goniometro	2
2.2	Elettrogoniometro	3
2.3	Motion Capture	4
2.4	Sensori IMU	4
3	METODI AI	6
3.1	Open Pose	6
3.2	Alpha Pose	9
3.3	Media Pipe	11
4	STUDIO DI FATTIBILITA'	15
4.1	Soggetto	15
4.2	Protocollo sperimentale	15
4.3	Strumentazione	15
4.4	Analisi dei dati	16
4.4.1	Dai video registrati al calcolo dell'angolo di ginocchio	17
4.4.2	Dall'angolo di ginocchio alle metriche d'interesse	18
4.5	Risultati	19
5	CONCLUSIONE	21
6	REFERENCES	22

INDICE FIGURE

Figura 1 a) Utilizzo del goniometro a braccia lunghe (Hancock et al., 2018b). b) Posizionamento dell'elettrogoniometro (Biometrics Ltd., 2015).	5
Figura 2 a) Setup motion capture (Camomilla et al., 2017). b) Posizionamento dei sensori IMU (Michael Stengel, 2017)	5
Figura 3 Workflow di Open Pose (Cao et al., 2018).	8
Figura 4 Architettura del CNN multi-stage (Cao et al., 2018).....	8
Figura 5 Esempio dello scheletro ottenuto utilizzando il modello COCO (Konrad & Masson, 2020).	9
Figura 6 Pipeline di Alpha Pose (Fang et al., 2022).	10
Figura 7 Convoluzione e ridimensionamento dell'immagine(Fang et al., 2022).	11
Figura 8 Modello Halpe-FullBody3 con136 keypoints totali (Fang et al., 2022)	11
Figura 9 Pipeline di Media Pipe (Bazarevsky et al., 2020b).....	13
Figura 10 Uomo Vitruviano allineato mediante due punti virtuali predetti da Blaze Pose in aggiunta al bounding box del viso (Bazarevsky et al., 2020a)	13
Figura 11 Architettura di rete per il tracking; regressione con supervisione tramite heatmap (Bazarevsky et al., 2020a).	14
Figura 12 Keypoints ottenuti utilizzando Media Pipe (Bazarevsky et al., 2020a)	14
Figura 13 Schema del posizionamento delle camere e del soggetto.....	16
Figura 14 Keypoints ottenuti per le due diverse angolazioni con entrambe le reti.	17
Figura 15 Valori di angolo nel tempo ottenuti con le due reti.	18
Figura 16 Singolo ciclo di movimento dettagliato dalle metriche d'interesse.	19
Figura 17 Confronto dei valori di angolo ottenuti con i 3 diversi metodi.	20

1 INTRODUZIONE

La cinematica articolare rappresenta un pilastro fondamentale nello studio del movimento umano, riuscendo ad offrire informazioni preziose non solo nel campo della biomeccanica ma anche nella riabilitazione e nel miglioramento delle prestazioni atletiche. La misurazione del movimento può essere utilizzata per valutare le prestazioni funzionali degli arti in condizioni normali e anomale (Di Paolo et al., 2021). Inoltre, la conoscenza cinematica è essenziale per una corretta diagnosi e trattamento chirurgico delle malattie articolari e per la progettazione di dispositivi protesici per ripristinare la funzione (An, 1984). Al giorno d'oggi esistono diversi strumenti in grado di quantificare la cinematica articolare. Uno dei primi strumenti utilizzati nella storia è il goniometro standard, uno strumento essenziale per misurare il range of motion (ROM) delle articolazioni. (Rwakabayiza et al., 2013). Il goniometro rappresenta uno strumento clinico ragionevole e semplice, tuttavia, per i protocolli di ricerca, spesso vengono preferiti altri strumenti a causa del più alto livello di precisione richiesto. (Chapleau et al., 2011). Tra gli strumenti che si preferiscono al goniometro figura, ad esempio, l'elettrogoniometro. Questo strumento offre l'opportunità di investigare la cinematica articolare durante numerose attività funzionali (Rowe, 1990) essendo economico, portatile, comodo da indossare e relativamente semplice da utilizzare. (Rowe et al., 1989). Tuttavia, per evitare errori, è indispensabile procedere con un accurato posizionamento e una precisa calibrazione dello strumento. (Martin, 2018). Inoltre, è stato notato come le caratteristiche dei soggetti studiati (ad esempio, la flessibilità della pelle, la struttura delle ossa, la composizione di grasso e muscolo) possono influenzare i risultati. (Balogh et al., 2009). Un terzo strumento spesso utilizzato per l'analisi della cinematica articolare è la motion capture, un metodo che utilizza almeno due videocamere e dei marker sul soggetto. La motion capture viene considerata come lo strumento "gold-standard" in quanto garantisce risultati precisi e ripetibili. (Lorenzetti et al., 2017). Inoltre, viene utilizzato sempre più spesso per valutare le prestazioni e la qualità del movimento dopo un infortunio o una malattia. (Alt Murphy et al., 2018). Tuttavia, questi sistemi presentano diversi svantaggi. Tra questi, vi è la necessità di dover attaccare i marker al corpo umano; richiedono un considerevole lasso di tempo per l'allestimento della sessione sperimentale; sono costosi, ingombranti e hanno elevate esigenze di spazio. (Ruiz-Olaya et al., 2017). Un ulteriore approccio si basa sull'utilizzo dei sensori inerziali (IMU), dispositivi avanzati capaci di misurare accelerazione e orientamento del corpo. I sensori inerziali forniscono una misurazione accurata della cinematica articolare (Worsey et al., 2019), e vengono sempre più spesso utilizzati per rilevare il movimento umano, in diversi campi di applicazione. (Lee & Park, 2011). Una limitazione riguardante l'utilizzo dei sensori IMU è legata al loro costo elevato. (Conceição et al., 2016)

Oltre a questi strumenti tradizionali, negli ultimi anni si stanno sviluppando sempre più rapidamente gli strumenti basati su intelligenza artificiale (AI). Questi sistemi AI funzionano attraverso algoritmi avanzati di deep-learning in grado di rilevare, tracciare e analizzare la posizione e il movimento del corpo umano anche in tempo reale. Attraverso l'analisi di immagini o video, questi sistemi sono in grado di identificare i keypoints del corpo (ad esempio, ginocchio, spalla, gomito ecc.) e di calcolare la loro posizione nello spazio (Cao et al., 2017), offrendo una stima della postura e del movimento. Una volta identificati i keypoints, che quindi rappresentano le diverse articolazioni corporee, questi vengono collegati per formare i vari segmenti corporei e ricostruire la struttura dello scheletro umano. Esistono diversi modelli di reti neurali in grado di ricreare la posa umana durante un movimento, tra cui Open Pose, Media Pipe, Alpha Pose, Deepcut, MultiPoseNet, Tensorflow MoveNet e altri ancora. Questi algoritmi hanno dimostrato un'impressionante capacità di tracciare specifiche caratteristiche del corpo umano dai video digitali registrati con dispositivi comuni presenti nelle case (ad esempio,

smartphone, tablet, computer portatili)(Cornman et al., 2021). Infatti, diversi studi (Ota et al., 2020, 2021; Stenum et al., 2021; Takeda et al., 2021) hanno rilevato che la stima della posa in 2D si è dimostrata un metodo valido per misurare la cinematica del piano sagittale durante la camminata, la corsa e gli squat bilaterali, se confrontata con l'analisi del movimento ottenuta con gli strumenti tradizionali. La valutazione della posizione umana può essere effettuata nel piano o nello spazio, e quindi vengono utilizzati metodi 2D o 3D per prevedere e rappresentare la posizione del corpo umano(Šajina & Ivašić-Kos, 2022). Questo consente di analizzare pattern di movimento complessi senza la necessità di attrezzature ingombranti o marcatori applicati sul corpo, rendendo l'analisi più accessibile e meno invasiva.

L'obiettivo di questo studio è stato valutare l'impiego di due reti neurali col fine di determinare quale tra le due sia in grado di quantificare con maggiore precisione i parametri della cinematica articolare. Questo obiettivo è stato motivato dalla potenzialità di implementare le reti neurali direttamente su smartphone, facilitando così l'analisi della cinematica articolare in maniera diretta e immediata superando i limiti imposti dall'uso degli strumenti tradizionali. Difatti, l'utilizzo di questi nuovi strumenti AI permetterebbe di ridurre i tempi e i costi necessari per condurre le valutazioni biomeccaniche rispetto i tradizionali strumenti, i quali richiedono attrezzature specializzate costose e sessioni di valutazione lunghe e complesse. Inoltre, un altro obiettivo è quello di ampliare la possibilità di valutare la biomeccanica del corpo ad una vasta gamma di utenti. Questo innovativo approccio tecnologico potrebbe consentire a professionisti della salute, atleti e individui interessati al benessere fisico di monitorare e valutare la propria cinematica articolare in modo efficiente, conveniente e rapido. Inoltre, potrebbe essere rivoluzionato il settore della riabilitazione, consentendo ai pazienti di monitorare la propria cinematica articolare e condividere i risultati direttamente con le strutture sanitarie. La domanda che è stata posta in questo studio è: quale tra Open Pose e Media Pipe è la rete neurale che permette di monitorare e valutare con maggior precisione i parametri cinematici articolari del ginocchio durante un esercizio di squat. Per poter rispondere a tale domanda, è stato deciso di utilizzare un elettrogoniometro come strumento di riferimento in quanto è ampiamente utilizzato per misurare i movimenti articolari umani (P. T. Wang et al., 2011) ed è considerato stabile, preciso, accurato e ripetibile nella sua prestazione.(Rowe et al., 2001). Inoltre, sono stati utilizzati due diversi smartphone per riprendere il soggetto, posti in due angolazioni diverse, per evidenziare possibili differenze nel calcolo degli angoli indotte dal punto di ripresa. Ci si è concentrati sulla cinematica articolare di ginocchio in quanto questo è soggetto, durante lo squat, ad una vasta gamma di movimenti, che vanno dalla flessione estrema all'estensione completa. Inoltre, lo squat è un esercizio ampiamente utilizzato per rafforzare la muscolatura della coscia e rappresenta un esercizio fondamentale nella maggior parte dei programmi di allenamento e riabilitazione del ginocchio. (Slater & Hart, 2017). La nostra ipotesi di base ha riguardato la possibilità di valutare la cinematica articolare del ginocchio mediante l'utilizzo di metodi di pose estimation, ipotizzando di ottenere stime precise ed accurate dei valori di ROM e di durata delle fasi di movimento. Inoltre, è stato ipotizzato che i valori dei parametri ottenuti tramite AI potessero essere confrontati con quelli ottenuti dall'elettrogoniometro.

2 METODI TRADIZIONALI

2.1 Goniometro

Il goniometro è uno strumento manuale usato per misurare l'angolo di movimento di una singola articolazione. Tale strumento è composto da due bracci mobili, i quali vengono allineati con i segmenti corporei adiacenti all'articolazione che si vuole analizzare. Questi goniometri sono disponibili in due tipologie: a braccia corte e a braccia lunghe. Il goniometro a braccia corte è utilizzato per articolazioni

più piccole come il polso, il gomito o la caviglia. I goniometri a braccia lunghe sono più accurati per articolazioni con leve lunghe come il ginocchio e l'anca.(Hancock et al., 2018a). Questi due bracci sono collegati ad un cerchio centrale sul quale sono segnati i valori dell'angolo da 0° a 360°. Una volta allineati i due bracci con i segmenti adiacenti all'articolazione in questione, è possibile ottenere una lettura diretta dell'angolo che si è formato. In Figura 1 a) è possibile osservare un esempio sull'utilizzo del goniometro a braccia lunghe. Nonostante la sua apparente semplicità, l'utilizzo del goniometro richiede precisione ed esperienza per garantire misurazioni accurate.(Scalzitti & White, 2016).

2.2 Elettrogoniometro

Un'evoluzione del goniometro standard è rappresentata dall'elettrogoniometro, il quale integra la tecnologia elettronica per la registrazione dei valori angolari. Questo è composto da due basi che vengono attaccate ai segmenti corporei adiacenti all'articolazione in esame. Oltre alle due basi vi è la presenza di un sensore, il quale può essere o un potenziometro o un estensimetro (Becari & Ramirez-Fernandez, 2016), entrambi basati su resistenze e meccanismi di variazione della resistenza. In Figura 1 b) è possibile osservare un esempio sul posizionamento dell'elettrogoniometro e la sua struttura. Entrambi le tipologie di elettrogoniometri sono costituite da una serie di circuiti elettronici alimentati da una tensione in ingresso al dispositivo. Il principio fisico su cui si fondano gli elettrogoniometri risiede nella relazione che vi è tra il movimento articolare e la variazione di resistenza elettrica all'interno del circuito. Nello specifico, il movimento dell'articolazione comporta un cambiamento nel valore della resistenza, che a sua volta comporta una variazione del valore di tensione in uscita dal circuito. Tale variazione nella tensione di uscita viene di conseguenza correlata alla variazione angolare dell'articolazione in movimento. Questa capacità di tradurre le fluttuazioni del segnale elettrico in valori angolari deriva da una precisa calibrazione dello strumento. Durante la calibrazione, l'elettrogoniometro viene fissato sull'articolazione, la quale viene piegata e stabilizzata in modo tale da formare angoli noti (ad esempio 0,90 e 180°). Mentre l'articolazione forma questi angoli noti, vengono registrate le tensioni in uscita dall'elettrogoniometro. L'insieme dei dati raccolti, angoli noti e tensione registrate, permettono di creare una curva o una formula matematica che verrà poi utilizzata per convertire le nuove variazioni di segnale elettrico durante il movimento in valori angolari. La principale differenza tra i due tipi di elettrogoniometri risiede nel modo con cui viene calcolata la variazione della resistenza elettrica. Nel caso del potenziometro, il sensore funziona attraverso una resistenza variabile e un cursore che, spostandosi, modifica il valore di questa resistenza. Quando l'articolazione si muove causando il piegamento dell'elettrogoniometro, tale movimento altera la posizione del cursore sul potenziometro provocando un cambiamento nel valore della resistenza elettrica. Questa modifica della resistenza comporta, a sua volta, una variazione della tensione di uscita dal circuito, che può essere misurata e interpretata per determinare l'angolo di flessione o estensione dell'articolazione in questione. Nel caso in cui si utilizzassero gli estensimetri, il principio fisico alla base della variazione del valore della resistenza è leggermente diverso. In questo caso tale principio si basa sulla relazione tra la deformazione meccanica e la variazione di resistenza. La formula è: $\frac{\Delta R}{R} = GF \times \epsilon$, dove ΔR è la variazione della resistenza dell'estensimetro, R è il valore della resistenza iniziale, GF è il fattore di gauge (costante che dipende dal materiale), ed infine ϵ rappresenta la deformazione meccanica definita come il rapporto tra la variazione di lunghezza e lunghezza originale ($\epsilon = \frac{\Delta L}{L}$). Quando vi è un movimento dell'articolazione, questo si riflette in una deformazione dell'estensimetro, che di conseguenza provoca una variazione della resistenza elettrica. Questa variazione di resistenza si traduce in una variazione del segnale elettrico in uscita che viene interpretato come variazione dell'angolo di flessione o estensione dell'articolazione considerata.

2.3 Motion Capture

Un'altra tipologia di strumento spesso utilizzato per valutare la cinematica articolare è la motion capture. Tale strumento è un sistema costituito da una serie di videocamere che riprendono la scena dove il soggetto si muove, con le quali si è in grado di ricostruire tridimensionalmente lo scheletro del soggetto e il suo movimento. Questo strumento di analisi del movimento viene considerato come il gold-standard per le misurazioni cinematiche tridimensionali delle articolazioni (Ceseracciu et al., 2014). Il primo step nell'utilizzo della motion capture consiste nel calibrare le diverse telecamere utilizzate in una posizione fissa in modo tale da poter registrare correttamente lo spazio tridimensionale. Questa fase di calibrazione è necessaria per creare il sistema di riferimento del laboratorio. Tale processo consiste nell'andare a definire quelli che sono i limiti dell'area di cattura e orientare le telecamere in modo tale da riuscire a coprire l'intero volume all'interno del quale il soggetto si muove. Per poter ricostruire il movimento del soggetto, vi devono essere un numero minimo di due videocamere, anche se di solito si usa un numero maggiore. Inoltre, la precisione nel ricostruire il movimento è fortemente influenzata dalle proprietà di risoluzione delle videocamere utilizzate. Successivamente vengono applicati sul soggetto dei particolari marker, su punti di riferimento anatomici secondo le raccomandazioni fatte dalla Società Internazionale di Biomeccanica (ISB) (Wu & Cavanagh, 1995). In Figura 2 a) è possibile osservare un esempio del possibile posizionamento delle telecamere e dei diversi marker. Questi marker possono essere di due tipi: passivi, ovvero ricoperti da materiali foto riflettenti che riflettono la luce infrarossa (flash delle videocamere), o attivi, ovvero emettono luce infrarossa (Longo et al., 2022). Il terzo step consiste nel catturare il movimento del soggetto nell'area di interesse, da diverse angolazioni. Le telecamere quindi, la cui frequenza di campionamento può arrivare fino a 500 frame al secondo (Pueo & Jimenez-Olmedo, 2017), riescono ad individuare frame per frame la posizione dei diversi marker e il loro spostamento nello spazio dovuto al movimento del soggetto. Una volta acquisite le diverse immagini 2D dalle telecamere, queste vengono date in input a particolari algoritmi basati sui principi della stereofotogrammetria (Cappozzo et al., 2005). La stereofotogrammetria consiste nella ricostruzione della posizione che un punto ha assunto nello spazio di laboratorio in ciascun istante del tempo campionato, ovvero fornisce le coordinate x, y, z in ciascun istante del tempo di osservazione. Attraverso l'utilizzo di questi particolari algoritmi quindi, si riescono a fondere le diverse immagini 2D ottenute in un'unica immagine 3D. Una volta ottenute le coordinate tridimensionali, si procede con l'analisi dei dati. Questa fase può includere il calcolo di parametri cinematici come la velocità, l'accelerazione, e l'angolo delle articolazioni.

2.4 Sensori IMU

Un altro strumento utilizzato per la valutazione della cinematica articolare è costituito dai sensori "Inertial Measurement Unit" (IMU). Questi sono dei sensori che utilizzano la combinazione di accelerometri, giroscopi e magnetometri. Questi sensori devono essere posizionati su punti di riferimento anatomici del corpo umano secondo le raccomandazioni fatte dalla Società Internazionale di Biomeccanica (ISB) (Wu & Cavanagh, 1995). In Figura 2 b) si può osservare un esempio sul posizionamento dei sensori IMU sulla parte superiore del corpo. L'accelerometro è in grado di misurare l'accelerazione lineare lungo i tre assi dello spazio. Il principio che permette il funzionamento degli accelerometri, si basa sul fatto che una massa accelerata presenta una propria inerzia, la quale può essere misurata. Gli accelerometri sono quindi in grado di rilevare le variazioni di accelerazione, che, se integrate permettono di ottenere la velocità e se nuovamente integrate permettono di ottenere lo spostamento del corpo. I giroscopi misurano l'accelerazione angolare intorno ad un singolo asse e possono essere utilizzati per determinare l'orientamento in un sistema di coordinate angolari. Questi sensori sono basati sul principio della conservazione del momento angolare, secondo cui il momento angolare di un sistema rimane costante a meno che agisca su di

esso una forza esterna. Infine, il magnetometro misura la forza del campo magnetico (Rana & Mittal, 2021). Tali sensori sono basati sul fatto che il campo magnetico terrestre varia in direzione ed intensità sulla Terra, di conseguenza possono essere utilizzati per determinare la forza agente di un campo magnetico noto. Utilizzando particolari algoritmi, si possono combinare le informazioni ottenute da questi sensori per ricostruire l'orientamento e il movimento di un corpo nello spazio.(Delgado-García et al., 2021)



Figura 1 a) Utilizzo del goniometro a braccia lunghe (Hancock et al., 2018b). **b)** Posizionamento dell'elettrogoniometro (Biometrics Ltd., 2015).




Figura 2 a) Setup motion capture (Camomilla et al., 2017). **b)** Posizionamento dei sensori IMU (Michael Stengel, 2017)

3 METODI AI

Esistono diversi metodi in grado di ricostruire la posa umana. Questi si dividono inizialmente in due categorie: rilevazione ‘single-person’ e ‘multi-person’. La prima è la stima della posa di singola persona, focalizzata su immagini o video con un singolo individuo. La seconda è la stima della posa multi-persona, che analizza le pose di più soggetti in una singola immagine o video. A differenza della stima della posa per singola persona, la stima della posa per più persone risulta più complicata a causa delle occlusioni che si possono verificare, delle varie scale dei singoli soggetti e delle interazioni imprevedibili tra diverse persone (Li et al., 2018). Esistono varie architetture di reti neurali progettate per la ricostruzione del movimento, le quali si distinguono in base all'approccio adottato e alla struttura della rete stessa. Nello specifico si possono distinguere principalmente due tipi di approcci: ‘top down’ e ‘bottom up’. Gli approcci top-down ottengono prima i soggetti candidati utilizzando un rilevatore di persone, per poi ottenere i keypoints e successivamente la stima della posa per ogni singola persona presente nell'immagine (Papandreou et al., 2017). Gli approcci bottom-up, invece, prevedono direttamente l'ottenimento di tutti i keypoints in una sola volta, per poi assemblarli nelle pose complete per tutte le persone (Pishchulin et al., 2015). Entrambe le categorie presentano alcune carenze. Gli approcci top-down sono molto sensibili allo spostamento e alla strettezza del bounding box poiché il loro modello è solitamente addestrato con immagini centrate sulla persona (Li et al., 2018). Inoltre, il run-time degli approcci top-down è proporzionale al numero di soggetti rilevati. Al contrario, i metodi bottom-up sono più efficienti nel calcolare le posizioni delle articolazioni (Insafutdinov et al., 2016; Pishchulin et al., 2015) ma richiedono molto tempo per ottenere i keypoints soprattutto nel caso di rilevazione ‘multi-person’. Entrambi i metodi permettono di ottenere un determinato numero di keypoints, che varia in base al modello di rete neurale che si sta utilizzando. Una volta ottenuti questi keypoints, è possibile ricostruire il modello scheletrico delle persone che si stanno analizzando. Partendo da questo modello scheletrico, che rappresenta la posizione delle articolazioni e la connessione tra esse, è possibile calcolare gli angoli formati dalle articolazioni stesse. Questo passaggio richiede di considerare ogni trio di keypoints adiacenti i quali formano due segmenti di linea con un punto in comune tra loro. Ad esempio, per calcolare l'angolo di ginocchio, si prendono in considerazione i keypoints corrispondenti al bacino, al ginocchio e infine la caviglia. Considerando le coordinate spaziali di tali keypoints si è in grado di ricostruire i segmenti, ad esempio, di tibia (ginocchio-caviglia) e del femore (bacino-ginocchio). Ottenuti questi due segmenti è possibile applicare le formule della geometria euclidea per ricostruire l'angolo e la sua variazione nel tempo. Le formule più tipicamente utilizzate sono quella dell'arcoseno o quella dell'arcotangente. Se si utilizza l'arcoseno, l'angolo viene calcolato come $\theta = \arccos\left(\frac{v \cdot u}{\|v\| \cdot \|u\|}\right)$, dove $v \cdot u$ rappresenta il prodotto scalare tra i due segmenti (ad esempio tibia e femore), mentre $\|v\| \cdot \|u\|$ rappresenta il prodotto tra le norme. Quindi in questo modo, applicando tali formule, è possibile ricostruire il valore dall'angolo articolare e la sua variazione nel tempo. I diversi modelli di pose estimation differiscono tra loro nel modo con cui vengono ottenuti i diversi keypoints. Tale differenza dipende da quella che è l'architettura della rete che viene utilizzata. Di seguito verranno illustrati tre possibili modelli di pose estimation (Open Pose, Media Pipe, e Alpha Pose) e spiegate le loro diverse architetture che portano all'ottenimento dei keypoints.

3.1 Open Pose

Open Pose utilizza un approccio ‘bottom-up’, un metodo di rilevazione frame per frame, dove per ogni frame vengono identificati i diversi keypoints e ricostruita la posa del soggetto. In Figura 3 è possibile osservare i diversi step che portano Open Pose alla rilevazione dei keypoints. Il processo comincia dando in input alla rete l'immagine o il video, con dimensione $w \times h$, che si vuole analizzare. L'immagine viene analizzata dal Convolutional Neural Network (CNN), il quale è inizializzato

sfruttando l'approccio dei primi 10 strati della rete neurale VGG-19 (Simonyan & Zisserman, 2014), ma con una configurazione adattata per la specifica esigenza di stima della posa. In questo processo, attraverso una serie di operazioni convoluzionali, vengono applicati consecutivamente tre filtri (kernel 3x3) a regioni dell'immagine al fine di estrarre le features (F) principali (Cao et al., 2018). Durante questo processo, il CNN effettua anche operazioni di pooling che comprimono l'informazione e riducono la dimensione delle mappe di features a $w' \times h'$. Questo ridimensionamento è fondamentale non solo per l'efficienza computazionale ma anche per catturare contesti più ampi dell'immagine, facilitando l'estrazione delle features principali. Utilizzando queste features come input, la rete effettua una prima predizione sia delle mappe di confidenza ' S ' sia dei Part Affinity Fields ' L ' (PAFs). La mappa di confidenza (una per ogni parte del corpo) è una matrice 2D che riflette le probabilità, pixel per pixel, di trovare un keypoint del corpo in specifiche posizioni dell'immagine (Cao et al., 2018). I PAFs (uno per ogni arto) invece sono dei vettori che codificano l'orientamento e la relazione spaziale tra le varie parti del corpo. Svolgono un ruolo cruciale nell'identificare e distinguere le parti del corpo appartenenti a persone diverse all'interno della stessa immagine, facilitando la corretta associazione tra i keypoints rilevati anche in scene affollate (Cao et al., 2018). Dopo questa prima fase iniziale, Open Pose entra all'interno di un ciclo iterativo, con l'obiettivo di raffinare le predizioni delle mappe di confidenza e dei PAFs. Tale processo iterativo è osservabile in Figura 4. Il ciclo comincia raffinando prima i diversi PAFs, rappresentato dal blocco di colore blu in Figura 4. Il sistema integra i risultati (L) ottenuti dallo stadio precedente con le features (F) iniziali per affinare le stime secondo la formula $L^t = \phi^t(F, L^{t-1})$, $\forall 2 \leq t \leq T_p$, (dove ϕ^t si riferisce all'inferenza del CNN per lo stage t , e T_p al numero totale di stage dei PAFs). L'obiettivo è quello di migliorare la precisione nella rappresentazione delle associazioni tra le parti del corpo. Una volta terminate le t -iterazioni, il processo viene ripetuto t -volte per le mappe di confidenza (S), partendo dalla predizione dei PAFs più aggiornata. (Cao et al., 2018). La formula che viene utilizzata è la seguente $S^t = \rho^t(F, L^{T_p}, S^{t-1})$ $\forall T_p < t \leq T_p + T_c$ (dove ρ^t si riferisce all'inferenza del CNN per lo stage t , e T_c al numero totale di stage per le mappe di confidenza). Tale processo è rappresentato dal blocco di colore beige in Figura 4. Sempre in Figura 4 è possibile notare anche l'utilizzo di una funzione di perdita alla fine di ogni stadio, utilizzata per l'addestramento della rete. Questa funzione di perdita è progettata per quantificare le discrepanze tra le previsioni della rete e i valori di riferimento, offrendo anche una soluzione al problema rappresentato dalla mancata etichettatura completa di tutte le persone presenti nell'immagine nei dataset. Questa supervisione intermedia ad ogni stadio permette, oltre che a raffinare le stime, di affrontare il problema del vanishing gradient, integrando periodicamente il gradiente (Wei et al., 2016). Dopo aver completato il ciclo iterativo per raffinare le mappe di confidenza e i PAFs, Open Pose avanza verso la fase di determinazione e assemblaggio delle pose. Questa fase inizia con l'identificazione dei keypoints attraverso le mappe di confidenza. Nello specifico, viene eseguita una soppressione non massima sulle mappe di confidenza per ottenere un insieme discreto di keypoints candidati per ciascuna parte del corpo. Ciascuna mappa di confidenza, specifica per una parte del corpo, viene esaminata per localizzare i picchi che rappresentano la presenza più probabile di quella parte del corpo. Questi picchi permettono di isolare i keypoints più significativi eliminando quelli meno probabili nelle immediate vicinanze (Cao et al., 2018). Ciascun keypoint identificato riceve quindi uno score basato sulla sua mappa di confidenza, il quale riflette la probabilità che quel punto sia effettivamente la parte del corpo indicata. Ricordiamo che per ciascuna parte del corpo potremmo avere diversi keypoints candidati in ciascuna mappa, non solo a causa di falsi positivi ma anche perché potrebbero esserci più persone nell'immagine. Successivamente, Open Pose calcola un secondo score che riflette quanto consistentemente i vettori PAFs supportino l'associazione tra due keypoints. Questo si fa tracciando una linea immaginaria tra due keypoints candidati e sommando i valori ottenuti dal prodotto scalare dei vettori PAFs con la direzione della linea immaginaria. Dopo aver determinato gli score dei keypoints e dei Part Affinity Fields (PAFs), il problema cruciale diventa capire

quali siano i collegamenti ottimali tra i keypoints per le diverse persone presenti nell'immagine. Per risolvere questo problema, OpenPose implementa un algoritmo di matching bipartito, che tratta i keypoints come nodi di un grafo e i potenziali collegamenti tra questi nodi come archi. Ogni arco viene pesato in base allo score ottenuto precedentemente con i PAFs. Questa fase si avvale dell'utilizzo dell'algoritmo ungherese (Kuhn, 1955), il quale obbiettivo è trovare l'abbinamento ottimale che massimizza la somma totale degli score dei PAF per gli archi selezionati nel matching. Ciò significa selezionare un insieme di connessioni tra keypoints in modo che ogni keypoint venga associato ad un altro keypoint in maniera ottimale, basandosi sugli score dei PAF, e che la configurazione totale delle connessioni abbia il punteggio complessivo più alto possibile. Dopo aver applicato l'algoritmo ungherese, si ottiene un set di connessioni ottimali tra i keypoints candidati. Infine, si procede con la fase di parsing nella quale vengono assemblate le pose per ognuna delle persone presenti nell'immagine. Le connessioni tra le parti del corpo ottenute dal matching bipartito sono ordinate in base alla loro confidenza (il peso degli archi nel grafo bipartito), che indica quanto sia probabile che rappresentino correttamente una parte della stessa persona. Partendo dalle connessioni più affidabili, la fase di parsing procede aggiungendo una connessione alla volta per formare le pose. Una connessione viene aggiunta ad una posa esistente solo se è coerente con le connessioni già presenti in quella posa, secondo i criteri definiti dai PAFs e dalle confidence maps. Il risultato finale della fase di parsing è un insieme di pose complete, con il sistema che fornisce in output la posizione 2D dei keypoints anatomici per ogni persona nell'immagine. Open Pose permette l'utilizzo di diversi modelli, che differiscono tra loro per il numero di keypoints calcolati. Tra questi modelli possiamo trovare COCO, MPII e BODY 25 (Cao et al., 2018). In Figura 5 è raffigurato lo scheletro ottenuto con l'utilizzo del modello COCO, modello in grado di ricostruire 18 keypoints.

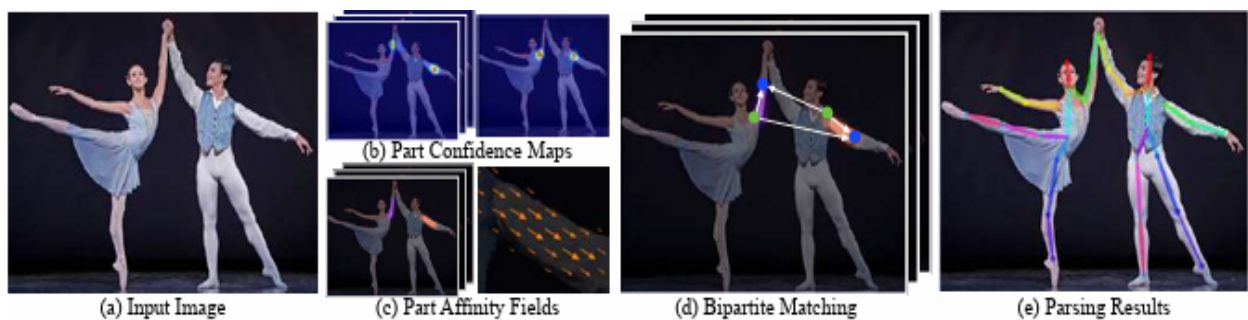


Figura 3 Workflow di Open Pose (Cao et al., 2018).

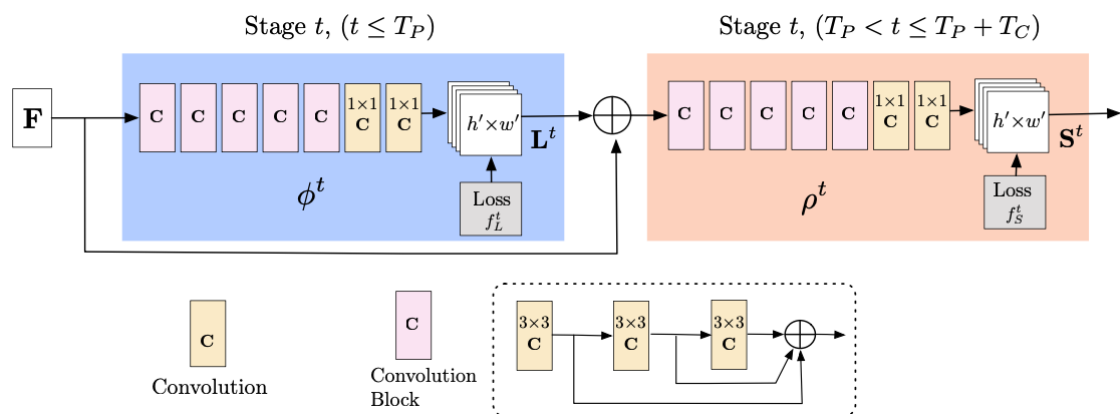


Figura 4 Architettura del CNN multi-stage (Cao et al., 2018).




Figura 5 Esempio dello scheletro ottenuto utilizzando il modello COCO (Konrad & Masson, 2020).

3.2 Alpha Pose

Un modello di tipo ‘top-down’ è rappresentato da Alpha Pose, un sistema capace di eseguire congiuntamente e in tempo reale la stima e il tracciamento della posa dell’intero corpo (Fang et al., 2022). Questo modello supera le limitazioni di altri sistemi di pose estimation introducendo innovazioni come la Regressione dei Keypoints Integrali Simmetrici (SIKR) per una localizzazione precisa e veloce e la Soppressione Non Massima Parametrica della Posa (P-NMS) per eliminare le rilevazioni umane ridondanti (Fang et al., 2022). L’architettura di Alpha Pose, illustrata in Figura 6, può essere divisa in cinque diversi stage: Data Loader (a), Detection (b), Data Transform (c), Pose Estimation (d) e Post Processing (e). Ogni fase comunica con i processi successivi attraverso una coda First-In-First-Out (FIFO), cioè, memorizza i risultati elaborati del modulo corrente e i moduli successivi prelevano direttamente i risultati dalla coda. Con tale progettazione, questi moduli sono in grado di funzionare in parallelo, risultando in un modello veloce che consente anche un’applicazione in real-time (Fang et al., 2022). Nella prima fase viene caricata l’immagine o il video che si vuole analizzare, oppure attivato lo stream della telecamera per un’analisi real-time. Nella seconda fase invece, quella di detection, vengono utilizzati alcuni rilevatori come YOLOV3(Redmon & Farhadi, 2018) e EfficientDet(Tan et al., 2020), i quali sono stati allenati sul dataset di COCO(Coco Dataset, 2016). L’utilizzo di questi rilevatori è fondamentale per identificare i bounding box, e quindi trovare le regioni di interesse (ROI), attorno a ciascuna persona presente nell’immagine o nel video. Per ogni bounding box trovato, viene associato un punteggio di confidenza che indica la probabilità che quel riquadro contenga il soggetto d’interesse. Dopo aver rilevato i soggetti presenti, i diversi dati passano nella terza fase di Data Transform. Durante questa fase viene applicato il Non-Maximum-Suppression ai diversi bounding box (Box NMS). Questa tecnica viene utilizzata in quanto potrebbe succedere che per un soggetto vengono trovati diversi bounding box sovrapposti. Applicando l’NMS viene selezionato solo il riquadro con il punteggio di confidenza più alto, mentre i restanti vengono scartati. Inoltre, l’immagine di ogni singolo soggetto viene tagliata e ridimensionata in modo tale da prepararla per l’analisi dei moduli successivi. L’immagine di ogni soggetto passa successivamente nella fase di Pose Estimation, nella quale vengono estratte le features principali dell’immagine e generate le diverse heatmap. La rete neurale utilizzata è FastPose (Fang et al., 2022) che incorpora tre moduli ‘Dense Upsampling Convolution’(DUC) per l’upsampling delle feature map estratte da un backbone ResNet (He et al., 2015) , seguito da una convoluzione 2D 1x1 per generare le heatmap. ResNet viene

applicato per fare una prima estrazione delle features principali dell'immagine, successivamente i moduli DUC vengono applicati per incrementare la risoluzione della features map. I tre moduli DUC applicano prima una convoluzione 2D all'immagine di dimensione $h \times w \times c$, la quale verrà ridimensionata in $2h \times 2w \times c'$ tramite un'operazione di PixelShuffle(Shi et al., 2016), seguita da una convoluzione 1x1. Tale operazione, illustrata in Figura 7, permette di ottenere le heatmap, le quali rappresentano la probabile posizione dei keypoints dei diversi soggetti. Col fine di analizzare le heatmap ed ottenere una corretta localizzazione dei keypoints, questa fase si avvale dell'utilizzo della Regressione dei Keypoints Integrali Simmetrici (SIKR). Il metodo SIKR supera due limitazioni del calcolo delle heatmap tradizionale: l'asimmetria del gradiente e l'imprecisione nel punteggio dei keypoints dovuta alla loro dimensione (Fang et al., 2022). A differenza dell'approccio convenzionale che identifica la posizione del keypoint cercando il punto massimo (argmax) sulla heatmap, la SIKR applica un metodo di regressione integrale lungo l'intera mappa. Ciò significa che viene considerata l'intera distribuzione delle intensità presenti nella heatmap, che si traduce in una maggiore precisione nella localizzazione dei keypoints. Una volta applicata la SIKR per la localizzazione dei keypoints, questi vengono utilizzati per stimare la posa e ricostruire lo scheletro di ogni soggetto presente nell'immagine. Contestualmente alla stima della posa, nella stessa fase di Pose Estimation, AlphaPose implementa un modello di Re-ID tracker. Questo modello, integrando il modulo 'Pose-Guided Attention' (PGA), estrae features specifiche per ciascun individuo nell'immagine, le quali vengono utilizzate per assegnare un identificativo (ID) unico a ciascun soggetto. Il PGA sfrutta le informazioni della posa stimata per ottimizzare la mappa di attenzione, assicurando che l'estrazione delle features di re-ID sia centrata sull'individuo e non venga influenzata dallo sfondo o da altre persone presenti nell'immagine. Dopo aver stimato tutte le pose e ottenuto le ID features, si procede all'ultima fase di Post Processing. Durante questa fase viene nuovamente implementato il Non-Maximum-Suppression (P-NMS), ma piuttosto che essere utilizzato sui bounding box come in precedenza, questa volta viene applicato sulle pose stimate. Il P-NMS, si applica per risolvere il problema dei multipli rilevamenti di pose per una singola persona. Questo utilizza una metrica di distanza tra le pose per decidere quali pose mantenere e quali scartare, con l'obiettivo di preservare solo le pose uniche e significative. Infine, l'algoritmo di Multi-Stage Identity Matching (MSIM) utilizza l'insieme delle informazioni raccolte (pose stimate, feature di re-ID e bounding boxes), per eseguire un tracking efficace e coerente degli individui attraverso i vari frame. L'MSIM è cruciale per mantenere la continuità degli ID degli individui nel tempo, assicurando così un tracciamento preciso e affidabile lungo l'intera sequenza video. Alpha Pose utilizza il modello Halpe-FullBody3, un modello in grado di ottenere 136 keypoints, osservabile in Figura 8. Nello specifico vengono annotati 20 punti per il corpo, 6 per i piedi, 42 per le mani e 68 per il volto. (Fang et al., 2022).

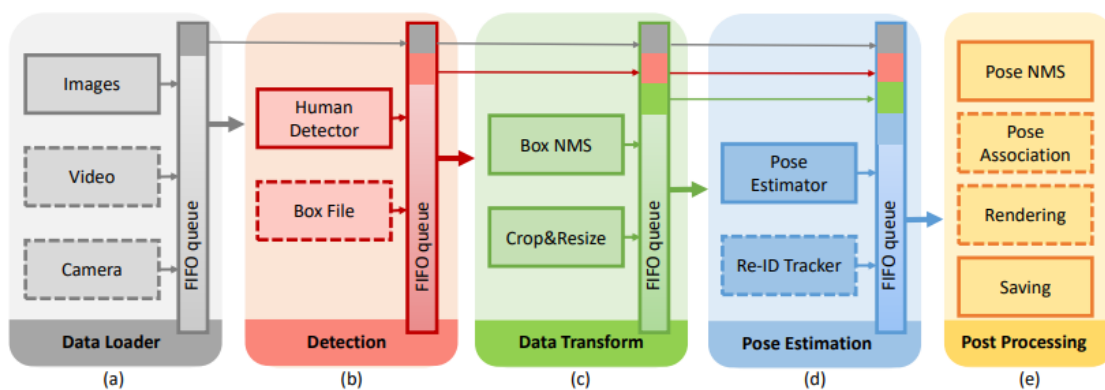


Figura 6 Pipeline di Alpha Pose (Fang et al., 2022).

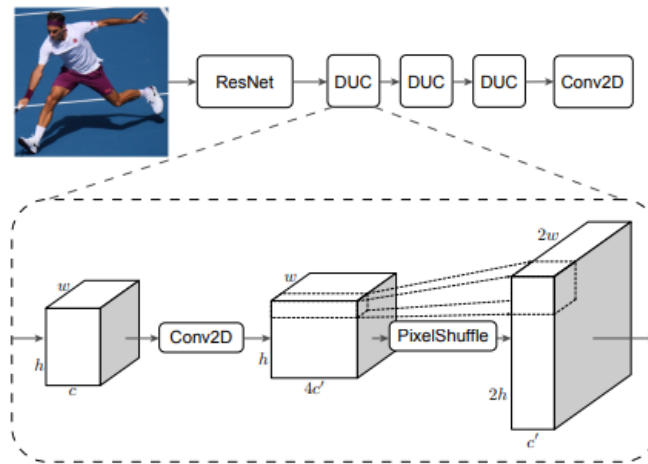


Figura 7 Convoluzione e ridimensionamento dell'immagine(Fang et al., 2022).




Figura 8 Modello Halpe-FullBody3 con 136 keypoints totali (Fang et al., 2022)

3.3 Media Pipe

Nel 2020, è stata rilasciata una soluzione chiamata Media Pipe per realizzare un tracciamento della posa del corpo umano utilizzando l'approccio del machine learning (Bazarevsky et al., 2020a). Media Pipe utilizza un approccio di rilevazione 'top-down', ciò significa che il processo inizia rilevando prima l'intero corpo o la figura umana nell'immagine o nel video, per poi procedere con l'identificazione e la stima dei keypoints. Il modello sul quale si basa Media Pipe è BlazePose (Bazarevsky et al., 2020a), con il quale si è in grado di calcolare un numero massimo di 33 keypoints.(Chung et al., 2022). Blaze Pose utilizza un'architettura composta da due componenti principali: un rilevatore (detector) e un

tracciatore (tracker), progettati per lavorare insieme per realizzare la stima delle pose anche in tempo reale (Bazarevsky et al., 2020a). È possibile osservare in Figura 9 la pipeline con la quale questi due elementi vengono utilizzati. Il processo comincia dando in input alla rete l'immagine o il video RGB che si desidera analizzare, oppure attivato lo stream della telecamera per un'analisi real-time. La prima fase dell'architettura utilizza un rilevatore per individuare la regione di interesse (ROI) della posa all'interno del frame (Bazarevsky et al., 2020a), ROI che verrà successivamente utilizzata dal tracker per localizzare i keypoints. Il rilevatore utilizzato è ispirato al modello di BlazeFace (Bazarevsky et al., 2019), addestrato a rilevare il volto come punto di riferimento. Per identificare correttamente la ROI viene utilizzato il viso come punto di riferimento, in quanto quest'ultimo fornisce un segnale forte alla rete a causa delle sue caratteristiche ad alto contrasto e della minor variabilità nell'aspetto (Bazarevsky et al., 2020a). Oltre al rilevamento del viso, il modello prevede il rilevamento di altri due punti virtuali che descrivono con precisione il centro, la rotazione e la scala del corpo umano, basati su un'ispirazione alla figura del Vitruviano di Leonardo da Vinci (Liu et al., 2022). Nello specifico vengono rilevati; il punto medio tra i fianchi, il punto che permette di circoscrivere l'intera persona, è l'angolo di inclinazione determinato dalla linea immaginaria che collega i punti medi delle spalle e dei fianchi. L'insieme di questi punti permette di ottenere un ROI allineata e centrata attorno al soggetto, anche nel caso di pose complesse. Questi punti e il bounding box del viso, utilizzati per l'ottenimento e allineamento della ROI, sono osservabili in Figura 10. Successivamente si passa alla seconda fase nella quale viene utilizzato il tracker, il quale utilizza le informazioni ottenute dal rilevatore, per ottenere la posizione dei 33 keypoints. Dalla Figura 9 si può notare come, nel caso di analisi video, il detector viene applicato solo nel primo frame, per poi procedere con la fase di tracking per i successivi frame. Se il tracker non rileva la presenza umana, il detector viene rieseguito sul frame successivo. In Figura 11 è illustrata l'architettura della rete neurale utilizzata da BlazePose per la fase di tracking dei keypoints corporei. Il modello di BlazePose impiega un metodo innovativo che coniuga la regressione supervisionata con la predizione di heatmap e offset maps per ciascun keypoint. (Bazarevsky et al., 2020a). L'elaborazione del tracker inizia analizzando la ROI ottenuta, la quale passa attraverso una serie di strati convoluzionali necessari per estrarre le features principali dell'immagine. Durante questo processo la dimensione dell'immagine viene ridotta, mantenendo allo stesso tempo una profondità sufficiente per un'accurata estrazione delle features. Parallelamente vengono generate le heatmap, che forniscono una rappresentazione probabilistica della posizione dei keypoints nell'immagine, indicando con una certa risoluzione spaziale dove il modello prevede che si trovino i keypoints. Gli offset maps, invece, sono impiegati per correggere le previsioni dei keypoints ottenute dalle heatmap, in quanto quest'ultime possono perdere precisione a causa della loro bassa risoluzione. Le dimensioni degli offset maps seguono le stesse riduzioni delle heatmap, assicurando che ogni correzione sia adeguata alla risoluzione della heatmap corrispondente. Durante la fase di addestramento iniziale, quindi, il modello allena la parte centrale e sinistra della rete (in Figura 11) utilizzando una funzione di perdita che combina gli errori delle heatmap con quelli degli offset. Questa fase permette di ottenere una prima rappresentazione intermedia dei keypoints corporei. Successivamente, si procede all'addestramento dell'encoder di regressione, la parte destra dell'architettura in Figura 11. La rappresentazione intermedia dei keypoints viene fornita all'encoder di regressione, che viene specificamente addestrato per mappare tali rappresentazioni alle coordinate dei keypoints. L'output dell'encoder di regressione sarà quindi un vettore 33x3, ovvero un vettore contenente le coordinate x e y di ogni keypoint e la sua visibilità (che rappresenta la probabilità del keypoint di essere visibile nel frame e non essere occluso da altri oggetti). In Figura 12 è possibile osservare la localizzazione dei 33 keypoints ottenuti. Il tracker, inoltre, utilizza la posizione dei keypoints ottenuti in modo tale da aggiornare la ROI per il frame successivo, nel caso di applicazioni video. Durante questo aggiornamento viene calcolato il punto medio tra i fianchi, il quale viene fatto corrispondere al centro dell'immagine in modo da ottenere una nuova ROI centrata sul soggetto.

Questo permette, come indicato in precedenza, di utilizzare il rilevatore solo nel primo frame, per poi procedere esclusivamente con l'utilizzo del tracker. L'architettura utilizza inoltre connessioni di salto (skip connections) per preservare le informazioni spaziali attraverso la rete e connessioni (stop gradient connections) che impediscono la retropropagazione del gradiente. Ciò garantisce che le features apprese in fasi diverse non si sovrapporranno durante l'apprendimento. L'utilizzo di questa strategia di addestramento permette a BlazePose di poter scartare il ramo riguardante la generazione delle heatmap (parte sinistra della rete) durante l'inferenza, e di calcolare la posizione dei keypoints mediante il solo utilizzo dell'encoder di regressione. In questo modo viene ridotto il carico computazionale rendendo BlazePose particolarmente adatto per applicazioni in tempo reale che richiedono elevata precisione e bassa latenza (Bazarevsky et al., 2020a).




Figura 9 Pipeline di Media Pipe (Bazarevsky et al., 2020b)




Figura 10 Uomo Vitruviano allineato mediante due punti virtuali predetti da Blaze Pose in aggiunta al bounding box del viso (Bazarevsky et al., 2020a)

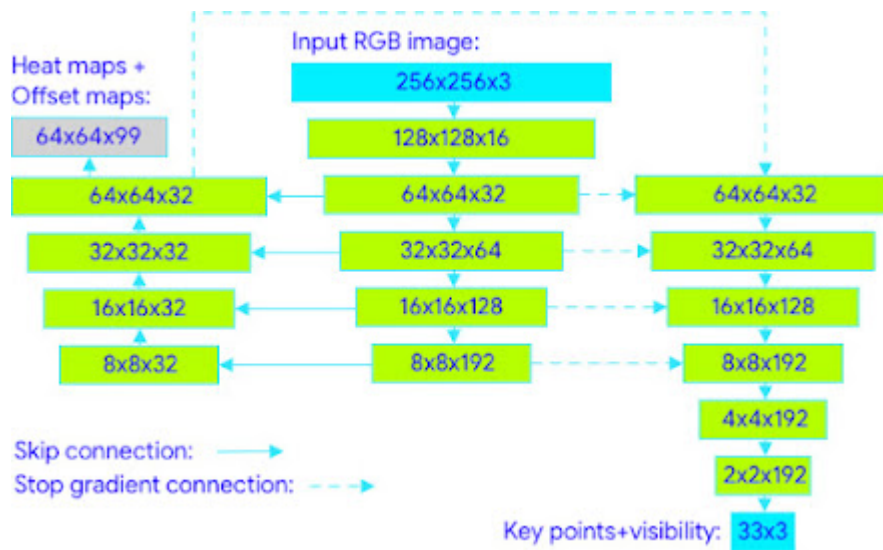


Figura 11 Architettura di rete per il tracking; regressione con supervisione tramite heatmap (Bazarevsky et al., 2020a).

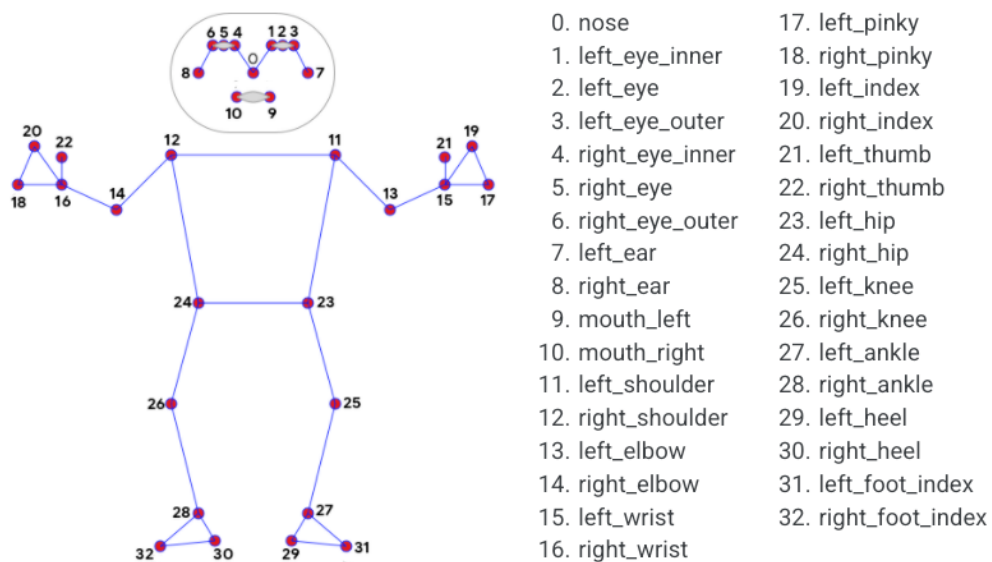


Figura 12 Keypoints ottenuti utilizzando Media Pipe (Bazarevsky et al., 2020a)

4 STUDIO DI FATTIBILITA'

4.1 Soggetto

È stato reclutato un soggetto di sesso maschile (età 24 anni; altezza 178 cm; massa corporea 98 kg). Il soggetto ha riportato di praticare attività fisica almeno due volte a settimana di avere familiarità con gli esercizi di squat. Non sono state segnalate lesioni neurologiche o muscolo-scheletriche al momento dell'esperimento. Lo studio è stato condotto nel rispetto dei principi della dichiarazione di Helsinki e ha ottenuto l'approvazione del comitato etico Health and Life Sciences dell'University of West Scotland. Il progetto è identificato dal numero di protocollo 16844. La conformità a tali linee guida etiche è stata rigorosamente mantenuta durante l'intera durata dello studio.

4.2 Protocollo sperimentale

La prova di squat è iniziata dopo che al partecipante è stato richiesto di mantenere una postura specifica e standard. È stato chiesto al soggetto di stare in piedi, con le articolazioni del ginocchio e dell'anca completamente estese, con i piedi in posizione parallela al livello dei fianchi. Le braccia sono state poste al livello del petto. In Figura 13 è possibile osservare la posizione del soggetto e dei due smartphone utilizzati. Non sono state imposte restrizioni sulla flessione massima del ginocchio; il partecipante ha eseguito gli squat fino al massimo della propria capacità, simile a come lo farebbe in palestra. Abbiamo optato per questa scelta poiché, in questo modo, abbiamo potuto valutare se gli algoritmi di stima della posa fossero in grado di calcolare un'ampia gamma di angoli, senza limitare il calcolo in un unico range. Inoltre, è risaputo che l'esercizio di full-squat migliora la forza muscolare (Pallarés et al., 2020) e induce adattamenti positivi nella dimensione e nella funzione del muscolo estensore. (Bloomquist et al., 2013). Lo squat è stato eseguito a corpo libero, senza l'utilizzo di carichi esterni, in quanto è stato dimostrato che l'allenamento con squat a peso libero aumenta la potenza degli arti inferiori (Styles et al., 2016) e migliora le capacità aerobica (T. Wang et al., 2021). Inoltre, l'assenza di carichi ha permesso di garantire una corretta esecuzione degli squat e di mantenere una postura corretta, senza l'interferenza del peso aggiuntivo che potrebbe influenzare il movimento. Il soggetto ha eseguito un set da 10 ripetizioni, in quanto è la frequenza raccomandata per atleti non professionisti (Hammami et al., 2022). La velocità durante la fase eccentrica e concentrica è stata regolata comunicando verbalmente al soggetto la sua cadenza di movimento in modo tale da rendere il più uniforme possibile il tempo impiegato per completare ognuna delle 10 ripetizioni.

4.3 Strumentazione

Per analizzare la cinematica del ginocchio durante gli squat attraverso Open Pose (OP) e Media Pipe (MP), è stato scelto di filmare il partecipante utilizzando due smartphone distinti. Il sistema di riferimento globale utilizzato è stato quello del laboratorio, con l'origine posta nel centro visivo dei due smartphone, dove appunto vi era il soggetto. Gli assi x, y, z corrispondevano alla direzione destra-sinistra, anteriore-posteriore e verticale. Il primo telefono è stato posizionato sul piano sagittale destro del soggetto, in modo tale che l'asse uscente dal centro dello smartphone fosse parallelo all'asse x del sistema di riferimento. Il secondo telefono è stato orientato in modo tale che il suo asse uscente formasse un angolo di 45° con l'asse x del sistema di riferimento, consentendo di inquadrare sia la parte destra che sinistra del soggetto, incluso il volto. Gli smartphone utilizzati sono un iPhone 13 Pro e uno Xiaomi 11T Pro, posizionati su due treppiedi ad 1 metro dal terreno. Il soggetto è stato posizionato a 1.5 metri da entrambe le fotocamere, le quali distavano 1.15 metri l'una dall'altra. Queste distanze sono state calcolate dal punto medio tra i due piedi del soggetto. Tale disposizione è osservabile nella Figura 13. Si è osservato come il video registrato con iPhone avesse una frequenza di campionamento di 30 frame per secondo. Il video registrato con Xiaomi invece ha rilevato una frequenza di campionamento pari a 29.16 frame per secondo. Inoltre, i frame dei video ottenuti con

iPhone sono stati campionati con una risoluzione di 1080p, quelli di Xiaomi con una risoluzione di 720p. Lo strumento utilizzato come riferimento (gold standard) è stato un elettrogoniometro (Twin-Axis Electrogoniometer SG150, Biometrics Ltd., UK). Le due basi che compongono l'elettrogoniometro (EG) sono state collocate equidistantemente al di sopra e al di sotto del condilo laterale del ginocchio mediante del nastro adesivo. Dal medesimo ginocchio sono stati estratti i keypoints necessari al calcolo dei parametri cinematici. Per effettuare la calibrazione dell'EG, è stato chiesto al soggetto di rimanere immobile in due posizioni specifiche: in piedi e in posizione di squat. Durante l'immobilità in entrambe queste posizioni, sono stati registrati sia il valore in mV fornito dall'EG sia il valore dell'angolo di ginocchio calcolato con un goniometro standard. Il segnale dell'EG è stato campionato a 2048 Hz, con 16 bit di risoluzione (DuePro, OT Bioelettronica, Italia). Con lo stesso sistema, un impulso analogico della durata di 500 ms e compreso tra 0 e 5 V è stato campionato insieme alla tensione fornita dall'EG. Lo stesso impulso è stato inviato ad un led che veniva ripreso da entrambi i telefoni, permettendo la sincronizzazione del segnale dell'EG con i video ripresi dai due telefoni.

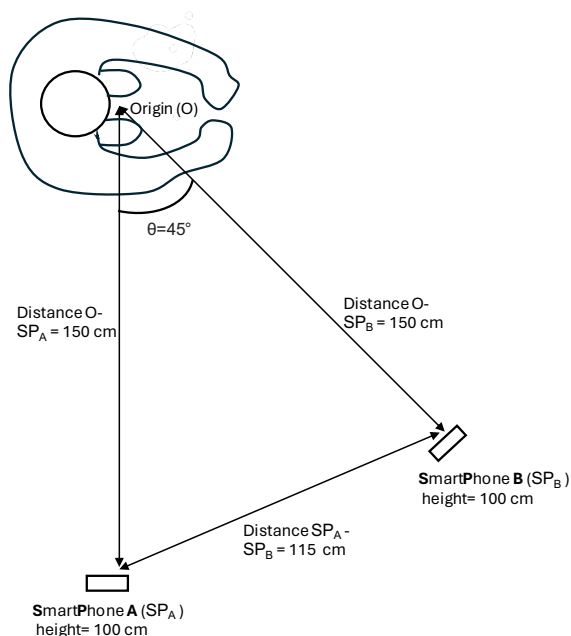


Figura 13 Schema del posizionamento delle camere e del soggetto.

4.4 Analisi dei dati

Per validare l'ipotesi dello studio sono state considerate due metriche: Range of motion (ROM) e durata del movimento, distinguendo la durata della fase concentrica (CON) e della fase eccentrica (ECC). Tali metriche d'interesse sono state ottenute mediante l'applicazione di tre approcci distinti: due basati sull'utilizzo di AI (Open Pose e Media Pipe), mentre il terzo si è concentrato sull'utilizzo dell'EG, strumento utilizzato come riferimento.

4.4.1 Dai video registrati al calcolo dell'angolo di ginocchio

Una volta registrati i video del partecipante durante lo squat, questi sono stati caricati sul programma Python nel quale sono stati implementati i codici necessari al funzionamento delle due reti neurali. Entrambe le reti hanno permesso di ottenere e salvare le coordinate spazio-temporali dei keypoints del corpo del soggetto durante lo squat. In Figura 14 è possibile notare i keypoints ottenuti con le due reti. Successivamente, utilizzando il software MatLab sono stati estratti i keypoints del bacino, del ginocchio e della caviglia. Utilizzando questi tre keypoints è stato calcolato l'angolo di flessione del ginocchio e la sua variazione nel tempo. L'angolo è stato determinato tramite il metodo dell'arco tangente della relazione tra le posizioni dei keypoints del bacino e della caviglia rispetto al ginocchio. Nello specifico, la formula utilizzata è stata la seguente: $\theta = \text{atan2}(c(2) - b(2), c(1) - b(1)) - \text{atan2}(a(2) - b(2), a(1) - b(1))$; dove a , b , e c rappresentano rispettivamente le coordinate dei keypoints del bacino, del ginocchio e della caviglia, mentre '2' e '1' rappresentano rispettivamente le coordinate y e x . Nella funzione, $\text{atan2}(c(2) - b(2), c(1) - b(1))$ esegue la sottrazione tra le coordinate della caviglia e del ginocchio, calcolando così l'orientamento del vettore ginocchio-caviglia e l'angolo formato rispetto alla componente positiva dell'asse x . Analogamente $\text{atan2}(a(2) - b(2), a(1) - b(1))$ sottrae le coordinate del bacino da quelle del ginocchio per determinare l'orientamento del vettore ginocchio-bacino e l'angolo formato rispetto alla componente positiva dell'asse x . Calcolando la differenza tra questi due angoli ottenuti si riesce a risalire all'angolo interno del ginocchio. Applicando tale formula si è ottenuto un angolo in radianti, il quale è stato poi convertito in gradi moltiplicando tale valore per 180° e dividendolo il risultato per π . Tale procedura è stata applicata a tutte le coordinate raccolte, analizzandole frame per frame, al fine di ricostruire l'angolo di flessione-estensione del ginocchio e la sua variazione nel tempo. Successivamente, gli angoli ottenuti dalle due reti e dall'EG sono stati filtrati con un filtro passa-basso con frequenza di taglio pari a 5 Hz e ordine 3. La Figura 15 mostra un esempio dei valori di angolo nel tempo per le due reti neurali.




Figura 14 Keypoints ottenuti per le due diverse angolazioni con entrambe le reti.




Figura 15 Valori di angolo nel tempo ottenuti con le due reti.

4.4.2 Dall'angolo di ginocchio alle metriche d'interesse

Una volta ottenuti i profili temporali di angolo con i tre metodi considerati, sono stati calcolati i ROM e la durata dei movimenti di fase ECC e CON. Per quanto riguarda i ROM, la rilevazione è avvenuta mediante l'utilizzo della funzione *'findpeaks'* su MatLab. Tale funzione ha permesso di calcolare i valori massimi e minimi di angolo per ciascuna delle dieci ripetizioni eseguite dal soggetto.

Successivamente è stata calcolata la differenza tra i massimi e i minimi, così da ottenere i dieci valori di ROM. Per quanto riguarda la durata delle fasi ECC e CON, queste sono state calcolate utilizzando la derivata prima dell'angolo articolare del ginocchio. Velocità angolari negative corrispondono alla flessione del ginocchio, mentre velocità angolari positive corrispondono all'estensione del ginocchio. La massima estensione del ginocchio corrisponde ad un valore ideale di 180°, valori di angolo minori corrispondono a flessione. Tra una ripetizione e l'altra il partecipante ha trascorso un breve tempo fermo con il ginocchio in completa estensione. Per evitare che questo tempo di stallo venga preso in considerazione per il calcolo delle due fasi, le fasi ECC e CON dello squat sono state definite per il 90% dei valori angolari osservati all'interno dei singoli cicli. Più specificamente, l'inizio e la fine delle fasi ECC sono stati definiti per istanti in cui l'angolo articolare del ginocchio ha rispettivamente superato e raggiunto il 5% e il 95% dell'intervallo dei valori angolari all'interno dei periodi di velocità angolare negative. Allo stesso modo, le fasi CON sono state definite negli istanti corrispondenti al 5% e al 95% dell'intervallo dei valori angolari durante i periodi di velocità angolare positive. È possibile osservare la distinzione tra le due fasi in Figura 16. Inoltre, è stato calcolato il valore del Root Mean Square (RMS) per la coppia EG-OP e EG-MP. Per far questo si è prima proceduto con un *'resample'* dell'angolo EG per trasformare la sua frequenza di campionamento da 2048 a 30 Hz. In seguito, i vari cicli di ciascun angolo sono stati individuati e aggregati in un unico ciclo medio. L'RMS è stato quindi determinato basandosi su questo ciclo unificato.

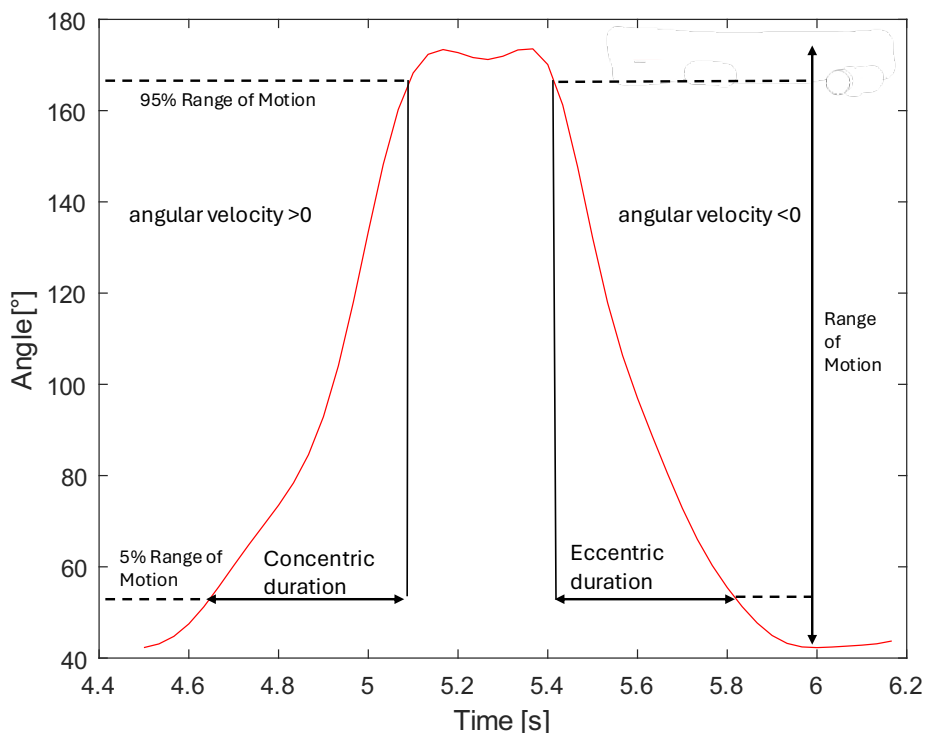


Figura 16 Singolo ciclo di movimento dettagliato dalle metriche d'interesse.

4.5 Risultati

La prima analisi condotta ha riguardato il calcolo del tempo di elaborazione necessario dalle due reti neurali per analizzare i video e ottenere i diversi keypoints. Il tempo di elaborazione di ciascun metodo è stato valutato utilizzando il modulo *'time'* su Python. Utilizzando questo modulo si è stati in grado di registrare il tempo necessario per ottenere i keypoints per ciascun frame analizzato. Questi tempi sono stati plottati sulla finestra del terminale per fornire una rappresentazione visiva immediata del tempo impiegato per l'analisi di ogni frame. Infine, i tempi registrati per l'elaborazione di ciascun frame sono stati sommati per ottenere il tempo totale necessario per l'elaborazione completa dei video. Inoltre, è stato calcolato il tempo medio necessario per analizzare ciascun frame, fornendo così una misura dell'efficienza di elaborazione di ciascun metodo. Questo approccio ha permesso di quantificare con precisione il tempo di elaborazione impiegato da OP ed MP, fornendo così una base solida per il confronto delle prestazioni di elaborazione tra i due metodi utilizzati. I due video analizzati, uno per ogni smartphone, hanno entrambi una durata 25 secondi e un numero di frames pari a 753. OP ha impiegato in media 0.971 secondi per processare ciascun frame, mentre MP ha impiegato in media 0.04 secondi. Il tempo necessario per processare entrambi i video è risultato pari a 24 minuti e 22 secondi per OP, mentre MP ha impiegato 1 minuto e 2 secondi. I video sono stati processati utilizzando il linguaggio di programmazione Python (versione 3.11) su un MacBook Pro 2020 con chip M1. Durante l'elaborazione dei video, il computer si trovava collegato all'alimentatore, assicurando così che le prestazioni non fossero influenzate da eventuali modalità di risparmio energetico. Inoltre, per garantire l'affidabilità dei risultati, oltre a Python non vi era nessun'altra applicazione in esecuzione al momento dei test. I risultati hanno evidenziato come MP sia nettamente più veloce di OP nel processare i diversi frame. Dopo aver svolto questo tipo di analisi ci si è concentrati sull'analizzare i risultati degli angoli e dei diversi parametri ottenuti. I risultati sono stati espressi sotto forma di valore medio \pm deviazione standard. La prima analisi ha riguardato l'osservazione dei valori angolari ottenuti con i 3 diversi strumenti. Tali valori sono osservabili in Figura

17. I tracciati evidenziano una notevole somiglianza, e sembrano rispecchiare quanto osservato durante le prove. La principale disparità tra le due reti neurali nel misurare gli angoli è associata alla rilevazione dei valori di minimo. Si può notare come MP rispecchi fortemente i valori di massimo e minimo ottenuti con EG. OP invece opera una sovrastima nella rilevazione dei valori di minimo. La principale differenza nel calcolo dell'angolo è dovuta dalla diversa rilevazione dei keypoints di bacino, ginocchio, e caviglia. Dalla Figura 14 si può notare come, sul piano sagittale, la posizione del ginocchio venga rilevata da OP in un punto più esterno rispetto a quanto fatto da MP. Sul piano laterale invece, vi è una discrepanza per tutti e tre i keypoints. OP rileva la posizione del bacino più in alto rispetto a MP, il ginocchio in un punto più esterno e la caviglia in punto più interno. Queste differenze comportano che, durante la flessione massima, il valore angolare del ginocchio calcolato con OP sia maggiore di quello calcolato con MP, portando ad una sottostima del ROM. Inoltre, la differente posizione dei keypoints per le due reti, comportano che il valore dell'angolo OP sia sottostimato nella prima metà della fase eccentrica e sovrastimato nella seconda metà della fase eccentrica. Inoltre, è stato osservato come l'andamento dell'angolo di OP sia più 'smooth' rispetto a quello di MP. Queste differenze sono dovute principalmente dal fatto che OP utilizza un approccio 'bottom-up', analizzando il video frame per frame, mentre MP utilizza un approccio 'top-down' dove la rilevazione avviene solo nel primo frame per poi procedere con un tracking. Questo può comportare ad una minore accuratezza nella ricostruzione dell'angolo durante il movimento.




Figura 17 Confronto dei valori di angolo ottenuti con i 3 diversi metodi.

L'analisi dei ROM con i 3 diversi strumenti ha portato ai seguenti risultati. Per EG è stato trovato un valore di ROM pari a $119.39 \pm 2.19^\circ$, per OP è stato trovato un valore pari a $106.76 \pm 1.14^\circ$, per MP invece $122.89 \pm 2.28^\circ$. Si può notare come il valore del ROM di MP sia maggiormente simile al valore ottenuto con EG, rispetto ad OP. Tale differenza è dovuta in maniera principale, come indicato precedentemente, al calcolo dei valori di minimo e alla sovrastima indotta da OP. Le stesse considerazioni sono state fatte anche per gli angoli ottenuti sul piano laterale con lo smartphone posto a 45° . Nello specifico per OP si è trovato un valore di ROM pari a $107.26 \pm 2.11^\circ$, mentre per MP è

pari a $137.73 \pm 2.83^\circ$. Ciò dimostra come OP non sembra essere influenzato dall'angolazione di 45° nel calcolo dei valori massimi e minimi. Per MP invece il valore registrato sul piano laterale è risultato superiore rispetto al ROM calcolato sul piano sagittale, indicando come l'angolazione di 45° influenzi il calcolo degli angoli. La differenza principale per i valori di ROM ottenuti con MP sul piano sagittale e quello laterale, è dovuta all'identificazione dei valori di angolo durante la massima estensione del ginocchio. MP sul piano sagittale ha rilevato un valore medio massimo di angolo pari a $178.00 \pm 1.72^\circ$, mentre sul piano laterale è risultato pari a $188.52 \pm 3.07^\circ$. Questa sovrastima è dovuta al fatto che, sul piano laterale durante la massima estensione, il keypoint del ginocchio viene rilevato in una posizione leggermente più interna rispetto a quanto accade sul piano sagittale. Per quanto riguarda invece la durata delle due fasi di movimenti, sono stati trovati i seguenti risultati. Per la fase ECC, l'EG ha registrato un valore pari a 0.97 ± 0.06 s, per OP si è ottenuto 0.98 ± 0.07 s, invece per MP si è ottenuto 0.95 ± 0.07 s. Per quanto riguarda invece la fase CON, con EG si è ottenuto 0.60 ± 0.05 s, con OP 0.58 ± 0.03 s, con MP 0.53 ± 0.07 s. I risultati mostrano quindi una notevole somiglianza da parte dei tre strumenti nel calcolo della durata delle due fasi di movimento. Infine, è stato calcolato anche il valore RMS tra gli angoli EG rispetto agli angoli delle due reti neurali ottenuti sul piano sagittale. Per la coppia EG-OP è stato trovato un valore di RMS pari a 7.40° , mentre per EG-MP è risultato pari a 7.82° . Il valore di RMS indicato per la coppia EG-OP è dato principalmente dalla differenza nel calcolo dei valori di minimo, mentre per la coppia EG-MP tale valore è dovuto principalmente al discostamento dei due angoli nella prima parte della seconda metà della fase eccentrica.

5 CONCLUSIONE

L'analisi dei risultati ha evidenziato come i metodi AI abbiano un elevato potenziale nel quantificare i parametri della cinematica articolare. È stato notato come, per l'analisi del ROM sul piano sagittale, ci sia una migliore corrispondenza dei valori di MP confrontati con l'EG, rispetto a quelli ottenuti con OP. Viceversa, sul piano laterale, è stata riscontrata una miglior corrispondenza dei valori di ROM ottenuti con OP rispetto ai valori ottenuti con MP. Per quanto riguarda la durata delle due fasi di movimento, OP ha rilevato una maggiore precisione rispetto a MP. Uno dei limiti del nostro studio di fattibilità riguarda l'analisi del movimento di un singolo individuo. Tale lavoro ha sicuramente permesso di valutare la fattibilità nell'utilizzo degli strumenti AI, ma uno studio con un maggior numero di campioni permetterebbe di valutare in maniera più precisa e affidabile l'utilizzo di OP e MP nella valutazione della cinematica articolare. Uno studio futuro potrebbe permettere l'integrazione di questi strumenti AI in un contesto di Velocity Based Training (VBT), il quale è un metodo di allenamento che utilizza il parametro della velocità per regolare l'intensità e il numero di ripetizioni di un esercizio (Fritsch et al., 2021). L'utilizzo di strumenti AI in questo contesto permetterebbe non solo di ottimizzare la personalizzazione degli allenamenti in base alle capacità del singolo individuo, ma anche fornire utili informazioni sulla qualità del movimento. Una ricerca futura potrebbe quindi permettere la valutazione di tali strumenti AI in contesti di allenamento diversificati e con un maggior numero di partecipanti. In questo modo si riuscirebbe ad avere un'idea più chiara sulla potenzialità e i limiti dei modelli di pose estimation nell'ambito della biomeccanica sportiva e della riabilitazione. Ciò potrebbe portare un contributo significativo alla scienza dell'allenamento e allo sviluppo delle metodologie di valutazione del movimento.

6 REFERENCES

- Alt Murphy, M., Murphy, S., Persson, H. C., Bergström, U.-B., & Sunnerhagen, K. S. (2018). Kinematic Analysis Using 3D Motion Capture of Drinking Task in People With and Without Upper-extremity Impairments. *Journal of Visualized Experiments*, 133. <https://doi.org/10.3791/57228>
- An, K. N. (1984). Kinematic analysis of human movement. *Annals of Biomedical Engineering*, 12(6), 585–597. <https://doi.org/10.1007/BF02371451>
- Balogh, I., Ohlsson, K., Nordander, C., Skerfving, S., & Hansson, G.-Å. (2009). Precision of measurements of physical workload during standardized manual handling part III: Goniometry of the wrists. *Journal of Electromyography and Kinesiology*, 19(5), 1005–1012. <https://doi.org/10.1016/j.jelekin.2008.07.003>
- Bazarevsky, V., Grishchenko, I., Raveendran, K., Zhu, T., Zhang, F., & Grundmann, M. (2020a). *BlazePose: On-device Real-time Body Pose tracking*.
- Bazarevsky, V., Grishchenko, I., Raveendran, K., Zhu, T., Zhang, F., & Grundmann, M. (2020b). *BlazePose: On-device Real-time Body Pose tracking*.
- Bazarevsky, V., Kartynnik, Y., Vakunov, A., Raveendran, K., & Grundmann, M. (2019). *BlazeFace: Sub-millisecond Neural Face Detection on Mobile GPUs*.
- Becari, W., & Ramirez-Fernandez, F. J. (2016). Electrogoniometer sensor with USB connectivity based on the IEEE1451 standard. *2016 IEEE International Symposium on Consumer Electronics (ISCE)*, 41–42. <https://doi.org/10.1109/ISCE.2016.7797360>
- Biometrics Ltd. (2015). *Twin-Axis Electrogoniometers for Joint Movement Analysis*.
- Bloomquist, K., Langberg, H., Karlsen, S., Madsgaard, S., Boesen, M., & Raastad, T. (2013). Effect of range of motion in heavy load squatting on muscle and tendon adaptations. *European Journal of Applied Physiology*, 113(8), 2133–2142. <https://doi.org/10.1007/s00421-013-2642-7>
- Camomilla, V., Cappozzo, A., & Vannozzi, G. (2017). Three-Dimensional Reconstruction of the Human Skeleton in Motion. In *Handbook of Human Motion* (pp. 1–29). Springer International Publishing. https://doi.org/10.1007/978-3-319-30808-1_146-1
- Cao, Z., Hidalgo, G., Simon, T., Wei, S.-E., & Sheikh, Y. (2018). *OpenPose: Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields*. <http://arxiv.org/abs/1812.08008>
- Cao, Z., Simon, T., Wei, S.-E., & Sheikh, Y. (2017). Realtime Multi-person 2D Pose Estimation Using Part Affinity Fields. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1302–1310. <https://doi.org/10.1109/CVPR.2017.143>
- Cappozzo, A., Della Croce, U., Leardini, A., & Chiari, L. (2005). Human movement analysis using stereophotogrammetry. *Gait & Posture*, 21(2), 186–196. <https://doi.org/10.1016/j.gaitpost.2004.01.010>

- Ceseracciu, E., Sawacha, Z., & Cobelli, C. (2014). Comparison of Markerless and Marker-Based Motion Capture Technologies through Simultaneous Data Collection during Gait: Proof of Concept. *PLoS ONE*, 9(3), e87640. <https://doi.org/10.1371/journal.pone.0087640>
- Chapleau, J., Canet, F., Petit, Y., Laflamme, G.-Y., & Rouleau, D. M. (2011). Validity of Goniometric Elbow Measurements: Comparative Study with a Radiographic Method. *Clinical Orthopaedics & Related Research*, 469(11), 3134–3140. <https://doi.org/10.1007/s11999-011-1986-8>
- Chung, J.-L., Ong, L.-Y., & Leow, M.-C. (2022). Comparative Analysis of Skeleton-Based Human Pose Estimation. *Future Internet*, 14(12), 380. <https://doi.org/10.3390/fi14120380>
- Coco Dataset. (2016). <http://mscoco.org/dataset/#keypoints-leaderboard>, 2016.
- Conceição, F., Fernandes, J., Lewis, M., González-Badillo, J. J., & Jimenéz-Reyes, P. (2016). Movement velocity as a measure of exercise intensity in three lower limb exercises. *Journal of Sports Sciences*, 34(12), 1099–1106. <https://doi.org/10.1080/02640414.2015.1090010>
- Cornman, H. L., Stenum, J., & Roemmich, R. T. (2021). Video-based quantification of human movement frequency using pose estimation: A pilot study. *PLOS ONE*, 16(12), e0261450. <https://doi.org/10.1371/journal.pone.0261450>
- Delgado-García, G., Vanrenterghem, J., Ruiz-Malagón, E. J., Molina-García, P., Courel-Ibáñez, J., & Soto-Hermoso, V. M. (2021). IMU gyroscopes are a valid alternative to 3D optical motion capture system for angular kinematics analysis in tennis. *Proceedings of the Institution of Mechanical Engineers, Part P: Journal of Sports Engineering and Technology*, 235(1), 3–12. <https://doi.org/10.1177/1754337120965444>
- Di Paolo, S., Lopomo, N. F., Della Villa, F., Paolini, G., Figari, G., Bragonzoni, L., Grassi, A., & Zaffagnini, S. (2021). Rehabilitation and Return to Sport Assessment after Anterior Cruciate Ligament Injury: Quantifying Joint Kinematics during Complex High-Speed Tasks through Wearable Sensors. *Sensors*, 21(7). <https://doi.org/10.3390/s21072331>
- Fang, H.-S., Li, J., Tang, H., Xu, C., Zhu, H., Xiu, Y., Li, Y.-L., & Lu, C. (2022). *AlphaPose: Whole-Body Regional Multi-Person Pose Estimation and Tracking in Real-Time*.
- Fritschi, R., Seiler, J., & Gross, M. (2021). Validity and Effects of Placement of Velocity-Based Training Devices. *Sports*, 9(9), 123. <https://doi.org/10.3390/sports9090123>
- Hammami, A., Harrabi, B., Mohr, M., & Krstrup, P. (2022). Physical activity and coronavirus disease 2019 (COVID-19): specific recommendations for home-based physical training. *Managing Sport and Leisure*, 27(1–2), 26–31. <https://doi.org/10.1080/23750472.2020.1757494>
- Hancock, G. E., Hepworth, T., & Wembridge, K. (2018a). Accuracy and reliability of knee goniometry methods. *Journal of Experimental Orthopaedics*, 5(1), 46. <https://doi.org/10.1186/s40634-018-0161-5>
- Hancock, G. E., Hepworth, T., & Wembridge, K. (2018b). Accuracy and reliability of knee goniometry methods. *Journal of Experimental Orthopaedics*, 5(1), 46. <https://doi.org/10.1186/s40634-018-0161-5>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Deep Residual Learning for Image Recognition*.
- Insafutdinov, E., Pishchulin, L., Andres, B., Andriluka, M., & Schiele, B. (2016). *DeeperCut: A Deeper, Stronger, and Faster Multi-Person Pose Estimation Model*.

- Konrad, S. G., & Masson, F. R. (2020). Pedestrian Skeleton Tracking Using OpenPose and Probabilistic Filtering. *2020 IEEE Congreso Bienal de Argentina (ARGENCON)*, 1–7. <https://doi.org/10.1109/ARGENCON49523.2020.9505458>
- Kuhn, H. W. (1955). The Hungarian method for the assignment problem. *Naval Research Logistics Quarterly*, 2(1–2), 83–97. <https://doi.org/10.1002/nav.3800020109>
- Lee, J. K., & Park, E. J. (2011). Quasi real-time gait event detection using shank-attached gyroscopes. *Medical & Biological Engineering & Computing*, 49(6), 707–712. <https://doi.org/10.1007/s11517-011-0736-0>
- Li, M., Zhou, Z., Li, J., & Liu, X. (2018). *Bottom-up Pose Estimation of Multiple Person with Bounding Box Constraint*.
- Liu, W., Liu, X., Hu, Y., Shi, J., Chen, X., Zhao, J., Wang, S., & Hu, Q. (2022). Fall Detection for Shipboard Seafarers Based on Optimized BlazePose and LSTM. *Sensors*, 22(14), 5449. <https://doi.org/10.3390/s22145449>
- Longo, U. G., De Salvatore, S., Carnevale, A., Tecce, S. M., Bandini, B., Lalli, A., Schena, E., & Denaro, V. (2022). Optical Motion Capture Systems for 3D Kinematic Analysis in Patients with Shoulder Disorders. *International Journal of Environmental Research and Public Health*, 19(19), 12033. <https://doi.org/10.3390/ijerph191912033>
- Lorenzetti, S., Lamparter, T., & Lüthy, F. (2017). Validity and reliability of simple measurement device to assess the velocity of the barbell during squats. *BMC Research Notes*, 10(1), 707. <https://doi.org/10.1186/s13104-017-3012-z>
- Martin, C. (2018). *Evidence-Based Practice Group Answers to Clinical Questions Validity and Reliability of Electrogoniometer in Musculoskeletal Injury/Disorder ROM Assessment Clinical Services-Worker and Employer Services*. www.worksafefbc.com/evidence
- Michael Stengel. (2017). *DIY PROJECT – WEARABLE IMU TRACKING SENSOR*.
- Ota, M., Tateuchi, H., Hashiguchi, T., & Ichihashi, N. (2021). Verification of validity of gait analysis systems during treadmill walking and running using human pose tracking algorithm. *Gait & Posture*, 85, 290–297. <https://doi.org/10.1016/j.gaitpost.2021.02.006>
- Ota, M., Tateuchi, H., Hashiguchi, T., Kato, T., Ogino, Y., Yamagata, M., & Ichihashi, N. (2020). Verification of reliability and validity of motion analysis systems during bilateral squat using human pose tracking algorithm. *Gait & Posture*, 80, 62–67. <https://doi.org/10.1016/j.gaitpost.2020.05.027>
- Pallarés, J. G., Cava, A. M., Courel-Ibáñez, J., González-Badillo, J. J., & Morán-Navarro, R. (2020). Full squat produces greater neuromuscular and functional adaptations and lower pain than partial squats after prolonged resistance training. *European Journal of Sport Science*, 20(1), 115–124. <https://doi.org/10.1080/17461391.2019.1612952>
- Papandreou, G., Zhu, T., Kanazawa, N., Toshev, A., Tompson, J., Bregler, C., & Murphy, K. (2017). *Towards Accurate Multi-person Pose Estimation in the Wild*.
- Pishchulin, L., Insafuldinov, E., Tang, S., Andres, B., Andriluka, M., Gehler, P., & Schiele, B. (2015). *DeepCut: Joint Subset Partition and Labeling for Multi Person Pose Estimation*.

- Pueo, B., & Jimenez-Olmedo, J. M. (2017). Application of motion capture technology for sport performance analysis (El uso de la tecnología de captura de movimiento para el análisis del rendimiento deportivo). *Retos*, 32, 241–247. <https://doi.org/10.47197/retos.v0i32.56072>
- Rana, M., & Mittal, V. (2021). Wearable Sensors for Real-Time Kinematics Analysis in Sports: A Review. *IEEE Sensors Journal*, 21(2), 1187–1207. <https://doi.org/10.1109/JSEN.2020.3019016>
- Redmon, J., & Farhadi, A. (2018). *YOLOv3: An Incremental Improvement*.
- Rowe, P. J. (1990). *The evaluation of the functional ability of total hip replacement patients, using a new computerised system of electrogoniometry*. University of Strathclyde.
- Rowe, P. J., Myles, C. M., Hillmann, S. J., & Hazlewood, M. E. (2001). Validation of Flexible Electrogoniometry as a Measure of Joint Kinematics. *Physiotherapy*, 87(9), 479–488. [https://doi.org/https://doi.org/10.1016/S0031-9406\(05\)60695-5](https://doi.org/https://doi.org/10.1016/S0031-9406(05)60695-5)
- Rowe, P. J., Nicol, A. C., & Kelly, I. G. (1989). Flexible goniometer computer system for the assessment of hip function. *Clinical Biomechanics*, 4(2), 68–72. [https://doi.org/10.1016/0268-0033\(89\)90041-7](https://doi.org/10.1016/0268-0033(89)90041-7)
- Ruiz-Olaya, A. F., Callejas-Cuervo, M., & Lara-Herrera, C. N. (2017). Wearable low-cost inertial sensor-based electrogoniometer for measuring joint range of motion. *DYNA*, 84(201), 180. <https://doi.org/10.15446/dyna.v84n201.59054>
- Rwakabayiza, S., Pereira, L. C., Lécureux, E., & Jolles-Haeberli, B. (2013). [Measurement of the knee range of motion: standard goniometer or smartphone?]. *Revue Medicale Suisse*, 9(411), 2372–2375.
- Šajina, R., & Ivašić-Kos, M. (2022). 3D Pose Estimation and Tracking in Handball Actions Using a Monocular Camera. *Journal of Imaging*, 8(11), 308. <https://doi.org/10.3390/jimaging8110308>
- Scalzitti, D. A., & White, D. J. (2016). Validity and Reliability of Goniometric Measurement. In C. C. Norkin & D. J. White (Eds.), *Measurement of Joint Motion: A Guide to Goniometry*, 5e. McGraw-Hill Education. [fadavispt.mhmedical.com/content.aspx?aid=1186282158](http://www.fadavispt.mhmedical.com/content.aspx?aid=1186282158)
- Shi, W., Caballero, J., Huszár, F., Totz, J., Aitken, A. P., Bishop, R., Rueckert, D., & Wang, Z. (2016). *Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network*.
- Simonyan, K., & Zisserman, A. (2014). *Very Deep Convolutional Networks for Large-Scale Image Recognition*. <http://arxiv.org/abs/1409.1556>
- Slater, L. V., & Hart, J. M. (2017). Muscle Activation Patterns During Different Squat Techniques. *Journal of Strength and Conditioning Research*, 31(3), 667–676. <https://doi.org/10.1519/JSC.0000000000001323>
- Stenum, J., Rossi, C., & Roemmich, R. T. (2021). Two-dimensional video-based analysis of human gait using pose estimation. *PLOS Computational Biology*, 17(4), e1008935. <https://doi.org/10.1371/journal.pcbi.1008935>
- Styles, W. J., Matthews, M. J., & Comfort, P. (2016). Effects of Strength Training on Squat and Sprint Performance in Soccer Players. *Journal of Strength and Conditioning Research*, 30(6), 1534–1539. <https://doi.org/10.1519/JSC.0000000000001243>

- Takeda, I., Yamada, A., & Onodera, H. (2021). Artificial Intelligence-Assisted motion capture for medical applications: a comparative study between markerless and passive marker motion capture. *Computer Methods in Biomechanics and Biomedical Engineering*, 24(8), 864–873. <https://doi.org/10.1080/10255842.2020.1856372>
- Tan, M., Pang, R., & Le, Q. V. (2020). EfficientDet: Scalable and Efficient Object Detection. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 10778–10787. <https://doi.org/10.1109/CVPR42600.2020.01079>
- Wang, P. T., King, C. E., Do, A. H., & Nenadic, Z. (2011). A durable, low-cost electrogoniometer for dynamic measurement of joint trajectories. *Medical Engineering & Physics*, 33(5), 546–552. <https://doi.org/10.1016/j.medengphy.2010.12.008>
- Wang, T., Kamon, M., Okada, S., Sawada, S., Ogawa, R., Shiozawa, N., & Machida, S. (2021). Design and Evaluation of an Online Squat Fitness System: Lessons Learned During the Early COVID-19 Pandemic in Japan. *Frontiers in Digital Health*, 3. <https://doi.org/10.3389/fdgth.2021.679630>
- Wei, S.-E., Ramakrishna, V., Kanade, T., & Sheikh, Y. (2016). Convolutional Pose Machines. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 4724–4732. <https://doi.org/10.1109/CVPR.2016.511>
- Worsey, M., Espinosa, H., Shepherd, J., & Thiel, D. (2019). Inertial Sensors for Performance Analysis in Combat Sports: A Systematic Review. *Sports*, 7(1), 28. <https://doi.org/10.3390/sports7010028>
- Wu, G., & Cavanagh, P. R. (1995). ISB RECOMMENDATIONS FOR STANDARDIZATION IN THE REPORTING OF KINEMATIC DATA. In *J. Bmwhanrcs* (Vol. 28, Issue 10).
- Alt Murphy, M., Murphy, S., Persson, H. C., Bergström, U.-B., & Sunnerhagen, K. S. (2018). Kinematic Analysis Using 3D Motion Capture of Drinking Task in People With and Without Upper-extremity Impairments. *Journal of Visualized Experiments*, 133. <https://doi.org/10.3791/57228>
- An, K. N. (1984). Kinematic analysis of human movement. *Annals of Biomedical Engineering*, 12(6), 585–597. <https://doi.org/10.1007/BF02371451>
- Balogh, I., Ohlsson, K., Nordander, C., Skerfving, S., & Hansson, G.-Å. (2009). Precision of measurements of physical workload during standardized manual handling part III: Goniometry of the wrists. *Journal of Electromyography and Kinesiology*, 19(5), 1005–1012. <https://doi.org/10.1016/j.jelekin.2008.07.003>
- Bazarevsky, V., Grishchenko, I., Raveendran, K., Zhu, T., Zhang, F., & Grundmann, M. (2020a). *BlazePose: On-device Real-time Body Pose tracking*.
- Bazarevsky, V., Grishchenko, I., Raveendran, K., Zhu, T., Zhang, F., & Grundmann, M. (2020b). *BlazePose: On-device Real-time Body Pose tracking*.
- Bazarevsky, V., Kartynnik, Y., Vakunov, A., Raveendran, K., & Grundmann, M. (2019). *BlazeFace: Sub-millisecond Neural Face Detection on Mobile GPUs*.
- Becari, W., & Ramirez-Fernandez, F. J. (2016). Electrogoniometer sensor with USB connectivity based on the IEEE1451 standard. *2016 IEEE International Symposium on Consumer Electronics (ISCE)*, 41–42. <https://doi.org/10.1109/ISCE.2016.7797360>
- Biometrics Ltd. (2015). *Twin-Axis Electrogoniometers for Joint Movement Analysis*.

- Bloomquist, K., Langberg, H., Karlsen, S., Madsgaard, S., Boesen, M., & Raastad, T. (2013). Effect of range of motion in heavy load squatting on muscle and tendon adaptations. *European Journal of Applied Physiology*, 113(8), 2133–2142. <https://doi.org/10.1007/s00421-013-2642-7>
- Camomilla, V., Cappozzo, A., & Vannozzi, G. (2017). Three-Dimensional Reconstruction of the Human Skeleton in Motion. In *Handbook of Human Motion* (pp. 1–29). Springer International Publishing. https://doi.org/10.1007/978-3-319-30808-1_146-1
- Cao, Z., Hidalgo, G., Simon, T., Wei, S.-E., & Sheikh, Y. (2018). *OpenPose: Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields*. <http://arxiv.org/abs/1812.08008>
- Cao, Z., Simon, T., Wei, S.-E., & Sheikh, Y. (2017). Realtime Multi-person 2D Pose Estimation Using Part Affinity Fields. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1302–1310. <https://doi.org/10.1109/CVPR.2017.143>
- Cappozzo, A., Della Croce, U., Leardini, A., & Chiari, L. (2005). Human movement analysis using stereophotogrammetry. *Gait & Posture*, 21(2), 186–196. <https://doi.org/10.1016/j.gaitpost.2004.01.010>
- Ceseracciu, E., Sawacha, Z., & Cobelli, C. (2014). Comparison of Markerless and Marker-Based Motion Capture Technologies through Simultaneous Data Collection during Gait: Proof of Concept. *PLoS ONE*, 9(3), e87640. <https://doi.org/10.1371/journal.pone.0087640>
- Chapleau, J., Canet, F., Petit, Y., Laflamme, G.-Y., & Rouleau, D. M. (2011). Validity of Goniometric Elbow Measurements: Comparative Study with a Radiographic Method. *Clinical Orthopaedics & Related Research*, 469(11), 3134–3140. <https://doi.org/10.1007/s11999-011-1986-8>
- Chung, J.-L., Ong, L.-Y., & Leow, M.-C. (2022). Comparative Analysis of Skeleton-Based Human Pose Estimation. *Future Internet*, 14(12), 380. <https://doi.org/10.3390/fi14120380>
- Coco Dataset. (2016). <http://mscoco.org/dataset/#keypoints-leaderboard,2016>.
- Conceição, F., Fernandes, J., Lewis, M., González-Badillo, J. J., & Jimenéz-Reyes, P. (2016). Movement velocity as a measure of exercise intensity in three lower limb exercises. *Journal of Sports Sciences*, 34(12), 1099–1106. <https://doi.org/10.1080/02640414.2015.1090010>
- Cornman, H. L., Stenum, J., & Roemmich, R. T. (2021). Video-based quantification of human movement frequency using pose estimation: A pilot study. *PLOS ONE*, 16(12), e0261450. <https://doi.org/10.1371/journal.pone.0261450>
- Delgado-García, G., Vanrenterghem, J., Ruiz-Malagón, E. J., Molina-García, P., Courel-Ibáñez, J., & Soto-Hermoso, V. M. (2021). IMU gyroscopes are a valid alternative to 3D optical motion capture system for angular kinematics analysis in tennis. *Proceedings of the Institution of Mechanical Engineers, Part P: Journal of Sports Engineering and Technology*, 235(1), 3–12. <https://doi.org/10.1177/1754337120965444>
- Di Paolo, S., Lopomo, N. F., Della Villa, F., Paolini, G., Figari, G., Bragonzoni, L., Grassi, A., & Zaffagnini, S. (2021). Rehabilitation and Return to Sport Assessment after Anterior Cruciate Ligament Injury: Quantifying Joint Kinematics during Complex High-Speed Tasks through Wearable Sensors. *Sensors*, 21(7). <https://doi.org/10.3390/s21072331>
- Fang, H.-S., Li, J., Tang, H., Xu, C., Zhu, H., Xiu, Y., Li, Y.-L., & Lu, C. (2022). *AlphaPose: Whole-Body Regional Multi-Person Pose Estimation and Tracking in Real-Time*.

- Fritschi, R., Seiler, J., & Gross, M. (2021). Validity and Effects of Placement of Velocity-Based Training Devices. *Sports*, 9(9), 123. <https://doi.org/10.3390/sports9090123>
- Hammami, A., Harrabi, B., Mohr, M., & Krusturup, P. (2022). Physical activity and coronavirus disease 2019 (COVID-19): specific recommendations for home-based physical training. *Managing Sport and Leisure*, 27(1–2), 26–31. <https://doi.org/10.1080/23750472.2020.1757494>
- Hancock, G. E., Hepworth, T., & Wembridge, K. (2018a). Accuracy and reliability of knee goniometry methods. *Journal of Experimental Orthopaedics*, 5(1), 46. <https://doi.org/10.1186/s40634-018-0161-5>
- Hancock, G. E., Hepworth, T., & Wembridge, K. (2018b). Accuracy and reliability of knee goniometry methods. *Journal of Experimental Orthopaedics*, 5(1), 46. <https://doi.org/10.1186/s40634-018-0161-5>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Deep Residual Learning for Image Recognition*.
- Insafutdinov, E., Pishchulin, L., Andres, B., Andriluka, M., & Schiele, B. (2016). *DeeperCut: A Deeper, Stronger, and Faster Multi-Person Pose Estimation Model*.
- Konrad, S. G., & Masson, F. R. (2020). Pedestrian Skeleton Tracking Using OpenPose and Probabilistic Filtering. *2020 IEEE Congreso Bienal de Argentina (ARGENCON)*, 1–7. <https://doi.org/10.1109/ARGENCON49523.2020.9505458>
- Kuhn, H. W. (1955). The Hungarian method for the assignment problem. *Naval Research Logistics Quarterly*, 2(1–2), 83–97. <https://doi.org/10.1002/nav.3800020109>
- Lee, J. K., & Park, E. J. (2011). Quasi real-time gait event detection using shank-attached gyroscopes. *Medical & Biological Engineering & Computing*, 49(6), 707–712. <https://doi.org/10.1007/s11517-011-0736-0>
- Li, M., Zhou, Z., Li, J., & Liu, X. (2018). *Bottom-up Pose Estimation of Multiple Person with Bounding Box Constraint*.
- Liu, W., Liu, X., Hu, Y., Shi, J., Chen, X., Zhao, J., Wang, S., & Hu, Q. (2022). Fall Detection for Shipboard Seafarers Based on Optimized BlazePose and LSTM. *Sensors*, 22(14), 5449. <https://doi.org/10.3390/s22145449>
- Longo, U. G., De Salvatore, S., Carnevale, A., Tecce, S. M., Bandini, B., Lalli, A., Schena, E., & Denaro, V. (2022). Optical Motion Capture Systems for 3D Kinematic Analysis in Patients with Shoulder Disorders. *International Journal of Environmental Research and Public Health*, 19(19), 12033. <https://doi.org/10.3390/ijerph191912033>
- Lorenzetti, S., Lamparter, T., & Lüthy, F. (2017). Validity and reliability of simple measurement device to assess the velocity of the barbell during squats. *BMC Research Notes*, 10(1), 707. <https://doi.org/10.1186/s13104-017-3012-z>
- Martin, C. (2018). *Evidence-Based Practice Group Answers to Clinical Questions Validity and Reliability of Electrogoniometer in Musculoskeletal Injury/Disorder ROM Assessment Clinical Services-Worker and Employer Services*. www.worksafefbc.com/evidence
- Michael Stengel. (2017). *DIY PROJECT – WEARABLE IMU TRACKING SENSOR*.

- Ota, M., Tateuchi, H., Hashiguchi, T., & Ichihashi, N. (2021). Verification of validity of gait analysis systems during treadmill walking and running using human pose tracking algorithm. *Gait & Posture*, *85*, 290–297. <https://doi.org/10.1016/j.gaitpost.2021.02.006>
- Ota, M., Tateuchi, H., Hashiguchi, T., Kato, T., Ogino, Y., Yamagata, M., & Ichihashi, N. (2020). Verification of reliability and validity of motion analysis systems during bilateral squat using human pose tracking algorithm. *Gait & Posture*, *80*, 62–67. <https://doi.org/10.1016/j.gaitpost.2020.05.027>
- Pallarés, J. G., Cava, A. M., Courel-Ibáñez, J., González-Badillo, J. J., & Morán-Navarro, R. (2020). Full squat produces greater neuromuscular and functional adaptations and lower pain than partial squats after prolonged resistance training. *European Journal of Sport Science*, *20*(1), 115–124. <https://doi.org/10.1080/17461391.2019.1612952>
- Papandreou, G., Zhu, T., Kanazawa, N., Toshev, A., Tompson, J., Bregler, C., & Murphy, K. (2017). *Towards Accurate Multi-person Pose Estimation in the Wild*.
- Pishchulin, L., Insafutdinov, E., Tang, S., Andres, B., Andriluka, M., Gehler, P., & Schiele, B. (2015). *DeepCut: Joint Subset Partition and Labeling for Multi Person Pose Estimation*.
- Pueo, B., & Jimenez-Olmedo, J. M. (2017). Application of motion capture technology for sport performance analysis (El uso de la tecnología de captura de movimiento para el análisis del rendimiento deportivo). *Retos*, *32*, 241–247. <https://doi.org/10.47197/retos.v0i32.56072>
- Rana, M., & Mittal, V. (2021). Wearable Sensors for Real-Time Kinematics Analysis in Sports: A Review. *IEEE Sensors Journal*, *21*(2), 1187–1207. <https://doi.org/10.1109/JSEN.2020.3019016>
- Redmon, J., & Farhadi, A. (2018). *YOLOv3: An Incremental Improvement*.
- Rowe, P. J. (1990). *The evaluation of the functional ability of total hip replacement patients, using a new computerised system of electrogoniometry*. University of Strathclyde.
- Rowe, P. J., Myles, C. M., Hillmann, S. J., & Hazlewood, M. E. (2001). Validation of Flexible Electrogoniometry as a Measure of Joint Kinematics. *Physiotherapy*, *87*(9), 479–488. [https://doi.org/https://doi.org/10.1016/S0031-9406\(05\)60695-5](https://doi.org/https://doi.org/10.1016/S0031-9406(05)60695-5)
- Rowe, P. J., Nicol, A. C., & Kelly, I. G. (1989). Flexible goniometer computer system for the assessment of hip function. *Clinical Biomechanics*, *4*(2), 68–72. [https://doi.org/10.1016/0268-0033\(89\)90041-7](https://doi.org/10.1016/0268-0033(89)90041-7)
- Ruiz-Olaya, A. F., Callejas-Cuervo, M., & Lara-Herrera, C. N. (2017). Wearable low-cost inertial sensor-based electrogoniometer for measuring joint range of motion. *DYNA*, *84*(201), 180. <https://doi.org/10.15446/dyna.v84n201.59054>
- Rwakabayiza, S., Pereira, L. C., Léclureux, E., & Jolles-Haeberli, B. (2013). [Measurement of the knee range of motion: standard goniometer or smartphone?]. *Revue Medicale Suisse*, *9*(411), 2372–2375.
- Šajina, R., & Ivašić-Kos, M. (2022). 3D Pose Estimation and Tracking in Handball Actions Using a Monocular Camera. *Journal of Imaging*, *8*(11), 308. <https://doi.org/10.3390/jimaging8110308>
- Scalzitti, D. A., & White, D. J. (2016). Validity and Reliability of Goniometric Measurement. In C. C. Norkin & D. J. White (Eds.), *Measurement of Joint Motion: A Guide to Goniometry*, 5e. McGraw-Hill Education. [fadavispt.mhmedical.com/content.aspx?aid=1186282158](https://www.fadavispt.mhmedical.com/content.aspx?aid=1186282158)

- Shi, W., Caballero, J., Huszár, F., Totz, J., Aitken, A. P., Bishop, R., Rueckert, D., & Wang, Z. (2016). *Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network*.
- Simonyan, K., & Zisserman, A. (2014). *Very Deep Convolutional Networks for Large-Scale Image Recognition*. <http://arxiv.org/abs/1409.1556>
- Slater, L. V., & Hart, J. M. (2017). Muscle Activation Patterns During Different Squat Techniques. *Journal of Strength and Conditioning Research*, 31(3), 667–676. <https://doi.org/10.1519/JSC.0000000000001323>
- Stenum, J., Rossi, C., & Roemmich, R. T. (2021). Two-dimensional video-based analysis of human gait using pose estimation. *PLOS Computational Biology*, 17(4), e1008935. <https://doi.org/10.1371/journal.pcbi.1008935>
- Styles, W. J., Matthews, M. J., & Comfort, P. (2016). Effects of Strength Training on Squat and Sprint Performance in Soccer Players. *Journal of Strength and Conditioning Research*, 30(6), 1534–1539. <https://doi.org/10.1519/JSC.0000000000001243>
- Takeda, I., Yamada, A., & Onodera, H. (2021). Artificial Intelligence-Assisted motion capture for medical applications: a comparative study between markerless and passive marker motion capture. *Computer Methods in Biomechanics and Biomedical Engineering*, 24(8), 864–873. <https://doi.org/10.1080/10255842.2020.1856372>
- Tan, M., Pang, R., & Le, Q. V. (2020). EfficientDet: Scalable and Efficient Object Detection. *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 10778–10787. <https://doi.org/10.1109/CVPR42600.2020.01079>
- Wang, P. T., King, C. E., Do, A. H., & Nenadic, Z. (2011). A durable, low-cost electrogoniometer for dynamic measurement of joint trajectories. *Medical Engineering & Physics*, 33(5), 546–552. <https://doi.org/10.1016/j.medengphy.2010.12.008>
- Wang, T., Kamon, M., Okada, S., Sawada, S., Ogawa, R., Shiozawa, N., & Machida, S. (2021). Design and Evaluation of an Online Squat Fitness System: Lessons Learned During the Early COVID-19 Pandemic in Japan. *Frontiers in Digital Health*, 3. <https://doi.org/10.3389/fdgth.2021.679630>
- Wei, S.-E., Ramakrishna, V., Kanade, T., & Sheikh, Y. (2016). Convolutional Pose Machines. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 4724–4732. <https://doi.org/10.1109/CVPR.2016.511>
- Worsey, M., Espinosa, H., Shepherd, J., & Thiel, D. (2019). Inertial Sensors for Performance Analysis in Combat Sports: A Systematic Review. *Sports*, 7(1), 28. <https://doi.org/10.3390/sports7010028>
- Wu, G., & Cavanagh, P. R. (1995). ISB RECOMMENDATIONS FOR STANDARDIZATION IN THE REPORTING OF KINEMATIC DATA. In *J. Bmwhanrcs* (Vol. 28, Issue 10).

Ringraziamenti

Infine, vorrei dedicare questo spazio per ringraziare tutti coloro che mi hanno guidato in questo percorso di studio.

Ringrazio di cuore la mia famiglia, Daniela, Gabriella, Maria Teresa e Serena. Loro sono state sempre presenti e di sostegno in ogni istante della mia vita. Grazie a loro ho trovato la forza per non mollare mai.

In particolare, vorrei ringraziare mia sorella Serena, la miglior sorella che potessi desiderare. Il suo continuo amore ed incoraggiamento sono stati fondamentali per me.

Grazie di cuore al mio relatore, Taian Martins. Grazie per l'opportunità che ha potuto darmi e per tutto il lavoro svolto. Insieme a lui, e al suo continuo supporto, è stata possibile la realizzazione di questo progetto.

Mille volte grazie a Lorenza. La sua infinita pazienza, il suo amore e il suo incoraggiamento costante mi hanno dato la forza per andare avanti e non mollare mai. Grazie per avermi supportato e sopportato in questo periodo pieno di ansie e preoccupazioni.

Un ringraziamento molto speciale va ad Alessandro, diventato come un fratello per me. Sempre disponibile e accogliente, ma soprattutto presente in ogni occasione. Trovare un'altra persona come lui è davvero difficile.

Ringrazio anche Pra, Valeria e tutto il gruppo di studio per il supporto che mi hanno saputo dare in questi anni. La loro collaborazione e il continuo aiuto sono stati fondamentali per poter superare le difficoltà incontrate durante l'intero percorso universitario, senza di voi non sarebbe stata la stessa cosa.

Grazie di cuore.