

UNIVERSITÀ  
DEGLI STUDI  
DI PADOVA



DIPARTIMENTO  
DI INGEGNERIA  
DELL'INFORMAZIONE

Dipartimento di ingegneria dell'informazione

Corso di Laurea Magistrale in  
Bioingegneria

**Sviluppo di un algoritmo per l'identificazione dei  
sollevamenti di carichi tramite sensori IMU e di  
pressione**

*Relatore:*

Prof. Zimi Sawacha

*Laureanda:*

Eleonora Rinaldi

2048426

*Correlatore:*

Dott. Annamaria Guiotto, PhD

Dott. Luigi Mattiello

Anno Accademico 2022/2023

Data di laurea 12/12/2023

# Sommario

Grazie ai continui progressi nella miniaturizzazione dei sensori, è diventato possibile acquisire dati relativi al movimento umano tra cui accelerazione, velocità angolare e pressioni plantari. Negli ultimi anni, queste tecnologie sono state principalmente utilizzate per la classificazione automatica delle attività. In questo lavoro di tesi, abbiamo sviluppato un metodo non invasivo per classificare automaticamente le attività di sollevamento dei carichi basandoci su dati provenienti da sensori inerziali e dalle pressioni plantari ottenuti da sistemi indossabili. In un ambiente d'ufficio controllato, quattro partecipanti sani hanno eseguito due tipi di movimenti di sollevamento. L'obiettivo principale era utilizzare questo sistema per identificare e classificare le posture scomode che potrebbero potenzialmente rappresentare rischi di infortuni per coloro che effettuano abitualmente questo tipo di movimentazione. Per la classificazione è stata impiegata una rete neurale artificiale, con un apprendimento automatico supervisionato, ottenendo un tasso di accuratezza superiore all'80%. Questa ricerca dimostra la possibilità di impiegare sistemi indossabili basati su IMU (Unità di Misura Inerziale) e sulle pressioni plantari per distinguere tra diverse attività umane e sfruttare questi risultati per ridurre l'esposizione a posture potenzialmente pericolose.



# Abstract

Thanks to continuous advancements in sensor miniaturization, it has become feasible to capture data related to various aspects of human motion, including acceleration, angular velocity, and foot pressure. In the last few years, these technologies have been mainly used for automatic activity classification. In this work, we developed a non-invasive method for automatically categorize postures based on inertial sensors and foot plantar pressure data obtained from a wearable systems. In a controlled office environment, four healthy participants performed two types of lifting movements. The primary objective was to utilize this system to identify and classify awkward postures that could potentially pose injury risks to warehouse workers. An artificial neural network, a supervised machine learning ,was used for the classification, achieving an accuracy rate exceeding 80%. This research demonstrate the possibility of employing wearable IMU (Inertial Measurement Unit) and insole pressure systems to distinguish between different human activities and exploit these findings to mitigate the exposure to potentially dangerous postures.



# Indice

<b>Introduzione</b>	<b>7</b>
<b>1 Disturbi muscolo-scheletrici da sovraccarico biomeccanico</b>	<b>9</b>
1.1 Fattori di rischio biomeccanici . . . . .	9
1.2 Patologie e disturbi muscolo-scheletrici . . . . .	10
1.2.1 La colonna vertebrale . . . . .	10
1.2.2 Gli arti superiori . . . . .	11
1.2.3 Gli arti inferiori . . . . .	12
1.3 Prevenzione . . . . .	13
1.4 Protocolli di valutazione del rischio . . . . .	14
1.4.1 Revised NIOSH Lifting Equation . . . . .	14
1.4.2 Rapid Upper Limb Assessment (RULA) . . . . .	16
1.4.3 Rapid Entire Body Assessment (REBA) . . . . .	16
1.4.4 Occupational Repetitive Actions (OCRA) . . . . .	17
1.4.5 Strain Index (SI) . . . . .	19
1.4.6 Hand Activity Level (ACGIH – HAL) . . . . .	19
1.4.7 Strumentazioni per la valutazione del rischio . . . . .	20
1.4.8 Sistemi optoelettronici . . . . .	20
1.4.9 Elettromiografia (EMGs) . . . . .	22
1.4.10 Sensori Inerziali e solette di pressione . . . . .	22
<b>2 Metodi di intelligenza artificiale</b>	<b>25</b>
2.1 Machine Learning . . . . .	26
2.1.1 K Nearest Neighbord (KNN) . . . . .	26
2.1.2 Naive Bayes (NB) . . . . .	27
2.1.3 Decision Tree (DT) . . . . .	28
2.1.4 Random Forest (RF) . . . . .	29
2.1.5 Support Vector MACHine (SVM) . . . . .	30

2.1.6	Rete neurale artificiale . . . . .	31
2.2	Stato dell'arte . . . . .	32
<b>3</b>	<b>Materiali e metodi</b>	<b>35</b>
3.1	Sensori Inerziali . . . . .	35
3.1.1	Accelerometro . . . . .	36
3.1.2	Giroscopio . . . . .	38
3.2	FSR . . . . .	39
3.3	Partecipanti . . . . .	40
3.4	Set up sperimentale . . . . .	40
3.5	Protocollo di acquisizione dati . . . . .	44
3.6	Analisi dei dati . . . . .	45
3.6.1	Pre-processing . . . . .	45
3.6.2	Etichettatura dei dati . . . . .	47
3.6.3	Caratteristiche statistiche . . . . .	48
3.6.4	Box-plot . . . . .	50
3.7	Selezione delle caratteristiche . . . . .	51
3.7.1	Approccio classico . . . . .	51
3.8	Modello AI . . . . .	52
3.9	Finestratura dei dati . . . . .	56
3.10	Allenamento e validazione del modello AI . . . . .	56
3.10.1	Selezione delle caratteristiche: approccio AI . . . . .	57
<b>4</b>	<b>Risultati</b>	<b>63</b>
4.0.1	Matrice di confusione . . . . .	63
4.0.2	Accuratezza . . . . .	64
4.0.3	Recall . . . . .	64
4.0.4	Precisione . . . . .	64
4.0.5	Balanced accuracy . . . . .	65
4.0.6	Punteggio F1 . . . . .	65
4.0.7	Kappa di Cohen . . . . .	66
4.1	Risultati: approccio classico . . . . .	66
4.2	Risultati: approccio AI . . . . .	68
4.3	Streaming dei dati . . . . .	70
<b>5</b>	<b>Conclusioni</b>	<b>73</b>

# Introduzione

Negli ultimi anni, i disturbi muscolo-scheletrici da sovraccarico biomeccanico (MSDs) hanno assunto un'importanza crescente, rappresentando uno dei principali problemi di salute professionale che colpiscono milioni di lavoratori in tutta Europa. Questi disturbi non solo hanno un impatto significativo sulla salute, ma comportano anche costi sociali elevati sia in termini di salute pubblica sia di perdita di produttività. In Italia nel 2022 le tecnopatie del sistema muscolo-scheletrico e del tessuto connettivo hanno rappresentato più del 70% del totale delle malattie professionali (INAIL, 2022a)[1]. Le attività lavorative che comportano movimenti ripetuti sono responsabili del 64% dei casi confermati di lesioni agli arti superiori, mentre il sollevamento di carichi è responsabile del 55% delle patologie alla schiena. Dai dati nazionali si evidenzia che i maggiori affetti da disturbi muscolo-scheletrici riguardano principalmente il sesso maschile con una prevalenza del 75%. I settori più a rischio risultano essere artigianato (28.5%), agricoltura (26.7%), industria (23.5%), servizi (18.7%) e pubblica amministrazione (2.9%) (INAIL, 2021a) [2]. I disturbi muscolo-scheletrici possono scatenare condizioni croniche con sintomi vari, tra cui dolori alla bassa schiena, alle spalle, al collo e tendiniti, causando disagio e compromettendo la qualità di vita dei lavoratori. Pertanto, l'identificazione e la prevenzione dei rischi potenziali sono di cruciale importanza per mitigare i danni. Particolarmente critico è il rischio associato alle attività manuali che coinvolgono il sollevamento di carichi pesanti, attività di spinta e traino, e movimenti ripetitivi con posture scomode [3,4]. Le prestazioni di professionisti come magazzinieri sono strettamente legate alla quantità di carichi sollevati, alla postura, alla durata delle posture e al tempo di recupero tra di esse, sottolineando la necessità di ridurre al minimo le posizioni scomode mediante formazione e intervento. Attualmente, i metodi di valutazione del rischio si basano spesso sull'osservazione diretta o sulla produzione video, ma questi approcci sono soggetti a variabilità inter ed intra osservatore. In alternativa sistemi optoelettronici, basati su telecamere ad infrarosso, possono fornire una valutazione altamente precisa ma richiedono ambienti strutturati e comportano costi elevati. Allo stesso modo anche l'elettromiografia di superficie è stata ampiamente utilizzata per valutare il rischio biomeccanico. Tuttavia l'elettromiografia richiede competenze specifiche nel posizionamento delle sonde che potrebbero risultare scomode durante l'esecuzione di determinati movimenti [5,6]. In questo contesto l'uti-



lizzo di sensori indossabili si pone come soluzione alternativa. Infatti, con i recenti sviluppi nella miniaturizzazione dei sensori, è possibile raccogliere dati relativi al movimento umano, come la velocità angolare e l'accelerazione, direttamente sui luoghi di lavoro. Questi dispositivi offrono diversi vantaggi come il fatto di essere di dimensioni e peso ridotti, di facile indossabilità, hanno alta precisione e permettono il monitoraggio in tempo reale del rischio biomeccanico. Tuttavia, tali dispositivi possono analizzare il movimento umano basandosi solo sui dati di velocità, orientazione e forza gravitazionale, per affinare ulteriormente la precisione delle misurazioni, si potrebbe combinare l'utilizzo di sensori inerziali indossabili con solette di pressione. Queste ultime, grazie alla loro capacità di misurare le forze verticali di reazione al terreno e di rilevare la distribuzione della pressione plantare, potrebbero completare i dati forniti dai sensori inerziali. La combinazione di queste due tecnologie potrebbe offrire una visione più completa e precisa del movimento umano, migliorando la capacità di rilevare e prevenire i sollevamenti scorretti di carichi durante le attività lavorative. Il presente lavoro di tesi, condotto in collaborazione con l'azienda 221e, si è posto l'obiettivo di sviluppare un algoritmo intelligente per rilevare in tempo reale il sollevamento manuale di carichi rispetto ad altre attività motorie attraverso l'utilizzo di unità di misurazione inerziale (IMU) e di sensori di pressione. La tesi è strutturata in cinque capitoli, ciascuno dedicato a specifici aspetti della ricerca. Nel primo capitolo, si offre una panoramica approfondita sui disturbi muscolo-scheletrici causati dal sovraccarico biomeccanico, esaminando dettagliatamente i fattori di rischio associati a tali condizioni, gli effetti dannosi sul sistema muscolo-scheletrico e i protocolli e le tecniche di valutazione attualmente utilizzati per la prevenzione. Nel secondo capitolo, l'attenzione si focalizza sulla spiegazione dei principali algoritmi di intelligenza artificiale impiegati in questo contesto, fornendo anche una panoramica dello stato dell'arte attuale. Il terzo capitolo si concentra sul lavoro di tesi; presentando una panoramica delle attrezzature, del set-up sperimentale e del protocollo di acquisizione dati utilizzato. Vengono forniti dettagli sui componenti dei sensori inerziali e dei sensori di forza. In questo capitolo, si approfondisce anche la fase di analisi dei dati estratti dalla sensoristica, discutendo delle scelte e della selezione delle caratteristiche rilevanti e presentando due diversi metodi di apprendimento: uno basato su un approccio classico e l'altro che sfrutta l'intelligenza artificiale (AI). Il quarto capitolo esplora dettagliatamente le misure utilizzate per valutare le performance del modello di machine learning e analizza i risultati ottenuti da entrambi gli approcci. Infine, nel quinto capitolo, vengono presentate considerazioni finali e possibili sviluppi futuri. In conclusione, questa ricerca, potrebbe contribuire all'innovazione nel campo della prevenzione delle lesioni muscolo-scheletriche e aprire la strada a nuove applicazioni nel campo della salute, della sicurezza sul lavoro e della qualità della vita. Questo studio potrebbe rappresentare un passo significativo verso l'ottimizzazione della salute muscolo-scheletrica, promuovendo uno stile di vita più sicuro e sano per gli individui.

# Capitolo 1

## Disturbi muscolo-scheletrici da sovraccarico biomeccanico

Il sistema muscolo-scheletrico rappresenta una complessa rete di strutture ossee, articolari e muscolari che svolgono un ruolo fondamentale nel fornire sostegno, difesa e abilità nei movimenti del corpo umano. Le malattie e i disturbi muscolo-scheletrici si verificano quando la capacità fisica dei muscoli, dei tendini e delle articolazioni non è in equilibrio con le forze applicate al corpo. Nel contesto lavorativo, il sollevamento di carichi pesanti emerge come una delle principali cause di affaticamento muscolare [7], infiammazione delle strutture tendinee e degenerazione dei dischi della colonna vertebrale. I disturbi comuni includono sensazioni di peso e fastidio, intorpidimento, formicolio, rigidità e dolore nella regione del rachide (collo e schiena), nonché agli arti superiori (spalle, braccia e mani) ed inferiori (gambe e piedi). Movimenti scorretti e posture statiche e prolungate possono anche contribuire a patologie dell'apparato circolatorio, come gonfiore agli arti e vene varicose. In questo capitolo definiremo i fattori di rischio biomeccanici, successivamente, esamineremo le patologie prevalenti nei diversi distretti anatomici colpiti da sovraccarico biomeccanico. Infine, esploreremo dettagliatamente gli aspetti preventivi e le norme tecniche da seguire al fine di mitigare il rischio di lesioni muscolo-scheletriche.

### 1.1 Fattori di rischio biomeccanici

I disturbi muscolo-scheletrici sono diffusi, soprattutto in contesti lavorativi, e la loro comprensione è essenziale per implementare adeguate misure preventive. Grazie alle moderne tecnologie ingegneristiche, possiamo calcolare con precisione l'entità del carico biomeccanico sostenuto dalle strutture anatomiche in risposta a differenti posizioni posturali assunte dai soggetti. Da queste analisi è emerso che il carico biomeccanico è massimo quando le posizioni adottate si discostano dalla posizione anatomica neutra [8]. Studi ulteriori indicano anche che il rischio di

disturbi aumenta significativamente quando queste posture vengono mantenute per lunghi periodi durante il lavoro, portando a sovraccarichi e danni ai tessuti. Inoltre, la movimentazione continua di un carico aumenta l'attività muscolare [9], portando all'affaticamento della zona e a una ridotta tolleranza al sollevamento [10]. Ricerche sul rachide mostrano che le pressioni sulla colonna sono proporzionali alla distanza e al peso dell'oggetto sollevato, di conseguenza anche il sollevamento scorretto di pesi relativamente leggeri, può compromettere l'integrità del disco nel tempo [11]. Oltre a danni a livello del tronco e lombare, la forza di impugnatura degli strumenti e il sollevamento di pesi possono correlarsi a problemi alle mani e ai polsi. La postura flessa o estesa e la deviazione ulnare contribuiscono ulteriormente ai disturbi del polso. Azioni come spingere, tirare, sollevare e trasportare carichi pesanti sono predittive per disturbi a collo, spalle, gomiti, polsi e mani. Movimenti ripetitivi, l'uso di strumenti pesanti e posture estreme del polso sono altri fattori di rischio [12]. Il sollevamento del braccio, in particolare sopra i 90°, è collegato ai disturbi della spalla, che possono derivare dalla riduzione del flusso sanguigno ai tendini della cuffia dei rotatori [13]. Infine posture scorrette del collo, in particolare la flessione superiore a 20 gradi per la maggior parte del turno lavorativo, sono associate a cervicalgie. È cruciale sottolineare che la complessità dei disturbi muscolo-scheletrici da sovraccarico biomeccanico rende arduo attribuirli esclusivamente al contesto lavorativo. Queste disfunzioni sono, infatti, influenzati da molteplici fattori, sia di natura individuale che ambientale. La comprensione approfondita di tali elementi risulta essenziale per promuovere in modo adeguato la salute nei contesti lavorativi.

## **1.2 Patologie e disturbi muscolo-scheletrici**

### **1.2.1 La colonna vertebrale**

Secondo i dati dell'INAIL, il 25% dei lavoratori dell'Unione Europea lamenta dolori alla schiena correlati alla movimentazione manuale dei carichi [14]. In anatomia, il termine "rachide" si riferisce a una struttura complessa costituita da vertebre, dischi intervertebrali, legamenti, muscoli e vasi sanguigni, che fornisce il sostegno primario del corpo. Il rachide ospita il midollo spinale, una struttura nervosa cruciale da cui si diramano i nervi verso le diverse parti del corpo. Muscoli e legamenti si inseriscono sulle vertebre, contribuendo alla stabilità e alla mobilità del rachide. Tra tutte queste strutture, il disco intervertebrale è particolarmente vulnerabile alle alterazioni, poiché svolge un ruolo chiave nel garantire la flessibilità della colonna durante vari movimenti e nel sopportare carichi considerevoli. Diverse patologie colpiscono tale distretto, tra cui lombalgie acute, malattie degenerative del disco e ernie discali [14]. Queste condizioni derivano principalmente dalle forze di compressione, taglio, torsione e flessione-estensione che agiscono sulla schiena, causando danni e fastidi [15]. La lombalgia, ad esempio, si presenta

con un dolore acuto causato da movimenti scorretti o sforzi eccessivi. Le malattie degenerative del disco comportano l'assottigliamento e la perdita delle caratteristiche di ammortizzatore del disco, interessando la zona cervicale [63], dorsale o lombare [64]. Queste patologie possono provocare dolore non solo nella zona colpita ma anche in altre parti del corpo. Ad esempio, l'artrosi cervicale può manifestarsi con cefalea, dolore al collo ma anche alla scapola e al braccio, accompagnato da formicolii o difficoltà nei movimenti. L'artrosi lombo-sacrale può causare dolori continui nella zona lombare e la formazione di osteofiti e sciatiche. Tra i disturbi alla schiena, l'ernia del disco si verifica quando il nucleo polposo del disco fuoriesce attraverso l'anello fibroso, andando a comprimere il nervo. Questa condizione è spesso conseguenza di movimentazioni manuali sovraccaricanti [65] e può provocare gravi disturbi come la lombo-sciatalgia, caratterizzata da dolore alla regione lombare irradiato al gluteo e alla coscia. Altre alterazioni della colonna vertebrale, come la scoliosi e l'iperlordosi, se presenti in forma rilevante, aumentano la probabilità di sviluppare disturbi alla schiena correlati al lavoro [14].

### **1.2.2 Gli arti superiori**

Le malattie da sovraccarico biomeccanico degli arti superiori coinvolgono patologie che interessano le strutture osteo-muscolo-neuro-tendinee e delle borse che sono sempre più frequentemente correlate a attività lavorative caratterizzate da un costante coinvolgimento funzionale dei diversi distretti dell'arto superiore. Queste problematiche sono prevalentemente concentrate sulla spalla, il gomito, il polso e la mano.

#### **Spalla**

La spalla è uno dei distretti anatomici maggiormente sollecitati durante il movimento degli arti superiori e presenta un'architettura anatomica molto complessa. I suoi movimenti, più ampi e numerosi rispetto a quelle di altre articolazioni, richiedono una maggiore libertà d'azione che corrisponde, anche, a una maggiore instabilità. Tra le alterazioni più comuni della spalla si riscontra la periartrite scapolo-omerale, caratterizzata da dolori iniziali leggeri, spesso notturni, seguiti da difficoltà nei movimenti delle braccia e, in assenza di trattamento, possono evolvere verso il blocco quasi totale dell'articolazione, noto come "spalla congelata" [16]. Altre patologie includono la tendinite della cuffia dei rotatori e le borsiti [17].

#### **Gomito**

I disturbi del gomito comprendono principalmente le epicondiliti e le epitrocleiti, patologie infiammatorie della giunzione osteo-tendinea causate da azione meccanica. L'epicondilite, comunemente nota come "gomito del tennista", coinvolge la parte laterale del gomito (epicondilo),

mentre l'epitrocleite o "gomito del giocatore di golf" è meno frequente e colpisce la parte mediale del gomito (epitroclea) [14]. Queste patologie rappresentano il 15% degli infortuni nelle industrie e sono considerate sindromi da sovraccarico, dove l'eccessivo stress funzionale dei muscoli coinvolti provoca infiammazione e dolore. Queste condizioni possono portare a difficoltà nella presa di oggetti e manifestarsi con dolore, gonfiore e possibile irradiazione lungo l'avambraccio [18].

## **Mano - Polso**

Tra le patologie più comuni a livello del polso, la sindrome del tunnel carpale è di rilievo. Questa condizione deriva dalla compressione del nervo mediano nel canale carpale, causata da un aumento della pressione all'interno. Fattori genetici, sociali, ambientali e occupazionali, soprattutto nelle attività con movimenti ripetuti del polso, sono associati all'insorgenza della sindrome. I sintomi iniziali coinvolgono dolore, intorpidimento e formicolii nelle prime tre dita della mano, spesso accentuati durante la notte. Al progredire della sindrome, i sintomi diventano più invalidanti anche durante le attività quotidiane [19]. Altre patologie riguardanti il polso comprendono le tendiniti, caratterizzate da dolore durante il movimento, e il dito a scatto, che comporta un nodulo nel tendine causando uno scatto caratteristico durante i movimenti di flessione ed estensione del dito interessato [14].

### **1.2.3 Gli arti inferiori**

Gli arti inferiori sono spesso soggetti a alterazioni connesse al lavoro, in particolare riguardanti il ginocchio e il piede. Queste patologie possono derivare da lavori prolungati in posizione inginocchiata o curva, e sono influenzate dall'intensità e dalla durata di attività che comportano sollecitazioni ripetute e microtraumi al ginocchio e al piede, come salti o la salita e discesa di gradini.

#### **Ginocchio**

Tra le patologie del ginocchio troviamo la lesione del menisco, la borsite pre-rotulea e la tendinopatia. La lesione del menisco è una tra le patologie più comuni del ginocchio e rappresenta un danno a carico dei suoi cuscinetti fibrosi, si manifesta con dolore, gonfiore e, nei casi più gravi, blocco articolare [20]. Quando, invece, si parla di borsite pre-rotulea si intende una condizione infiammatoria della borsa sinoviale situata vicino al ginocchio. Il segno caratteristico di queste patologie è il gonfiore localizzato, spesso nella parte anteriore o laterale del ginocchio associato a dolore e sensibilità nella zona colpita. Questa patologia è anche conosciuta con il nome di "ginocchio della lavandaia" poichè è correlato alle attività che si svolgono stando inginocchiati

[21]. La tendinopatia del ginocchio si riferisce a una condizione in cui uno dei tendini attorno all'articolazione del ginocchio è affetto da dolore, infiammazione o danni. Questa condizione può coinvolgere diversi tendini, ma uno dei più comunemente colpiti è il tendine rotuleo. Il dolore si manifesta nella parte anteriore del ginocchio, specialmente durante attività come correre, saltare o salire le scale ed è causato da sollecitazioni eccessive, sovraccarico o attività sportive con salti frequenti.

## **Piede**

Gli arti inferiori, in particolare la zona del piede, possono essere suscettibili a diverse patologie a causa di movimenti ripetitivi dell'arto inferiore. Queste condizioni spesso derivano da stress eccessivo, tensione muscolare o irritazione dei tessuti, provocati da specifici movimenti ripetitivi. Esaminiamo alcune delle patologie del piede correlate a tali dinamiche troviamo la talalgia plantare, infiammazione del tendine di Achille e la sindrome del tunnel tarsale [14]. La talalgia plantare è una condizione dolorosa che colpisce il tallone ed è spesso associata a soggetti costretti a posture erette prolungate o esposti a traumi ripetuti. Questa patologia può manifestarsi con dolore localizzato al tallone, specialmente durante il carico, come durante la deambulazione o il supporto del peso corporeo sulla parte anteriore del piede. Il tendine di Achille, che connette i muscoli del polpaccio al tallone, è, invece, suscettibile di infiammazione a seguito di movimenti ripetitivi di flessione dorsale del piede. Questa patologia si presenta con dolore, gonfiore, rigidità mattutina e, nei casi più gravi, riduzione della mobilità [22]. Infine la sindrome del tunnel tarsale coinvolge la compressione del nervo tibiale posteriore che attraversa il tunnel tarsale, una stretta via sul lato interno della caviglia. Questo nervo svolge un ruolo critico nel controllo e nella sensibilità dei muscoli della parte inferiore della gamba e del piede. La sindrome del tunnel tarsale si manifesta con dolore alla caviglia, al piede e talvolta alle dita, spesso associato a sensazioni di bruciore o formicolio durante la deambulazione. La causa esatta di questa infiammazione può essere attribuita a una combinazione di fattori, tra cui traumi, movimenti involontari o stress articolare, che possono convergere nella creazione di una sintomatologia dolorosa [23].

## **1.3 Prevenzione**

L'ampia diffusione dei Disturbi Muscolo-Scheletrici Relativi al Lavoro (WRMSDs) in varie professioni e i significativi costi sociali ed economici ad essi associati, sottolineano l'importanza di implementare programmi preventivi per limitarne l'insorgenza o prevenirli del tutto. Le evidenze scientifiche hanno confermato l'efficacia dei principi ergonomici nel ridurre e prevenire questi disturbi, proponendo strategie preventive [24]. Risulta essenziale fornire ai lavoratori informazioni adeguate sui rischi specifici connessi alla movimentazione manuale dei carichi. È

importante segnalare norme comportamentali ed accorgimenti da seguire per eliminare o ridurre al minimo la probabilità di rischi per la sicurezza e la salute associati a tale attività. Molte organizzazioni di prevenzione forniscono indicazioni dettagliate per una corretta movimentazione manuale dei carichi, accompagnate da illustrazioni grafiche che ne esemplificano i contenuti [25]. Inoltre l'apprendimento e l'adozione di stili di vita sani, con la pratica quotidiana di esercizio fisico e stretching [26,27], sono indicazioni preziose per la prevenzione e la tutela della salute. L'esercizio fisico, a sua volta, si è dimostrato efficace nel ridurre i sintomi, migliorando la salute, il benessere e la qualità di vita dei lavoratori. Integrare queste pratiche nella routine quotidiana può contribuire significativamente a mantenere la salute muscolo-scheletrica e prevenire disturbi legati all'attività lavorativa ("Back School"). La partecipazione e il coinvolgimento attivo dei lavoratori risultano, dunque, fondamentali nella prevenzione in questo ambito. I datori di lavoro, in aggiunta, dovrebbero adottare approcci di valutazione del rischio, considerando i lavoratori più a rischio e adattando le condizioni di lavoro di conseguenza [25].

## **1.4 Protocolli di valutazione del rischio**

Negli ultimi trent'anni, sono stati sviluppati diversi metodi per analizzare e quantificare il rischio di lesioni muscolo-scheletriche durante le attività lavorative, incorporati negli standard internazionali come ISO 11228-1, ISO 11228-2 e ISO 11228-3 . Questi metodi utilizzano diverse variabili per identificare le attività lavorative ad alto rischio e consentendo ai professionisti della sicurezza sul lavoro di identificare e implementare misure preventive. Tra i metodi tradizionali più noti per la valutazione del rischio vi sono:

- Revised Niosh Lifting Equation;
- Rapid Upper Limb Assessment (RULA);
- Rapid Entire Body Assessment (REBA);
- Occupational Repetitive Actions (OCRA);
- Strain Index (SI);
- Hand Activity Level (ACGIH – HAL).

### **1.4.1 Revised NIOSH Lifting Equation**

La "NIOSH lifting equation" [28] è uno strumento utilizzato per valutare il rischio di lesioni muscolo-scheletriche associate alle attività di sollevamento. La NIOSH lifting equation nasce nel 1981 dalla NIOSH (National Institute for Occupational Safety and Health). L'equazione




Figura 1.1: FAttori multipli per nell'equazione NIOSH

fornisce un metodo quantitativo per valutare il rischio di lesioni durante il sollevamento di carichi sul luogo di lavoro ed individuare limiti di peso sicuri per la movimentazione manuale di carichi. L'equazione tiene conto di vari fattori, tra cui il peso del carico, la distanza dal corpo, la frequenza dei sollevamenti e la postura. L'obiettivo è stabilire se un determinato compito di sollevamento può essere eseguito in modo sicuro o se è necessario apportare modifiche per ridurre il rischio di lesioni. La formula per trovare il limite di peso consigliato per l'attività di sollevamento è:

$$RWL = L \times H \times V \times D \times A \times F \times C$$

dove  $L$  è la costante di peso,  $H$  è la distanza orizzontale delle mani al centro del corpo,  $V$  la distanza verticale tra la mano che sorregge il carico e il pavimento,  $D$  la distanza verticale percorso dal carico sollevato, misurata dal punto di partenza al punto di arrivo,  $A$  rappresenta l'angolo di asimmetria del sollevamento. Il grado necessario per torcere il corpo durante l'attività di sollevamento,  $F$  è il tempo tra i sollevamenti e la durata complessiva dei sollevamenti durante un turno di lavoro, infine  $C$  è la qualità della presa sul carico definita come 'buona', 'sufficiente' o 'scarsa'.

Una volta quantificato ciascuno dei fattori richiesti dall'equazione RNLE, si procede al calcolo del valore di RWL e, successivamente, al calcolo dell'indice di rischio (Lifting Index - LI). Per trovare l'LI è necessario conoscere il peso del carico sollevato e avere il RWL per l'attività di sollevamento.

$$LI = \frac{Peso}{RWL}$$

L'LI dà un'indicazione del livello di rischio associato all'attività di sollevamento. Maggiore è l'indice maggiore è il rischio di DMS o lesioni. I numeri inferiori a 1,0 sono considerati sicuri



per la maggior parte dei lavoratori.

### 1.4.2 Rapid Upper Limb Assessment (RULA)

Il Rapid Upper Limb Assessment (RULA) è un metodo di valutazione posturale rapida che viene utilizzato per valutare il rischio di lesioni muscolo-scheletriche associate a posture di lavoro scomode o prolungate. Questo metodo è specificamente progettato per valutare le posture degli arti superiori, come braccia, spalle e collo, durante attività lavorative [29]. Con questo metodo è necessario, prima di iniziare la valutazione, identificare chiaramente il compito o l'attività che si sta valutando. Questo può includere qualsiasi attività che coinvolga movimenti degli arti superiori, come sollevamento, spostamento di oggetti, utilizzo di strumenti, ecc. Durante l'attività, l'operatore o l'individuo viene osservato attentamente tramite registrazione video. L'osservatore si concentra sulle posture degli arti superiori, osservando la posizione delle spalle, dei gomiti, dei polsi e delle mani selezionando le posture più significative per quella determinata attività. Per focalizzare l'attenzione su parti specifiche del corpo il corpo dell'individuo viene diviso in segmenti anatomici e per ognuno di essi vengono attribuiti punteggi in base alla posizione osservata. I punteggi tengono conto di fattori come la flessione, l'estensione, la lateralità e l'inclinazione degli arti superiori [30]. Sulla base dei punteggi assegnati, quindi, viene determinato il livello di rischio associato alle posture. Questo può variare da posture sicure a posture che richiedono un'azione correttiva immediata come visualizzato in Tabella 1.1.

Punteggio	Livelli di azione
1 o 2	Livello 1: Indica che la postura è accettabile se non è mantenuta o ripetuta per lunghi periodi
3 o 4	Livello 2: Indica che sono necessarie ulteriori osservazioni e che sono richieste delle modifiche.
5 o 6	Livello 3: Indica che sono necessarie indagini e modifiche in tempi brevi.
7	Livello 4: Indica la necessità di indagini e modifiche immediate.

Tabella 1.1: Livelli di rischio secondo il metodo RULA

### 1.4.3 Rapid Entire Body Assessment (REBA)

Nel Metodo REBA (Rapid Entire Body Assessment), sviluppato da McAtamney e Corlett presso l'Università di Nottingham nel 1993, si prendono in considerazione le posture assunte, la ripetitività dei movimenti, la forza applicata e attività statica del sistema muscoloscheletrico.

A differenza del metodo RULA, dal quale deriva, il REBA include anche la valutazione della esposizione degli arti inferiori [31]. Oltre alla postura, vengono analizzati altri aspetti quali il carico gestito, il tipo di presa e l'attività muscolare svolta dal lavoratore, sia in posture statiche che dinamiche. Questo metodo si dimostra particolarmente sensibile alle attività che comportano repentini cambiamenti di postura, come quelli derivanti dalla movimentazione di carichi instabili. La valutazione avviene attraverso l'analisi articolare delle posizioni assunte dalla parte superiore del corpo (braccio, avambraccio, polso), tronco, collo e gambe. Vengono assegnati punteggi a ciascuna zona corporea in base agli angoli formati rispetto agli assi di riferimento. Ogni combinazione di posture viene valutata in termini di livello di rischio. Il metodo utilizza una scala per assegnare un punteggio in base alla gravità delle pose, in base al punteggio ottenuto, vengono fornite raccomandazioni per migliorarle e ridurre, così, il rischio di lesioni muscolo scheletriche. In tabella 1.2 si osservano i diversi livelli di rischio.

Punteggio	Livelli di azione
1	Livello 1: Indica che la postura è accettabile se non è mantenuta o ripetuta per lunghi periodi
2 o 3.	Livello 2: Indica che sono necessarie ulteriori osservazioni e che sono richieste delle modifiche.
tra 4 e 7	Livello 3: Indica che sono necessarie indagini e modifiche in tempi brevi.
tra 8 e 10	Livello 4: Indica la necessità di indagini e modifiche urgenti.
tra 11 e 15	Livello 4: Indica la necessità di indagini e modifiche immediate.

Tabella 1.2: Livelli di rischi secondo il metodo REBA

#### 1.4.4 Occupational Repetitive Actions (OCRA)

Il metodo OCRA (Occupational Repetitive Actions) è uno strumento di valutazione ergonomico sviluppato per valutare il rischio di disturbi muscolo-scheletrici correlati alle attività lavorative caratterizzate da ripetitività e movimenti monotoni [32]. Per la precisione che consente di ottenere, il metodo OCRA è riconosciuto come il principale strumento per una valutazione dettagliata del rischio, secondo quanto stabilito dalla norma UNI ISO 11228-3. L'implementazione del metodo OCRA risulta molto complessa in quanto considera diversi fattori come la frequenza, ovvero quanti atti ripetitivi si eseguono in un determinato periodo di tempo, la forza richiesta per eseguire le azioni, la postura assunta durante l'esecuzione delle attività, la durata complessiva delle attività ripetitivi e le caratteristiche del ciclo di lavoro. Questo protocollo ci consente di

OCRA Index	Rischio	Azioni correttive
$\leq 2,2$	Rischio accettabile	Azioni correttive
$2,3 \div 3,5$	Rischio incerto / molto lieve	Ripetere la valutazione del rischio; ridurre il rischio laddove possibile.
$3,5 \div 4,5$	Rischio lieve	Riduzione del rischio secondo le priorità; sorveglianza sanitaria; interventi di informazione/formazione.
$4,5 \div 9,0$	Rischio medio	Riduzione del rischio a breve scadenza; sorveglianza sanitaria; interventi di informazione/formazione.
$\leq 9,0$	Rischio elevato	Riduzione immediata del rischio; sorveglianza sanitaria; interventi di informazione/formazione.

Tabella 1.3: Varie fasce di rischio e le relative azioni correttive associate secondo il metodo OCRA

ottenere un indice di rischio che dipende dal rapporto tra il numero di azioni tecniche eseguite durante il turno di lavoro ( $nATA$ ) e il numero massimo di azioni raccomandate ( $nRTA$ ).

$$IR = \frac{nATA}{nRTA}$$

Dove  $nRTA$  a sua volta viene ricavato come :

$$nRTA = \sum_{j=1}^n [k_f (F_M j \times P_M j \times R_e M j \times A_M j) \times t_j] \times (R_c M \times t_M)$$

ovvero il calcolo del numero massimo di azioni raccomandate, coinvolge parametri che considerano le peculiarità dei compiti svolti e la magnitudine dei fattori di rischio. Questi parametri includono: la forza applicata ( $F_M$ ); la postura dei diversi distretti articolari degli arti superiori ( $P_M$ ); la frequenza delle azioni eseguibili in condizioni ideali, pari ad una costante di 30 azioni/minuto ( $k_f$ ); l'inadeguatezza dei periodi di recupero ( $R_e M$ ); la durata dei compiti ripetitivi ( $t$ ); la durata del turno di lavoro ( $t_M$ ) e alcuni fattori complementari che caratterizzano l'attività ( $A_M$ ). Questo indice viene calcolato per ogni arto e il risultato finale del metodo OCRA si traduce in un punteggio di rischio che indica il livello di esposizione del lavoratore al rischio di disturbi muscolo-scheletrici come mostrato in tabella 1.3.

### **1.4.5 Strain Index (SI)**

Il Strain Index (SI) è un metodo per valutare situazioni in cui i lavoratori sono esposti a compiti che coinvolgono movimenti ripetitivi degli arti superiori [33]. Nonostante sia efficace nel pianificare misure preventive, il metodo presenta una limitazione importante, focalizzandosi esclusivamente sulla parte distale degli arti superiori, ossia avambraccio e mano. Al contempo, non tiene in considerazione altri distretti articolari cruciali come spalla e gomito. Il calcolo dello SI si basa sul prodotto di sei fattori ciascuno dei quali assume un valore specifico grazie a scale quantitative, esso prevede la valutazione di:

- Intensità dello sforzo;
- Durata dello sforzo;
- Frequenza delle azioni;
- Postura della mano e del polso;
- Velocità di svolgimento delle attività;
- durata del compito nel turno.

In funzione del valore SI assunto è possibile classificare il compito in tre fasce come mostrato in Figura 1.2.

### **1.4.6 Hand Activity Level (ACGIH – HAL)**

Il concetto di Hand Activity Level (HAL) è introdotto dall'ACGIH (American Conference of Governmental Industrial Hygienists) e rappresenta un metodo di valutazione del rischio ergonomico legato alle attività manuali ripetitive [34]. L'HAL si basa sull'analisi di due valori principali:

- Livello di attività manuale, teso come ripetitività dei movimenti e durata relativa del lavoro rispetto alle pause.
- Intensità della forza applicata, ovvero l'impegno muscolare a carico di ciascun arto nello svolgimento delle azioni che costituiscono il compito.

In base ai valori assegnati ai fattori, si individua un punto su un grafico (Figura 1.3) (HAL, forza massima). Su questo grafico, emergono tre zone distintive, corrispondenti a condizioni di rischio trascurabile, sensibile ed elevato. Le linee divisorie tra queste zone rappresentano il livello di azione (che segna il confine tra rischio trascurabile e significativo) e il TLV (limite

tra rischio significativo ed elevato). La posizione del punto su questo grafico indica il livello di rischio associato al compito in esame, per ogni livello vengono fornite le indicazioni utili per implementare misure preventive e migliorare le condizioni ergonomiche sul posto di lavoro.

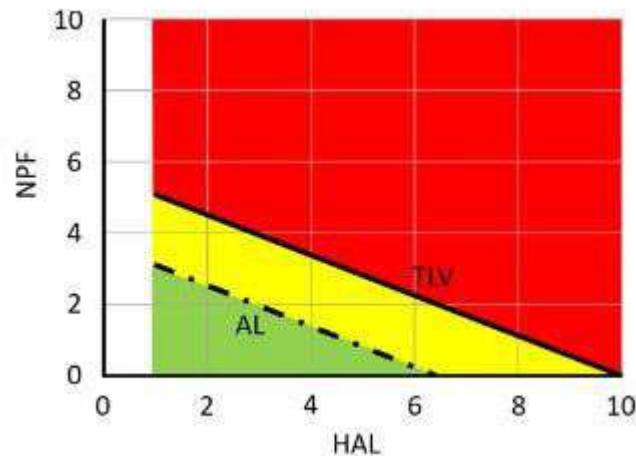


Figura 1.2: Limiti di soglia di attività della mano secondo il metodo HAL

#### 1.4.7 Strumentazioni per la valutazione del rischio

Ciascuno dei metodi sopra esaminati, sono stati progettati per precisi contesti applicativi e per la valutazione del rischio da sovraccarico biomeccanico in distretti anatomici specifici, considerando le diverse caratteristiche lavorative e organizzative. Pur offrendo diversi vantaggi, come l'economicità e la rapidità di applicazione, questi metodi presentano anche alcune limitazioni, principalmente legate alla soggettività nell'assegnazione dei punteggi finali di rischio. Tali metodologie sono prevalentemente di natura osservazionale e, pertanto, possono essere imprecise e dipendenti dalla competenza e dall'esperienza del valutatore [36]. Da tali limiti nasce l'esigenza di disporre di altre metodologie per la valutazione del rischio che siano quantitative, ripetibili, precise e oggettive e soprattutto utilizzabili facilmente nei moderni contesti lavorativi [6]. Diversi sistemi come quelli optoelettronici, sensori inerziali, elettromiografia di superficie e solette di pressione, ci permettono di integrare le metodologie tradizionali. Queste tecnologie permettono lo studio preciso del movimento delle articolazioni del soggetto in esame, la valutare dell'intensità di attivazione di determinati muscoli e del loro affaticamento, e lo studio delle distribuzioni plantari durante l'esecuzione di un task motorio.

#### 1.4.8 Sistemi optoelettronici

I sistemi optoelettronici per la valutazione del rischio biomeccanico rappresentano una categoria avanzata di strumenti utilizzati per analizzare e monitorare i movimenti del corpo durante

l'esecuzione di attività lavorative. Questi sistemi sfruttano tecnologie ottiche ed elettroniche per raccogliere dati precisi sui movimenti, consentendo una valutazione dettagliata degli sforzi biomeccanici e delle posture assunte dai lavoratori. Quando ci si riferisce a sistemi ottici normalmente si preferisce utilizzare la denominazione di "optoelettrici" in quanto questa tecnica combina l'utilizzo di sistemi ottici, come le telecamere, insieme a sistemi elettronici utili nell'acquisizione ed elaborazione dei segnali.



Figura 1.3: Esempio di setting del sistema optoelettronico, con le telecamere ad infrarossi e sul soggetto i marker catarifrangenti.

Questi sistemi sfruttano i principi della stereofotogrammetria: il movimento di un soggetto viene ripreso da più telecamere e poi ricostruito tridimensionalmente. A partire dalle posizioni assunte da punti specifici del corpo, in vari istanti di tempo, rispetto al sistema globale del laboratorio, si risale alla cinematica articolare del soggetto. In generale i sistemi optoelettronici utilizzano telecamere operanti nella gamma dell'infrarosso e si basano sull'utilizzo di marcatori posti sulla superficie corporea del soggetto (Figura 1.4). I marcatori possono essere di due tipi: marcatori attivi e marcatori passivi. I primi sono costituiti da LED e generano automaticamente un segnale luminoso capace di essere rilevato dalle telecamere. Tuttavia necessitano di un'alimentazione elettrica che potrebbe portare a problemi di ingombro riducendone, quindi, l'impiego. I marcatori passivi non presentano, invece, alimentazione e fili di collegamento. Sono costituiti da una sfera ricoperta da materiale catarifrangente e in grado di riflettere la luce emessa da un dispositivo di illuminazione. Sono quelli maggiormente utilizzati [35]. Sebbene questi metodi si siano rilevati utili e precisi nello studio delle posture e nella classificazione di diversi movimenti, permettendo anche il monitoraggio in tempo reali, essi sono limitati dai costi elevati richiesti e dalla necessità di un ambiente strutturato. Metodi di misurazione diretta, invece, prevedono l'utilizzo dell'elettromiografia di superficie e dei sensori inerziali. Questa tecnologia si propone di superare le limitazioni precedentemente menzionate.

### **1.4.9 Elettromiografia (EMGs)**

L'elettromiografia di superficie (EMGs) è una tecnica non invasiva utilizzata per monitorare l'attività elettrica dei muscoli superficiali durante l'attività fisica. In questo tipo di acquisizione degli elettrodi vengono posizionati sulla pelle, sopra i muscoli di interesse, e sono in grado di catturare le variazioni nel potenziale elettrico generato dalle cellule muscolari durante la contrazione. Durante l'attività muscolare, le unità motorie dei muscoli generano segnali elettrici noti come potenziali d'azione. L'EMG di superficie registra questi segnali, riflettendo l'intensità e il timing dell'attività muscolare. I segnali raccolti vengono amplificati e registrati per l'analisi anche in tempo reale. Il suo uso è previsto dai metodi standardizzati più comuni nella valutazione del rischio dei movimenti ripetuti dell'arto superiore per quantificare la forza muscolare [62]. Analisi più dettagliate permettono anche di avere indicazioni utili sull'affaticamento del muscolo. Tra i limiti troviamo il fatto che l'EMGs fornisce dati principalmente sul movimento di un gruppo ristretto di muscoli superficiali, limitando la capacità di ottenere informazioni approfondite. Inoltre la precisione dell'EMGs può essere influenzata dalla posizione dei sensori sulla pelle e richiedono la presenza di un esperto per la loro collocazione precisa. Infine i sensori così collocati potrebbero causare fastidio ed essere scomodi ai lavoratori [36].

### **1.4.10 Sensori Inerziali e solette di pressione**

La sensoristica inerziale è una tecnologia avanzata che si avvale di sensori di accelerazione e giroscopi per misurare accelerazioni, velocità angolari e orientamento di un oggetto o di una parte del corpo durante il movimento. Nel contesto dell'analisi del rischio biomeccanico, questa tecnologia sta guadagnando crescente rilevanza nella ricerca, poiché offre una visione dettagliata dei movimenti, consentendo una valutazione approfondita delle condizioni lavorative e dell'esecuzione di attività fisiche [40]. I moderni sensori offrono elevata precisione e affidabilità nelle misurazioni, garantendo dati accurati in tempo reale. Inoltre, essendo dispositivi poco ingombranti e indossabili direttamente sul corpo, consentono una valutazione del rischio in condizioni reali di utilizzo senza interferire con il gesto motorio del lavoratore. Le solette di pressione, d'altra parte, si configurano come validi strumenti di analisi del movimento e di identificazione dei rischi ergonomici [36]. Diversi studi hanno confermato l'importanza di questa tecnologia. Le posture generano pattern unici nelle pressioni plantari del piede, i quali vengono accuratamente catturati dalle solette [43]. Le solette di pressione sono utili nell'identificare alterazioni nella postura e nell'equilibrio, misurando le forze di impatto durante la deambulazione e fornendo dati utili per comprendere il carico biomeccanico su articolazioni e tessuti. Grazie ai significativi vantaggi descritti, emerge la centralità del lavoro svolto in questa tesi, focalizzato sull'identificazione e la classificazione automatica, continua e non invasiva delle diverse posture assunte dai

lavoratori. In particolare, i sensori IMU e di pressione, ampiamente impiegati per la rilevazione di posture errate in ambito lavorativo [37], costituiscono la chiave per la realizzazione di questa ricerca. L'idea fondamentale è amalgamare queste tecnologie al fine di ottenere informazioni più dettagliate e raggiungere una classificazione automatica più precisa e efficace. Per la loro grande importanza, il loro utilizzo verrà esaminato in modo più dettagliato nei capitoli successivi.

### Strain Index Scoring Sheet

Analysis Date: _____		Location: _____			
Analyst: _____		Job/Task Desc: _____			

Risk Factor	Rating Criterion	Observation	Multiplier	Left	Right
Intensity of Exertion (Borg Scale)	Light	Barely noticeable or relaxed effort (0-2)	1		
	Somewhat Hard	Noticeable or definite effort (3)	3		
	Hard	Obvious effort, unchanged expression (4-5)	6		
	Very Hard	Substantial effort, changed expression (6-7)	9		
	Near Maximal	Uses shoulder or trunk for force (8-10)	13		
Duration of Exertion (% of Cycle)	< 10%		0.5		
	10-29%		1.0		
	30-49%		1.5		
	50-79%		2.0		
	>80%		3.0		
Efforts per Minute <small>If duration of exertion is 100%, then Efforts/Minute multiplier should be set to 3.0</small>	< 4		0.5		
	4-8		1.0		
	9-14		1.5		
	15-19		2.0		
	≥ 20		3.0		
Hand/Wrist Posture	Very Good	Perfectly neutral	1.0		
	Good	Near neutral	1.0		
	Fair	Non-neutral	1.5		
	Bad	Marked deviation	2.0		
	Very Bad	Near extreme	3.0		
Speed of Work	Very Slow	Extremely relaxed pace	1.0		
	Slow	Taking one's own time	1.0		
	Fair	Normal speed of motion	1.0		
	Fast	Rushed, but able to keep up	1.5		
	Very Fast	Rushed and barely/unable to keep up	2.0		
Duration of Task per Day (Hours)	< 1		0.25		
	1 < 2		0.50		
	2 < 4		0.75		
	4 ≤ 8		1.00		
	> 8		1.50		
Results: Find the product of the six multipliers to obtain the SI score		SI ≤ 3	Job is probably safe		
		3 < SI < 7	Job may place individual at increased risk for distal upper extremity disorders		
		7 ≤ SI	Job is probably hazardous		

© 12/06 The Ergonomics Center of North Carolina

Figura 1.4: Foglio di punteggio dello Strain Index





## Capitolo 2

# Metodi di intelligenza artificiale

L'intelligenza artificiale (IA) nel XXI secolo costituisce il nucleo centrale della tecnologia. Questo settore dell'informatica si dedica allo sviluppo di algoritmi e sistemi in grado di eseguire compiti che tradizionalmente richiedono l'intelligenza umana. L'obiettivo primario dell'IA è la creazione di macchine capaci di apprendere, ragionare e risolvere problemi complessi in modo analogo agli esseri umani. Al suo interno, vengono impiegati diversi software in base alle esigenze, fondati sui concetti di machine learning e deep learning. L'IA è attualmente impiegata in svariati settori, tra cui automazione, attività industriali, analisi di video e immagini, elaborazione dei dati, ecc., ma la sua applicazione per il riconoscimento delle attività emerge come un'area particolarmente interessante e in rapida crescita. Tale approccio coinvolge l'utilizzo di tecnologie diverse, come EMGs, IMU e sensori di pressione, insieme a algoritmi e modelli di machine learning, per identificare e classificare automaticamente le diverse attività umane. La necessità di sistemi automatizzati di classificazione delle attività è stata riconosciuta in diversi settori. Nell'ambito clinico e sanitario, ad esempio, il monitoraggio dei pazienti per rilevare cambiamenti nei loro schemi di attività risulta utile nella gestione di malattie croniche [37,38]. Anche nell'ambito della sicurezza e del soccorso, il rilevamento delle attività riveste un ruolo fondamentale [39]. Recentemente, si è notato un crescente interesse nell'utilizzo dell'intelligenza artificiale per la rilevazione delle posizioni in ambito lavorativo. I Disturbi Muscolo-Scheletrici (DMS) costituiscono la principale causa di infortuni sul lavoro, con il potenziale di causare patologie croniche e disabilità permanenti. Fattori di rischio biomeccanici, come posture scomode, sforzi fisici, movimenti ripetitivi e sollevamento di carichi, possono contribuire a tali condizioni. Di conseguenza, è essenziale rilevare queste attività e utilizzare queste tecnologie per valutare il rischio biomeccanico del lavoratore. Nel prosieguo di questo capitolo, analizzeremo i principali algoritmi utilizzati in questo contesto [40], come Support Vector Machine (SVM), Decision Trees (DTs), k-Nearest Neighbors (KNN), Naive Bayes (NB) e Artificial Neural Network (ANN), fornendo una panoramica dello stato dell'arte nella classificazione delle posture.

## 2.1 Machine Learning

Il Machine Learning (ML) costituisce una sottobranca fondamentale dell'intelligenza artificiale, dedicandosi allo studio e alla creazione di algoritmi capaci di apprendere informazioni dai dati disponibili. La sua peculiarità risiede nella capacità di predire nuove informazioni basandosi su quanto appreso. Uno degli aspetti fondamentali del machine learning è la concetto di funzione costo, che gioca un ruolo cruciale nell'addestramento dei modelli. La funzione costo, o funzione di perdita (*loss function*), è una misura della discrepanza tra i valori predetti dal modello e i valori reali nel set di dati di addestramento. In altre parole, essa quantifica l'errore del modello rispetto alle risposte attese. L'obiettivo durante l'addestramento di un modello di machine learning è quello di minimizzare questa funzione costo. I sistemi di apprendimento nel machine learning possono essere principalmente divisi in due categorie:

- **Apprendimento supervisionato:** In questo approccio, il modello viene addestrato su un insieme di dati annotati, in cui ogni esempio è associato a un'etichetta o risposta conosciuta. L'obiettivo è insegnare al modello a fare previsioni o classificazioni basandosi su queste etichette.
- **Apprendimento non supervisionato:** Contrariamente all'approccio supervisionato, il modello nell'apprendimento non supervisionato deve fare previsioni o individuare pattern nei dati senza avere etichette o risposte predefinite. Qui, il modello cerca autonomamente modelli o strutture nei dati.

### 2.1.1 K Nearest Neighbor (KNN)

L'algoritmo dei K-Nearest Neighbors (K-NN) è un metodo di apprendimento supervisionato ampiamente utilizzato per la classificazione [41]. La sua idea fondamentale consiste nel classificare o predire l'etichetta di classe di un'istanza di test assegnandola in base alle classi di istanze di addestramento più simili.

Un modello Nearest Neighbor rappresenta ciascuna istanza del problema come un punto in uno spazio  $d$ -dimensionale, dove " $d$ " è il numero di attributi. La classificazione avviene confrontando le distanze tra gli attributi della nuova istanza e quelli presenti nel set di addestramento. Il parametro  $K$ , che indica il numero di vicini più prossimi da considerare, è cruciale per la classificazione.

Per identificare i vicini più prossimi, comunemente, si utilizza la distanza euclidea, che richiede spesso la normalizzazione dei dati per un confronto accurato. In questo modo, vengono individuati i  $K$  punti più vicini al punto da classificare, e in caso di più vicini, l'etichetta di classe è determinata dalla maggioranza delle etichette.

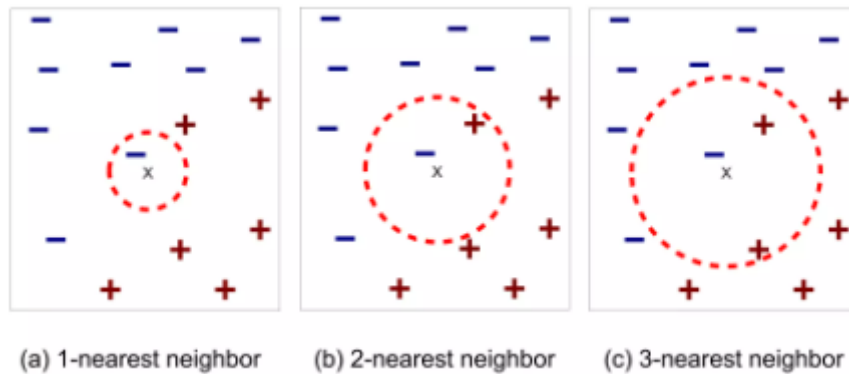


Figura 2.1: K-Nearest Neighbors con K=1,2,3

L'algoritmo offre il vantaggio di essere semplice da implementare e comprendere, adattandosi facilmente all'aggiunta di nuovi vettori di apprendimento. Tuttavia, cresce in complessità computazionale all'aumentare del dataset. La scelta di un valore appropriato per il parametro K è fondamentale: valori bassi possono portare a un adattamento eccessivo (overfitting), mentre valori alti possono causare previsioni errate includendo punti molto lontani dall'istanza nuova.

In sintesi, sebbene K-NN sia una tecnica flessibile e intuitiva, richiede attenzione nella gestione del parametro K per garantire risultati ottimali, bilanciando precisione e generalità del modello.

### 2.1.2 Naive Bayes (NB)

L'algoritmo di Naive Bayes è un metodo di classificazione probabilistico basato sul Teorema di Bayes [41]. La sua "ingenuità" deriva dall'assunzione che le caratteristiche utilizzate per la classificazione siano indipendenti, anche se questo può non essere sempre vero nella realtà. Il teorema di Bayes rappresenta il fulcro di questo algoritmo di classificazione; si utilizza per calcolare la probabilità condizionata di un evento, in base alle informazioni disponibili su altri eventi correlati. Consideriamo quindi una matrice delle caratteristiche  $X$  e il vettore classe  $y$ :

$$P(y|X) = \frac{P(X|y) \times P(y)}{P(X)}$$

Dove  $P(y|X)$  è la probabilità di osservare la classe  $y$  dato il campione  $X$ . Con le assunzioni fatte in precedenza :

$$P(y|x_1, \dots, x_n) = \frac{P(y) \prod_{i=1}^n P(x_i|y)}{P(x_1) \times P(x_2) \dots P(x_n)}$$

Poiché il denominatore rimane costante per un input dato possiamo scrivere:

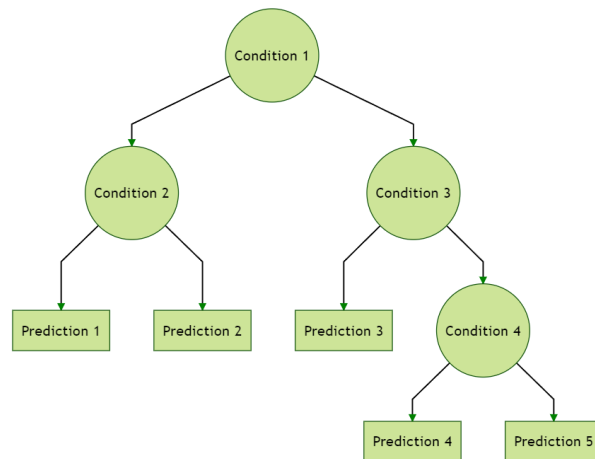


Figura 2.2: Albero decisionale

$$P(y|x_1, \dots, x_n) \propto P(y) \prod_{i=1}^n P(x_i|y)$$

Infine, si calcola la probabilità di un insieme dato di input per tutti i possibili valori della variabile di classe  $y$  e si sceglie l'output con la massima probabilità. Questo può essere espresso matematicamente come:

$$y = \underset{y}{\operatorname{argmax}} P(y) \prod_{i=1}^n P(x_i|y)$$

Ci sono diverse varianti di classificatori bayesiani, differenziati dal tipo di distribuzione di probabilità che adottano. Il punto di forza di questo tipo di classificatore risiede nella sua robustezza nei confronti del rumore e nella capacità di ottenere buone prestazioni anche con data set di dimensioni ridotte. Tuttavia, uno dei principali svantaggi di questo modello è rappresentato dall'assunzione di indipendenza tra le caratteristiche, aspetto che potrebbe non riflettere accuratamente la complessità di molte situazioni reali.

### 2.1.3 Decision Tree (DT)

Un classificatore ad albero decisionale (o decision tree) è un algoritmo di apprendimento supervisionato utilizzato per la classificazione e la regressione [41]. L'obiettivo principale è quello di creare un modello predittivo in forma di un albero di decisione, costituito da nodi che rappresentano decisioni e archi che collegano queste decisioni. Ogni nodo interno del ramo dell'albero contiene delle condizioni con cui gli attributi vengono confrontati e separati mentre ogni foglia rappresenta l'etichetta di classe o il valore predetto, e i rami rappresentano gli esiti possibili di ogni test. Durante l'addestramento la creazione dell'albero avviene tramite la divisione ricor-

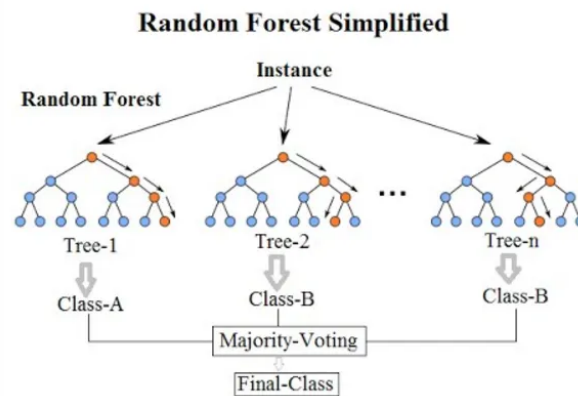


Figura 2.3: Random Forest

siva dei dati basata su regole decisionali. Questi criteri di divisione si basano sul fatto che la separazione dei dati deve aumentare l'informazione e ridurre l'impurità. Questa suddivisione continua fino a quando viene raggiunto un criterio di arresto, come una profondità massima, un numero minimo di campioni in una foglia, o quando tutti i dati in una foglia appartengono alla stessa classe. L'algoritmo così allenato è ora pronto per la classificazione: La nuova istanza da classificare si riduce ad applicare, partendo dalla radice, le condizioni di test di ciascun nodo all'istanza stessa a seguire il ramo composto dai risultati dei confronti. Questo algoritmo risulta facile da interpretare, la logica booleana e le rappresentazioni visive degli alberi li rendono più facili da comprendere e utilizzare. Gli alberi decisionali richiedono poca preparazione del data set in quanto riescono a lavorare sia con valori categorici sia continui e gestiscono bene i valori mancanti. Inoltre gli alberi decisionali possono essere utilizzati sia per la classificazione che per la regressione rendendo la loro applicazione più vasta e flessibile. Tuttavia, possono essere suscettibili all'overfitting, specialmente se non vengono controllati tramite tecniche come la potatura dell'albero o l'utilizzo di parametri di regolarizzazione. Inoltre piccole variazioni all'interno dei dati potrebbero produrre un albero decisionale molto diverso.

#### 2.1.4 Random Forest (RF)

Random Forest è una metodologia di classificazione e regressione che sfrutta la forza di un insieme di alberi decisionali indipendenti [41]. Ogni albero è creato utilizzando un set di dati (*Bags*) estratto con reinserimento in modo casuale dal set di dati originale, insieme a un sottoinsieme casuale delle caratteristiche. Questo processo, noto come *bagging* (Bootstrap Aggregating), contribuisce a creare diversità tra gli alberi. Durante la creazione di un nuovo modello, il dato da predire attraversa ciascun albero creato, e ogni albero emette un voto per la sua classe prevista. La classe che riceve la maggioranza dei voti diventa la previsione finale del Random Forest.

L'approccio di aggregazione di molteplici alberi rende il modello più robusto e meno incline all'overfitting rispetto a un singolo albero decisionale. Tuttavia, è importante notare che l'addestramento di molteplici alberi può richiedere risorse computazionali maggiori rispetto a un singolo albero, data la complessità computazionale associata alla gestione dell'ensemble

## 2.1.5 Support Vector Machine (SVM)

Gli algoritmi di Support Vector Machine (SVM) rappresentano un insieme di tecniche di apprendimento supervisionato con l'obiettivo principale di individuare l'iperpiano ottimale che massimizza la separazione tra due classi di un campione [41]. L'equazione dell'iperpiano è espressa come:

$$w^T x + b = 0$$

In un contesto di classificazione binaria bidimensionale, ad esempio, l'iperpiano corrisponde a una retta. L'obiettivo è identificare il piano che massimizza la distanza tra i punti più vicini delle due classi, noti come vettori di supporto.

Nel caso in cui i dati non siano linearmente separabili, viene introdotta la funzione kernel, che consente di mappare i dati in uno spazio di dimensione superiore, facilitando la separazione. La funzione kernel svolge questo ruolo di mappatura senza effettuare esplicitamente l'operazione, consentendo di ridurre la complessità computazionale associata alla trasformazione in uno spazio di dimensione maggiore. Tra i kernel più comuni ci sono il kernel lineare, gaussiano, sigmoidale e polinomiale. La decisione di assegnare una classe a un nuovo punto è basata su quale lato dell'iperpiano esso occupa. Gli SVM offrono numerosi vantaggi, tra cui l'efficacia in spazi ad alta dimensionalità, un'accuratezza elevata, la versatilità derivante dalla varietà di funzioni kernel e il minor utilizzo di memoria grazie all'uso di una parte dei dati di addestramento. Tuttavia, vi sono anche svantaggi associati agli SVM. L'addestramento può richiedere




Figura 2.4: Iperpiano con i margini minimi e massimi

una computazione intensiva, soprattutto su dataset di grandi dimensioni, comportando notevoli risorse temporali e computazionali. Le prestazioni dell'algoritmo dipendono significativamente dalla scelta dei parametri, inclusa la selezione del kernel, e la sua interpretazione può risultare più complessa rispetto ad altri algoritmi.

## 2.1.6 Rete neurale artificiale

Una rete neurale artificiale, nota anche come ANN (Artificial Neural Network) o più semplicemente NN (Neural Network), costituisce un sottoinsieme fondamentale del campo del machine learning e rappresenta l'elemento centrale degli algoritmi di deep learning [42]. Il termine "rete neurale" trae la sua ispirazione dai neuroni biologici presenti nel cervello umano, i quali sono connessi tra loro, ricevono informazioni, le elaborano e le trasmettono ad altri neuroni. Analogamente, una rete neurale artificiale riceve informazioni attraverso il suo strato di input, le elabora tramite uno o più strati nascosti (hidden layers) e quindi produce un risultato attraverso il suo strato di output.




Figura 2.5: Esempio di rete neurale con uno strato nascosto

Ogni nodo o neurone artificiale, all'interno di una rete neurale, è connesso ad altri nodi e possiede un peso associato. Tutti gli input vengono moltiplicati per i rispettivi pesi e quindi sommati. Il risultato viene passato attraverso una funzione di attivazione, che determina il valore di uscita, secondo la formula:

$$y_j = f \left( \sum_i w_{ij} x_i + b_j \right)$$

Dove  $j$  è l'indice del neurone del livello considerato,  $i$  indica l'indice del neurone del livello precedente,  $x_i$  è il valore di attivazione di ogni neurone  $i$ ,  $w_{ij}$  sono i pesi di ogni collegamento che unisce il neurone  $i$  al neurone  $j$ ,  $b_j$  è il valore di bias del neurone  $j$  mentre con  $f$  simboleggia



la funzione di attivazione non lineare. Quindi, per ogni livello nascosto e per il livello di output di una rete neurale, vengono applicate funzioni di attivazione ai nodi per produrre i valori di uscita dei nodi stessi. Questi valori di uscita vengono poi utilizzati come input per i nodi nel livello successivo, e così via, fino a raggiungere il livello di output finale. Questo processo di attivazione e trasmissione di informazioni attraverso i nodi è ciò che permette alla rete neurale di apprendere e prendere decisioni.

Nel contesto della classificazione, gli input di una rete neurale solitamente rappresentano caratteristiche (features) derivate dai dati dei sensori o da altre fonti. Gli output della rete, invece, rappresentano le diverse classi o categorie in cui gli input devono essere classificati. Per addestrare l'algoritmo, viene spesso utilizzato un approccio di apprendimento supervisionato, dove si forniscono dati in input insieme alle etichette di output corrispondenti per insegnare alla rete neurale a fare previsioni accurate. Nell'ambito di questa tesi è stato utilizzato questo approccio per l'addestramento del modello. Un esempio comune di rete neurale artificiale è il "*neural network multistrato feedforward*", che è una rete neurale con più strati nascosti in cui l'informazione viaggia in una sola direzione, dalla fase di input alla fase di output. I neuroni, quindi, possono avere connessioni entranti soltanto con i neuroni del livello precedente e connessioni uscenti con il livello successivo. Quando, invece, ciascun nodo di un layer è collegato a nodi del proprio layer o con nodi di layer precedenti, si fa riferimento a una Rete Neurale Multistrato Ricorrente. Per addestrare una rete neurale, viene spesso utilizzata la tecnica di retropropagazione (*backpropagation*). Questo processo prevede la correzione degli errori nell'output della rete attraverso un processo che si sposta nella direzione opposta; dall'output all'input. Durante l'addestramento del modello, l'accuratezza della rete neurale viene valutata utilizzando una funzione costo che calcola la distanza tra il valore di uscita predetto dalla rete ed il valore di uscita desiderato. In questa fase, quindi, il modello modifica i propri parametri interni in modo da ridurre il valore della funzione di errore. Il processo attraverso il quale l'algoritmo regola i pesi dei collegamenti tra i nodi della rete è noto come discesa del gradiente. Questo metodo consente al modello di determinare la direzione da seguire per ridurre progressivamente gli errori durante l'addestramento.

## **2.2 Stato dell'arte**

Numerose ricerche nel campo dell'intelligenza artificiale applicate al contesto lavorativo, sottolineano un crescente interesse nell'impiego di queste tecnologie per la classificazione delle attività lavorative. Dopo l'analisi del riconoscimento delle posture, la ricerca si è concentrata sull'utilizzo di vari sensori, tra cui inerziali, optoelettronici, EMGs e di pressione, per automatizzare il rilevamento del rischio biomeccanico. Dal punto di vista dell'accuratezza, diversi

algoritmi dimostrano buone capacità, rendendo difficile la scelta del classificatore ottimale. Tra gli algoritmi di tipo "ensemble", il Random Forest si è rivelato il più efficace, superando il 90% di accuratezza nel riconoscimento automatizzato delle attività legate allo sforzo e nella valutazione del rischio ergonomico. Ciò è stato ottenuto utilizzando una soletta di pressione e dati relativi all'accelerazione [43]. Un altro studio condotto da Roland Z. et al. [44] ha identificato posture utilizzando sensori di forza e accelerometri integrati in una sedia. Tra cinque metodi di machine learning testati (Support Vector Machine, Multinomial Regression, Boosting; Neural Network e Random Forest), il Random Forest ha raggiunto la migliore performance con una media dell'90.9% di accuratezza. Al contrario, l'algoritmo di Naive Bayes non è mai riuscito ad ottenere livelli di accuratezza elevati, probabilmente a causa delle sue limitazioni intrinseche. Il Naive Bayes si evidenzia come un approccio con limitate capacità di adattamento al dataset, mostrandosi particolarmente idoneo per input di natura categorica piuttosto che numerica. In aggiunta, richiede l'applicazione di algoritmi di livellamento per gestire situazioni in cui il dataset presenta una carenza di dati [45]. Il SVM, utilizzato da Ilaria C. et al., ha raggiunto un'accuratezza del 99.4% nel riconoscimento di posizioni scorrette attraverso dati cinematici provenienti da 8 sensori posizionati sui partecipanti [46]. Anche Adithyan P. et al. hanno conseguito successo nel riconoscimento automatico di posizioni scomode, impiegando come algoritmo il Support Vector Machine (SVM) con un'accuratezza del 94.4%. Questo risultato è stato ottenuto attraverso l'utilizzo di 13 sensori posizionati sul corpo dei partecipanti [47]. Tuttavia, studi futuri dovrebbero approfondire il costo computazionale elevato associato al SVM. Inoltre, lo studio utilizza numerosi sensori per la raccolta di dati sulle posture. Sebbene un maggior numero di sensori possa migliorare l'accuratezza delle classificazioni, risulta evidente che questa approccio risulterebbe poco pratico per un'applicazione nella vita reale. Un ulteriore studio [36] è stato concepito con l'obiettivo di classificare posture scorrette attraverso l'impiego di una soletta di pressione dotata di un accelerometro. La ricerca ha esaminato diversi algoritmi, tra cui Decision Trees (DT), K-Nearest Neighbors (K-NN), Support Vector Machine (SVM), e Artificial Neural Networks (ANN). I risultati indicano che l'SVM si dimostra particolarmente intuitivo nella classificazione delle diverse posture. Tuttavia, è importante notare che la limitazione di questa ricerca risiede nel fatto che la classificazione è stata condotta su posture statiche. Sarebbe pertanto opportuno approfondire ulteriormente tale indagine considerando anche condizioni dinamiche. Juhyeong R. et al. hanno impiegato gli algoritmi K-Nearest Neighbors (KNN), Support Vector Machine (SVM), e Multilayer Perceptron (MLP) nel riconoscimento delle attività, utilizzando un sensore inerziale posizionato sul polso [48]. Il MLP ha ottenuto la migliore performance con un valore del 97.38%. Gli altri algoritmi, comunque, si sono dimostrati altrettanto accurati. Va sottolineato che l'MLP è noto per la sua robustezza, in grado di identificare caratteristiche significative e relazioni anche in presenza di variazioni o interferenze nei dati, come il rumore. Le reti neurali

artificiali (ANN) sono state anche utilizzate per la classificazione delle posture mediante dati raccolti dall'EMG [49]. Le diverse features statistiche estratte da ciascun segnale EMG corrispondono all'attivazione di differenti muscoli associati a diverse posture. Complessivamente, data la vasta gamma di ricerche condotte, individuare il modello più adatto risulta complesso e difficile. La scelta del modello dipende dalle dimensioni del dataset e dalla complessità del problema. Poiché le reti neurali permettono di individuare tendenze in dataset estremamente complessi e presentano un'alta capacità di elaborazione in tempo reale, vengono utilizzate anche nel presente studio. Tuttavia, l'obiettivo si concentra anche sull'ottenere una buona accuratezza nel rilevare le attività di movimentazione manuale dei carichi con il minor costo computazionale possibile, impiegando solamente due sensori inerziali e due sensori di pressione direttamente posizionati sulle scarpe dei partecipanti all'esperimento. Nel capitolo successivo, verrà fornito un dettaglio completo della fase di elaborazione e classificazione delle attività.

# Capitolo 3

## Materiali e metodi

Nel presente studio, sono stati condotti una serie di esperimenti in un laboratorio per raccogliere dati di pressioni plantari, accelerazioni lineari e velocità angolari durante l'esecuzione di movimentazione manuale dei carichi. L'obiettivo di questa tesi è stato quello di riconoscere e classificare attività di sollevamento di carichi, distinguendole da altre tipologie di movimento. Per raggiungere tale scopo, i dati acquisiti sono stati utilizzati per l'allenamento di un algoritmo di classificazione. In questo capitolo verrà fornita una breve panoramica dei sensori inerziali noti come Inertial Measurement Unit (IMU) [50] e dei sensori di pressione chiamati Force Sensing Resistor (FSR). Questi strumenti, ampiamente utilizzati in diverse discipline, si rivelano altamente promettenti nell'ambito della medicina del lavoro e nelle applicazioni ergonomiche [51]. Successivamente, presenteremo in dettaglio il set up sperimentale e il protocollo di acquisizione dati.

### 3.1 Sensori Inerziali

I sensori inerziali (IMU) sono dispositivi elettronici che consentono di rilevare informazioni sul movimento, l'orientamento e la posizione del corpo, utilizzando una combinazione di accelerometri, giroscopi e talvolta magnetometri. Ciò che rende questa tecnologia straordinaria è la miniaturizzazione che ha permesso di creare dispositivi di dimensioni e peso ridotti (MEMS - Micro e Electro Mechanical Systems). Le micro-tecnologie e le nano-tecnologie hanno aperto la strada all'utilizzo dei sensori inerziali in una vasta gamma di ambienti applicativi, tra cui il loro impiego per il monitoraggio nei luoghi di lavoro. Questi aspetti rendono tali tecnologie ideali poiché sono semplici da indossare, compatti e dotati di protocolli di comunicazione wireless che consentono l'analisi del movimento in qualsiasi situazione, senza interferire con il gesto motorio del lavoratore. Di seguito verranno spiegati brevemente i due componenti IMU utilizzati in questo lavoro di tesi.

### 3.1.1 Accelerometro

L'accelerometro è uno dei componenti chiave dei sensori IMU ed è progettato per misurare l'accelerazione lineare di un oggetto. Gli accelerometri sfruttano il principio fondamentale della seconda legge di Newton: la forza ( $F$ ) è uguale alla massa ( $m$ ) moltiplicata per l'accelerazione ( $a$ ) applicata ad un oggetto.

$$F = m \times a$$

Il principio base di funzionamento dell'accelerometro si basa su un sistema massa-molla-smorzatore. Come titolo di esempio consideriamo l' accelerometro monoassiale visualizzato in Figura 3.1.




Figura 3.1: Modello fisico dell'accelerometro

Questo sistema presenta una massa di prova  $M$  in grado di generare una forza inerziale se sottoposta ad una accelerazione  $a_i$ . La massa è collegata ad una molla di costante elastica  $Ks$  fissata ad un *case*. In parallelo, sempre connessa con la massa, si trova uno smorzatore con fattore di smorzamento  $B$ . Quando l'accelerometro è soggetto ad una accelerazione, la massa interna risponde spostandosi e, misurando questo spostamento  $x$ , possiamo calcolare i valori di velocità e di accelerazione con le classiche leggi della dinamica:

$$v(t) = \frac{dx(t)}{dt} \quad a(t) = \frac{d^2x(t)}{dt^2}$$

Per derivare il modello fisico, quindi, si eguagliano le forze agenti sulla massa di prova con la forza di inerzia che agisce sulla molla, ottenendo così la seguente equazione:

$$Ma(t) = M \frac{d^2x(t)}{dt^2} + B \frac{dx(t)}{dt} + Kx(t)$$

Dalla quale si può ricavare l'accelerazione

$$a(t) = \frac{d^2x(t)}{dt^2} + \frac{B}{M} \frac{dx(t)}{dt} + \frac{K}{M}x(t)$$

Attualmente il principio della molla è superato, ad oggi si utilizzano materiali capacitivi, piezoresistivi e piezoelettrici. I primi due sono in grado di misurare il cambiamento di accelerazione dalla deflessione delle loro microplastiche capacitivo o piezoresistive mentre il terzo materiale è in grado di caricarsi elettricamente se compresso dalla massa. Nel caso degli accelerometri capacitivi, la massa, realizzata con materiale conduttivo, costituisce una delle armature, mentre l'altra armatura è fissa alla struttura del dispositivo. Un circuito dedicato rileva la capacità del condensatore e la converte in un segnale elettrico proporzionale alla posizione della massa, permettendo così di ricavare l'accelerazione dell'intero sistema. Gli accelerometri piezoelettrici, invece, sfruttano l'effetto piezoelettrico di alcuni materiali che sono in grado di convertire cambiamenti meccanici in piccoli segnali elettrici; quando una perturbazione fisica agisce sull'accelerometro, la massa provoca una compressione del materiale piezoelettrico e grazie alla variazione di tensione generata da questo materiale è possibile dedurre la forza applicata. I sensori MEMS trovano impiego anche come accelerometri. Tale tecnologia, anch'essa capacitiva, è facile da realizzare e gode di elevata accuratezza e stabilità. In Figura 3.2 viene rappresentata questa particolare struttura definita a "pettine" nella quale alcune armature sono fisse mentre altre sono mobili e collegate perpendicolarmente a un'asta. L'asta è ancorata alle sue estremità mediante delle molle di cui è nota la costante elastica, le quali ne determinano il suo movimento. Questo movimento provoca lo spostamento delle armature mobili rispetto a quelle fisse, generando una variazione delle capacità. Calcolando le differenze tra le capacità, si può ricavare lo spostamento della massa e quindi la sua accelerazione. Per ottenere misurazioni lungo i tre assi, è possibile montare tre di tali strutture in modo perpendicolare tra loro.

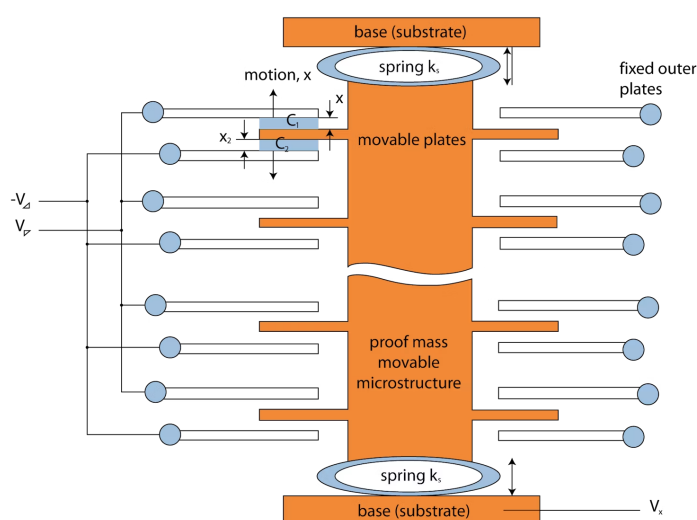


Figura 3.2: Accelerometro capacitivo MEMS

L'accelerometro a tre assi, è comunemente utilizzato per misurare l'accelerazione in tre direzioni spaziali: x, y e z. Combinando questi valori si può determinare con precisione il movimento e l'orientamento di un oggetto nello spazio tridimensionale.

### 3.1.2 Giroscopio

I giroscopi nei sensori IMU sono dispositivi progettati per misurare la velocità angolare o la rotazione di un oggetto intorno a un asse specifico. Questa tecnologia sfrutta il principio della forza di Coriolis; una forza apparente che agisce su oggetti in movimento quando li si osservano dai punti di vista di un sistema di riferimento rotante rispetto ad un sistema di riferimento inerziale. Per esempio, osservando la Figura 3.3, prendiamo una massa di prova  $m$ , che ruota attorno all'asse z con velocità angolare costante  $\Omega_z$  rispetto ad un sistema di riferimento inerziale e che si muove lungo l'asse x con velocità  $v$  rispetto al sistema rotante.




Figura 3.3: Forza di Coriolis

In questo caso la massa di prova sarà soggetta ad una forza di Coriolis, espressa matematicamente come:

$$\mathbf{F} = -2m\boldsymbol{\Omega} \times \mathbf{v}$$

Si può notare come  $F$  è in funzione della velocità angolare che è la variabile desiderata in output dal giroscopio.

$$\mathbf{a}_{cor} = -2\boldsymbol{\Omega} \times \mathbf{v}$$

Nei giroscopi MEMS vengono impiegate delle masse di prova con due coppie di braccia: due di queste coppie sono denominate *sensing arms* e forniscono la misura vera e propria, mentre le altre due coppie sono chiamate *drive arms* e sono fondamentali per il funzionamento del meccanismo. Le masse vengono fatte oscillare lungo l'asse di guida da degli attuatori, questo movimento degli elementi genera una velocità oscillante. Quando il sensore viene ruotato attorno ad un asse perpendicolare a quello di guida (lungo l'asse z secondo la Figura 3.4), viene prodotta una forza di Coriolis che devia il movimento vibrante verso l'asse di rilevamento. Questo movimento verticale causa la deformazione dei materiali piezoelettrici di cui sono costituiti i *sensing arms*, generando una differenza di potenziale e consentendo di misurare la velocità angolare dell'oggetto [52,53].

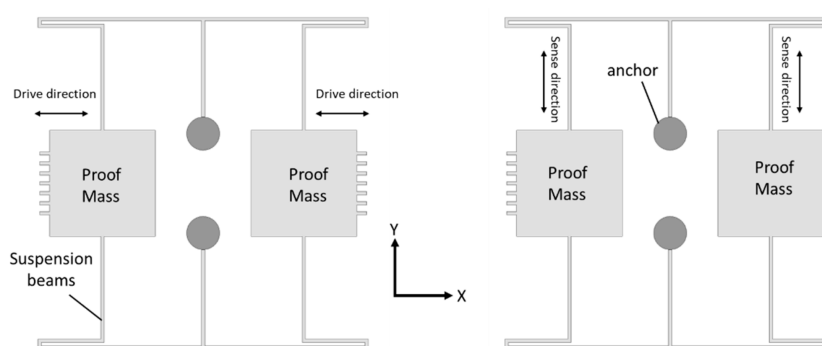


Figura 3.4: struttura giroscopio

## 3.2 FSR

Con il termine FSR (Force Sensing Resistor) si intende un tipo di sensore in grado di rilevare e misurare la forza o la pressione applicata ad una superficie. La tipologia di sensori di pressione più ampiamente adottata nelle applicazioni *wearable* è rappresentata dai sensori piezoresistivi, che sono anche quelli impiegati in questo studio. Questa tecnologia sfrutta elementi passivi caratterizzati da proprietà piezoelettriche, in grado di modificare la propria resistenza elettrica in risposta a deformazioni o pressioni. Essenzialmente questi elementi agiscono come resistori variabili in un circuito elettrico. Quando sono in uno stato di riposo presentano una resistenza elevata, che diminuisce all'aumentare della forza applicata. Questi sensori sono caratterizzati da una elevata sensibilità e sono in grado di fornire una risposta lineare proporzionale alla forza entro l'intervallo di misurazione previsto dal sensore. Di solito il materiale piezoresistivo viene integrato all'interno di una membrana di supporto appositamente progettata per garantire flessibilità e deformabilità. Questa membrana costituisce il substrato su cui viene esercitata la pressione o la forza da misurare. Per consentire la misurazione della variazione di resistenza, vengono applicati collegamenti elettrici direttamente sui materiali piezoresistivi. Prima di poter



essere impiegati in applicazioni pratiche, questi sensori richiedono un processo di calibrazione che stabilisce una correlazione tra l'output registrato dal sensore e l'intensità della forza applicata. Questa procedura di calibrazione è fondamentale per garantire la precisione delle misurazioni ottenuta dal sensore.

### 3.3 Partecipanti

Quattro partecipanti sono stati reclutati volontariamente per prendere parte all'esperimento. L'età media, il peso, l'altezza e il numero di scarpe dei partecipanti erano rispettivamente  $27.5 \pm 1.73$  anni,  $66.5 \pm 8.27$  Kg,  $1.6975 \pm 0.08$  m,  $39.75 \pm 2.9$  taglia UE, vengono riportate in dettaglio nella Tabella 3.1. Tutti i partecipanti, al momento dello studio, non presentavano storie di lesioni significative ai piedi o anomalie degli arti inferiori, né nessun tipo di disturbo muscolo-scheletrico, condizioni neurologiche o disabilità che avrebbero potuto influenzare il movimento o l'equilibrio.

Soggetto	Età (anni)	Peso (Kg)	Altezza (m)	Taglia scarpe UE	Taglia Yeti
soggetto 1	25	67	1.69	40	36/37
soggetto 2	28	60	1.60	36	36/37
soggetto 3	29	61	1.70	40	42/43
soggetto 4	28	78	1.80	43	42/43

Tabella 3.1: descrizione della tabella

### 3.4 Set up sperimentale

Per la rilevazione dei dati di accelerometro e giroscopio è stata utilizzata la piattaforma MITCH (Multipurpose InerTial CHameleon) <sup>1</sup> mentre per la raccolta dei dati di pressione la membrana Yeti <sup>2</sup>, entrambi i dispositivi sono stati sviluppati e prodotti dall'azienda 221e s.r.l [54], le specifiche sono riportate nelle tabelle 3.2 e 3.3.

<sup>1</sup><https://www.221e.com/wp-content/uploads/2023/03/221e-Mitch-datasheet-A3b4v02.pdf>

<sup>2</sup>[https://www.221e.com/wp-content/uploads/2023/01/221e-Yeti-datasheet-C3b1v02\\_mitch-addon.pdf](https://www.221e.com/wp-content/uploads/2023/01/221e-Yeti-datasheet-C3b1v02_mitch-addon.pdf)

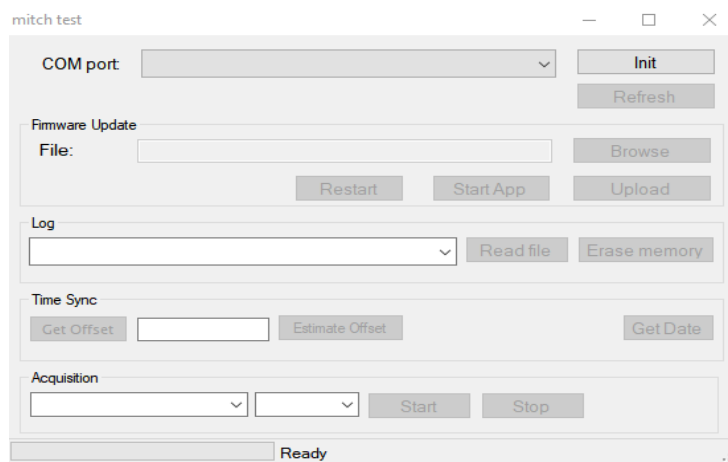
Accelerometer	Full scale: 16 g; sensitivity: 0.488 mg
Gyroscope	Full scale: 2000 dps; sensitivity: 70 mdps
Magnetometer	Full scale: 50 G; sensitivity: 1.5 mG
Microprocessor	32-bit ARM® Cortex®-M4-based
Sampling Frequency Memory Log	25 Hz / 1000 Hz
Sampling Frequency BLE streaming	5 Hz / 50 Hz
Memory	NAND Flash, 1 Gbit
Wired communication	USB 2.0, micro-USB connector
Wireless communication	Bluetooth Low Energy v4.1
Power supply	Rechargeable Lithium Polymer Battery 155 mAh, 0.57Wh
Board dimensions	29 W x 31 L x 7 H mm
Housing dimensions	48 W x 36 L x 21 H mm
Overall Weight	16 gr
Operating Temperature	-20°C / +60°C

Tabella 3.2: Specifiche tecniche MITCH

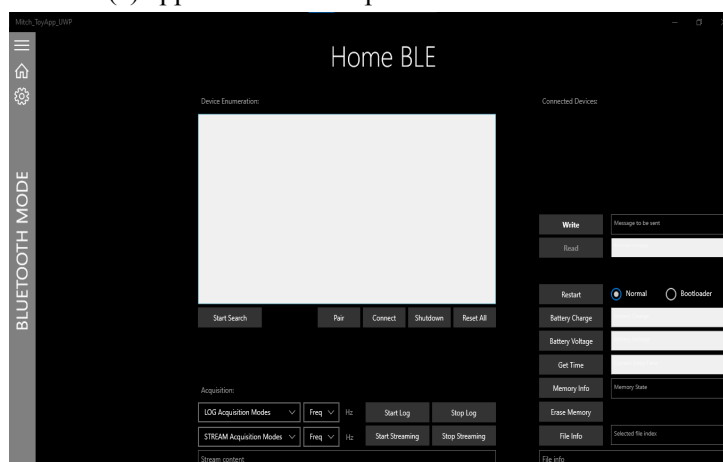
Substrate	Polyester
Overall membrane thickness	240 $\mu\text{m}$
Polyester with resistive print thickness	50 $\mu\text{m}$
Double sided adhesive separator thickness	90 $\mu\text{m}$
Circuit thickness	100 $\mu\text{m}$
Height/Width of the pads	16.67 mm / 15.00 mm
Overall sensing area	40.00 cm <sup>2</sup>
Connection flat length (including connector)	280 mm
Linearity (typical)	$\pm 10 \%$
Repeatability (typical)	$\pm 3 \%$
Operating Temperature	-20°C / +50°C
Taglie disponibile	36/37, 40/41, 42/43

Tabella 3.3: Specifiche tecniche Yeti

La membrana Yeti è dotata di 16 sensori di pressione posizionati strategicamente per massimizzare l'acquisizione di informazioni utili sulla camminata e sul monitoraggio della distribuzione delle pressioni plantari [55,56] (Figura 3.5 (b)). Prima di ogni utilizzo, ciascun dispositivo è stato connesso al computer tramite cavo USB ed è stato utilizzato un software per sincronizzare i vari MITCH con la data e l'ora del computer e per scaricare i dati acquisiti durante l'esperimento. In questa sezione era anche possibile visualizzare e, se necessario, ripristinare i dati in memoria. Un software BLE (Bluetooth Low Energy) è stato utilizzato per controllare le acquisizioni, consentendo il loro avvio e la loro conclusione. Per le acquisizioni è stata utilizzata la modalità "log" che permetteva di salvare i dati in memoria; in particolare sono stati acquisiti i dati di accelerometro, giroscopio e pressioni plantari ad una frequenza di campionamento di 100 Hz.



(a) applicazione USB per il download dei file



(b) applicazione BLE per il controllo dei dispositivi


Figura 3.5: Applicazioni utilizzate

Il set up sperimentale, inoltre, includeva la presenza di un carico che è stato ottenuto mediante l'uso di bottiglie di acqua per un totale di 6 Kg. Tutte le fasi di elaborazione dati, estrazione delle

caratteristiche statistiche, sviluppo del modello di classificazione e test di validazione sono stati eseguiti utilizzando il software Matlab (R2022b) <sup>3</sup>.



(a) dispositivo MITCH



(b) soletta YETI

Figura 3.6: Dispositivi utilizzati

I dati sono stati scaricati via USB e vengono salvati in chiaro in file di testo, come mostrato in Figura 3.7

```

File Modifica Cerca Visualizza Formato Linguaggio Configurazione Strumenti Macro Esegui Plugin Finestra ?
1 Device information:
2 Device Id: Mitch
3 Firmware Version: 5.5.0
4 Hardware Version: v2.0
5 Acquisition Information:
6 Mode:MODE IMU
7 Sampling frequency:100Hz
8 Axl FS:16 g Gyro FS:2000 dps
9 Timestamp Acc.X Acc.Y Acc.Z Gyro.X Gyro.Y Gyro.Z Magn.X Magn.Y Magn.Z Distance.x Distance.y P.0 P.1 P.2 P.3 P.4 P.5 P.6 P.7 P.8 P.9 P.10 P.11
10 1684934169414 -81.008 532.408 858.88 3.99 4.83 0 303 292.5 103.5 0 0 32 37 52 25 32 31 32 35 253 139 244 131 253 188 74 107 0 0 0
11 1684934169424 -93.696 540.216 852.048 33.32 -27.93 38.99 246 39 -348 0 0 32 37 52 25 32 31 32 35 253 141 247 136 253 189 74 107 0 0 0
12 1684934169434 -93.208 522.16 844.728 -15.19 10.64 -17.01 244.5 40.5 -345 0 0 32 37 52 25 32 31 32 35 253 141 252 141 251 135 252 189 74 108 0
13 1684934169444 -87.84 551.44 859.368 -15.61 7.35 -14.7 246 34.5 -346.5 0 0 32 37 51 25 32 31 32 35 253 141 252 135 252 189 74 108 0 0
14 1684934169454 -81.744 538.752 852.536 -5.04 0.7 -2.8 244.5 34.5 -351 0 0 32 37 52 25 32 31 32 35 253 143 253 139 252 190 74 108 0 0
15 1684934169464 -88.816 529.968 858.88 -2.31 -0.42 -0.28 241.5 37.5 -348 0 0 32 37 51 25 32 31 32 35 253 147 252 142 253 190 74 108 0
16 1684934169474 -91.256 536.8 846.68 -1.96 -0.56 -0.7 246 37.5 -346.5 0 0 32 37 52 25 32 31 32 35 253 149 253 144 252 190 74 108 0 0
17 1684934169484 -95.16 532.408 848.632 -3.43 -0.28 -0.7 252 31.5 -351 0 0 32 37 51 25 32 31 32 35 253 149 252 144 253 189 75 109 0 0
18 1684934169494 -109.312 525.088 864.736 -3.08 -0.07 -0.84 252 31.5 -345 0 0 32 37 51 25 32 31 32 35 253 150 252 147 252 190 74 109 0
19 1684934169504 -92.232 523.624 842.288 -3.85 -0.63 -1.4 252 31.5 -345 0 0 32 37 51 25 31 31 32 35 253 151 253 147 253 189 74 109 0 0
20 1684934169512 -97.6 531.432 858.88 -2.66 0.35 -0.91 250.5 39 -346.5 0 0 32 37 51 25 31 31 32 35 253 151 253 148 253 188 74 109 0 0
21 1684934169522 -103.844 525.088 848.144 -2.8 0.56 -0.84 247.5 37.5 -349.5 0 0 32 37 51 25 31 31 32 35 253 152 253 147 252 187 74 10
22 1684934169532 -100.04 529.968 850.096 -1.68 1.12 -0.7 246 33 -351 0 0 31 36 51 25 31 31 32 34 252 152 252 145 253 186 73 108 0 0 0
23 1684934169542 -98.088 525.088 854.976 -1.54 0.28 -0.35 246 34.5 -349.5 0 0 31 36 51 25 31 31 32 34 253 150 253 143 253 184 72 108 0 0
24 1684934169552 -104.432 526.064 862.296 -0.56 0.07 -0.07 244.5 31.5 -349.5 0 0 31 36 50 25 31 31 31 34 253 149 252 142 253 184 72 10
25 1684934169562 -95.648 523.136 860.344 1.12 -0.14 -0.21 244.5 27 -349.5 0 0 31 36 50 25 31 30 31 34 253 147 253 141 252 183 71 107 0 0
26 1684934169572 -101.016 529.48 863.272 0.98 -0.14 0.07 247.5 36 -351 0 0 31 36 50 25 31 30 31 34 252 145 252 141 253 183 71 106 0
27 1684934169582 -103.456 520.208 859.856 1.12 -0.56 0.28 252 43.5 -351 0 0 31 36 50 25 31 31 31 34 253 142 253 137 253 182 71 106 0
28 1684934169592 -102.48 531.432 857.416 2.73 -1.61 0.7 252 39 -351 0 0 31 36 51 25 31 30 31 34 253 143 253 137 253 182 71 106 0 0 0
29 1684934169602 -97.112 538.752 852.536 2.66 -1.54 0.91 247.5 33 -352.5 0 0 31 36 50 25 31 31 31 34 253 140 253 137 253 183 70 105 0 0
30 1684934169610 -96.624 533.384 857.904 2.8 -2.03 1.05 249 36 -346.5 0 0 31 36 51 25 31 31 34 252 136 253 136 252 183 70 105 0 0 0
31 1684934169620 -94.672 533.384 855.952 2.8 -2.1 1.05 253.5 39 -339 0 0 31 36 51 25 31 31 31 34 253 135 253 135 253 182 70 105 0 0 0
32 1684934169630 -97.112 529.968 849.608 3.36 -1.96 0.84 249 37.5 -345 0 0 31 36 51 25 31 31 32 34 253 134 252 134 252 183 71 105 0 0
33 1684934169640 -93.696 531.432 857.904 2.87 -1.96 0.84 244.5 30 -351 0 0 31 36 51 25 31 31 32 34 252 133 252 134 253 186 71 105 0 0
34 1684934169650 -89.304 537.288 853.024 2.8 -2.52 0.84 244.5 30 -352.5 0 0 32 37 51 25 31 31 32 35 253 131 252 134 253 186 71 105 0 0
35 1684934169660 -84.424 533.384 856.44 2.73 -1.82 0.35 244.5 37.5 -345 0 0 32 37 51 25 31 31 32 35 253 131 246 132 253 185 71 105 0
36 1684934169670 -85.4 538.752 856.928 2.87 -1.89 0 247.5 37.5 -340.5 0 0 32 37 51 25 31 31 32 35 253 131 238 131 253 186 71 106 0 0
37 1684934169680 -89.304 538.264 852.536 1.82 -1.54 -0.14 244.5 33 -343.5 0 0 32 37 51 25 32 31 32 35 253 130 236 131 253 186 71 105 0 0
38 1684934169690 -86.864 538.752 862.296 1.68 -1.26 0 246 28.5 -348 0 0 32 37 51 25 32 31 32 35 253 129 235 130 252 186 71 105 0 0 0
39 1684934169700 -81.136 533.384 855.952 1.32 0.56 0.35 246 33 348 0 0 32 37 51 25 32 31 32 35 253 128 234 129 252 185 71 105 0 0 ^
Normal text file length:3.984.651 lines:26.950 Ln:1 Col:1 Pos:1 Windows (CRLF) UTF-8 INS

```

Figura 3.7: Dati acquisiti in formato file di testo

<sup>3</sup>MATLAB R2022b, The MathWorks, Inc., Natick, Massachusetts, United States.

### 3.5 Protocollo di acquisizione dati

Le solette di pressione sono state posizionate all'interno della calzatura di ogni partecipante, mentre il dispositivo MITCH è stato fissato al piede utilizzando i lacci delle scarpe o una fascia elastica, come illustrato in figura 3.8



Figura 3.8: Set up sperimentale

Successivamente, è stato sviluppato un protocollo sperimentale per acquisire i dati di addestramento necessari per il modello di deep learning. Nello specifico sono stati selezionati due movimenti ampiamente diffusi nel contesto industriale: il sollevamento di un carico da terra e lo spostamento di un carico che prevede torsione del busto. I partecipanti hanno svolto questi compiti motori intervallati da una camminata di circa un minuto. La prima azione richiedeva di sollevare il peso da una scrivania, posta a 72 cm dal pavimento, e di appoggiarlo a terra, e viceversa. Questo movimento è stato eseguito in maniera corretta cioè piegando le ginocchia. La seconda attività consisteva nel spostare il peso da un'altezza di 72 cm a una di 148 cm. Ogni sollevamento è stato eseguito per tre volte, ottenendo così 6 movimentazioni manuali di carichi per ogni individuo d'esame, portando alla registrazione di 24 sollevamenti totali. Ai soggetti è stato chiesto di eseguire i movimenti nel modo più naturale possibile, al fine di ottenere una somiglianza con i gesti eseguiti nella vita reale.

## 3.6 Analisi dei dati

### 3.6.1 Pre-processing

La fase di elaborazione dei dati è stato un processo cruciale per garantire che i valori acquisiti fossero pronti per l'analisi. Attraverso l'applicazione vista precedentemente, sono stati scaricati, via USB, i segnali provenienti dalla sensoristica inerziale e dalle pressioni plantari in formato di testo. Successivamente, questi dati sono stati importati nel software Matlab per renderli leggibili e di più facile analisi. Come primo passo in questa fase di pre-processing è stata eseguita una verifica per assicurarsi che i vettori di timestamp dei piedi destro e sinistro avessero la stessa lunghezza. Questo è importante perché i sensori potrebbero aver iniziato a registrare l'attività in istanti diversi, portando a vettori tempo di lunghezza diversa, come mostrato in figura 3.9






Figura 3.9: (a) dati prima della sincronizzazione, (b) dati dopo la sincronizzazione

Per risolvere questo problema, è stata implementata una funzione apposita in grado di identificare il vettore dei dati più lungo e di effettuare un taglio opportuno. Questo lavoro è stato essenziale in quanto ci ha permesso di confrontare correttamente i dati dei due piedi, allineandoli temporalmente, e di avere risultati accurati per le analisi successive. Dal plot (Figura 3.10) delle pressioni plantari si può dimostrare come questa operazione sia stata essenziale per sincronizzare al meglio i dati.

Poiché il sensore inerziale MITCH integra al suo interno un magnetometro, che però non è stato preso in considerazione in questo studio, sono stati estratti e salvati in una matrice solo



(a)



(b)

Figura 3.10: Forze di reazione al suolo prima (a) e dopo (b) la sincronizzazione dei dati

i valori x,y,z di accelerometro e giroscopio e i 16 valori di pressione plantare di entrambi i dispositivi. In figura 3.11 si possono osservare tali dati per una porzione di acquisizione dove il soggetto stava camminando.

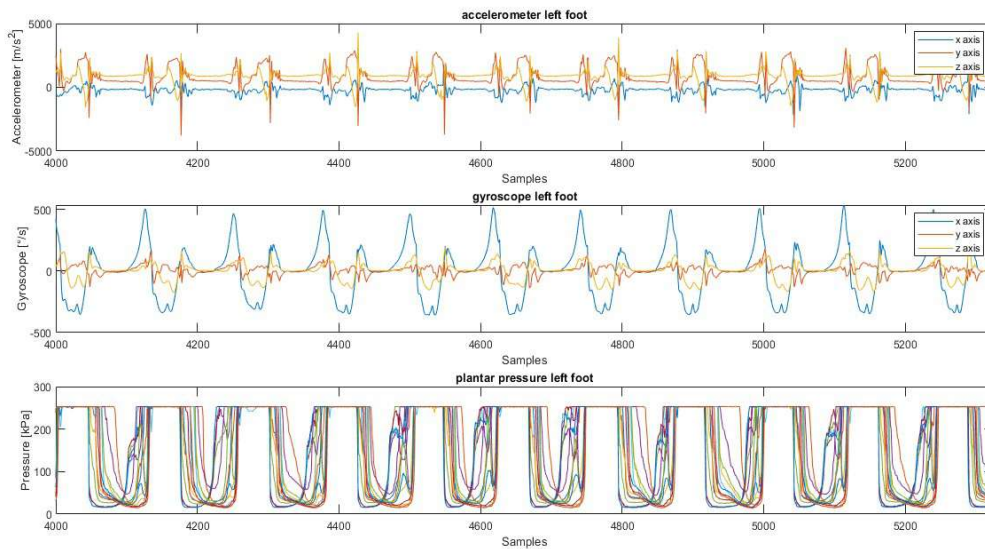


Figura 3.11: Dall'alto: valori di accelerometro, giroscopio e pressioni plantari del piede destro di un soggetto in camminata

<b>parametro</b>	<b>valore</b>	<b>95% intervallo di confidenza</b>	<b>CV%</b>
a	2.524	(2.243;2.804)	5.5%
b	-0.7137	(-0.7372;-0.6902)	1.6%
c	0.1350	(0.1340;0.1359)	0.4%

Tabella 3.4: parametri per la funzione di fit con il corrispondente intervallo di confidenza

Successivamente si è eseguito un processo di calibrazione dei dati di pressione ottenuti dai sensori. Come già spiegato precedentemente, quando si applica una forza o una pressione sulla superficie dei sensori FSR, il materiale sensibile all'interno del sensore si comprime provocando una variazione della resistenza elettrica. Questa variazione di resistenza viene tradotta in un segnale elettrico, sotto forma di tensione. Attraverso la calibrazione si stabilisce una relazione, in questo caso non lineare, tra la tensione elettrica e la forza applicata effettiva. La seguente funzione di calibrazione è stata estrapolata dall'azienda 221e s.r.l [57]:

$$F = f(V) = \left(\frac{V - c}{a}\right)^{\frac{1}{b}}$$

Per stabilire questa relazione, l'azienda 221e s.r.l, ha eseguito una serie di test in cui si sono applicate diverse pressioni conosciute ai sensori e si sono misurate le tensioni generate, questi valori hanno costituito il set di calibrazione. Successivamente i dati raccolti sono stati analizzati per determinare una curva di calibrazione e quindi una formula matematica in grado di correlare la tensione elettrica ai valori di forza applicata. Una volta ottenuta la relazione tra tensione e forza, sono stati calcolati i parametri di calibrazione, riportati in tabella 3.4. Si è poi andati ad ordinare le pressioni plantari, e quindi i *pads*, attraverso delle funzioni opportunamente create, in modo da rendere le pressioni del piede destro perfettamente speculari alle pressioni del piede sinistro. Come ultime due procedure si sono invertire le pressioni in modo tale che acquisissero solo valori crescenti all'aumentare del carico applicato e si sono raggruppati i sensori in due zone: avampiede e retro piede.

### 3.6.2 Etichettatura dei dati

Nella seconda fase del processo, è stata posta l'attenzione sull'etichettatura dei dati, con l'obiettivo di identificare i periodi in cui si verificava il sollevamento del carico. Questo processo è avvenuto manualmente e ha richiesto l'individuazione degli istanti di inizio e fine di ciascun gesto motorio associato al sollevamento. Durante il movimento sono emerse variazioni significative nei dati registrati dall'accelerometro e dal giroscopio lungo i tre assi. In particolare, l'asse z, che era orientato frontalmente, ha rilevato variazioni nell'accelerazione in avanti o indietro rispetto alla caviglia. Queste variazioni sono emerse perché la caviglia si inclina in avanti o indietro per sollevare o abbassare il carico. Per quanto riguarda il giroscopio una significativa



variazione la si è osservata lungo l'asse x in quanto registrava la rotazione della caviglia attorno proprio a questo asse durante l'accosciata. Inoltre, sono state rilevate altre variazioni nei segnali dei sensori dovuti a passi di avvicinamento o di allontanamento dal tavolo compiuti dal soggetto prima e dopo l'esecuzione del movimento di sollevamento.

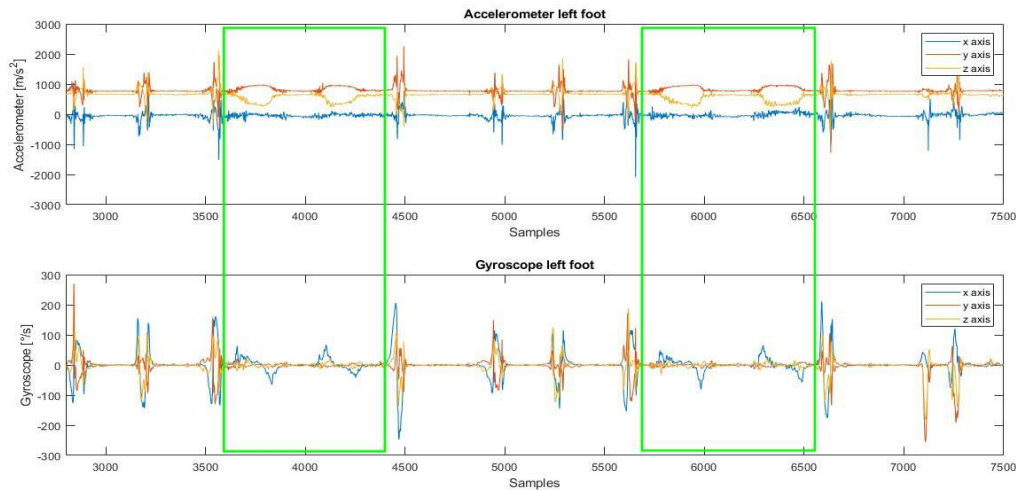


Figura 3.12: Valori di accelerometro e giroscopio di due sollevamenti

Una volta individuati gli istanti iniziali e finali in base a queste variazioni nei dati dei sensori, le informazioni sono state salvate in un vettore. I dati etichettati sono stati salvati in una struttura “cell” insieme ai loro valori di accelerometro, giroscopio e pressioni plantari corrispondenti. Le etichette ottenute da questo processo sono state successivamente combinate con i dati relativi ad altre classi di movimento, creando così un dataset di addestramento completo, che è poi risultato fondamentale per l'allenamento del modello di machine learning permettendogli di apprendere e classificare automaticamente i diversi tipi di movimento.

### 3.6.3 Caratteristiche statistiche

Nel contesto del machine learning, le *features* (caratteristiche o attributi di un segnale) rappresentano le variabili o i dati di input utilizzati per addestrare un modello e fare previsioni o classificazioni. In altre parole, quando si acquisiscono dati da un sensore, questi dati possono essere elaborati o trasformati attraverso vari metodi. La scelta delle *features* gioca un ruolo importante in un sistema di riconoscimento delle attività. Quando si analizzano dati o segnali provenienti da diverse attività, infatti, l'estrazione delle caratteristiche mira ad identificare gli aspetti distintivi o le proprietà rilevanti di tali segnali che li rendono simili all'interno della stessa categoria o classe. Durante la scelta delle caratteristiche bisogna tenere in considerazione diversi aspetti, come la loro complessità di calcolo o il loro numero poiché potrebbero avere un grande impatto

sulle prestazioni del sistema. In questo lavoro di tesi sono state scelte *features* nel dominio del tempo, che forniscono statistiche sui segnali e richiedono capacità di calcolo ridotta, in quanto sono ottenute con semplici funzioni matematiche. Otto caratteristiche statistiche sono state estratte da ognuno dei tre assi dell'accelerometro, del giroscopio e per ognuno dei dati di pressione anteriore e posteriore; questo ci ha permesso di ottenere un totale di 64 attributi [58]. Queste caratteristiche sono state calcolate per tutti i sollevamenti del carico e per una breve porzione di camminata; permettendoci di condurre un confronto delle caratteristiche al fine di analizzare le variazioni che si verificano durante i due tipi di movimento. Di seguito vengono spiegate nel dettaglio le otto caratteristiche calcolate:

1) *Media* : La media è definita come il valore che si ottiene addizionando tra loro dati numerici e dividendo la somma ottenuta per il numero dei dati raccolti. La media di una variabile  $x$ , dati  $n$  valori può essere espressa come

$$Media(x) = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.1)$$

2) *Varianza*: La varianza di una variabile  $x$  fornisce una misura della variabilità dei valori assunti dalla variabile stessa; nello specifico è la misura di quanto essi si discostino quadraticamente dalla media aritmetica o dal valore atteso.

$$var(x) = \frac{1}{n-1} \sum_{i=0}^n (x_i - \mu)^2 \quad (3.2)$$

3) *Standard Deviation*: La deviazione Standard è definita come la radice quadrata della varianza

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=0}^n (x_i - \mu)^2} \quad (3.3)$$

4) *Massimo*: definiamo il massimo  $M$  di un insieme  $A$  come l'elemento di  $A$  maggiore o uguale a tutti gli elementi dell'insieme  $A$

$$\begin{cases} M \in A \\ M \geq a \quad \forall a \in A \end{cases}$$

5) *Minimo*: definiamo il minimo  $m$  di un insieme  $A$  come l'elemento di  $A$  minore o uguale a tutti gli elementi dell'insieme  $A$

$$\begin{cases} m \in A \\ m \leq a \quad \forall a \in A \end{cases}$$

6) *Kurtosis* : il valore di kurtosis della variabile  $x$ , avente media  $\mu$  e standard deviation  $\sigma$  è data da

$$\kappa = \frac{E\{x - \mu\}^4}{\sigma^4} \quad (3.4)$$

7) *Skewness*: il valore di skewness della variabile  $x$ , avente media  $\mu$  e standard deviation  $\sigma$  è data da:

$$\gamma = \frac{E\{x - \mu\}^3}{\sigma^3} \quad (3.5)$$

8) *Root Mean Square (RMS)*: il valore RMS di un segmento di dati è la radice della media dei quadrati. Il RMS di una variabile casuale  $x$  avente  $n$  valori può essere espressa come

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (3.6)$$

### 3.6.4 Box-plot

Le varie *features* così calcolate, sono state poi visualizzate nei boxplot, per verifica visiva della distribuzione dei dati tra la camminata e il sollevamento. Essi, infatti, sono uno strumento statistico molto utilizzato in quanto mostrano la distribuzione dei dati per una variabile continua. Quando si ha a che fare con dei box-plot bisogna tenere in considerazione diversi elementi fondamentali:

- La linea centrale del box rappresenta la mediana dei dati, se i dati sono simmetrici allora la mediana si troverà al centro del rettangolo altrimenti sarà spostata più in alto o più in basso.
- La parte superiore ed inferiore del box mostrano invece i 75° e 25° percentile o quantile e la sua lunghezza è la differenza tra i due percentili e si chiama range interquartile (IQR).
- Le linee che si estendono a partire dal box sono chiamate baffi. I baffi rappresentano la variazione dei dati attesa e si estendono per 1.5 volte IQR sia superiormente che inferiormente. Se i dati ricadono sopra o sotto questi limiti allora vengono rappresentati con dei “+”, questi valori sono chiamati *outliers* e rappresentano valori che potrebbero essere considerati anomali rispetto al resto del data set.

A fine capitolo vengono mostrate i box-plot delle features di accelerometro (Figura 3.15), giroscopio (Figura 3.16) e pressioni plantari (Figura 3.17).

## 3.7 Selezione delle caratteristiche

La selezione di un sottoinsieme di features è stata una fase cruciale nel processo di analisi dei dati. In questa fase sono state scelte solo quelle caratteristiche che contenevano maggiori informazioni. I vantaggi della selezione delle caratteristiche sono molteplici: diminuisce la complessità del modello, aumenta la sua accuratezza generale e inoltre la scelta di un sottoinsieme più specifico di caratteristiche, riduce il tempo necessario per allenare il modello [59]. In questo studio, la selezione delle features è stata effettuata attraverso due modalità: la prima segue un approccio “classico” basato sull’osservazione dei box-plot, calcolati in precedenza, mentre la seconda utilizza un metodo iterativo descritto nella sezione 3.10.1.

### 3.7.1 Approccio classico

La selezione delle caratteristiche più significative con l’approccio classico è avvenuto mediante un’osservazione diretta dei box-plot. In particolare, le caratteristiche che presentavano differenze significative tra la camminata e il sollevamento sono state identificate come rilevanti. A titolo di esempio, si considerino i due grafici riportati in seguito:

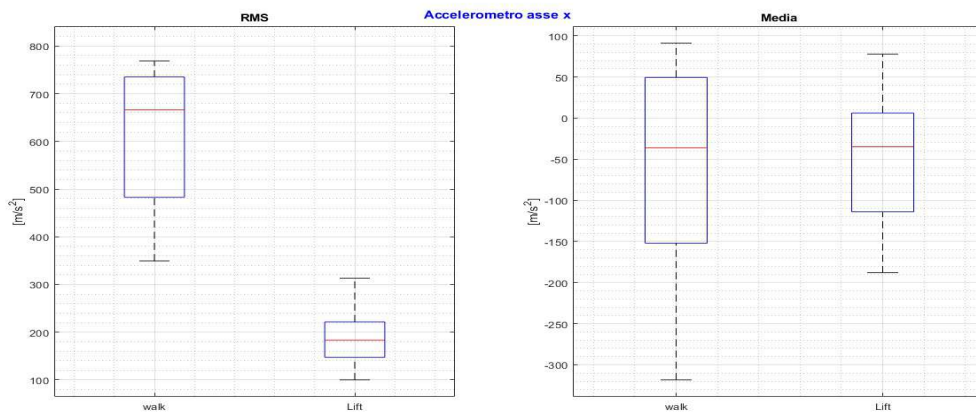


Figura 3.13: Da sinistra a destra: Box plot dell’RMS e della media di accelerometro lungo l’asse X

Dai boxplot presentati, possiamo trarre alcune osservazioni rilevanti per la selezione delle caratteristiche: nel grafico dell’RMS, possiamo notare una chiara separazione tra i gruppi delle classi “*lift*” e “*walk*”. Ciò suggerisce che i dati si trovino in una posizione completamente diversa per le due classi, indicando che questa caratteristica è importante per discriminare le due attività. Nel grafico della media, invece, i due box risultano molto vicini con all’incirca la stessa mediana, indicando una scarsa separazione tra le classi, questo suggerisce che la feature non è distintiva per le due categorie. Attraverso questa tecnica si sono scelte 14 caratteristiche

principali, utilizzate in seguito per la classificazione “classica” basata sull’utilizzo di soglie. Le caratteristiche scelte sono:

- Deviazione standard di accelerometro lungo la direzione x
- Deviazione standard di accelerometro lungo la direzione y
- Deviazione standard di accelerometro lungo la direzione z
- Root Mean Square di accelerometro lungo la direzione x
- Root Mean Square di accelerometro lungo la direzione y
- Root Mean Square di accelerometro lungo la direzione z
- Root Mean Square di giroscopio lungo la direzione x
- Varianza di accelerometro lungo la direzione y
- Varianza di accelerometro lungo la direzione z
- Varianza di giroscopio lungo la direzione x
- Varianza di giroscopio lungo la direzione y
- Varianza di giroscopio lungo la direzione z
- Varianza delle pressioni plantari posteriori
- Skewness delle pressioni plantari anteriori

Inoltre si sono osservate differenze significative tra i diversi tipi di sollevamento, ciò indica che anche i due tipi di sollevamento potrebbero essere distinguibili tra loro. Queste osservazioni sono di notevole importanza in quanto suggeriscono la possibilità di sviluppare ulteriori ricerche future.

### **3.8 Modello AI**

Per costruire il modello di deep learning utilizzato in questo studio, abbiamo inizialmente definito l’architettura della rete, includendo i seguenti strati (*layers*) mostrati nell’elenco 3.1.

```

1 layers_new = [
2     featureInputLayer ( numFeatures , "Name" , "input" , "Normalization" , "
3         zscore" )
4     fullyConnectedLayer ( 10 , "Name" , "Fully_connected_layer_1" )
5     batchNormalizationLayer ( "Name" , "Batch_Normalization_layer" )
6     reluLayer ( "Name" , "ReLU_layer" )
7     fullyConnectedLayer ( numClasses , "Name" , "Fully_connected_layer_2" )
8     softmaxLayer ( "Name" , "Softmax_layer" )
9     classificationLayer ( "Name" , "Classification" ) ];

```

Listing 3.1: Architettura della rete neurale

Abbiamo iniziato definendo uno strato di input delle caratteristiche (*featureInputLayer*) con un numero di caratteristiche pari a “*numFeatures*”. Questo strato è stato denominato “*input*” e include una normalizzazione dei dati utilizzando “*z-score*”; ai dati viene sottratta la media e vengono divisi per la deviazione standard. Successivamente si è aggiunto uno strato completamente connesso (*fullyConnectedLayer*) con 10 neuroni identificato come “*Fully connected layer 1*” . In questo strato, ciascun neurone è connesso a tutti i neuroni del layer precedente e, per ogni input precedentemente normalizzato  $x_i$ , moltiplica una matrice di pesi  $W$  e somma un vettore *bias*  $b_i$ .

$$z_i = Wx_i + b_i$$

Dopo di ciò abbiamo inserito uno strato di normalizzazione in batch (*batchNormalizationLayer*). Questo strato normalizza le attivazioni dei neuroni nel mini-batch, contribuendo a stabilizzare l’addestramento della rete e migliorare la convergenza. In termini pratici, per ogni elemento  $z_i$  dell’input precedente, vengono calcolate la media  $\mu$  e la varianza  $\sigma^2$  per ciascun canale, quindi si calcolano le attivazioni normalizzate utilizzando la seguente formula:

$$\hat{x}_i = \frac{z_i - \mu}{\sqrt{\sigma^2 + \epsilon}}$$

Le attivazioni normalizzate vengono quindi ridimensionate mediante un parametro di scala  $\gamma$  e di offset  $\beta$

$$y_i = \hat{x}_i\gamma + \beta$$

A seguire, abbiamo incluso uno strato di attivazione ReLu (*reluLayer*), denominato “*ReLU layer*”. Questo strato applica una funzione di attivazione *Rectified Linear Unit (ReLU)* alle uscite dei layers precedenti. Questa funzione è utilizzata comunemente per introdurre non linearità nella rete, consentendo di apprendere rappresentazioni complesse dei dati. Nello specifico la funzione esegue un’operazione di soglia su ciascun elemento di input, impostando a zero

qualsiasi valore inferiore a zero:

$$f(x) = \max(0, x)$$

Dopo lo strato ReLU, abbiamo applicato nuovamente uno strato completamente connesso e aggiunto uno strato di Softmax (*softmaxLayer*), chiamato “*Softmax layer*”. In problemi di classificazione la funzione di attivazione softmax è comunemente utilizzata nell’ultimo livello della rete neurale. Questa funzione calcola la probabilità della classe corrente rispetto alle altre, consentendo di fare previsioni di classificazione. Infine, abbiamo inserito uno strato di classificazione (*classificationLayer*), denominato “*Classification*”. Questo strato è responsabile della classificazione finale dei dati in base alle probabilità prodotte dallo strato Softmax ed è associato alla funzione di perdita di entropia incrociata; aiuta a determinare la classe di appartenenza per ciascuna serie di dati in ingresso.

Dopo aver definito l’architettura della rete, ci siamo concentrati sulla configurazione delle sue opzioni di addestramento utilizzando la funzione *trainingOptions*. In particolare per l’addestramento di questa rete è stata utilizzata l’ottimizzazione Adam. Questo algoritmo di ottimizzazione è noto per la sua efficienza computazionale e il basso utilizzo di memoria. Tramite l’opzione “*MiniBatchSize*” si è specificata la dimensione del mini-batch utilizzato durante l’addestramento. Questa opzione suddivide i dati in piccoli gruppi chiamati mini-batch e l’ottimizzazione aggiorna i pesi della rete dopo ogni mini-batch. Con l’opzione “*ValidationData*” si sono definiti i dati di validazione utilizzati per valutare le prestazioni della rete durante l’addestramento, con “*ValidationPatience*” si è indicato il numero massimo di volte in cui il punteggio di validazione poteva essere superiore o uguale alla perdita precedente più piccola prima di interrompere l’addestramento, nel nostro caso è stato impostato un numero massimo di 7. Questo parametro aiuta a prevenire l’*overfitting* cioè una condizione che si verifica nel caso in cui il modello si adatta troppo ai dati di addestramento e non è in grado, quindi, di generalizzare in modo efficace su nuovi dati. Con l’opzione “*ValidationFrequency*” si è specificata la frequenza con cui veniva eseguita la convalida, ad esempio, ogni “*valFreq*” epoche. Con “*InitialLearnRate*” abbiamo definito il tasso di apprendimento iniziale utilizzato durante l’addestramento. Questo rappresenta la quantità di aggiornamento dei pesi di ciascun passaggio di ottimizzazione. È un parametro importante in quanto se la velocità di apprendimento è troppo bassa, l’addestramento può richiedere un tempo molto grande se, al contrario, la velocità di apprendimento è troppo alta, l’addestramento potrebbe raggiungere un risultato non ottimale e deviare. Nel nostro lavoro abbiamo impostato un valore pari a 0.001. “*L2Regularization*” rappresenta la regolarizzazione L2, o decadimento dei pesi, applicata durante l’addestramento. È una tecnica di regolarizzazione che opera sulla funzione costo con l’obiettivo di ridurre gli effetti del sovrallenamento della rete. In particolare queste tecniche prevedono l’aggiunta di un fattore, in questo caso pari alla somma dei quadrati dei pesi, dopo l’espressione di una funzione costo. L’opzione “*Shuf-*

*fle*” è stata utilizzata in quanto permetteva il mescolamento dei dati prima di ciascuna epoca di addestramento, garantendo una maggiore variabilità durante il training. La funzione “*Plot*” ha permesso di visualizzare i grafici di progresso durante l’addestramento e ottenere informazioni visuali sull’andamento del training. “*MaxEpochs*” è stata impiegata, invece, per specificare il numero massimo di epoche con le quali addestrare la rete; una volta raggiunto questo numero l’addestramento viene interrotto. Infine “*Verbose*” è un parametro che controlla se vengono visualizzati messaggi dettagliati durante l’addestramento nella finestra di comando . Se imposto su “*true*”, vengono visualizzati messaggi dettagliati, se imposto su “*false*”, vengono nascosti. Di seguito viene mostrato lo script Matlab, Listing 3.2.

```
9 miniBatchSize = 3000;
10 valFreq = 100;
11
12 options = trainingOptions('adam', ...
13     'MiniBatchSize', miniBatchSize, ...
14     'ValidationData', XTest, ...
15     'ValidationPatience', 7, ...
16     'ValidationFrequency', valFreq, ...
17     'InitialLearnRate', 0.001, ...
18     'L2Regularization', 0.0001, ...
19     'Shuffle', 'every-epoch', ...
20     'Plots', 'training-progress', ...
21     'MaxEpochs', 4000, ...
22     'Verbose', false);
```

Listing 3.2: Opzioni di addestramento della rete neurale

La funzione *trainNetwork* è stata utilizzata per allenare la rete neurale sul nostro dataset di addestramento.

```
23 [Net, Info] = trainNetwork(XTrain, layers_new, options);
```

Listing 3.3: Opzione di allenamento della rete neurale

Questa funzione richiede tre input principali: i dati di training contenenti vettori di caratteristiche precedentemente estratte dai dati, tutti i layers che definiscono l’architettura della rete e le opzioni di addestramento che specificano come verranno ottimizzati i pesi della rete durante il processo di addestramento. Come risultato della funzione *trainNetwork*, otteniamo due oggetti principali: “net” che rappresenta la rete neurale completamente addestrata e che può essere utilizzata per effettuare previsioni sui nuovi dati e “info”, oggetto che contiene i valori delle funzioni di perdita durante l’addestramento, l’accuratezza sui dati di addestramento e di convalida, il tasso di apprendimento utilizzato e altre metriche utili per valutare le prestazioni della rete durante l’addestramento.



### 3.9 Finestratura dei dati

La tecnica della finestra scorrevole è stata utilizzata per suddividere i dati di accelerometro, giroscopio e pressioni plantari in segmenti temporali più piccoli, al fine di facilitare la segmentazione dei dati e renderli adatti alle applicazioni in tempo reale. In particolare, è stata utilizzata una finestra di dimensioni pari a 500 campioni, corrispondenti a 5 secondi di acquisizione. È stata applicata una sovrapposizione del 50%, il che significa che le finestre adiacenti condividevano 250 campioni. Questo approccio è stato adottato per i dati di ogni partecipante. In ogni finestra, sono state calcolate le caratteristiche specifiche e il tempo di inizio di ciascuna finestra è stato registrato; i valori risultanti sono stati salvati in una matrice. Successivamente è stata aggiunta una ulteriore colonna a questa matrice, che rappresentava la classe di appartenenza delle varie finestre. È stato, poi, confrontato il timestamp salvato con il timestamp etichettato precedentemente; se il timestamp rientrava nell'intervallo di sollevamento, la finestra veniva classificata come "1", altrimenti come "0". In questo modo la matrice risultante rappresentava il dataset necessario per l'addestramento del modello, con le caratteristiche estratte e le relative etichette di classe associate a ciascuna finestra.

### 3.10 Allenamento e validazione del modello AI

In questa sezione scaveremo più in dettaglio il processo di allenamento e validazione del modello creato. Prima di addestrare la rete è stato necessario preparare correttamente il dataset, dividendolo in una parte di training e in una di test set. La divisione dei dati tra addestramento e test è stata eseguita utilizzando una funzione chiamata *cvpartition*. Nel nostro caso è stata utilizzata una divisione "HoldOut", dove il 20% dei dati è stato destinato al test e il restante 80% al training. Siamo quindi stati in grado di creare due matrici; "XTrain" e "XTest", che contengono rispettivamente i dati di addestramento e di test del modello. Il processo di addestramento è stato ripetuto per otto volte salvando ogni volta il modello allenato in una matrice. Le reti neurali così addestrate sono state utilizzate per effettuare previsioni su dati senza etichette. La classificazione è stata eseguita attraverso la funzione *classify* e le previsioni sono state memorizzate nella variabile "YPred" che contenente le classi previste per ciascun campione di input. Per ciascuno degli otto modelli addestrati sono state calcolate le metriche di accuratezza di validazione e di addestramento. Queste metriche sono state poi combinate per generare uno specifico punteggio, denominato "Score", che mirava a premiare i modelli con le migliori prestazioni sul set di validazione. Questo punteggio è stato determinato mediante la seguente formula:

$$Score = 2 \times validation\ accuracy \times training\ accuracy$$

ed è stato utilizzato per identificare il modello migliore.

Model	% Validation	% Training	Score
Model 1	82.68	99.30	5.4738e+03
Model 2	84.36	99.17	5.5769e+03
Model 3	83.80	99.03	5.5322e+03
Model 4	81.56	98.89	5.3771e+03
Model 5	84.36	100	5.6238e+03
Model 6	86.03	99.30	5.6957e+03
Model 7	83.80	99.58	5.5633e+03
Model 8	83.80	98.33	5.4934e+03

Tabella 3.5: Specifiche tecniche Yeti

Come mostrato in tabella 3.5 il modello che è risultato migliore nel nostro studio, è stato il sesto. Tale modello è stato quindi salvato e utilizzato nelle analisi successive. Risulta significativo sottolineare come l'accuratezza del training (99,30%) sia notevolmente superiore rispetto all'accuratezza di validazione (86.03%). Questa osservazione è in linea con le aspettative teoriche poiché i modelli di deep learning durante l'addestramento si adattano molto ai dati di training, pertanto è normale che l'accuratezza sia notevolmente alta in questo contesto dove il modello è esposto ai dati di addestramento stessi. D'altra parte è corretto aspettarsi che l'accuratezza sia più bassa nella fase di validazione poiché il modello è testato su dati che non ha mai incontrato prima, mettendo alla prova la sua capacità di generalizzazione. Se l'accuratezza di validazione fosse risultata superiore rispetto a quella sul training molto probabilmente sarebbe stato dovuto ad un set di validazione troppo piccolo o uno sbilanciamento dei dati all'interno di quest'ultimo.

### 3.10.1 Selezione delle caratteristiche: approccio AI

Come già spiegato in precedenza, la selezione di un sottoinsieme di caratteristiche è una forma di riduzione delle dimensioni di un data set. Questo procedimento è fondamentale per migliorare l'efficienza nella creazione di un modello, riducendo il carico sulla CPU e la quantità di memoria necessaria per l'addestramento della rete. Inoltre un numero elevato di caratteristiche può portare a informazioni ridondanti, non necessarie o addirittura errate. In questa sezione, esamineremo il secondo metodo di selezione delle caratteristiche utilizzato nel contesto della tesi. In questo approccio, abbiamo adottato un metodo iterativo per selezionare le caratteristiche più significative, seguendo le metodologie di Fisher, Rudin, and Dominici (2018) [60]. Per valutare l'importanza di ciascuna caratteristica, abbiamo misurato l'incremento nell'errore di previsione del modello, precedentemente salvato, dopo aver permutato la specifica caratteristica. Ricordiamo che una

feature è considerata importante quando la sua permutazione comporta un aumento nell'errore del modello, al contrario, una caratteristica è considerata “non importante” se la permutazione dei suoi valori non modifica significativamente l'errore del modello. Definiamo quindi con  $\hat{f}$  il modello addestrato, con  $X$  la matrice delle features (dove le righe rappresentano le osservazioni e le colonne rappresentano le caratteristiche) e con  $y$  il vettore delle etichette, ovvero le classi da prevedere. Utilizziamo  $L(y, \hat{f})$  per indicare la misura dell'errore del modello.

Come primo passo, abbiamo calcolato l'errore del modello originale:

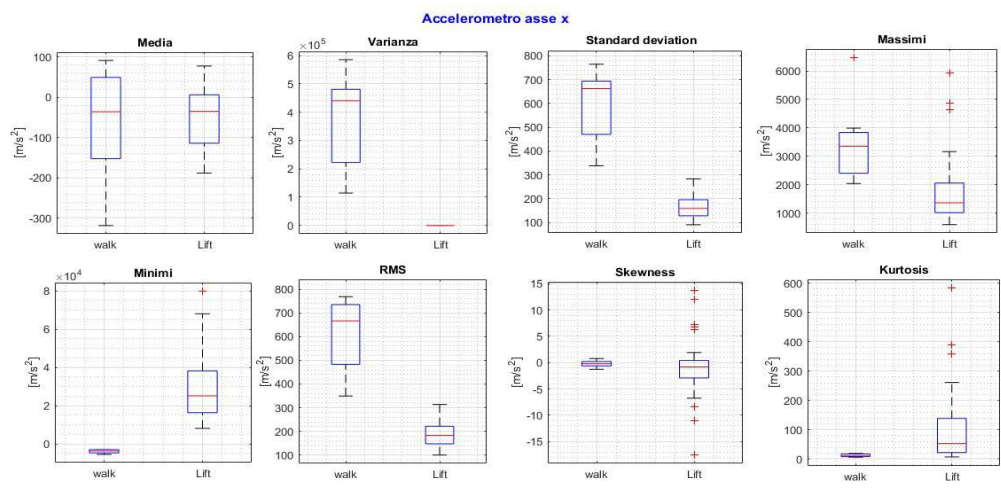
$$e_{orig} = L(y, \hat{f}(X))$$

cioè il modello allenato con tutte le caratteristiche presenti nella matrice  $X$ . Successivamente per ciascuna delle feature  $j = 1 \dots p$  si è creata una matrice permutata  $X_{perm}$ , permutando la  $j$ -esima caratteristica. Questo ha comportato la “rottura” dell'associazione tra la feature  $j$  e l'output  $y$ . Abbiamo quindi validato il modello con la matrice  $X_{perm}$  ottenuta dalla permutazione e stimato l'errore risultante. L'importanza della caratteristica di permutazione è stata calcolata come il rapporto tra l'errore ottenuto con la permutazione e l'errore calcolato originalmente.

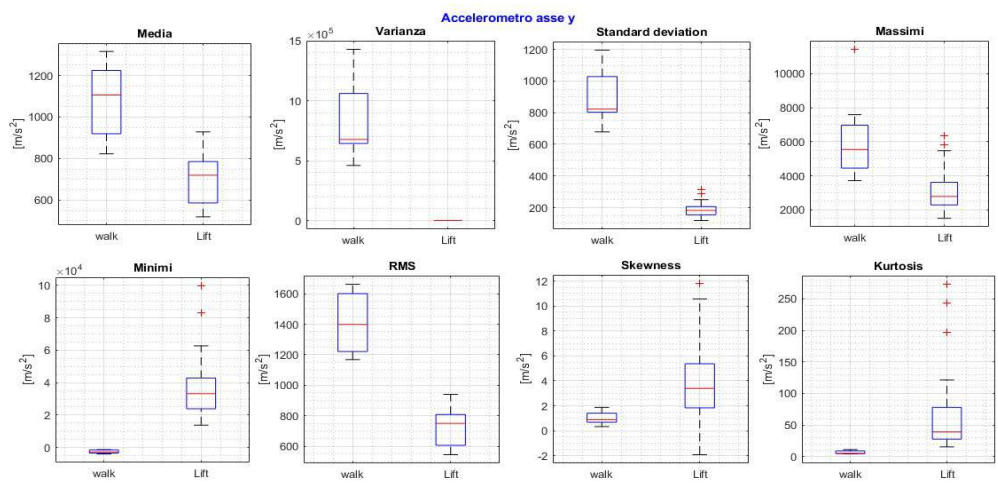
$$FI_j = \frac{e_{perm}}{e_{orig}}$$

Rapporti di errore più elevati indicano features più importanti. Questo processo è stato ripetuto per 20 iterazioni. Alla fine abbiamo ottenuto una matrice con dimensione “numero di features” x “numero di iterazioni”. Successivamente abbiamo calcolato la media delle 20 iterazioni per ogni ciascuna caratteristica e le abbiamo ordinate in ordine decrescente, come mostrato in Figura 3.14. Per selezionare le caratteristiche da utilizzare nel modello finale, abbiamo introdotto tre soglie: una a 2, una ad 3 e una ad 4. Per ciascuna soglia abbiamo selezionato solo le caratteristiche con un valore di importanza superiore a quella soglia e addestrato il modello utilizzando tali features. Abbiamo quindi scelto la soglia che ha portato al miglior compromesso tra accuratezza finale e numero di features: il modello scelto è stato quello corrispondente a soglia pari a 2, che utilizza 44 features, ed ha portato ad un'accuratezza finale del 96.66%. Dalla figura 3.14 è significativo notare che le caratteristiche più rilevanti coincidono in gran parte con quelle selezionate mediante metodo classico. Il modello così creato è stato salvato e sarà utilizzato per la classificazione di nuovi dati.

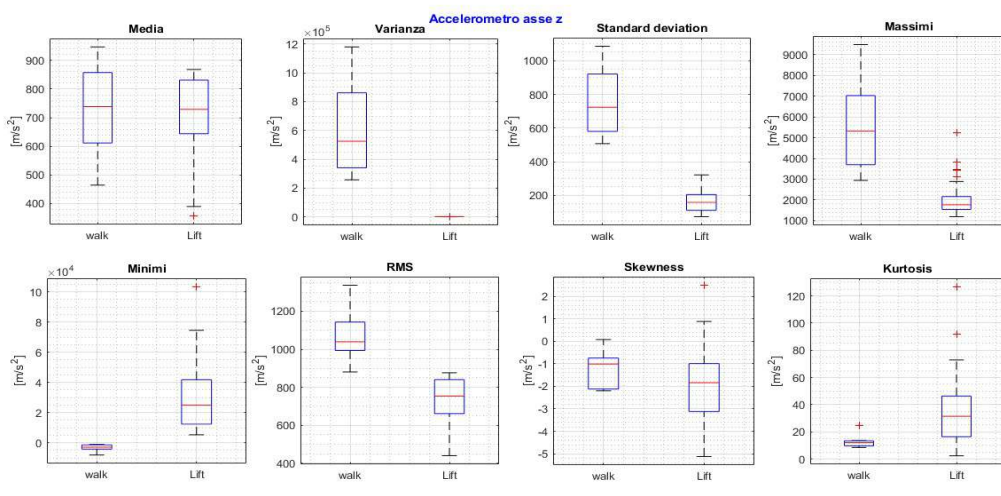




(a) Accelerometro asse x

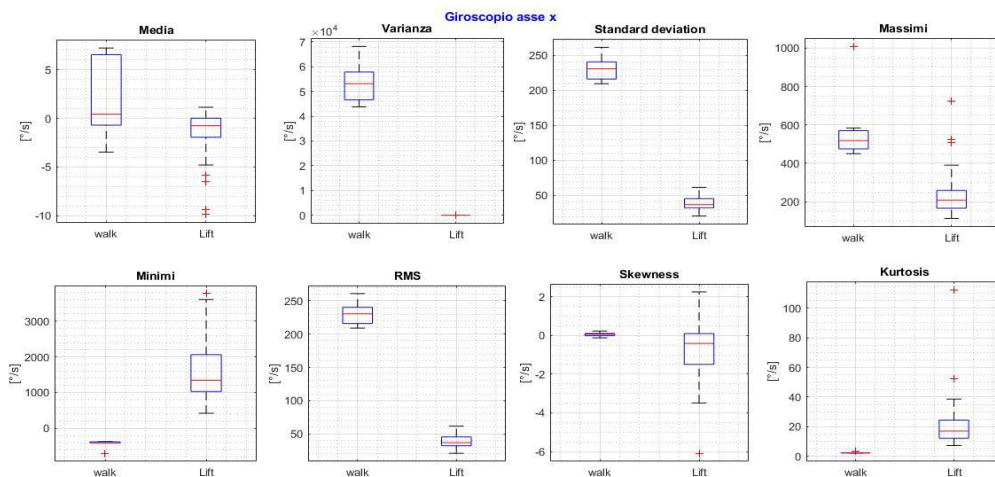


(b) Accelerometro asse y

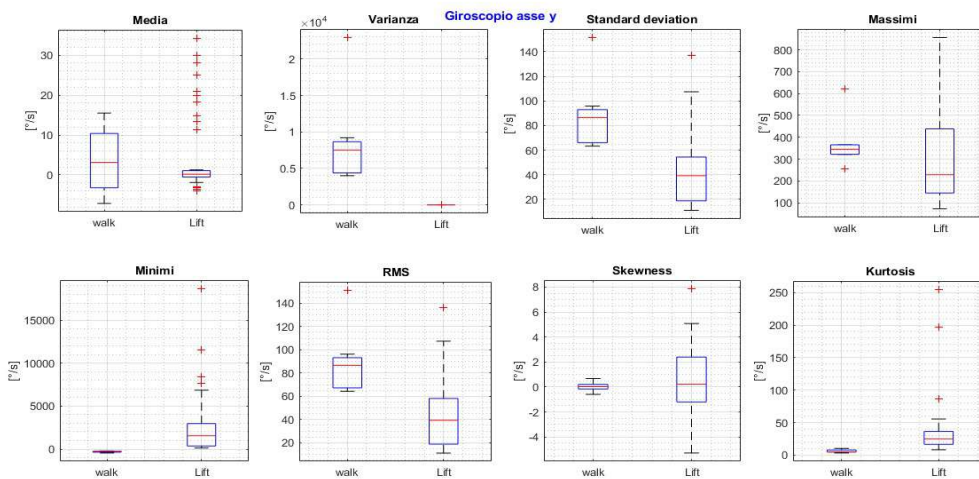


(c) Accelerometro asse z

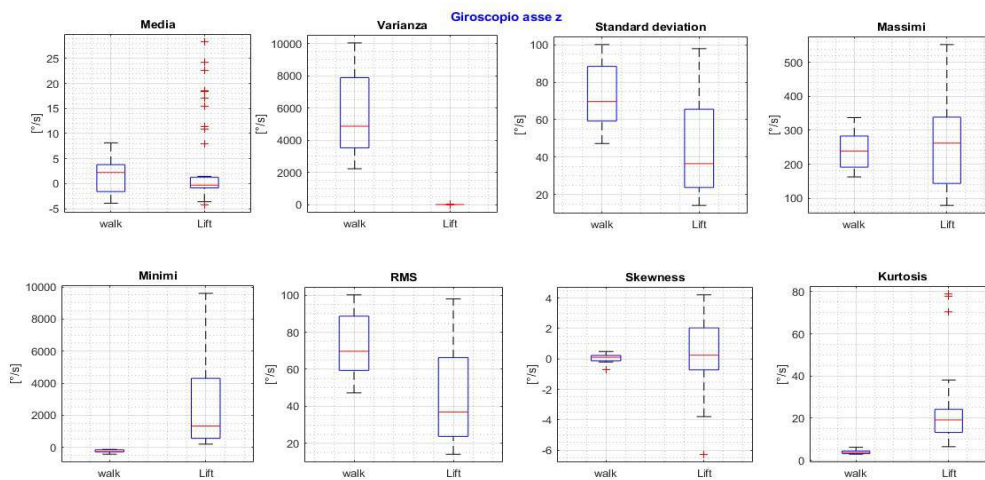
Figura 3.15: Box-plot delle features dell'accelerometro lungo i suoi tre assi



(a) Giroscopio asse x



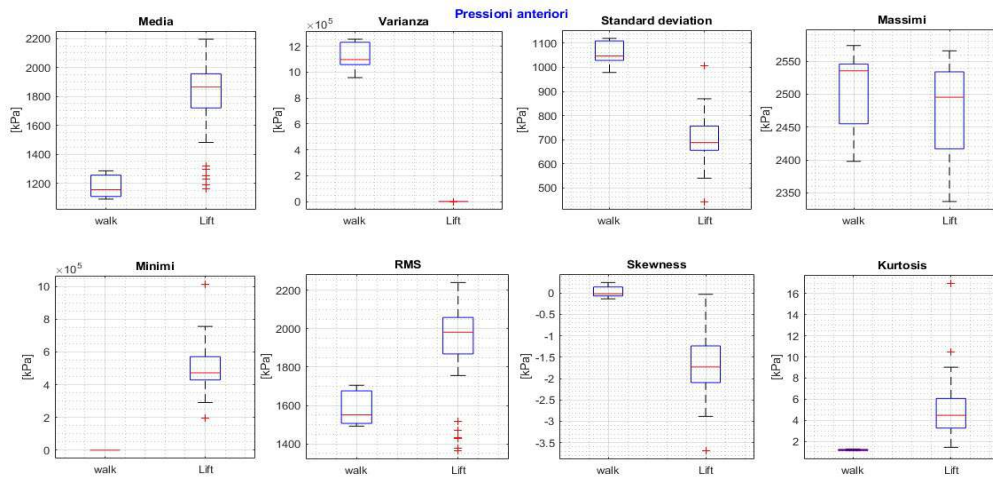
(b) Giroscopio asse y



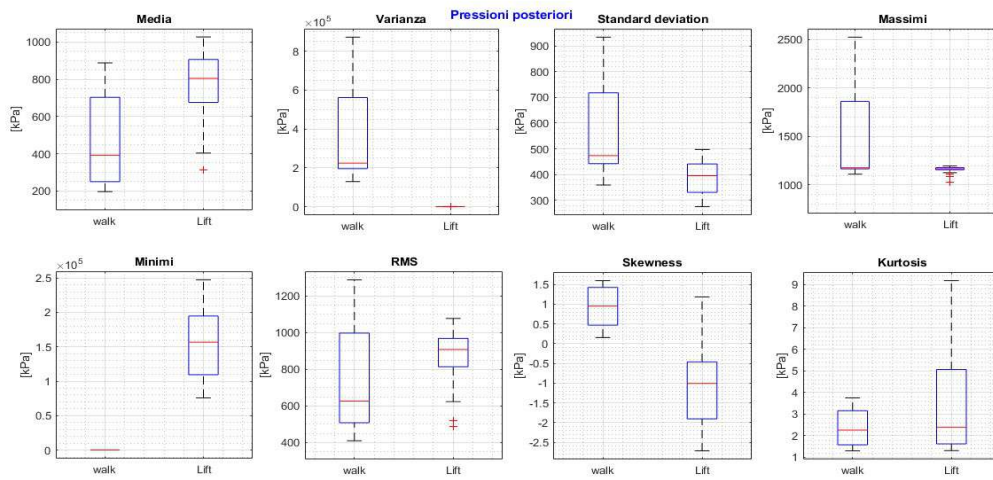
(c) Giroscopio asse z

Figura 3.16: Box-plot delle features del giroscopio lungo i suoi tre assi





(a) Pressioni plantari anteriori



(b) Pressioni plantari posteriori

Figura 3.17: Box-plot delle features delle pressioni plantari anteriori e posteriori

# Capitolo 4

## Risultati

Al fine di confrontare modelli diversi e esaminarne le prestazioni durante la fase di test, è essenziale utilizzare metriche di valutazione adeguate. Solitamente affidarsi ad una sola metrica non è la scelta migliore poiché potrebbe non spiegare appieno le capacità effettive del modello [61]. Pertanto, in questo capitolo, verranno illustrate brevemente diverse metriche di valutazione e, successivamente, verranno presentati i risultati relativi ai due metodi di classificazione utilizzati. Ciò consentirà un'analisi più accurata e dettagliata delle prestazioni dei modelli. Infine verrà fornita una breve spiegazione del codice Matlab utilizzato per la visualizzazione in tempo reale dei risultati.

### 4.0.1 Matrice di confusione

Un importante strumento che mostra le performance del modello è la matrice di confusione, comunemente conosciuta come “*confusion matrix*”. Questa matrice non rappresenta una metrica in sé ma una tabella che mette a confronto le previsioni del modello con le vere appartenenze del data set. La confusion matrix è di solito strutturata come:

		Classi predette	
		Positive	Negative
Classi effettive	Positive	Veri positivi (TP)	Falsi negativi (FN)
	Negative	Falsi positivi (FP)	Veri negativi (TN)

Tabella 4.1: Matrice di confusione

dove, le colonne rappresentano i valori predetti dal modello, mentre le righe rappresentano i valori reali nel data set. Gli elementi all'interno della matrice mostrano quanti casi sono stati classificati correttamente (veri positivi e veri negativi) e quante previsioni errate sono state



fatte (falsi positivi e falsi negativi). La matrice di confusione è quindi uno strumento utile per valutare le prestazioni di un modello di classificazione e per calcolare diverse metriche come l'accuratezza, la precisione, il richiamo e il punteggio F1.

## 4.0.2 Accuratezza

L'accuratezza è forse la metrica più semplice da utilizzare e da implementare, in quanto rappresenta la percentuale dei casi correttamente classificati all'interno del set di dati. Tuttavia, va notato che uno dei limiti principali dell'accuratezza è l'assegnazione dello stesso peso a tutti i tipi di errore (Falsi positivi e Falsi negativi) e la sua forte influenza dalla distribuzione delle classi nei dati. L'accuratezza è calcolata come il rapporto tra il numero totale di previsioni corrette e il numero totale di previsioni effettuate.

$$Accuratezza = \frac{TP + TN}{TP + TN + FP + FN}$$

Mentre essa è una metrica importante per valutare le prestazioni di un modello, è essenziale considerare anche altre misure, specialmente quando si ha a che fare con un set di dati sbilanciati o quando alcuni tipi di errore sono più costosi o pericolosi di altri.

## 4.0.3 Recall

Il *recall*, noto come richiamo o sensibilità, rappresenta la proporzione dei casi effettivamente positivi che sono previsti correttamente come positivi. È definito matematicamente come il numero di veri positivi (TP) diviso per la somma del numero di veri positivi (TP) e il numero di falsi negativi (FN). In altre parole, il recall misura quanto il modello sia in grado di catturare tutti i casi veramente positivi all'interno del dataset. La formula per il calcolo di questa metrica è la seguente:

$$Recall = \frac{TP}{TP + FN}$$

## 4.0.4 Precisione

La precisione è una metrica che misura la percentuale di campioni identificati correttamente come positivi rispetto a tutti i campioni previsti come positivi dal modello. La precisione del modello può essere calcolata utilizzando la formula:

$$Precisione = \frac{TP}{TP + FP}$$

In altre parole, la precisione misura la capacità del modello di evitare di classificare erroneamente casi negativi come positivi. Una precisione elevata indica che le previsioni positive del modello sono affidabili.

#### 4.0.5 **Balanced accuracy**

La “*Balanced Accuracy*” è una metrica che tenta di superare i limiti dell’accuratezza in quanto tiene conto dell’esattezza del modello in situazioni in cui le classi nel data set possono essere sbilanciate. Questa metrica è particolarmente utile quando si hanno classi con una distribuzione diseguale, ad esempio, quando una classe è molto più numerosa rispetto ad all’altra. La formula per calcolare la balanced accuracy è la seguente:

$$\text{Balanced Accuracy} = \frac{\text{sensibilità} + \text{specificità}}{2}$$

dove la specificità misura la proporzione di elementi negativi correttamente identificati rispetto al totale delle previsioni negative che potrebbero essere fatte dal modello.

$$\text{Specificità} = \frac{TN}{TN + FP}$$

In sostanza, questa metrica tiene conto di come il modello si comporta sia nella classificazione della classe positiva (sensibilità) che nella classificazione della classe negativa (specificità) e calcola una media ponderata di entrambi i valori.

#### 4.0.6 **Punteggio F1**

Un’altra misura in grado di fornire informazioni riguardanti le prestazioni di un modello di classificazione è il punteggio F1 o *F1 score*. Essa è una metrica che combina il richiamo e la precisione in un unico valore, è utile quando si desidera ponderare l’importanza di entrambe queste misure, soprattutto quando si ha a che fare con classi sbilanciate. Il punteggio F1 viene calcolato come:

$$F1\ score = 2 \times \frac{\text{Precisione} \times \text{Recall}}{\text{Precisione} + \text{Recall}}$$

Quando il punteggio F1 è elevato, indica che il modello ha sia una buona capacità di identificare correttamente i positivi (precisione) sia di catturare tutti i positivi effettivi (richiamo).

#### 4.0.7 Kappa di Cohen

L'indice di concordanza Kappa di Cohen (K di Cohen) è una metrica utilizzata per misurare l'accordo tra le previsioni di un modello di classificazione e le classi effettive, tenendo conto della possibilità di concordanza casuale. In altre parole, Kappa aiuta a valutare se l'accuratezza del modello è dovuta al caso o riflette una vera capacità di classificazione.

L'equazione per calcolare il K di Cohen è la seguente:

$$\kappa = \frac{P_o - P_e}{1 - P_e}$$

dove  $P_o$  rappresenta l'accuratezza complessiva del modello, ovvero la percentuale di previsioni corrette e  $P_e$  rappresenta la probabilità di accordo casuale e viene calcolata come il prodotto dei totali positivi sommato a quelli negativi, il tutto diviso per il quadrato del totale dei giudizi. Di conseguenza se la nostra matrice di confusione è la seguente:

		Valore predetto		total
		p	n	
Valore vero	p'	Veri Positivi	Falsi Negativi	P'
	n'	Falsi Positivi	Veri Negativi	N'
total		P	N	T

il valore di  $P_e$  sarà definito come:

$$P_e = \frac{PP' + NN'}{T^2}$$

#### 4.1 Risultati: approccio classico

In questo studio, con il termine "approccio classico" ci si riferisce a un metodo di classificazione basato su soglie. In particolare, dopo aver identificato le caratteristiche più significative attraverso l'osservazione diretta dei boxplot, è stata calcolata la media delle mediane delle caratteristiche "lift" e "walk". Questo valore ottenuto è stato utilizzato come soglia di riferimento. Va notato come in questo specifico caso, per tutte le categorie di dati che abbiamo selezionato,

si è verificata una tendenza in cui i boxplot della classe “lift” avevano valori più basso rispetto alla classe “walk”. È importante sottolineare che questa osservazione è specifica per le categorie di dati considerate e rappresenta un caso particolare. In altre categorie di dati, avremmo potuto incontrare situazioni in cui il boxplot della classe “lift” presentavano valori più alti rispetto a quelli della classe “walk”. In seguito, quindi, per ciascun nuovo dato finestrato in fase di test, sono state calcolate le caratteristiche più significative. Nel nostro caso, se i valori di queste caratteristiche erano inferiori alla soglia precedentemente calcolata, i dati venivano classificati come “sollevamento” ed etichettati con il valore 1.

In questo modo si è ottenuta una classificazione con un’accuratezza di circa il 75%. Se andiamo a vedere nel dettaglio la matrice di confusione mostrata in tabella 4.2 essa rivela che molte classi sono state correttamente predette, ma circa il 25% dei dati nel data set è stato erroneamente classificato.

Inoltre, sono state calcolate e riportate le seguenti metriche in tabella 4.3.

Accuratezza	75%
Recall	24%
Precisione	44%
Balanced accuracy	0.57
F1 score	0.31
K Cohen	0.2

Tabella 4.3: Valori delle metriche per il modello classico

Con il modello basato su soglie si è ottenuta un’accuratezza del 75%, esso risulta un buon valore in quanto ci suggerisce che il modello è riuscito a prevedere correttamente l’etichetta di classe per il 75% dei casi. Tuttavia i valori di recall e precisione risultano essere molto bassi e pari a 24% e 44% rispettivamente. Un valore di questo tipo suggerisce che solo il 24% dei veri casi positivi sono stati correttamente identificati dal modello, mentre una precisione del 44% indica che solo il 44% delle previsioni positive fatte dal modello sono effettivamente corrette. La balanced accuracy, invece, risulta avere valore pari a 0.57, indicando che il modello si comporta leggermente meglio di un modello casuale, ma non è altamente accurato. Un F1 score di 0.31

		Predicted	
		Lift	Walk
Actual	Lift	8	25
	Walk	10	96

Tabella 4.2: Matrice di confusione metodo classico

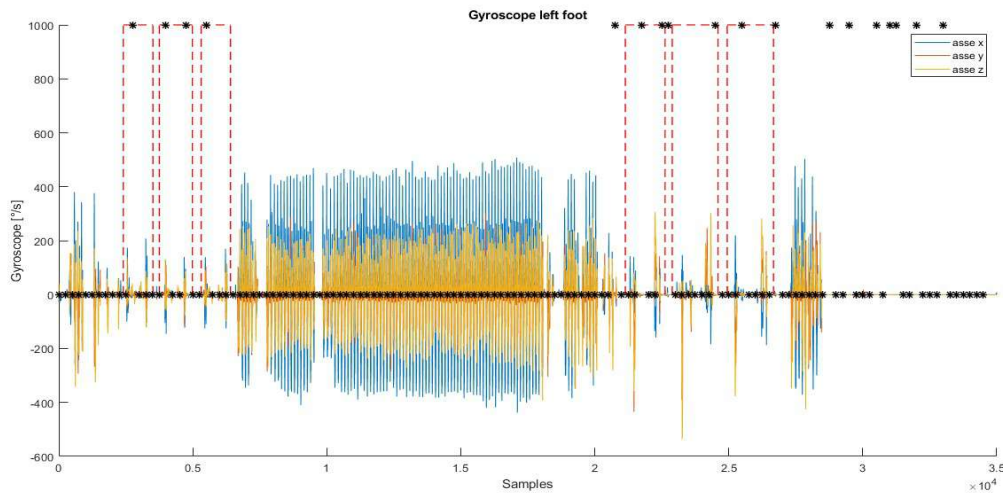


Figura 4.1: Dati del giroscopio del piede sinistro di un soggetto. Vengono presentati gli istanti effettivi di sollevamento (linee tratteggiate) e gli istanti predetti dal modello secondo il metodo classico (asterischi neri)

suggerisce che il modello ha difficoltà a bilanciare la capacità di catturare correttamente i casi positivi e la capacità di evitare falsi positivi. Infine il valore Kappa di Cohen è pari a 0.2 che, secondo i valori proposti da Landis JR e Koch GG (1977), definisce una scarsa concordanza tra i due valutatori e quindi una scarsa affidabilità del modello di classificazione. In figura 4.1 vengono rappresentati i dati di giroscopio del piede sinistro di un soggetto. I rettangoli tratteggiate in rosso rappresentano gli istanti di sollevamento effettivi, mentre gli asterischi neri rappresentano le classi predette dal modello secondo il metodo classico.

## 4.2 Risultati: approccio AI

Con “metodo AI” ci riferiamo al metodo di classificazione basato sul modello di deep learning descritto nel capitolo precedente. Dopo aver creato il modello di rete neurale con strati nascosti multipli, abbiamo identificato le caratteristiche più significative tra i dati sensoriali e abbiamo addestrato il modello utilizzando un data set in cui erano fornite le etichette di classe di appartenenza. In questa fase, quindi, il modello ha imparato a fare previsioni corrette basate sulle caratteristiche estratte. Abbiamo validato le prestazioni del modello utilizzando una parte separata del data set che non era stata utilizzata nel training e abbiamo quindi osservato le capacità di generalizzazione sui dati nuovi. Infine, per verificare ulteriormente le capacità di classificazione della rete neurale, abbiamo somministrato alla rete una serie di nuovi dati che non erano ancora stati inclusi né nel training né nella fase di validazione. I dati sono stati finestrati e per ogni finestra sono state calcolate le 44 features più importanti. Le caratteristiche sono state date

in pasto al modello nello stesso ordine con cui il modello è stato allenato. Questo test ha valutato l'abilità del modello nell'affrontare dati sconosciuti. Osserviamo la matrice di confusione riportata in tabella 4.4:

		Predicted	
		Lift	Walk
Actual	Lift	18	15
	Walk	5	101

Tabella 4.4: Matrice di confusione metodo AI

Fin da subito possiamo notare come questo modello è in grado di prevedere correttamente un numero maggiore di istanze.

Dalla tabella 4.5 è evidente che l'accuratezza del modello è molto alta, pari all'86%; ciò suggerisce che il modello è in grado di fare previsioni corrette sulla maggior parte dei dati di test. Anche gli altri parametri indicano una prestazione del modello molto positiva, infatti, sia la recall che la precisione sono abbastanza alte e pari a 54.5% e 78% rispettivamente. Ciò denota che il modello è in grado di catturare un numero significativo di casi positivi e al contempo riesce a minimizzare gli errori facendo previsioni positive con una buona precisione. Avere sia una buona recall che un'alta precisione suggerisce che il modello è bilanciato nel catturare i casi positivi e non genera troppi falsi positivi o falsi negativi. Se, infatti, osserviamo la matrice di confusione notiamo che le classi predette non correttamente rappresentano solo il 14.4% di tutto il data set. La balanced accuracy mostra un valore di 0.75, valore più basso della vera accuratezza, poiché tiene conto in modo ponderato delle due classi, positive e negative. Tuttavia, questo valore, è molto più vicino ad 1 che a 0 e ciò suggerisce che il modello è in grado di gestire abbastanza efficacemente le classi sbilanciate, ottenendo buone performance sia sulle classi di maggioranza che su quelle di minoranza. L'F1 score presenta un range di valori che varia tra 0 e 1, nel nostro modello assume un valore pari a 0.66. Un valore di F1 come questo indica che il modello ha un buon equilibrio tra la capacità di catturare correttamente casi positivi e capacità di evitare falsi positivi. Il modello è quindi efficace nel discriminare tra le classi e ha prestazioni generali buone.

Accuratezza	86%
Recall	54.5%
Precisione	78%
Balanced accuracy	0.75
F1 score	0.66
K Cohen	0.56

Tabella 4.5: Valori delle metriche per il modello AI

L'ultima metrica presa in considerazione in questo studio è il Kappa di Cohen, il quale assume un valore pari a 0.56 e sottolinea un accordo moderato tra le previsioni del modello che quindi presenta capacità di classificazione migliore rispetto a una previsione casuale, ma non raggiunge un accordo eccezionalmente alto con le classi effettive. Di seguito una rappresentazione visuale (Figura 4.2) della classificazione dei dati di giroscopio del piede sinistro di un soggetto.

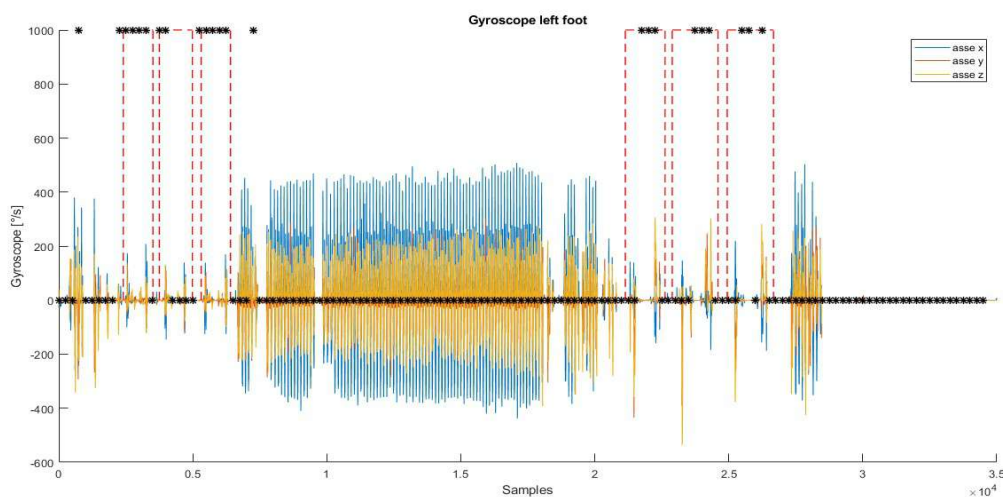


Figura 4.2: Dati del giroscopio del piede sinistro di un soggetto. Vengono presentati gli istanti effettivi di sollevamento (linee tratteggiate) e gli istanti predetti dal modello secondo il metodo AI (asterischi neri)

### 4.3 Streaming dei dati

Come fase conclusiva di questo lavoro di tesi, è stato sviluppato un codice Matlab che elaborasse e visualizzasse i dati provenienti dalla sensoristica inerziale e dalle pressioni plantari e che eseguisse una classificazione in tempo reale. In dettaglio, nello script Matlab, abbiamo importato il modello di deep learning precedentemente allenato e salvato. Successivamente abbiamo richiesto all'utente di specificare il percorso e il nome del file dati da caricare, considerando sia file in formato “.mat” che file di testo. Abbiamo estratto le colonne di dati rilevanti dalle variabili importate e inizializzato la matrice di elaborazione. Si è quindi chiesto all'utente di specificare se i dati appartenessero al piede destro o sinistro e, in base alla risposta dell'utente, abbiamo eseguito operazioni specifiche di elaborazione dati, come la definizione delle posizioni di riferimento per i sensori di pressione. Un esempio di domande e di risposte viene riportato in figura 4.3.

```
Command Window
Please provide the path to the folder: C:\Users\rinal\Desktop\New_Data
What file would you like to open?: Data_LeftFoot.mat
fx Are the data in the file related to the right (R) or left (L) foot?: L
```

Figura 4.3: Screenshot della Command Window con richieste e risposte dello script

Successivamente, abbiamo calcolato le 44 statistiche sui dati e utilizzato la finestrata per applicare queste statistiche in maniera sequenziale al modello di deep learning. Le previsioni sono state quindi registrate. Per visualizzare in tempo reale i risultati, abbiamo creato dei grafici che mostravano sequenzialmente i dati di accelerometro, giroscopio e di pressione plantare di un solo piede, insieme alle previsioni effettuate dal modello. Sulla base dei dati elaborati, abbiamo quindi generato un'animazione per informare l'utente sul tipo di attività che si stava svolgendo (*Lift* o *No lift*), viene riportato un esempio in Figura 4.4 .

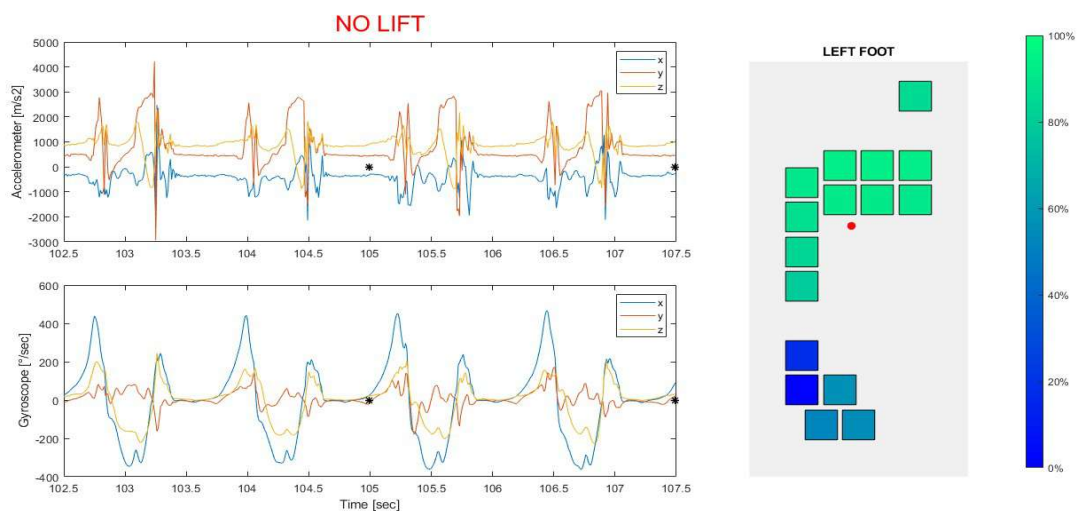


Figura 4.4: Istante dell'animazione in tempo reale dei dati





# Capitolo 5

## Conclusioni

I disturbi muscolo-scheletrici da sovraccarico biomeccanico rappresentano una delle principali cause di assenza nei luoghi di lavoro in Italia. Tra le ragioni che occupano il primo posto in questa classifica, troviamo la movimentazione manuale dei carichi eseguita in modo improprio. È, pertanto, essenziale prevenire l'adozione di gesti motori scorretti al fine di evitare danni muscolo-scheletrici permanenti. Questa tesi, condotta presso l'azienda 221e s.r.l, ha affrontato questo tema critico proponendo una soluzione innovativa: lo sviluppo di un algoritmo di deep learning in grado di classificare l'attività di movimentazione manuale dei carichi rispetto ad altri movimenti. I dati utilizzati per addestrare e successivamente validare l'algoritmo intelligente provengono da sensori inerziali e solette di pressione plantare ideati e progettati dalla stessa azienda. I risultati di questa ricerca hanno dimostrato che l'algoritmo ha un'accuratezza dell'86% nel riconoscere i vari tipi di sollevamento, confermando il potenziale di questa tecnologia nell'ambito della sicurezza sul lavoro. Inoltre, i sensori inerziali e le solette di pressione si sono dimostrati altamente adatti in questo contesto, grazie alla loro facilità d'uso, alla non invasività durante l'esecuzione dei vari movimenti e al costo competitivo. Questi dispositivi sono accessibili a una vasta gamma di realtà, dalle piccole alle grandi imprese, fino al settore sanitario, oltre che per un utilizzo personale nelle attività quotidiane. Inoltre, la semplicità delle features e la non necessità di elevate capacità di calcolo per la creazione dell'algoritmo lo rendono facilmente integrabile in sistemi *embedded*. Tuttavia, questo studio ha identificato diversi limiti di natura variegata. I sensori inerziali, sebbene comunemente utilizzati per valutare il movimento umano, sono influenzati dalla posizione in cui vengono indossati. Il possibile utilizzo di cinghie, braccialetti e dispositivi di fissaggio potrebbe non risultare sufficiente come ancoraggio, con il rischio che questi si muovano durante l'attività lavorativa. Diverse strategie per superare tali limitazioni potrebbero includere un involucro appositamente progettato per il sistema MITCH, in modo che abbia un ancoraggio migliore alla scarpa. Altre limitazioni significative includono il fatto che il campione di soggetti coinvolti nella raccolta dei dati è stato

ristretto e composto esclusivamente da individui relativamente giovani, con un'età media di 27 anni e i dati sono stati acquisiti in un ambiente controllato. Pertanto, ulteriori ricerche dovrebbero esaminare l'applicabilità di questa tecnologia in contesti lavorativi reali e coinvolgere una popolazione più diversificata. Nonostante tutto, il nostro studio apre la strada a vari sviluppi futuri. È importante sottolineare che durante l'analisi dei due tipi di sollevamento, abbiamo notato differenze significative nelle features calcolate. Questa scoperta suggerisce un'interessante possibilità di evoluzione dell'algoritmo. Una prospettiva di ricerca futura potrebbe concentrarsi sul raffinamento del modello di deep learning al fine di consentire la distinzione tra diversi tipi di sollevamento carichi. Un'altra direzione potenzialmente promettente è l'applicazione pratica di questo algoritmo attraverso l'implementazione di applicazioni mobili in grado di rilevare posture o movimenti scorretti durante il sollevamento dei carichi. Queste applicazioni potrebbero avvisare i lavoratori tramite segnali sonori e/o vibrazioni nel caso in cui stiano assumendo posizioni o eseguendo gesti motori incongrui, contribuendo così a prevenire danni muscolo-scheletrici e a migliorare la salute e la sicurezza sul luogo di lavoro. Inoltre, è importante sottolineare che il futuro di questa tecnologia potrebbe vedere un impegno costante nel perfezionamento della rete neurale utilizzata, al fine di raggiungere livelli di accuratezza e precisione sempre più elevati ed efficienti nel riconoscimento delle attività di movimentazione manuale dei carichi. Questa costante evoluzione costituisce un elemento chiave nell'implementazione di soluzioni sempre più avanzate per la prevenzione dei disturbi muscolo-scheletrici da sovraccarico, contribuendo così a migliorare la salute e la sicurezza sul luogo di lavoro in modo significativo. In definitiva, questo lavoro rappresenta un passo avanti nell'ambito della prevenzione delle malattie professionali, offrendo una promettente soluzione basata sull'intelligenza artificiale e su sensori avanzati. La nostra speranza è che questa tecnologia possa contribuire a ridurre il numero di infortuni legati al lavoro e migliorare la qualità della vita dei lavoratori sia in Italia che altrove.

# Bibliografia

1. Mario G. Recupero.«ANDAMENTO DEGLI INFORTUNI SUL LAVORO E DELLE MALATTIE PROFESSIONALI».Inail (Ottobre 2023). ISSN 2035-5645. <https://www.inail.it/cs/internet/docs/alg-dati-inail-2023-ottobre-pdf>.
2. EU-OSHA – European Agency for Safety and Health at Work. «Prevention of musculoskeletal disorders and psychosocial risks in the workplace: EU strategies and future challenges», 2022. Available at: <https://osha.europa.eu/en/publications/prevention-musculoskeletal-disorders-and-psychosocial-risks-workplace-eu-strategies-and-future-challenges>.
3. Antwi-Afari, M.F., H. Li, D.J. Edwards, E.A. Pärn, J. Seo, e A.Y.L. Wong. «Biomechanical Analysis of Risk Factors for Work-Related Musculoskeletal Disorders during Repetitive Lifting Task in Construction Workers». *Automation in Construction* 83 (novembre 2017): 41–47.<https://doi.org/10.1016/j.autcon.2017.07.007>.
4. Wang, Di, Fei Dai, e Xiaopeng Ning. «Risk Assessment of Work-Related Musculoskeletal Disorders in Construction: State-of-the-Art Review». *Journal of Construction Engineering and Management* 141, fasc. 6 (giugno 2015): 04015008. [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0000979](https://doi.org/10.1061/(ASCE)CO.1943-7862.0000979).
5. Antwi-Afari, Maxwell Fordjour, Heng Li, Yantao Yu, e Liulin Kong. «Wearable Insole Pressure System for Automated Detection and Classification of Awkward Working Postures in Construction Workers». *Automation in Construction* 96 (dicembre 2018): 433–41. <https://doi.org/10.1016/j.autcon.2018.10.004>.
6. INAIL - Istituto Nazionale per l'Assicurazione contro gli Infortuni sul Lavoro, «Metodologie innovative per la valutazione del rischio biomeccanico». Inail 2021. Available at: <https://www.inail.it/cs/internet/comunicazione/pubblicazioni/catalogo-generale/pubbli-motedologie-innovative-valutazione-rischio-biom.html>.
7. Agenzia europea per la salute e sicurezza sul lavoro. (2023). «Disturbi muscoloscheletrici». EU.OSHA. <https://osha.europa.eu/it/themes/musculoskeletal-disorders>

8. Bazzini, G, E Capodaglio, M Panigazzi, E Prestifilippo, e C Vercesi. «Rischi da posture incongrue», s.d.
9. McGill, Stuart M. «The Biomechanics of Low Back Injury: Implications on Current Practice in Industry and the Clinic». *Journal of Biomechanics* 30, fasc. 5 (maggio 1997): 465–75. [https://doi.org/10.1016/S0021-9290\(96\)00172-8](https://doi.org/10.1016/S0021-9290(96)00172-8).
10. Antwi-Afari, M.F., H. Li, D.J. Edwards, E.A. Pärn, J. Seo, e A.Y.L. Wong. «Biomechanical Analysis of Risk Factors for Work-Related Musculoskeletal Disorders during Repetitive Lifting Task in Construction Workers». *Automation in Construction* 83 (novembre 2017): 41–47. <https://doi.org/10.1016/j.autcon.2017.07.007>.
11. Marco Tedesco. «RUOLO DEL DIRIGENTE NELLA PREVENZIONE DEI DANNI DA SOVRACCARICO BIOMECCANICO DEL RACHIDE NEL SETTING DELLA RIABILITAZIONE FUNZIONALE». Dipartimento di Ricerca Traslazionale e delle Nuove Tecnologie in Medicina e Chirurgia. Università di Pisa (2015).
12. Squaiella Alessia. «PREVALENZA DEI DISTURBI MUSCOLOSCELETRICI LAVORO- CORRELATI NELL'INDUSTRIA METALMECCANICA ED EFFICACIA DI DIFFERENTI STRATEGIE DI PREVENZIONE». Corso di Laurea in fisioterapia. Università degli Studi di Padova. (2016).
13. Richard E. Hughes, Barbara A. Silverstein, and Bradley A. Evanoff. «Risk Factors for Work-Related Musculoskeletal Disorders in an Aluminum Smelter». *AMERICAN JOURNAL OF INDUSTRIAL MEDICINE* 32:66–75 (1997).
14. Elisabetta B., Angela G., Adriano O., Adriano P. « I disturbi muscoloscheletrici lavorativi. La causa, l'insorgenza, la prevenzione, la tutela assicurativa.». INAIL SBN 978-88-7484-227-8 (2012). <https://www.inail.it/cs/internet/comunicazione/pubblicazioni/catalogo-generale/i-disturbi-muscolo-scheletrici-lavorati.html>
15. CARLO OTTAVIANI. « Le spondiloartropatie del rachide dorso-lombare come malattia professionale non tabellata ». ISBN 88-7484-029-2 Stampato dalla Tipolitografia INAIL di Milano. <https://www.inail.it/cs/internet/docs/le-spondiloartropatie-del-rachide-dorso.pdf>
16. «Periartrite alla spalla: come si curano i sintomi del dolore e della rigidità». Magalini Medica. <https://www.magalinimedica.it/blog/periartite-alla-spalla/>
17. DR. SSA GIUSEPPINA DINO. «I DISTURBI MUSCOLO SCHELETRICI CORRELATI AL LAVORO: PREVENZIONE E RIABILITAZIONE». Inail. 3 di-

cembre 2020. <https://www.inail.it/cs/internet/docs/alg-dino-evento-webinar-sconti-inail-impresse-sicurezza-sicilia.pdf>

18. Dott.ssa Albertina Ciferri. «Malattia professionale da sovraccarico dell'arto superiore: epicondilite ed epitrocleite». patronato anmil. 2019. <https://www.patronatoanmil.it/notiziario-giugno-2019-ciferri-malattie-professionali-da-sovraccarico-dellarto-superiore-epicondilite-ed-epitrocleite/>
19. «LA SINDROME DEL TUNNEL CARPALE». ASUGI. 2022. <https://asugi.sanita.fvg.it/export/sites/aas1/it/documenti/all-dao/mat-info/nch-tunnel-carpale-rev-01.pdf>
20. «LE LESIONI MENISCALI». Joint Care Team. 2020. <https://www.jointcareteam.it/wp-content/uploads/2020/06/Advance-2-menisco-lesioni.pdf>
21. «Borsite del ginocchio: sintomi, cause, trattamenti». Brexido. <https://www.brexido.it/il-dolore/dolore-al-ginocchio/borsite-al-ginocchio>
22. alberto V. «TENDINOPATIA DELL'ACHILLE». Gennaio 2020. <https://www.albertovascellari.it/wp-content/uploads/2020/12/TENDINITE-ACHILLE.pdf>
23. Davide S. «Sindrome del Tunnel Tarsale». <https://www.fisioscience.it/patologie/sindrome-del-tunnel-tarsale/>
24. Daniel O. Odebiyi and Udoka Arinze Chris Okafor. «Musculoskeletal Disorders, Workplace Ergonomics and Injury Prevention». DOI: 10.5772/intechopen.106031. 08 February 2023. <https://www.intechopen.com/chapters/84280>
25. Legge italiana. (2008). Decreto Legislativo 9 aprile 2008, n. 81. Testo Unico sulla Salute e Sicurezza sul Lavoro. «La movimentazione manuale dei carichi». Protocollo italiano. (2013). Prot. 5085/a20 del 11.10.2013
26. Da Costa, Br, e Er Vieira. «Stretching to Reduce Work-Related Musculoskeletal Disorders: A Systematic Review». *Journal of Rehabilitation Medicine* 40, fasc. 5 (2008): 321–28. <https://doi.org/10.2340/16501977-0204>.
27. Lacaze, Denise Helena De Castro, Isabel De C.N. Sacco, Lys Esther Rocha, Carlos Alberto De Bragança Pereira, e Raquel Aparecida Casarotto. «Stretching and Joint Mobilization Exercises Reduce Call-Center Operators' Musculoskeletal Discomfort and Fatigue». *Clinics* 65, fasc. 7 (2010): 657–62. <https://doi.org/10.1590/S1807-59322010000700003>.

28. Autori: U. Caselli, F. Nappi, D. Rughi. «Attività di sollevamento semplici». Inail (2019). [https://www.inail.it/cs/internet/docs/comparto\\_edilizia\\_misure\\_di\\_prev\\_pdf\\_2443085401782.pdf?section=attivita](https://www.inail.it/cs/internet/docs/comparto_edilizia_misure_di_prev_pdf_2443085401782.pdf?section=attivita)
29. Mark Middlesworth. A Step-by-Step Guide. «Rapid Upper Limb Assessment (RULA)». Ergonomics Plus. <https://ergo-plus.com/wp-content/uploads/RULA-A-Step-by-Step-Guide1.pdf>
30. Fabrizio B. «Traumi da sforzi ripetuti in edilizia». Inail (2003). <https://www.inail.it/cs/internet/docs/alg-traumi-da-sforzi-ripetuti-in-edilizia.pdf>
31. Michela Santoni. «Studio e applicazione di nuove tecniche di Intelligenza Artificiale per l'analisi ergonomica di operatori in ambienti di fabbrica». CORSO DI LAUREA MAGISTRALE IN INGEGNERIA MECCANICA. UNIVERSITÀ POLITECNICA DELLE MARCHE. <https://tesi.univpm.it/retrieve/ed9f146f-7ea8-4788-8544-6d5be15730fb/Tesi%20Santoni>
32. Francesco Nappi, Ugo Caselli, Diego Rughi, Daniela Sar-to, Nicoletta Todaro. «Il protocollo OCRA». Inail (2017). [https://www.inail.it/cs/internet/docs/ocra\\_pdf.pdf?section=attivita](https://www.inail.it/cs/internet/docs/ocra_pdf.pdf?section=attivita)
33. Francesco Nappi, Ugo Caselli, Diego Rughi, Daniela Sar-to, Nicoletta Todaro. «Il metodo Strain index». Inail (2017). [https://www.inail.it/cs/internet/docs/strain\\_index\\_pdf.pdf?section=attivita](https://www.inail.it/cs/internet/docs/strain_index_pdf.pdf?section=attivita)
34. Francesco Nappi, Ugo Caselli, Diego Rughi, Daniela Sar-to, Nicoletta Todaro. «Il metodo HAL/ACGIH TLV». Inail (2017). [https://www.inail.it/cs/internet/docs/il\\_metodo\\_halacgih\\_tlv\\_pdf.pdf?section=attivita](https://www.inail.it/cs/internet/docs/il_metodo_halacgih_tlv_pdf.pdf?section=attivita)
35. Eleonora R. «Applicazioni dell'analisi del cammino alla patologia del piede diabetico: cinematica e pressioni plantari». Corso di laurea triennale in Ingegneria Biomedica. Università degli Studi di Padova.
36. Antwi-Afari, Maxwell Fordjour, Heng Li, Yantao Yu, e Liulin Kong. «Wearable Insole Pressure System for Automated Detection and Classification of Awkward Working Postures in Construction Workers». Automation in Construction 96 (dicembre 2018): 433–41. <https://doi.org/10.1016/j.autcon.2018.10.004>.
37. Cheng, Wei-Yi, Alf Scotland, Florian Lipsmeier, Timothy Kilchenmann, Liping Jin, Jens Schjodt-Eriksen, Detlef Wolf, et al. «Human Activity Recognition from Sensor-Based Large-Scale Continuous Monitoring of Parkinson's Disease Patients». In 2017

IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE), 249–50. Philadelphia, PA: IEEE, 2017. <https://doi.org/10.1109/CHASE.2017.87>.

[

38. Kazemimoghadam, Mahdiah, e Nicholas P. Fey. «An Activity Recognition Framework for Continuous Monitoring of Non-Steady-State Locomotion of Individuals with Parkinson's Disease». *Applied Sciences* 12, fasc. 9 (6 maggio 2022): 4682. <https://doi.org/10.3390/app12094682>.
39. Liu, Chien-Liang, Chia-Hoang Lee, e Ping-Min Lin. «A Fall Detection System Using K-Nearest Neighbor Classifier». *Expert Systems with Applications* 37, fasc. 10 (ottobre 2010): 7174–81. <https://doi.org/10.1016/j.eswa.2010.04.014>.
40. Donisi, Leandro, Giuseppe Cesarelli, Noemi Pisani, Alfonso Maria Ponsiglione, Carlo Ricciardi, e Edda Capodaglio. «Wearable Sensors and Artificial Intelligence for Physical Ergonomics: A Systematic Review of Literature». *Diagnostics* 12, fasc. 12 (5 dicembre 2022): 3048. <https://doi.org/10.3390/diagnostics12123048>.
41. Morten Gram P.,(anno scolastico 2022/2023). «Machine Learning for Bioengineering». Università degli Studi di Padova.
42. Atzoi M. Agostini F.,(anno scolastico 2022/2023). «Deep learning applied to nuroscience and rehabilitation». Università degli Studi di Padova.
43. Antwi-Afari, Maxwell Fordjour, Heng Li, Waleed Umer, Yantao Yu, e Xuejiao Xing. «Construction Activity Recognition and Ergonomic Risk Assessment Using a Wearable Insole Pressure System». *Journal of Construction Engineering and Management* 146, fasc. 7 (luglio 2020): 04020077. [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0001849](https://doi.org/10.1061/(ASCE)CO.1943-7862.0001849).
44. Zemp, Roland, Matteo Tanadini, Stefan Plüss, Karin Schnüriger, Navrag B. Singh, William R. Taylor, e Silvio Lorenzetti. «Application of Machine Learning Approaches for Classifying Sitting Posture Based on Force and Acceleration Sensors». *BioMed Research International* 2016 (2016): 1–9. <https://doi.org/10.1155/2016/5978489>.
45. Srijan, Mallika, Alpana, e Priyanka Gupta. «A Review on Posture Detection and Correction Using Machine Learning and Deep Learning». In *2022 Second International Conference on Next Generation Intelligent Systems (ICNGIS)*, 1–5. Kottayam, India: IEEE, 2022. <https://doi.org/10.1109/ICNGIS54955.2022.10079726>.



- [46] - Conforti, Ilaria, Ilaria Mileti, Zaccaria Del Prete, e Eduardo Palermo. «Measuring Biomechanical Risk in Lifting Load Tasks Through Wearable System and Machine-Learning Approach». *Sensors* 20, fasc. 6 (11 marzo 2020): 1557. <https://doi.org/10.3390/s20061557>.
46. Palaniappan, Adithyan, R. Bhargavi, e V. Vaidehi. «Abnormal Human Activity Recognition Using SVM Based Approach». In *2012 International Conference on Recent Trends in Information Technology*, 97–102. Chennai, Tamil Nadu, India: IEEE, 2012. <https://doi.org/10.1109/ICRTIT.2012.6206829>.
47. Ryu, Juhyeong, JoonOh Seo, Meiyin Liu, SangHyun Lee, e Carl T. Haas. «Action Recognition Using a Wristband-Type Activity Tracker: Case Study of Masonry Work». In *Construction Research Congress 2016*, 790–99. San Juan, Puerto Rico: American Society of Civil Engineers, 2016. <https://doi.org/10.1061/9780784479827.080>.
48. Tripathy, Rajesh Kumar, Ashutosh Acharya, Sumit Kumar Choudhary, e Santosh Kumar Sahoo. «Artificial Neural Network Based Body Posture Classification from EMG Signal Analysis». *Indonesian Journal of Electrical Engineering and Informatics (IJEI)* 1, fasc. 2 (11 aprile 2013): 59–63. <https://doi.org/10.11591/ijeel.v1i2.59>.
49. Martina V., Cappon G. (anno scolastico 2022/2023). «Biomedical Wearable Technologies for Healthcare and Wellbeing». Università degli Studi di Padova.
50. Lim, Sol, e Clive D'Souza. «A Narrative Review on Contemporary and Emerging Uses of Inertial Sensing in Occupational Ergonomics». *International Journal of Industrial Ergonomics* 76 (marzo 2020): 102937. <https://doi.org/10.1016/j.ergon.2020.102937>.
51. Colombo A, (2019 - 2020). «SISTEMA INERZIALE INDOSSABILE UPPER BODY PER L'ERGONOMIA FISICA: ANALISI E VALIDAZIONE». (Corso di Laurea Magistrale in Ingegneria Biomedica, Politecnico di Milano). <https://www.politesi.polimi.it/handle/10589/166385>.
52. Santoni F., (2016). «Design, Fabbricazione e Caratterizzazione di Giroscopi MEMS». (Università degli studi Roma Tre). <https://arcadia.sba.uniroma3.it/handle/2307/5880>
53. 221e s.r.l. (2023). Homepage di 221e : <https://www.221e.com/>
54. Mattiello L., «Foot Pressure Sensors Placement». 221e s.r.l. (2 Maggio 2019).

55. Ciniglio A., Guiotto A., Spolaor F., Sawachal Z (2021). «The Design and Simulation of a 16-Sensors Plantar Pressure Insole Layout for Different Applications: From Sports to Clinics, a Pilot Study». *Sensors (Basel)*, 21(4), 1450. <https://doi.org/10.3390/s21041450>
56. Mattiello L., (2019). «Yeti – Load test: Experimental calibration with dynamometer measurements». 221e s.r.l.
57. Dehkordi, M. B., Zareki, A., Setchi, R. (2020). «Feature extraction and feature selection in smartphone-based activity recognition». *Procedia Computer Science*, 176, 2655–2664. <https://doi.org/10.1016/j.procs.2020.09.301>
58. Preece, S. J., Goulermas, J. Y., Kenney, L. P. J., Howard, D., Meijer, K., Crompton, R. (2009). «Activity identification using body-mounted sensors—a review of classification techniques. *Physiological Measurement*», 30(4), R1–R33. <https://doi.org/10.1088/0967-3334/30/4/R01>.
59. Molnar, C. (2023). «Interpretable Machine Learning: A Guide for Making Black Box Models Explainable». <https://christophm.github.io/interpretable-ml-book/>.
60. Atzoi M. Agostini F.,(anno scolastico 2022/2023). «Deep learning applied to nuroscience and rehabilitation». Università degli Studi di Padova.
61. Ranavolo, Alberto, Tiwana Varrecchia, Sergio Iavicoli, Agnese Marchesi, Martina Rinaldi, Mariano Serrao, Silvia Conforto, Mario Cesarelli, e Francesco Draicchio. «Surface Electromyography for Risk Assessment in Work Activities Designed Using the “Revised NIOSH Lifting Equation”». *International Journal of Industrial Ergonomics* 68 (novembre 2018): 34–45. <https://doi.org/10.1016/j.ergon.2018.06.003>.
62. Cagnie, B., L. Danneels, D. Van Tiggelen, V. De Loose, e D. Cambier. «Individual and Work Related Risk Factors for Neck Pain among Office Workers: A Cross Sectional Study». *European Spine Journal* 16, fasc. 5 (maggio 2007): 679–86. <https://doi.org/10.1007/s00586-006-0269-7>.
63. De Beeck, Rik Op, e Veerle Hermans. *Research on Work-Related Low Back Disorders*. Brussels, Belgium: Institute for Occupational Safety and Health, 2000.
64. Barr, Ann E, Mary F Barbe, e Brian D Clark. «Work-Related Musculoskeletal Disorders of the Hand and Wrist: Epidemiology, Pathophysiology, and Sensorimotor Changes», 2006.