



UNIVERSITÀ
POLITECNICA
DELLE MARCHE

FACOLTÀ DI INGEGNERIA

CORSO DI LAUREA IN INGEGNERIA MECCANICA

**MISURA E ANALISI DEI SEGNALI ACCELEROMETRI PER L'IDENTIFICAZIONE
DELLE ATTIVITÀ DI UTENTI IN AMBIENTI INDOOR (MEASUREMENT AND
ANALYSIS OF ACCELEROMETER SIGNALS FOR THE IDENTIFICATION OF USER
ACTIVITIES IN INDOOR ENVIRONMENTS)**

Relatore:

Prof. Gian Marco
Revel

Tesi di Laurea di:

Ye David Bo Qian

Correlatore:

Prof. Sara Casaccia
Dot. Ilaria Ciuffreda

Anno accademico 2023/2024

INDICE

LISTA DI FIGURE	3
LISTA DELLE TABELLE	4
ABSTRACT	5
1. INTRODUZIONE.....	6
1.1 COMFORT AMBIENTALI IN AMBIENTI DI VITA.....	6
1.2 COMFORT ACUSTICO	7
1.3 COMFORT SULLA QUALITÀ D'ARIA	7
1.4 COMFORT VISIVO.....	8
1.5 COMFORT TERMICO	8
1.5.1 L'INFLUENZA DELLE ATTIVITÀ SUL TASSO METABOLICO	10
1.5.2 IMPORTANZA DEL RICONOSCIMENTO DELLE ATTIVITÀ UMANE	11
1.6 SCOPO DI QUESTA TESI	12
2. STATO DELL' ARTE.....	14
2.1 SENSORI PER IL RICONOCIMENTO DELLE ATTIVITÀ UMANE	14
2.1.1 SENSORI NON INDOSSABILI: SENSORE ULTRASONORI	15
2.1.2 SENSORI INDOSSABILI: ACCELEROMETRI.....	16
2.2 MACHINE LEARNING (ML)	19
2.3 DEEP LEARNING (DL)	21
3. MATERIALI E METODI	24
3.1 PROTOCOLLO DI MISURA E SETUP SPERIMENTALE	24
3.2 METODOLOGIE PER L'HAR	33
3.2.1 PREPROCESSAMENTO	34
3.2.2 FILTRAGGIO DEI DATI (DWT)	34
3.2.3 VETTORE MAGNITUDINE (VM)	35
3.2.3 INDICATORI TEMPORALI	36
4. RISULTATI	38
4.1 RISULTATI DEL FILTRAGGIO.....	38
4.2 RISULTATI DELL'INDICATORE TEMPORALE	41
4.2.1 VALUTAZIONE INTRASOGGETTO	41
4.2.2 VALUTAZIONE INTERSOGETTO	46

5. DISCUSSIONE	49
6. CONCLUSIONE	51
RICONOSCIMENTI.....	51
RIFERIMENTI.....	49

LISTA DI FIGURE

Figura 1. Rappresentazione intuitiva su come lavora la PMV.....	9
Figura 2. Impostazione della scrivania.....	26
Figura 3. Esempio di domande di survey1.....	27
Figura 4. Esempio di domande di survey2.....	27
Figura 5. Netatmo NWS01.....	30
Figura 6. DOM-X.....	30
Figura 7. EMPATICA E4.....	32
Figura 8. Lo schema a blocchi della metodologia impiegata.....	34
Figura 9. Grafico dei dati grezzi senza Wavelet per l'attività leggere l'articolo dell'utente S01B.....	39
Figura 10. Grafico dei dati grezzi con Wavelet per l'attività leggere l'articolo dell'utente S01B.....	40
Figura 11. Valori RMS intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 1.....	41
Figura 12. Valori RMS intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 2.....	42
Figura 13. Valori RMS intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 3.....	42
Figura 14. Valori FC intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 1.....	43
Figura 15. Valori FC intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 2.....	43
Figura 16. Valori FC intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 3.....	44
Figura 17. Valori FF intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 1.....	44
Figura 18. Valori FF intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 2.....	45
Figura 19. Valori FF intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 3.....	45
Figura 20. Valori RMS intersoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) per tutti gli utenti.....	46

Figura 21. Valori FC intersoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) per tutti gli utenti.....	47
Figura 22. Valori FF intersoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) per tutti gli utenti.....	47
Figura 23. Valori RMS intersoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) per tutti gli utenti senza DWT.....	48
Figura 24. Valori FC intersoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) per tutti gli utenti senza DWT.....	48
Figura 25. Valori FF intersoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) per tutti gli utenti senza DWT.....	49

LISTA DELLE TABELLE

Tabella 1. Informazioni generali sui partecipanti.....	25
Tabella 2. Procedura dell'esperimento.....	27
Tabella 3. Liste di sensori ambientali e caratteristiche tecniche.....	29
Tabella 4. Stato ambientale.....	31

ABSTRACT

L'obiettivo di questo esperimento è stato l'analisi e il riconoscimento delle attività umane (Human Activity Recognition - HAR) utilizzando accelerometri con l'intento di contribuire al miglioramento del comfort personale in ambienti lavorativi o domestici. Sono stati coinvolti 52 soggetti, distribuiti per età, sesso e indice di massa corporea, che hanno svolto diverse attività in un ambiente controllato. Durante l'esperimento, i partecipanti hanno eseguito una serie di attività (come la lettura, la scrittura al computer, la conversazione telefonica e la discussione) mentre venivano registrati i dati degli accelerometri e di altri sensori. I dati raccolti sono stati elaborati utilizzando tecniche classiche di elaborazione, che prevedono l'impiego della Trasformata Wavelet Discreta (DWT), il calcolo del vettore magnitudo (VM) e l'estrazione di marcatori temporali.

L'analisi dei dati ha evidenziato che, utilizzando metodologie classiche come il calcolo della radice quadrata media (RMS) dai segnali accelerometrici, è possibile discriminare alcuni livelli di attività, ma con una capacità limitata, probabilmente a causa della natura statica delle attività e delle piccole variazioni nei segnali. Per ottenere una classificazione più dettagliata e accurata, sarebbe opportuno integrare tecniche avanzate, come algoritmi di machine learning. Nonostante ciò, il riconoscimento delle attività umane tramite accelerometri ha mostrato un grande potenziale per l'analisi del comportamento e la valutazione del comfort personale, con possibili applicazioni future nella personalizzazione degli ambienti lavorativi. I risultati suggeriscono che, se adeguatamente calibrati, questi sistemi potrebbero contribuire significativamente alla creazione di ambienti intelligenti e orientati al benessere umano.

1. INTRODUZIONE

1.1 COMFORT AMBIENTALI IN AMBIENTI DI VITA

Il comfort ambientale è un elemento cruciale per il benessere delle persone che trascorrono gran parte del loro tempo in ambienti chiusi come abitazioni, uffici e spazi pubblici. Questo concetto si riferisce al livello di benessere percepito in relazione a vari fattori ambientali, tra cui temperatura, qualità dell'aria, illuminazione e acustica, tutti determinanti per la salute, la produttività e la qualità della vita [1][2]. Tradizionalmente, modelli come il Predicted Mean Vote (PMV) hanno cercato di quantificare il comfort termico medio per gruppi di persone, ma questi strumenti presentano limiti significativi: ignorano le differenze individuali, come genere, età, preferenze personali e dinamiche fisiologiche, e faticano a rappresentare situazioni transitorie, come il passaggio tra ambienti con differenti condizioni climatiche [13][14]. Per superare queste limitazioni, si è sviluppato il Personal Comfort Model (PCM), un approccio innovativo che utilizza dati personalizzati raccolti tramite sensori avanzati e algoritmi di intelligenza artificiale per adattare dinamicamente le condizioni ambientali alle necessità di ciascun individuo. Il PCM integra il riconoscimento delle attività umane (HAR), che consente di monitorare i movimenti e classificare le attività fisiche in tempo reale, calcolando così con precisione il tasso metabolico individuale, un parametro chiave per determinare il comfort termico [3][4][19].

Questo approccio personalizzato non solo ottimizza le condizioni interne in base alle esigenze specifiche, ma contribuisce anche alla sostenibilità, regolando dinamicamente parametri come temperatura, rumorosità, e illuminazione per ridurre il consumo energetico [17][18]. Parallelamente, il comfort ambientale si estende oltre l'aspetto termico per includere aspetti come il comfort acustico, che migliora la concentrazione e riduce lo stress, la qualità dell'aria, fondamentale per prevenire problemi di salute legati all'inquinamento

indoor, e il comfort visivo, che garantisce un'illuminazione adeguata a diminuire l'affaticamento e potenziare la produttività [1].

1.2 COMFORT ACUSTICO

Il comfort acustico riguarda la percezione di un ambiente in relazione ai rumori e suoni presenti. Un buon livello di comfort acustico è essenziale per il benessere e la produttività degli occupanti in spazi lavorativi, educativi o residenziali.

Quando il rumore è eccessivo o di scarsa qualità, può ostacolare le attività quotidiane, ridurre la concentrazione, compromettere le capacità cognitive e aumentare lo stress.

Diversi fattori influenzano il comfort acustico, tra cui l'intensità del suono, il tipo di rumore (ad esempio, rumore di fondo o voci) e la frequenza dei suoni. In generale, ambienti silenziosi o con rumori non invadenti favoriscono un buon comfort acustico, mentre ambienti con suoni forti, continui o improvvisi possono risultare fastidiosi e creare disagio.

La qualità acustica ha anche un impatto diretto sulle prestazioni cognitive, come l'attenzione e la creatività. L'esposizione a rumori elevati può compromettere la capacità di concentrarsi su compiti complessi, mentre ambienti più tranquilli o con rumori controllati possono stimolare una maggiore produttività e creatività.

Inoltre, il comfort acustico interagisce con altri fattori ambientali, come la temperatura e la qualità dell'aria. Alcuni studi suggeriscono che la percezione del rumore può essere influenzata dalla temperatura, con determinati livelli termici che amplificano o attenuano il suo impatto. Pertanto, il comfort acustico deve essere considerato all'interno di un sistema integrato di fattori che contribuiscono al benessere globale degli occupanti [1][7].

1.3 COMFORT SULLA QUALITÀ D'ARIA

La qualità dell'aria interna (Indoor Air Quality, IAQ) è un aspetto fondamentale del comfort ambientale, in quanto influisce direttamente sulla salute, sul benessere e sulla produttività delle persone. L'IAQ si riferisce alla qualità dell'aria negli ambienti chiusi, come abitazioni, uffici e scuole, ed è determinata dalla concentrazione di inquinanti, dalla ventilazione, dall'umidità relativa e da altri parametri ambientali. Poiché le persone trascorrono fino al

90% del loro tempo al chiuso, un'IAQ ottimale è essenziale per garantire un ambiente salubre e confortevole [8][9].

1.4 COMFORT VISIVO

Il comfort visivo è strettamente legato alle attività svolte all'interno di uno spazio, poiché ogni attività richiede condizioni specifiche di illuminazione per garantire un'esperienza visiva ottimale e sicura. Ad esempio:

- Attività di lettura o scrittura: richiedono un'illuminazione diretta e uniforme, con livelli di luminanza adeguati a evitare affaticamento visivo.
- Lavoro al computer: necessita di un equilibrio tra luce naturale e artificiale per ridurre riflessi e abbagliamenti sullo schermo.
- Attività di relax o intrattenimento: possono beneficiare di un'illuminazione soffusa e regolabile per creare un'atmosfera confortevole.
- Attività manuali o tecniche: come cucinare o lavori artigianali, richiedono luce direzionata con un'alta resa cromatica per distinguere dettagli e colori con precisione.

La relazione tra attività e comfort visivo è anche influenzata dai fattori personali, come l'età, la salute visiva e le esigenze individuali. Ad esempio, gli anziani possono richiedere livelli di illuminazione più elevati e una migliore uniformità per svolgere le stesse attività rispetto ai giovani. Allo stesso modo, le persone con sensibilità alla luce o con condizioni oculari particolari necessitano di soluzioni personalizzate.

Questo approccio consente di personalizzare l'esperienza visiva, migliorando il benessere degli utenti e ottimizzando l'uso dell'energia. In sintesi, il comfort visivo non è solo una questione di progettazione statica, ma si evolve in base alle attività svolte e alle esigenze degli occupanti, creando ambienti più adattivi e confortevoli [16].

1.5 COMFORT TERMICO

Il comfort termico è un concetto fondamentale negli ambienti di lavoro, poiché influisce direttamente sul benessere e sulla produttività dei lavoratori. Si riferisce alla sensazione di comfort che una persona sperimenta in relazione, per esempio, alle condizioni termiche dell'ambiente. Quando questi fattori sono percepiti come adeguati, i lavoratori si sentono a loro agio e sono in grado di

concentrarsi meglio sulle proprie attività, con effetti positivi sulla produttività e sul benessere psicofisico.

Per valutare il comfort termico, si utilizzano parametri come il Predicted Mean Vote (PMV), che misura la sensazione termica complessiva di un individuo, e il Predicted Percentage of Dissatisfied (PPD), che indica la percentuale di persone insoddisfatte in base alla temperatura percepita. Un PMV pari a 0.0, che corrisponde a una condizione termicamente neutra, rappresenta il massimo livello di soddisfazione (come mostrato in figura 1), ma studi recenti suggeriscono che una temperatura leggermente più fresca o più calda può stimolare una maggiore concentrazione, grazie a una leggera sensazione di stress che aumenta la produttività.

Tuttavia, il comfort termico non dipende solo dalla temperatura ambientale, ma anche da altri fattori. In particolare, il tasso metabolico (metabolic rate) gioca un ruolo cruciale nella percezione del comfort termico. Il metabolismo umano, che determina la quantità di calore prodotto dal corpo in relazione all'attività fisica, influisce sulla sensazione di caldo o freddo. Inoltre, le caratteristiche individuali, come età e genere, influenzano la percezione termica, poiché ciascuna persona ha una risposta fisiologica unica alle condizioni ambientali [5][6].

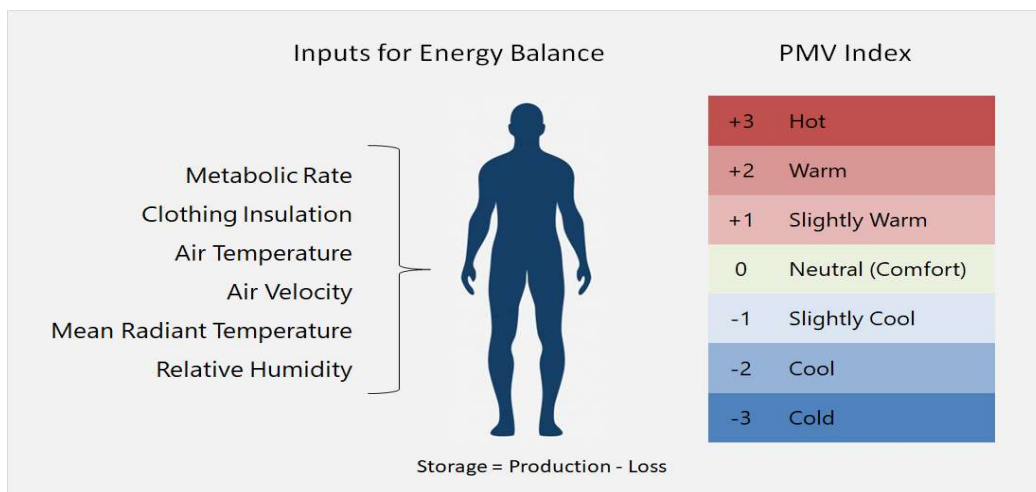


Figura 1: rappresentazione intuitiva su come lavora la PMV

1.5.1 L'INFLUENZA DELLE ATTIVITÀ SUL TASSO METABOLICO

Il tasso metabolico (MR) di una persona è influenzato da una combinazione di fattori interni ed esterni, ma uno degli elementi più rilevanti è l'attività fisica che viene svolta. Durante l'esercizio fisico, il corpo richiede più energia per sostenere i movimenti muscolari e rispondere alle esigenze fisiologiche, come la respirazione e la circolazione sanguigna, con un conseguente aumento del MR. Le attività che richiedono un maggiore sforzo, come correre o sollevare pesi, portano ad un incremento notevole del metabolismo rispetto ad attività più leggere, come camminare o stare seduti. Ad esempio, correre può aumentare il MR fino a 5-8 volte rispetto alla condizione di riposo, mentre altre attività di bassa intensità, come camminare, provocano un incremento più contenuto. Per questo è anche importante tenere conto e riconoscere le attività che sta svolgendo una persona.

Tuttavia, oltre all'attività fisica, altri fattori influenzano il MR, come la composizione corporea (in particolare la percentuale di massa muscolare e di tessuto adiposo), l'età e il sesso. La massa muscolare è particolarmente importante, poiché i muscoli sono più attivi dal punto di vista energetico rispetto al tessuto adiposo. Le persone con una maggiore massa muscolare tendono ad avere un MR più elevato, mentre con l'invecchiamento, la perdita di massa muscolare porta a un rallentamento del metabolismo. Anche il sesso gioca un ruolo significativo, poiché, in generale, gli uomini tendono ad avere un MR più elevato rispetto alle donne, principalmente per la maggiore quantità di massa muscolare e minor percentuale di grasso corporeo.

Per il riconoscimento delle attività umane (HAR), il monitoraggio e l'analisi del MR possono essere effettuati utilizzando sensori indossabili come accelerometri, che rilevano i movimenti e determinano l'intensità delle attività svolte. Questo è particolarmente utile per adattare dinamicamente parametri come il comfort termico, regolando la temperatura o la ventilazione in base all'attività fisica e al tasso metabolico della persona. L'integrazione di dati raccolti dai sensori con modelli predittivi, come la PCM, consente di ottenere una stima più precisa e personalizzata del comfort ambientale in tempo reale, migliorando il benessere degli individui e ottimizzando l'efficienza energetica. In questo contesto, il HAR e il monitoraggio del MR sono strumenti chiave per

la creazione di ambienti adattivi che rispondono alle necessità specifiche degli utenti, considerando le variazioni individuali nelle attività e nel metabolismo [34][24].

1.5.2 IMPORTANZA DEL RICONOSCIMENTO DELLE ATTIVITÀ UMANE

Il riconoscimento delle attività umane (HAR) è un campo di ricerca in crescita che si concentra sull'identificazione e l'interpretazione delle azioni fisiche delle persone, utilizzando i dati provenienti dai loro movimenti corporei. Le applicazioni di questa tecnologia sono molteplici e spaziano dalla salute al monitoraggio delle attività anomale, dai giochi interattivi alla domotica, con l'obiettivo di migliorare la qualità della vita quotidiana.

Uno degli approcci principali per l'HAR è l'utilizzo di sensori, tra cui accelerometri e sensori ultrasonori. Gli accelerometri sono dispositivi che misurano le accelerazioni lungo uno o più assi, permettendo di rilevare i movimenti e le variazioni di posizione di un corpo. Questi sensori, molto diffusi in dispositivi portatili come smartphone, smartwatch e braccialetti intelligenti, sono spesso usati per il monitoraggio delle attività fisiche quotidiane. I sensori ultrasonori, invece, utilizzano onde sonore ad alta frequenza per rilevare distanze e movimenti, e sono particolarmente utili in applicazioni che richiedono precisione e sensibilità, come la misurazione delle posture o la valutazione di ambienti in movimento.

L'approccio basato su sensori offre numerosi vantaggi rispetto alla visione computerizzata, poiché è più discreto, economico e pratico per un utilizzo quotidiano e continuativo. Inoltre, i sensori indossabili, come quelli incorporati in smartwatch, smart band o dispositivi emergenti come gli smart ring, permettono una raccolta di dati in tempo reale senza interferire con le normali attività della persona. Grazie all'Internet of Things (IoT), questi dispositivi non solo monitorano i movimenti, ma forniscono anche informazioni vitali sulla salute, come la frequenza cardiaca e la pressione sanguigna, creando nuove opportunità per la gestione della salute e la prevenzione di malattie.

Il riconoscimento delle attività tramite sensori, combinato con l'analisi dei dati, offre inoltre la possibilità di personalizzare il monitoraggio delle persone,

adattandosi alle caratteristiche fisiche individuali, come età, sesso e stato di salute. Le tecnologie emergenti, come la pelle elettronica(e-skin) o i tatuaggi intelligenti, che integrano sensori direttamente sulla pelle o su oggetti quotidiani, stanno aprendo nuovi orizzonti nel monitoraggio della salute e nel miglioramento della qualità della vita, offrendo un'analisi in tempo reale dei comportamenti e delle condizioni fisiche delle persone.

Con l'integrazione di modelli di intelligenza artificiale (AI), l'HAR sta diventando sempre più sofisticato. I modelli di AI possono essere integrati direttamente nei dispositivi, migliorando l'accuratezza delle analisi e riducendo il consumo energetico, fondamentale per i dispositivi portatili. Questi progressi tecnologici sono destinati a rendere il riconoscimento delle attività umane sempre più preciso e utile, sia per applicazioni mediche che per miglioramenti nella vita quotidiana.

Le applicazioni del HAR sono in continua evoluzione, con la prospettiva che dispositivi sempre più piccoli ed economici consentano un monitoraggio continuo delle attività, fornendo informazioni vitali in tempo reale e contribuendo così al benessere degli utenti. La combinazione di sensori avanzati e tecnologie intelligenti promette di rivoluzionare vari ambiti, da quello sanitario a quello tecnologico, con applicazioni sempre più precise e personalizzate, come nel caso della medicina preventiva, dell'analisi comportamentale e della gestione dell'ambiente domestico e lavorativo [10][11][12].

1.6 SCOPO DI QUESTA TESI

Questo lavoro di tesi si focalizza sull'uso degli accelerometri per il riconoscimento delle attività umane (HAR), con l'obiettivo di sviluppare metodologie innovative per la calibrazione e il filtraggio dei dati provenienti da questi sensori. Gli accelerometri, dispositivi piccoli, leggeri e facilmente indossabili, sono ideali per monitorare l'attività fisica e l'interazione dell'individuo con l'ambiente circostante.

Inizialmente, l'attenzione è rivolta allo sviluppo di metodi di calibrazione dei dati accelerometrici, necessari per ottimizzare la qualità dei segnali raccolti. I dati grezzi ottenuti dagli accelerometri richiedono un'elaborazione accurata per

rimuovere rumori e distorsioni che potrebbero compromettere l'accuratezza dell'analisi. A tal fine, sono stati implementati algoritmi di filtraggio per migliorare la qualità del segnale, estraendo caratteristiche temporali significative come l'accelerazione sui tre assi, che sono cruciali per distinguere correttamente le diverse attività. Questi metodi di calibrazione e filtraggio sono essenziali per garantire che i dati siano il più possibile accurati e utilizzabili per il successivo riconoscimento delle attività.

Successivamente, viene esplorata una serie di metodologie per l'estrazione delle caratteristiche dai dati accelerometrici, al fine di determinare quale approccio fosse il più adatto per l'analisi delle attività. L'obiettivo è identificare il metodo che permette di ottenere la miglior performance nel riconoscimento delle attività, ottimizzando l'accuratezza e riducendo al minimo gli errori, e identificare quale tra le tecniche di estrazione delle caratteristiche fornisce i risultati migliori in termini di accuratezza del riconoscimento delle attività. Queste caratteristiche sono fondamentali per distinguere le diverse attività fisiche, come camminare, correre, salire le scale o altre azioni quotidiane.

Questo lavoro di tesi si inserisce nel contesto del progetto WEPOP (Wearable Platform for Optimised Personal comfort), che propone di sviluppare una piattaforma integrata di monitoraggio personalizzato del comfort. Il progetto WEPOP adotta un approccio innovativo per misurare e controllare il comfort personale in tempo reale, considerando non solo il comfort termico, ma anche le attività svolte dall'utente e la qualità dell'ambiente circostante. L'approccio proposto, che integra l'uso di accelerometri e machine learning per il riconoscimento delle attività, contribuirà a questo obiettivo più ampio, offrendo una componente fondamentale per il monitoraggio del benessere fisico e per la gestione del comfort in ambienti residenziali e lavorativi.

2. STATO DELL' ARTE

2.1 SENSORI PER IL RICONOCIMENTO DELLE ATTIVITÀ UMANE

L'ambito del HAR è diventato di grande interesse grazie alle sue numerose applicazioni in settori come la salute, lo sport, la sorveglianza e la domotica. I sensori utilizzati per il riconoscimento delle attività umane si dividono principalmente in due categorie: sensori non indossabili e sensori indossabili.

I sensori non indossabili comprendono dispositivi come i sensori ultrasonori, che sono spesso utilizzati per monitorare i movimenti del corpo a distanza. Questi sensori utilizzano onde sonore ad alta frequenza per rilevare la distanza e il movimento degli oggetti nelle vicinanze, permettendo di monitorare attività come camminare o muoversi in uno spazio. I sensori ultrasonori possono essere impiegati per misurare la velocità e la posizione degli utenti, ma, purtroppo, sono più limitati rispetto ai sensori indossabili in ambienti complessi, dove i movimenti del corpo potrebbero non essere facilmente tracciati senza un contatto diretto o una riflessione precisa delle onde sonore [11].

I sensori indossabili, come gli accelerometri, sono invece strumenti più comuni per il riconoscimento delle attività umane. Gli accelerometri rilevano l'accelerazione del corpo umano in tre dimensioni, misurando i cambiamenti di velocità durante il movimento. Questi sensori sono in grado di monitorare una vasta gamma di attività fisiche come camminare, correre, saltare, o anche compiti più delicati come l'analisi posturale. Grazie alla loro portabilità, i sensori indossabili sono particolarmente utili per acquisire dati in tempo reale durante le attività quotidiane, senza interferire con la naturale condotta del soggetto [25].

Una volta raccolti i dati dai sensori, essi vengono analizzati utilizzando tecniche di machine learning o deep learning. Questi metodi avanzati permettono di identificare schemi e caratteristiche rilevanti direttamente dai dati grezzi, migliorando la precisione nel riconoscimento delle attività umane. Mentre le

tecniche di machine learning si basano su algoritmi che apprendono dai dati attraverso processi di classificazione e clustering, le tecniche di deep learning, come le reti neurali, sono in grado di apprendere modelli più complessi e astratti, ottimizzando la capacità di riconoscere attività in scenari variabili e con una grande quantità di dati sensoriali [20].

L'uso dei sensori per il riconoscimento delle attività umane ha rivoluzionato il modo in cui monitoriamo e comprendiamo le azioni quotidiane, con applicazioni che spaziano dalla salute al fitness, alla sorveglianza, e alla gestione intelligente degli ambienti. L'integrazione dei dati provenienti dai sensori con algoritmi di machine learning e deep learning ha reso possibile l'automazione e il miglioramento continuo delle tecnologie di HAR, portando a soluzioni sempre più precise e personalizzabili [11][25].

2.1.1 SENSORI NON INDOSSABILI: SENSORE ULTRASONORI

I sensori ultrasonori sono uno dei sensori più utilizzati nel campo dell'HAR, rappresentano una tecnologia avanzata utilizzata per il riconoscimento delle attività umane (HAR) in contesti intelligenti. Questi sensori funzionano emettendo onde sonore ad alta frequenza (oltre 20 kHz), che vengono riflesse dagli oggetti circostanti e analizzate per rilevare movimenti o misurare distanze. La loro applicazione nel HAR si distingue per la capacità di monitorare i movimenti del corpo umano in modo non invasivo, garantendo la privacy rispetto alle soluzioni basate su immagini, come le videocamere, che possono presentare limiti in termini di illuminazione e campo visivo, oltre a problemi di intrusività.

Negli ambienti smart, i sensori ultrasonori sono particolarmente apprezzati per la loro precisione nel rilevare movimenti e posture, contribuendo all'ottimizzazione del comfort personale e al miglioramento dell'efficienza energetica. A differenza dei sensori indossabili, che possono risultare scomodi e influenzati da rumore e deriva nei dati, i sensori ultrasonori integrati nell'ambiente offrono un'alternativa non intrusiva per monitorare le attività umane.

Questa tecnologia, se combinata con altre fonti di dati fisiologici e ambientali, consente una rappresentazione completa dello stato di benessere di un individuo, facilitando il controllo termo-igrometrico degli ambienti e riducendo i consumi energetici. Sebbene ancora poco esplorata rispetto ad altre tecnologie, l'integrazione dei sensori ultrasonori in piattaforme di monitoraggio multi-dominio rappresenta un'importante innovazione, ampliando le possibilità di classificazione e riconoscimento delle attività umane in tempo reale [20][21].

2.1.2 SENSORI INDOSSABILI: ACCELEROMETRI

Negli ultimi anni, l'evoluzione delle tecnologie di monitoraggio e analisi dei movimenti umani ha portato alla diffusione di dispositivi indossabili avanzati, tra cui gli accelerometri, che hanno trovato applicazione in numerosi ambiti, dalla salute e il benessere alla sicurezza, passando per la riabilitazione e l'analisi dell'attività fisica. Gli accelerometri sono sensori che misurano l'accelerazione su uno o più assi, fornendo dati precisi sul movimento e sulla postura del corpo umano. Grazie alla loro capacità di rilevare e analizzare i cambiamenti di posizione e accelerazione, questi dispositivi sono diventati strumenti fondamentali per la valutazione dell'attività fisica, del rischio di cadute e per la rilevazione dei pattern di movimento.

L'uso degli accelerometri per il monitoraggio dell'attività fisica è cruciale per comprendere il comportamento motorio delle persone, in particolare degli anziani, per i quali l'attività fisica ha un impatto significativo sulla salute e sul benessere psicofisico. La pandemia di COVID-19 ha ulteriormente messo in evidenza l'importanza di soluzioni tecnologiche per monitorare il distanziamento sociale e per incentivare l'attività fisica in sicurezza, specialmente in contesti ad alto rischio, come negli ambienti residenziali per anziani. Tuttavia, il sedentarismo aumentato a causa delle misure di distanziamento ha accelerato il declino fisico e mentale, evidenziando la necessità di soluzioni innovative che possano monitorare in tempo reale le attività fisiche e promuovere comportamenti sani [24].

In quest'ottica, la HAR tramite sensori come gli accelerometri è diventata una delle applicazioni più rilevanti per migliorare la qualità della vita e ridurre i

rischi legati a infortuni. Possono essere usati i sensori inerziali (IMU) per raccogliere dati accelerometrici sulle attività fisiche, per monitorare il comportamento motorio e analizzare il rischio di cadute, contribuendo così a strategie di prevenzione e intervento.

Uno degli esempi più significativi di applicazione di sensori IMU in HAR è presentato nello studio di [24], dove un sistema di localizzazione in tempo reale (RTLS) viene utilizzato per tracciare la posizione delle persone anziane, monitorando non solo la loro attività fisica, ma anche il rispetto della distanza sociale durante la pandemia. I sensori IMU, come i “tag Leonardo IMU” posizionati sul polso e supportati dalla tecnologia Ultra-Wide Band (UWB), raccolgono dati accelerometrici che vengono poi elaborati tramite la trasformata Discreta Wavelet (DWT) per rimuovere il rumore e ottenere dati più precisi. I valori accelerometrici vengono utilizzati per calcolare l'intensità dell'attività fisica, suddividendo l'attività in livelli di intensità (leggera, moderata e alta) tramite un sistema di sogliazione basato su valori di Radice Quadrata della Media dei Quadrati (RMS). Sebbene efficace, il sistema presenta alcuni limiti, tra cui l'incertezza nel sistema di localizzazione, con una precisione di ± 1 m/s² nei sensori IMU e una possibile imprecisione nella misurazione della distanza sociale (± 30 cm), che potrebbe influenzare la classificazione delle attività, specialmente nelle transizioni tra attività di bassa e media intensità.[24]

Un altro esempio è descritto nello studio [22]. Questa ricerca si concentra sullo sviluppo di un sistema HAR economico e in tempo reale. Il sistema utilizza i dati di un accelerometro indossato sul corpo per riconoscere e classificare le attività umane, offrendo una soluzione economica, facile da usare e altamente precisa. Una delle principali sfide affrontate in questo studio è l'esecuzione di un riconoscimento efficiente dei movimenti in un ambiente con risorse limitate. Le caratteristiche proposte sono la Deviazione Assoluta Media (AAD), la Deviazione Standard (STD), l'Intervallo Interquartile (IQR), l'Intervallo e la Radice della Media Quadrata (RMS). La ricerca ha condotto numerosi esperimenti e confronti per stabilire i parametri ottimali al fine di garantire l'efficacia del sistema, tra cui la definizione di una frequenza di campionamento di 50 Hz e la selezione di una finestra di 8 secondi con una sovrapposizione del 40% tra le finestre. La validazione è stata effettuata sia sul dataset pubblico

WISDM che su un dataset raccolto autonomamente, concentrandosi su cinque attività quotidiane fondamentali: stare in piedi, sedersi, correre, camminare e salire le scale. I risultati hanno mostrato un'alta precisione nel riconoscimento, con il sistema che ha raggiunto il 96,7% di accuratezza sul dataset WISDM e il 97,13% sul dataset raccolto. Questa ricerca conferma la fattibilità di implementare sistemi HAR su microcontrollori a bassa prestazione e ne evidenzia le potenziali applicazioni nel supporto ai pazienti, nella riabilitazione e nella cura degli anziani [22].

Il monitoraggio dell'attività fisica di una persona ha una vasta gamma di applicazioni sia nello sport che nella medicina. Con i progressi tecnologici nella misurazione del movimento umano, è possibile monitorare l'attività svolta senza la necessità di un esperto che sovrintenda direttamente all'allenamento. Recentemente la ricerca si è concentrata anche sugli esercizi di forza: l'obiettivo è ottenere la massima precisione nel tracciamento dei movimenti, mantenendo però basso il costo e l'autonomia energetica del dispositivo di monitoraggio. Nell'articolo [23] viene presentato un algoritmo per la segmentazione e la classificazione dei movimenti ripetitivi durante gli allenamenti, basato su dati di accelerometro a 3 assi provenienti da un dispositivo indossabile. I segnali dell'accelerometro sono stati registrati continuamente durante la sessione di allenamento, che consisteva tipicamente in 9 esercizi di forza, con 8 movimenti ripetuti in tre serie. La segmentazione dei segnali di accelerazione registrati durante l'allenamento è stata effettuata utilizzando lo spettro di frequenza della magnitudine dell'accelerazione con un'accuratezza del 99,4%, mentre la classificazione dei movimenti segmentati è stata eseguita utilizzando l'algoritmo Dynamic Time Warping (DTW) con un'accuratezza dell'85,7% [23].

Ulteriori studi hanno esaminato anche l'uso di tecniche alternative per la classificazione delle attività, come l'analisi basata su k-Nearest Neighbors (k-NN) o Support Vector Machines (SVM), per migliorare la robustezza e l'affidabilità delle previsioni. L'approccio di filtraggio dei dati tramite trasformate Wavelet o altre tecniche di riduzione del rumore è stato frequentemente utilizzato per ridurre gli errori causati da rumori ambientali o movimenti non pertinenti. La combinazione di queste tecniche avanzate ha permesso di ottenere risultati promettenti, con precisioni superiori al 90% nella

classificazione delle attività. Nonostante i progressi, le sfide legate all'incertezza dei sensori, alle variazioni individuali nei movimenti e alla complessità nell'interpretazione dei dati accelerometrici rimangono ancora tematiche cruciali. Inoltre, l'utilizzo di sensori indossabili, come i tag IMU, può essere influenzato dalla disponibilità e accettazione degli utenti, dove la portabilità e il comfort del dispositivo sono fattori determinanti per la sua adozione [24][32].

Le metodologie per il riconoscimento delle attività umane tramite accelerometri sono in continua evoluzione. Ogni approccio ha vantaggi significativi, ma deve affrontare anche limitazioni tecniche legate all'incertezza dei sensori, alla complessità computazionale e all'accettabilità da parte dell'utente [32].

2.2 MACHINE LEARNING (ML)

L'uso del machine learning (ML) ha permesso significativi progressi nell'ambito del riconoscimento delle attività umane (HAR), sfruttando algoritmi tradizionali come Naïve Bayes (NB), Random Forest (RF), Support Vector Machine (SVM), Decision Tree (DT) e k-Nearest Neighbors (k-NN). Questi metodi si basano su pipeline consolidate che includono la raccolta dei dati, la segmentazione delle azioni, l'estrazione manuale delle caratteristiche e la classificazione. Offrono vantaggi quali efficienza computazionale e semplicità di implementazione, ma presentano limiti evidenti. In particolare, l'estrazione manuale delle caratteristiche richiede tempo ed esperienza, limitando la capacità di tali modelli di affrontare attività complesse o scenari dinamici [20].

Per affrontare queste limitazioni, lo studio [26] propone un dispositivo di edge computing integrato per il rilevamento umano in spazi intelligenti interni. Il dispositivo utilizza il metodo della somma cumulativa (CUSUM) per raccogliere e processare i dati da diversi sensori e adotta un algoritmo random forest a bassa complessità (RFA) per rilevare e classificare i movimenti del corpo. I sensori integrati sono infrarossi (IR) e ultrasonici (US). L'articolo confronta i benefici dell'uso combinato di CUSUM e RFA rispetto agli approcci di machine learning tradizionali in termini di accuratezza, complessità, tempo di calcolo e memoria. La soluzione proposta è testata sperimentalmente per il

rilevamento delle cadute in ambienti intelligenti, con il sistema RFA che riduce la complessità di almeno tre volte rispetto ai metodi tradizionali, come le reti neurali convoluzionali e la memoria a lungo termine. Il sistema ha un tempo di elaborazione di circa 0,1 secondi e un'accuratezza del 94% [26].

Un altro approccio emergente nel HAR riguarda l'uso di segnali EEG (segnali elettrici registrati dall'attività cerebrale) che vengono integrati sul ML per classificare attività quotidiane (come il riposo, compiti motori e cognitivi), utilizzando tecniche di XAI per identificare le caratteristiche EEG più rilevanti per i diversi stati di riconoscimento delle attività umane (HAR). Lo studio ha coinvolto 75 individui sani senza disturbi neurologici preesistenti, con registrazioni EEG effettuate durante il riposo, due attività motorie (camminare e lavorare) e un'attività cognitiva (leggere). Gli elettrodi sono stati posizionati in specifiche aree cerebrali (frontale, centrale, temporale e occipitale). Diversi modelli di machine learning sono stati addestrati sui dati EEG per il riconoscimento delle attività, e LIME (Local Interpretable Model-Agnostic Explanations) è stato utilizzato per interpretare le caratteristiche spettrali EEG più influenti nei modelli HAR. I risultati di classificazione, in particolare con Random Forest e Gradient Boosting, hanno mostrato ottime performance nel distinguere le attività umane analizzate [28].

Nell'ambito della sicurezza e sorveglianza, il HAR ha dimostrato grande potenziale nella rilevazione di comportamenti anomali o rischiosi. Lo studio [27] presenta una panoramica dei lavori di ricerca esistenti nell'area della sicurezza e della sorveglianza, che include algoritmi tradizionali, di machine learning (ML) e deep learning (DL) applicabili al settore. Questo articolo di revisione offre linee guida per la selezione degli algoritmi appropriati, dei set di dati e delle metriche di performance nella valutazione dei sistemi HAR nel contesto della sicurezza e della sorveglianza e i risultati dicono che la scelta tra modelli di ML o DL dipende dalla dimensione del set di dati, dalle risorse hardware, dai requisiti in tempo reale, dall'interpretabilità del modello e dai requisiti di calcolo. Sebbene il DL sia una famiglia più ampia della ML, ciò non significa che il DL sia sempre migliore del machine learning. I modelli ML sono statistici, mentre quelli DL sono dinamici. L'interpretabilità dei modelli DL è bassa e richiede unità di elaborazione parallela più potenti. Se il set di dati disponibile è piccolo e semplice, è meglio applicare un modello ML, che

risparmia risorse computazionali, riduce la complessità temporale e spaziale e abbassa i costi di GPU e TPU. Tuttavia, per attività complesse, è preferibile scegliere modelli DL per la classificazione e il riconoscimento.[27]

Il campo del HAR continua a migliorarsi, combinando metodi tradizionali, come RF e SVM, che offrono robustezza e interpretabilità, con approcci innovativi basati su sensori avanzati e tecnologie come XAI. Questi sviluppi mirano a bilanciare efficienza, accuratezza e scalabilità, affrontando le sfide legate alla complessità computazionale e all'adattabilità a scenari reali. Le soluzioni proposte non solo migliorano le capacità di monitoraggio e classificazione delle attività, ma ampliano anche le possibilità di applicazione in contesti sempre più complessi e multidimensionali [20][26][27][28].

2.3 DEEP LEARNING (DL)

L'HAR ha visto un notevole progresso grazie all'introduzione delle tecniche di deep learning (DL), che hanno superato le limitazioni degli approcci tradizionali di machine learning, come la necessità di ingegnerizzare manualmente le caratteristiche.

I metodi di DL hanno trasformato il riconoscimento delle attività umane basato su sensori, offrendo approcci diversi con vantaggi specifici: gli auto-encoder eccellono nella riduzione del rumore e nell'apprendimento non supervisionato, ma soffrono di scarsa interpretabilità; le CNN sono flessibili e potenti per l'elaborazione di dati strutturati, ma richiedono grandi dataset annotati; RNN e LSTM gestiscono bene i dati temporali, ma sono difficili da addestrare; le GAN sono utili per l'augmentazione dei dati, ma hanno una complessità di addestramento elevata; il reinforcement learning consente l'apprendimento online, ma richiede definizione manuale delle ricompense. L'articolo [29] ha concluso che la scelta del metodo dipende dalla complessità del problema, dalla quantità e qualità dei dati, dalle risorse computazionali e dagli obiettivi specifici, con soluzioni diverse per problemi semplici o complessi.

Una delle tecniche più diffuse per l'elaborazione dei segnali accelerometrici, sono le reti neurali convoluzionali (CNN), utilizzate per l'analisi dei dati spaziali grazie alla loro capacità di estrarre pattern da dati grezzi in modo automatico, riducendo il rischio di sovra campionamento.

Le CNN sono particolarmente efficaci nell'analizzare segnali provenienti da sensori indossabili, come accelerometri e giroscopi, e nel riconoscere movimenti del corpo umano o eventi specifici [20]. Per dati sequenziali come quelli accelerometrici, le Long Short-Term Memory (LSTM), una variante delle Reti Neurali Ricorrenti (RNN), sono particolarmente utili. Le LSTM, infatti, sono in grado di memorizzare informazioni su ampi intervalli di tempo, superando il problema del gradiente che svanisce tipico delle RNN, e gestendo in modo efficace sequenze temporali di dati [20].

Un esempio concreto di successo nell'applicazione di DL al HAR è il framework AccNet24, un framework basato sul deep learning per classificare le categorie di attività su 24 ore utilizzando dati di accelerometri da polso. Partendo da un dataset pubblico di 151 partecipanti (18-91 anni), i segnali di accelerazione (assi x, y, z) sono stati segmentati in finestre di 30 secondi, trasformati in immagini, e analizzati con il trasferimento di apprendimento per estrarre caratteristiche profonde. Queste caratteristiche sono state utilizzate in una rete neurale ricorrente BiLSTM per classificare quattro comportamenti: sonno, comportamento sedentario, attività fisica leggera e moderata/intensa. Il modello è stato confrontato con cinque algoritmi di machine learning tradizionali (es. Random Forest e SVM), mostrando un miglioramento della precisione del 16-30% su dati non visti, raggiungendo un'accuratezza superiore al 95%. Questo dimostra il potenziale delle tecniche di deep learning per migliorare le analisi di accelerometri di prossima generazione [30].

Un' altro vantaggio significativo dell'adozione del deep learning è la possibilità di ridurre la dipendenza dalla posizione dell'accelerometro. Lo studio [31] utilizza reti neurali profonde basate su Long Short-Term Memory (LSTM) per classificare il posizionamento del dispositivo (polso, anca, torace) e l'intensità dell'attività fisica utilizzando dati accelerometrici grezzi raccolti da 54 partecipanti. I valori di riferimento per l'intensità (espressi in equivalenti metaboliche, MET) sono stati ottenuti tramite il sistema metabolico portatile COSMED K5. I modelli LSTM hanno raggiunto un'accuratezza superiore al 90% per entrambe le classificazioni, superando i tradizionali algoritmi basati sui "count", che hanno mostrato un'accuratezza tra il 64% e l'85% in caso di errata specificazione del posizionamento. Includendo parametri aggiuntivi come età, altezza e peso, l'accuratezza è aumentata oltre il 95%, evidenziando

il potenziale delle LSTM per analisi accelerometriche avanzate, indipendentemente dal sito di posizionamento del dispositivo [31].

Più recentemente, sono stati proposti approcci avanzati nella classificazione delle attività umane. Un esempio innovativo è rappresentato dal modello FusionActNet di [32], una rete neurale che integra due reti residuali per analizzare separatamente il comportamento statico e dinamico degli utenti. Questa ricerca propone uno schema efficace per il riconoscimento delle attività umane, che introduce due approcci unici all'interno di un'architettura multistrutturale, denominata FusionActNet. Il primo approccio mira a catturare il comportamento statico e dinamico di una particolare azione utilizzando due reti residue dedicate, mentre il secondo approccio facilita il processo finale di decisione introducendo un modulo di guida. È stato progettato un processo di addestramento in due fasi: nella prima fase, le reti residue vengono pre-addestrate separatamente utilizzando dati statici (dove il corpo umano è immobile) e dinamici (che coinvolgono il movimento del corpo umano). Nella fase successiva, il modulo di guida, insieme ai modelli statici/dinamici pre-addestrati, viene utilizzato per addestrare i dati sensoriali. Qui, il modulo di guida apprende a enfatizzare il vettore di previsione più rilevante ottenuto dai modelli statici/dinamici, il che aiuta a classificare efficacemente le diverse attività umane. Lo schema proposto è stato valutato utilizzando due dataset di riferimento e confrontato con i metodi più avanzati. I risultati hanno raggiunto un'accuratezza del 97,35% e del 95,35% rispettivamente sui dataset UCI HAR e MotionSense, il che evidenzia l'efficacia e la stabilità dello schema proposto.

Tuttavia, l'adozione del deep learning presenta anche delle sfide. Le CNN e le LSTM richiedono dataset di grandi dimensioni per l'addestramento e un'alta potenza computazionale, limitando l'applicabilità di questi metodi in ambienti con risorse limitate. Inoltre, l'interpretabilità dei risultati rimane una questione importante. Sebbene i modelli deep learning siano molto precisi, comprendere come una rete neurale arrivi a una determinata decisione non è sempre immediato, motivo per cui le tecniche di Intelligenza Artificiale Spiegabile sono fondamentali per migliorare la comprensibilità dei modelli [20][29].

In conclusione, le tecniche di deep learning, hanno aperto nuove possibilità per il riconoscimento delle attività umane, migliorando l'accuratezza e la flessibilità

delle soluzioni esistenti. Nonostante le sfide, il futuro del riconoscimento delle attività sembra orientato verso l'adozione di questi approcci avanzati, con l'aspettativa di ulteriori miglioramenti nei modelli e nelle tecniche di interpretabilità.

3. MATERIALI E METODI

In questo capitolo sono descritti i set-up sperimentali e i metodi utilizzati per l'estrazione delle caratteristiche dai dati raccolti.

3.1 PROTOCOLLO DI MISURA E SETUP SPERIMENTALE

Il test ha coinvolto un totale di 52 volontari con la distribuzione della popolazione impostata per includere almeno il 20% dei partecipanti di età compresa tra 18 e 43 anni, il 20% tra 44 e 65 anni e il 20% sopra i 65 anni. Inoltre, è stato garantito che almeno il 20% dei partecipanti fosse di sesso femminile e almeno il 20% di sesso maschile. Per quanto riguarda l'indice di massa corporea (BMI), almeno il 10% dei partecipanti aveva un BMI inferiore a 18,5, il 10% un BMI compreso tra 18,6 e 25 e il 10% un BMI superiore a 30(come mostrato nella tabella 1).

<p>Partecipanti</p> <p><i>Nota: le caratteristiche di questo campione sono probabilmente difficilmente raggiungibili. Tuttavia, sarebbe utile avvicinarsi il più possibile a queste caratteristiche.</i></p>	<p>Dimensione -> Non meno di 25-30 Età -> almeno il 20% tra 18 e 43 anni -> almeno il 20% tra 44 e 65 anni -> almeno il 20% sopra i 65 anni Genere -> almeno il 20% femmine; almeno il 20% maschi Razza/Etnia -> almeno il 10% per ciascun punto della scala Fitzpatrick (6) BMI -> almeno il 10% sotto 18,5 almeno il 10% tra 18,6 e 25 almeno il 10% sopra 30 Idoneità -> Nessuna terapia farmacologica Nessuna malattia cardiovascolare Firma del consenso informato</p>

Tabella 1: informazioni generali sui partecipanti

Questi criteri hanno permesso di includere una vasta gamma di caratteristiche individuali, assicurando che i risultati fossero generalizzabili a una popolazione più ampia. Prima della partecipazione, tutti i volontari hanno fornito il loro consenso informato firmando un modulo, e i dati raccolti sono stati completamente anonimizzati e gestiti nel pieno rispetto delle normative GDPR. Lo studio, inoltre, è stato approvato dal Comitato Etico dell'Università Politecnica delle Marche (UNIVPM) e condotto in collaborazione con l'Università di Perugia, seguendo i principi della Dichiarazione di Helsinki.

L'esperimento si è svolto nella stanza NEXT.ROOM, un ambiente controllato progettato per simulare un contesto lavorativo, caratterizzato da una differenza di temperatura tra interno ed esterno di almeno 15 °C, regolata in base alle condizioni stagionali per riflettere realisticamente variazioni termiche. La stanza comprendeva due postazioni di prova posizionate strategicamente (in modo da avere due utenti): una orientata verso la porta e l'altra verso una finestra aperta con vista sull'esterno (Figura 2). Ogni postazione era equipaggiata con due monitor (di dimensioni da specificare), tastiera, mouse, webcam, quaderni e matite per annotazioni manuali, cuffie con cancellazione del rumore (modello SONY WH-1000XM4), una camera a 360° (modello RICOH THETA SC2) montata sul soffitto, e, quando necessario, camere visibili e a infrarossi (modello FLIR AX8). Questo setup è stato progettato per raccogliere dati dettagliati sulle interazioni dei partecipanti con l'ambiente e i dispositivi.




Figura 2: impostazione della scrivania

I partecipanti hanno eseguito una sequenza di attività progettata per simulare scenari tipici di un contesto lavorativo. Le attività includevano:

- Leggere un articolo predefinito,
- Scrivere al computer su un foglio elettronico
- Simulare una conversazione telefonica leggendo frasi preimpostate e partecipare a una discussione su temi specifici.
- Discussione (conversazione) tra i due partecipanti

Un elemento chiave del protocollo è stato l'uso di sondaggi per raccogliere dati qualitativi sui partecipanti. Prima dell'inizio dell'esperimento, ogni volontario ha completato un sondaggio iniziale (Survey1) progettato per raccogliere informazioni personali di base, come nome, età, sesso e stato di salute generale. Durante le pause tra un'attività e l'altra, ai partecipanti è stato somministrato un secondo sondaggio (survey2) focalizzato sulla valutazione delle loro condizioni fisiche e del comfort generale, includendo aspetti legati al comfort termico, visivo, acustico e alla qualità dell'aria (figura 3 e 4).

Ogni attività è stata intervallata da un periodo di riposo di 5 minuti, necessario sia per consentire ai partecipanti di rilassarsi sia per eseguire i sondaggi. L'intera sequenza di attività è stata ripetuta due volte per ciascun partecipante.

Prima di eseguire il secondo ciclo della prova, i due partecipanti hanno la necessità di scambiare postazione con una durata di circa 2 minuti, dopodiché si ripetono le attività con una durata totale complessiva di 116 minuti (tabella 2).

USER ID (to be defined by experimenter)
SESSION NAME (I guess to be defined according with the specific experimental session goal, so to be defined by experimenter)
AGE
GENDER
NATIONALITY
WEIGHT (KG)
HEIGHT (CM)

Figura 3: esempio di domande di survey1

THERMAL PERCEPTION

Q1: WHAT IS YOUR THERMAL SENSATION [-3;3]

Q2: WHAT IS YOUR THERMAL COMFORT [-3;3]

Q3: HOW DO YOU PREFER THERMAL ENVIRONMENT [-3;3]

VISUAL PERCEPTION

Q1: WHAT IS YOUR VISUAL SENSATION [-3;3]

Q2: WHAT IS YOUR VISUAL COMFORT [-3;3]

Q3: HOW DO YOU PREFER VISUAL ENVIRONMENT [-3;3]

Figura 4: esempio di domande di survey2

Durata(m inuti)	Compito
2	Stare in piedi
20	Tempo di acclimatamento, istruzioni per il test firma del consenso e sondaggio 1
5	Riposo, linea di base dei segnali fisiologici e sondaggio 2
19(totale)	attività individuali in ufficio:
5	leggere un articolo,
2	riposo & sondaggio 2,
5	scrivere su carta,
2	riposo & sondaggio 2,
5	scrivere un testo al computer
5	Riposo, linea di base dei segnali fisiologici e sondaggio 2
12(totale)	Espletamento di attività interattive in ufficio (tra i lavoratori):
5	discussione tra i due partecipanti,
2	riposo & sondaggio 2,
5	attività di interferenza: chiamata in conferenza (soggetto 1 ci presenta telefonicamente quanto detto dal soggetto 2) e riassunto della discussione (soggetto 2 scrive su carta quanto detto dal soggetto 1)
5	Riposo, linea di base dei segnali fisiologici e sondaggio 2
2	Stare in piedi e scambiarsi di posizione
5	Riposo(seduto), linea di base dei segnali fisiologici e sondaggio 2

Tabella 2: procedura dell'esperimento

Nel test vengono utilizzati sensori ultrasonici e accelerometri in combinazione con sensori ambientali.

I sensori ambientali sono dispositivi fondamentali per la valutazione del comfort in vari ambiti, inclusi quelli termici, acustici, visivi e della qualità dell'aria interna. È cruciale ottimizzare le condizioni ambientali all'interno degli spazi lavorativi per garantire il benessere dei dipendenti e, allo stesso tempo, aumentare la loro produttività. Per ottenere risultati affidabili, è necessario raccogliere dati precisi non solo sulle condizioni ambientali, ma anche sull'attività svolta dalle persone in ufficio, in modo da poter adattare gli spazi alle specifiche necessità degli utenti.

Vengono utilizzati i sensori multiparametrici per monitorare una serie di parametri ambientali all'interno di uffici e altri spazi indoor. I parametri monitorati in questo studio sono stati: temperatura, umidità relativa, livello di rumore, concentrazione di CO₂, composti organici volatili, particolato (PM) con diverse dimensioni e luminosità ambientale (come mostrato nella tabella 3).

SENSORI	<i>Precisione</i>	<i>Range</i>	<i>Parametri</i>
DOM-X	Temperatura: ± 1 °C; Umidità: $\pm 3\%$ RH; PM1/PM2.5/PM10: $\pm 10\%$.		T, RH, PM1, PM2.5, PM10, CO ₂ , VOC, illuminazione
Netatmo nws01	Temperatura: $\pm 0,3$ °C; Umidità: $\pm 3\%$ RH	Temperatura: 0 - 50 °C; Umidità: 0 - 100% RH. Ambient noise: 35 - 120 dB; CO ₂ : 0 - 5000ppm	T, RH, rumori, CO ₂

Tabella 3: liste di sensori ambientali e caratteristiche tecniche

A seguito di un'accurata analisi di mercato, sono stati selezionati due sensori che si sono rivelati particolarmente idonei per le misurazioni necessarie:

- Netatmo (Boulogne-Billancourt, Francia), che consente di monitorare con precisione la temperatura (T), l'umidità relativa (Rh), la concentrazione di CO2 e il livello di rumore (rappresentato nella Figura 5).
- DOM-X, che è stato scelto per la sua capacità di misurare vari parametri ambientali come temperatura, umidità e qualità dell'aria. (Figura 6)



Figura 5: Netatmo NWS01




Figura 6: DOM-X

Le misurazioni dei parametri ambientali sono state effettuate a intervalli regolari durante il periodo di test, come descritto nella Tabella 1.

I dati acquisiti sono stati salvati in un database interno per permettere successive analisi.

Questi sensori, grazie alla loro versatilità e affidabilità, sono stati scelti per raccogliere informazioni utili al fine di ottimizzare l'ambiente lavorativo e migliorare il comfort degli occupanti. Attraverso l'analisi dei dati, si mira a ottenere un ambiente di lavoro più adatto alle esigenze degli utenti.

Nella tabella 4 vengono illustrati lo stato ambientale dell'ufficio.

Dominio	Fattori	Livelli	
		Inverno	estate
Termico	Temperatura d'aria [°C]	22	26
		28	20
Visuale	-Temperatura superficiale (involucro) [°C]	~ 4000	
	-Temperatura di colore correlata della luce (luce artificiale) (K) - Illuminamento (luce artificiale) sul piano della	~ 500 lx	

	scrivania al livello degli occhi - Vista esterna (scrivania di fronte alla finestra, una persona la vede, l'altra no)	~ 300 lx YES, NO
Acustico	*Rumore HVAC, cuffie con cancellazione del rumore	YES, NO

Tabella 4: Stato ambientale

In questo test vengono utilizzati sensori ultrasonici e accelerometri per raccogliere dati utili al monitoraggio e al riconoscimento delle attività umane. Tuttavia, il lavoro di tesi si concentra sulla metodologia sviluppata, strettamente correlata ai dati accelerometrici forniti dal dispositivo Empatica E4 (mostrato in figura 7) che è un dispositivo indossabile altamente sofisticato, progettato per il monitoraggio continuo e in tempo reale di parametri fisiologici e comportamentali, particolarmente utile per applicazioni di HAR. Il dispositivo è stato concepito per fornire una visione dettagliata e accurata dei movimenti corporei in ambienti reali e in condizioni di vita quotidiana, attraverso l'integrazione di diversi sensori, tra cui un accelerometro MEMS (Sistema Micro-Electro-Meccanica) a tre assi; è un dispositivo che garantisce l'affidabilità e la sicurezza per l'uso in contesti sanitari e di ricerca. Questo rende il dispositivo particolarmente utile non solo per applicazioni di HAR, ma anche per studi clinici e monitoraggio del benessere fisiologico in scenari di vita quotidiana. Grazie alla sua forma compatta e al design ergonomico, l'Empatica E4 è progettato per essere comodo da indossare per lunghi periodi, con un'impronta minima sul comfort dell'utente.



Figura 7: EMPATICA E4

L'accelerometro presente nell'Empatica E4 ha una frequenza di campionamento di 32 Hz, il che consente di raccogliere dati a intervalli regolari e precisi, adatti per il riconoscimento e la classificazione delle attività fisiche. La risoluzione dell'accelerometro è di 8 bit, il che implica che ogni campione di accelerazione acquisito dal dispositivo è rappresentato da un valore che riflette i movimenti nei tre assi spaziali (X, Y, Z). Questo permette al dispositivo di monitorare con precisione le variazioni di movimento in direzioni diverse, come camminare, correre, sedersi o alzarsi, facilitando l'identificazione automatica delle attività.

Un aspetto importante del funzionamento dell'accelerometro è la calibrazione dei dati grezzi per ottenere misurazioni di accelerazione effettive. Il dispositivo utilizza un fattore di conversione che traduce i dati grezzi in valori di accelerazione reali, con una formula di conversione di $g/64$, dove "g" rappresenta l'accelerazione gravitazionale (circa 9.81 m/s^2). La gamma di misurazione dell'accelerometro va da $-2g$ a $+2g$, ma attraverso l'uso di firmware personalizzati, è possibile estendere la portata fino a $\pm 4g$ o $\pm 8g$, a seconda delle necessità specifiche per l'applicazione di HAR.

Oltre all'accelerometro, Empatica E4 è equipaggiato con altri sensori che contribuiscono al monitoraggio completo delle condizioni fisiologiche dell'utente. Tra questi, il sensore PPG (Photoplethysmogram) rileva la frequenza cardiaca e la variabilità dell'intervallo tra i battiti (IBI), mentre il sensore SC (Skin Conductance) misura le variazioni nella conduttanza elettrica

della pelle, indicativa dello stress o dell'attivazione del sistema nervoso simpatico. Un altro sensore importante è il termometro a infrarossi, che misura la temperatura corporea, fornendo dati rilevanti per analizzare il comfort termico dell'utente; può operare anche in modalità di streaming per la visualizzazione in tempo reale dei dati, tramite un'interfaccia Bluetooth Low Energy (BLE) e un app mobile dedicata, oppure in modalità di registrazione in memoria, dove i dati vengono temporaneamente memorizzati nella memoria interna del dispositivo. Il dispositivo ha una durata della batteria dichiarata di circa 24 ore in modalità di streaming e più di 48 ore in modalità di registrazione in memoria. In entrambi i casi, i dati registrati vengono inviati a un archivio cloud sicuro, chiamato E4 Connect, dove vengono organizzati in sessioni separate per ogni sensore. Ogni sessione, salvata in un archivio compresso zip, include file CSV separati per ogni sensore, che possono essere facilmente analizzati [33].

3.2 METODOLOGIE PER L'HAR

Lo schema a blocchi della metodologia impiegata per svolgere l'intero lavoro è mostrato nella figura 8. Nei successivi sottocapitoli, vengono descritti i vari blocchi. Una volta acquisiti tutti i segnali necessari attraverso l'impostazione dei sensori, la quantità di dati è stata memorizzata ed elaborata in tempo reale nell'ambiente Python, seguendo una procedura ben definita che viene successivamente spiegata passo dopo passo. La metodologia di elaborazione dei dati ha coinvolto principalmente i dati accelerometrici, posizionato nei polsi degli utenti.

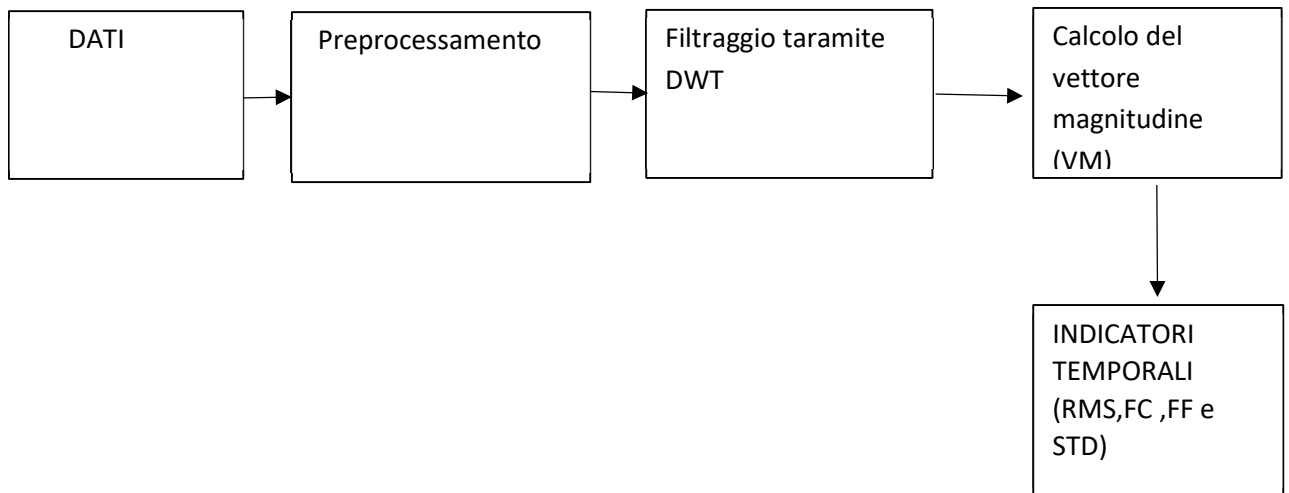


Figura 8: Lo schema a blocchi della metodologia impiegata

3.2.1 PREPROCESSAMENTO

Dopo l'acquisizione dei dati dall'accelerometro, il primo passo consiste nell'estrarli da un file in formato CSV. Tra tutti i dati disponibili, vengono selezionati quelli rilevanti per le analisi successive. Questa selezione viene effettuata utilizzando Python e librerie specifiche per la manipolazione dei dati.

Successivamente, i dati vengono etichettati con le attività corrispondenti (leggere, scrivere, discussione e telefonare). L'etichettatura avviene basandosi sulle informazioni temporali contenute nel file originale, dove sono specificati i periodi di tempo associati a ciascuna attività.

Per l'etichettatura delle attività, si incorporano nel codice i tempi di inizio e fine di ciascuna attività, insieme alla loro durata. Queste informazioni vengono quindi utilizzate per associare le etichette corrette ai dati registrati nel periodo corrispondente. Infine, i dati elaborati vengono salvati in un nuovo file CSV, che include una colonna aggiuntiva contenente le etichette delle attività.

Questo approccio garantisce un flusso di lavoro chiaro e strutturato, facilitando l'analisi e l'interpretazione dei dati raccolti.

3.3.3 FILTRAGGIO DEI DATI (DWT)

I dati grezzi accelerometrici etichettati vengono successivamente sottoposti a un processo di filtraggio per ridurre il rumore attraverso l'utilizzo della

Trasformata Wavelet Discreta (DWT), implementata in Python. La trasformata Wavelet è una tecnica matematica utilizzata per analizzare segnali e dati in modo da ottenere informazioni sia sul loro comportamento temporale che sulla loro frequenza. Essa è una generalizzazione della trasformata di Fourier, ma a differenza di quest'ultima, che analizza i segnali in modo globale. Questo metodo isola i dati originali dai segnali contaminati dal rumore, evitando così di introdurre errori nell'analisi delle informazioni.

Nello specifico, è stata applicata la Wavelet di Daubechies di ordine 4 ai dati accelerometrici, ottenendo una trasformazione numerica composta da due componenti principali: i coefficienti dettagliati, che catturano le fluttuazioni ad alta frequenza, e i valori approssimativi, che rappresentano le componenti a bassa frequenza del segnale.

Per ridurre il rumore, è stato adottato un approccio sistematico: i coefficienti dettagliati, spesso associati al rumore di fondo, sono stati azzerati. Successivamente, è stata applicata l'inversa della DWT per ricostruire il segnale accelerometrico originario. Questo processo ha prodotto dati filtrati, privi di rumore, che mantengono le informazioni rilevanti per l'analisi successiva.

L'utilizzo di questa tecnica consente di ottenere segnali accelerometrici più puliti e affidabili, migliorando significativamente la qualità dei dati destinati alle fasi successive di elaborazione e interpretazione.[24]

3.2.3 VETTORE MAGNITUDINE (VM)

Dopo il filtraggio delle accelerazioni lungo i tre assi, è stato calcolato il valore della Magnitudine del Vettore (VM) di ogni singolo campione combinando le accelerazioni sui tre assi per fornire una misura complessiva dell'intensità del movimento [24]. Questo valore è stato calcolato utilizzando la seguente equazione per ciascun campione acquisito dagli accelerometri(eq.1):

$$VM = \sqrt{x^2 + y^2 + z^2} \quad (1)$$

In cui x , y e z rappresentano rispettivamente l'accelerazione lungo i rispettivi assi di quello specifico campione.

3.2.3 INDICATORI TEMPORALI

Successivamente, vengono applicati diversi metodi per l'estrazione delle caratteristiche associate alle varie attività, utilizzando i dati accelerometrici precedentemente elaborati. Tutti questi metodi vengono applicati utilizzando una tecnica di finestra temporale di 30 secondi, il che significa che i calcoli e le analisi vengono eseguiti su segmenti di dati di durata pari a 30 secondi. Questo approccio consente di analizzare il comportamento del segnale in intervalli temporali definiti, rendendo l'analisi dei dati più dettagliata e permettendo una corretta caratterizzazione delle attività attraverso il monitoraggio di picchi, variazioni e altre caratteristiche significative.

I valori del Vettore magnitudine (VM) sono già stati calcolati e vengono utilizzati come base per le tecniche applicate, descritte di seguito:

- Valore quadratico medio (RMS): Il primo metodo consiste nel calcolare la RMS con i valori della VM, al fine di ottenere una misura della dispersione dei dati relativi a ciascuna attività (eq.2).

$$RMS = \sqrt{\frac{1}{n} \sum x_{vm}^2} \quad (2)$$

L'RMS è stato calcolato facendo la Radice quadrata del valore medio dei quadrati di "n" numeri dei campioni della VM (x_{vm}) all'interno di ogni finestra.

- Fattore di Cresta (FC): Il secondo metodo si concentra sulla Magnitudine del Vettore (VM) e calcola il fattore di cresta (FC) su finestre temporali di 30 secondi. Il fattore di cresta misura il picco dei dati ed è un indicatore utile per identificare movimenti improvvisi o intensi, come quelli che si verificano durante attività fisiche ad alta intensità (eq.3).

$$FC = \frac{\text{valore di picco}}{\text{valore RMS}} \quad (3)$$

Il CF, noto anche come Fattore di Picco, è stato calcolato come il rapporto tra il massimo valore assoluto e l'RMS di ogni finestra.

- Fattore di forma (FF): Il terzo metodo prevede l'applicazione del fattore di forma (FF) ai dati di VM. Successivamente, si calcola la deviazione standard del fattore di forma, che fornisce un'indicazione della variabilità nelle forme d'onda accelerometriche, utile per discriminare tra diverse tipologie di attività (eq.4).

$$FF = \frac{\text{valore RMS}}{\text{valore medio}} \quad (4)$$

Il FF è stato calcolato come il rapporto tra il valore RMS e il valore medio assoluto di ogni finestra.

Oltre ai grafici, viene creato un file CSV contenente tutti i valori calcolati di VM e RMS, che funge da archivio strutturato per eventuali controlli o analisi successive. Inoltre, viene effettuata una valutazione intra-soggetto, che consente di analizzare i dati relativi a ciascun singolo soggetto, e una valutazione inter-soggetto, che fornisce una panoramica complessiva delle performance di tutti i soggetti coinvolti nello studio. Questa duplice valutazione viene fatto graficando i valori ottenuti tramite i 3 metodi applicati e permette di confrontare le caratteristiche estratte all'interno dello stesso soggetto e tra i diversi partecipanti, garantendo una comprensione più completa delle variazioni nei dati accelerometrici.

Questa metodologia assicura un flusso di lavoro ordinato ed efficiente, accompagnato da una documentazione completa dei dati elaborati, che facilita ulteriori analisi o verifiche.

Per valutare quale indicatore temporale permette di discriminare le attività si è calcolato la media dei valori degli indicatori con la rispettiva deviazione standard (STD).

La STD è un indicatore statistico che misura la dispersione o la variabilità di un insieme di dati rispetto alla loro media. Più precisamente, la deviazione standard rappresenta quanto i singoli valori del dataset si discostano in media dalla media aritmetica del gruppo. In altre parole, se la deviazione standard è elevata, i dati sono molto sparsi rispetto alla media, mentre una deviazione standard bassa indica che i dati sono concentrati attorno alla media.

La formula per calcolare la deviazione standard (σ) di un insieme di dati è data dall'eq.5.

$$\sigma = \sqrt{\frac{1}{n} \sum (x - \mu)^2} \quad (5)$$

Con “n” il numero di valori e “x” è ogni singolo valore della variabile (RMS, FC o FF) e infine μ è la media della variabile. La deviazione standard (STD) viene rappresentata insieme ai grafici generati in base ai metodi applicati, offrendo una visualizzazione chiara della variabilità dei dati all'interno di ciascuna finestra temporale.

4.RISULTATI

In questa sezione vengono illustrati in dettaglio i risultati ottenuti attraverso l'applicazione di vari metodi volti all'estrazione delle caratteristiche distintive associate alle attività svolte. I risultati sono presentati in forma grafica, con l'obiettivo di evidenziare le peculiarità e le differenze tra le attività analizzate, consentendo una rappresentazione chiara e visivamente efficace delle informazioni emerse dal processo di analisi.

4.2 RISULTATI DEL FILTRAGGIO

Per offrire una comprensione più chiara del filtraggio DWT, in questa sezione vengono rappresentati due grafici dei dati accelerometrici lungo i tre assi in funzione al tempo dell'utente S01B per l'attività leggere l'articolo sia con l'applicazione del DWT sia senza (Figura 9 e 10).

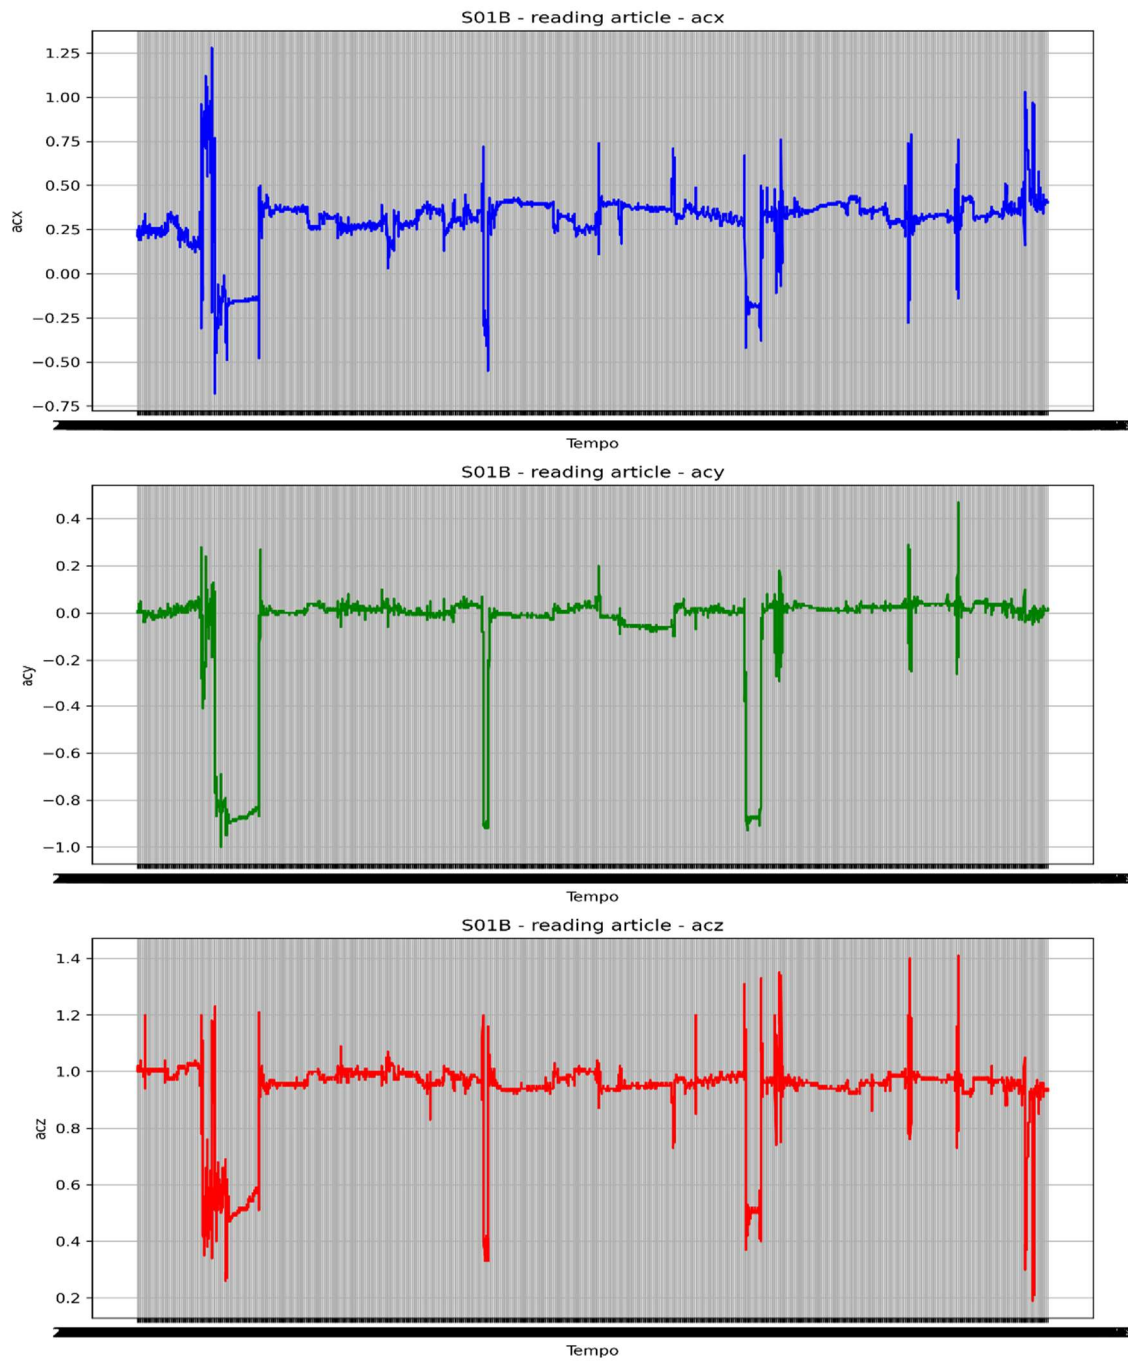


Figura 9: grafico dei dati grezzi senza Wavelet per l'attività leggere l'articolo dell'utente S01B

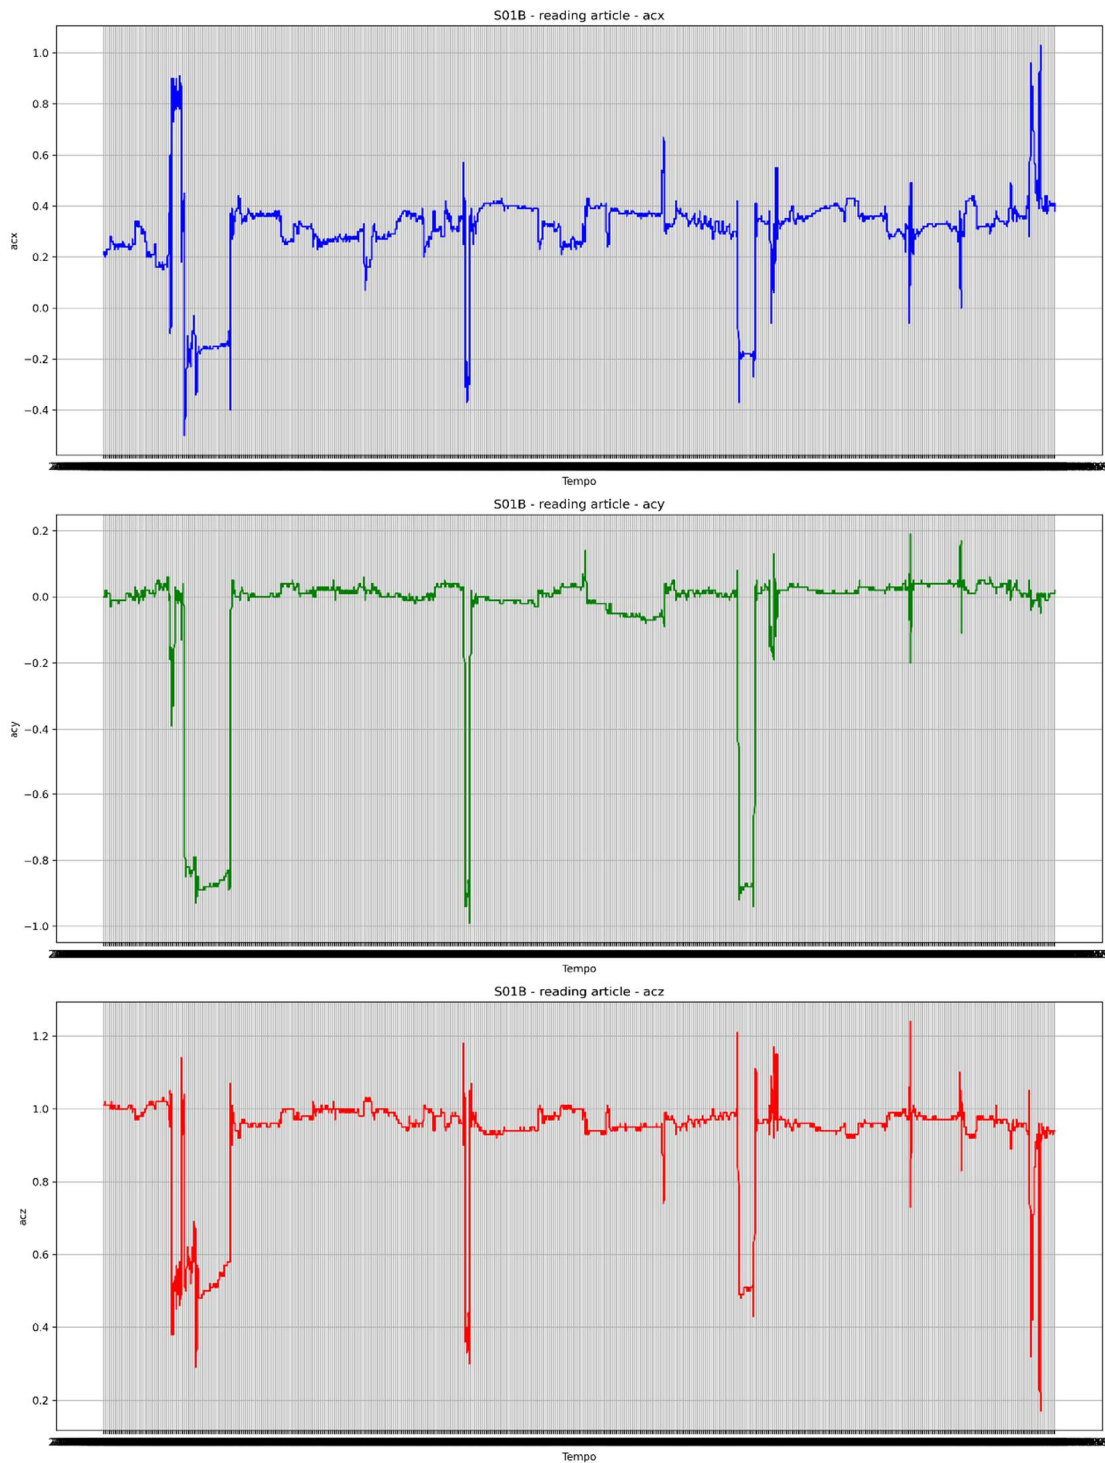


Figura 10: grafico dei dati grezzi con la Wavelet per l'attività leggere l'articolo dell'utente S01B

Possiamo osservare che, dopo l'applicazione della trasformata Wavelet di ordine 4, l'influenza del rumore sui dati accelerometrici viene ridotta in modo significativo, migliorando la qualità e la chiarezza del segnale analizzato.

4.2 RISULTATI DELL'INDICATORE TEMPORALE

In questa sezione vengono presentati i risultati ottenuti dall'applicazione dei metodi descritti, insieme alla loro deviazione standard, come indicato nelle sezioni 3.2.3 e 3.2.4. Tali risultati riguardano sia la valutazione intrasoggetto sia quella intersoggetto, offrendo una panoramica dettagliata delle analisi condotte.

4.2.1 VALUTAZIONE INTRASOGGETTO

In questa sezione viene effettuata l'analisi dei dati relativi ai singoli utenti. Nelle pagine successive sono presentati i grafici, rappresentati in formato a colonne, che illustrano i risultati ottenuti per i metodi applicati, ovvero i valori di RMS, FC e FF medi per ciascuna attività analizzata. Inoltre, per questa valutazione sono stati selezionati tre utenti rappresentativi, al fine di evidenziare le caratteristiche principali e confrontare i risultati ottenuti nei diversi scenari analizzati.

Vediamo prima i grafici del metodo RMS, che rappresentano l'andamento dei valori medi quadrati dei segnali accelerometrici per ciascuna delle attività analizzate (figura 11,12 e 13).

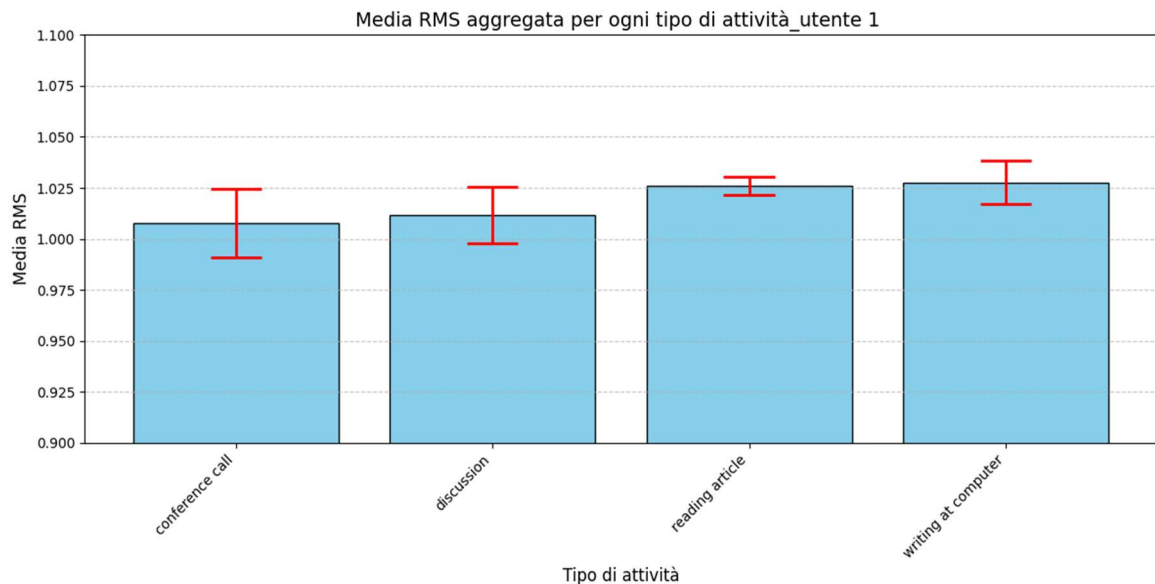


Figura 11: Valori RMS intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 1

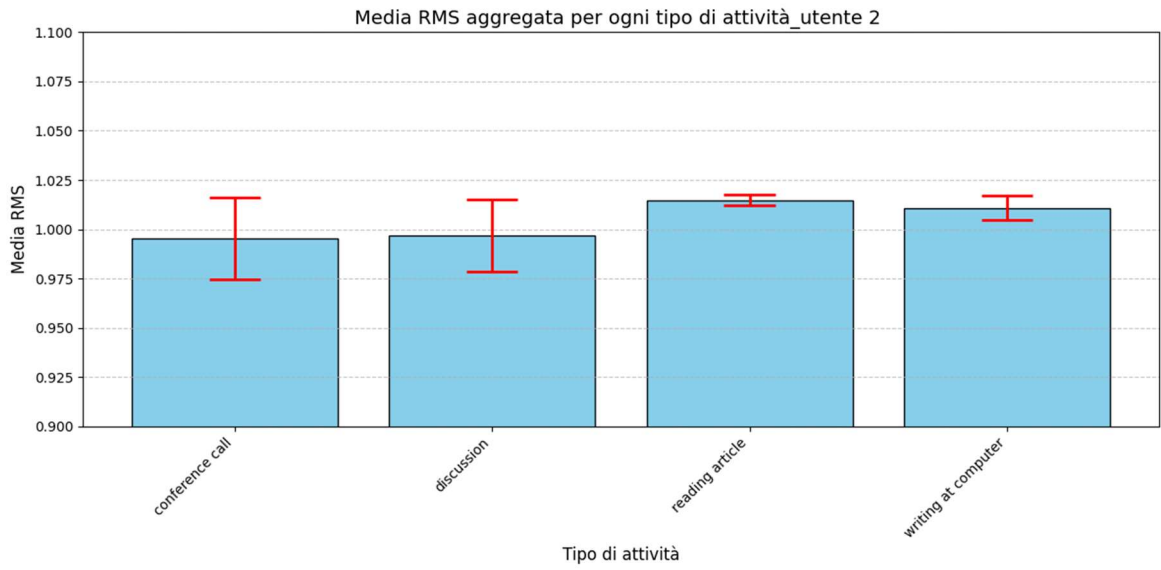


Figura 12: Valori RMS intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 2

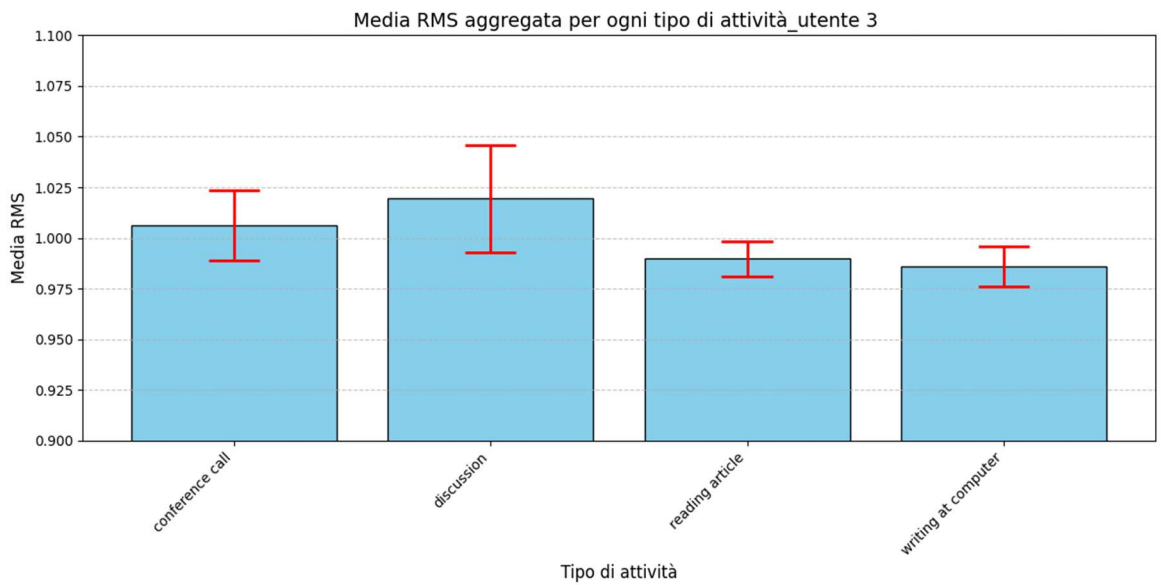


Figura 13: Valori RMS intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 3

Vediamo ora il secondo metodo applicato, cioè FC:

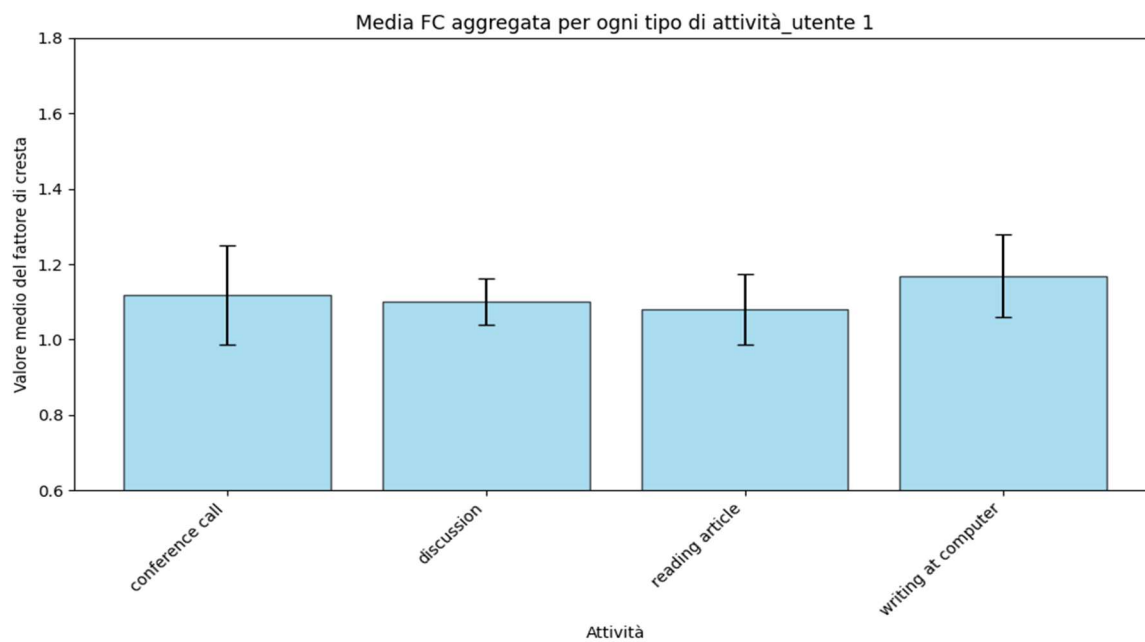


Figura 14: Valori FC intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 1




Figura 15: Valori FC intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 2




Figura 16: Valori FC intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 3

Invece per il metodo del Fattore di Forma (FF):

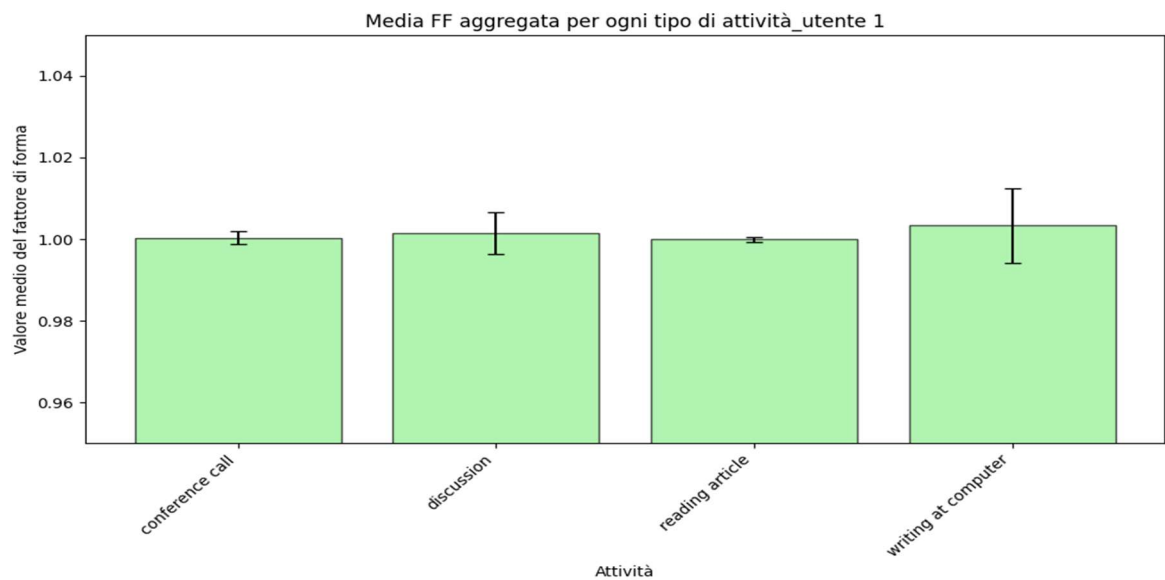


Figura 17: Valori FF intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 1

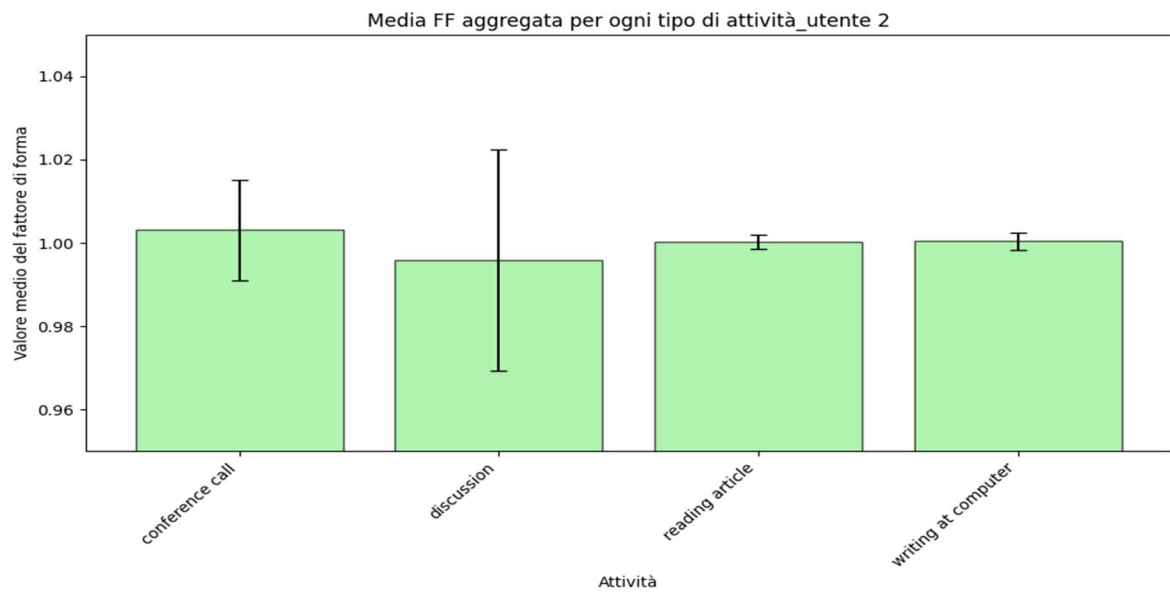


Figura 18: Valori FF intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 2




Figura 19: Valori FF intrasoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) dell'utente 3

4.3.2 VALUTAZIONE INTERSOGGETTO

In questa valutazione intersoggetto, vengono analizzati i dati di tutti i soggetti nel complesso, permettendo un confronto globale tra le diverse risposte individuali alle stesse attività. Questo approccio consente di osservare le tendenze generali e le variazioni tra i partecipanti, evidenziando le differenze intersoggettive nei segnali accelerometrici raccolti (Figura 19,20 e 21).

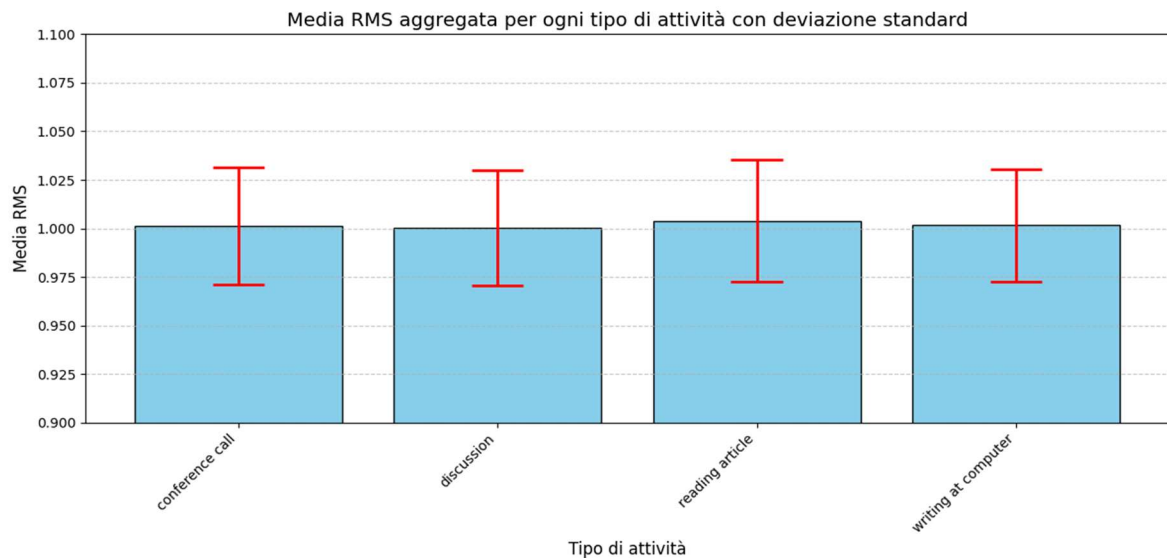


Figura 20: Valori RMS intersoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) per tutti gli utenti

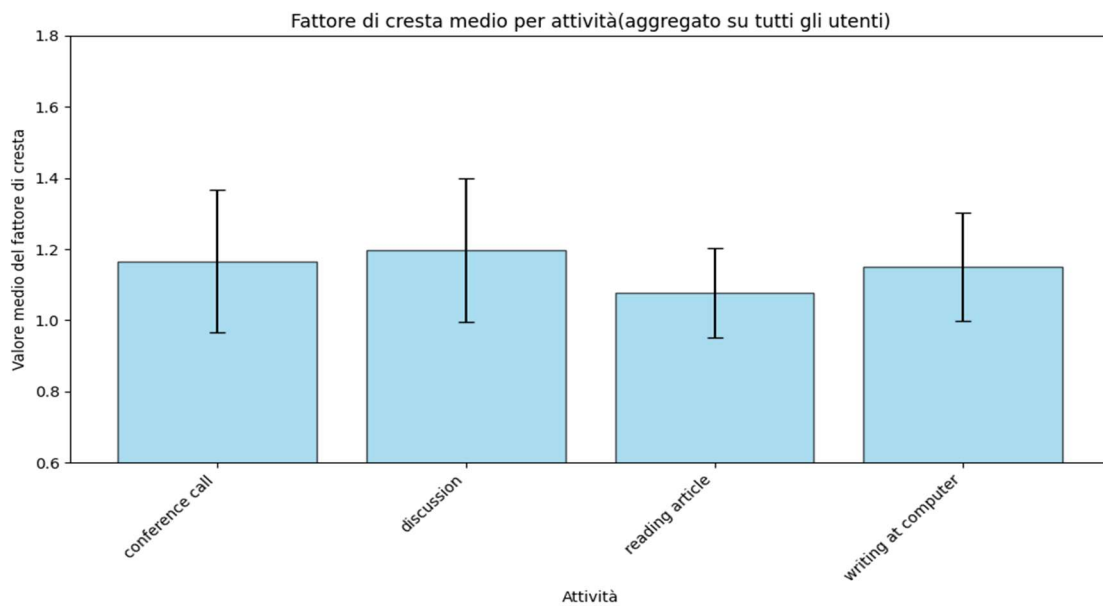


Figura 21: Valori FC intersoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) per tutti gli utenti

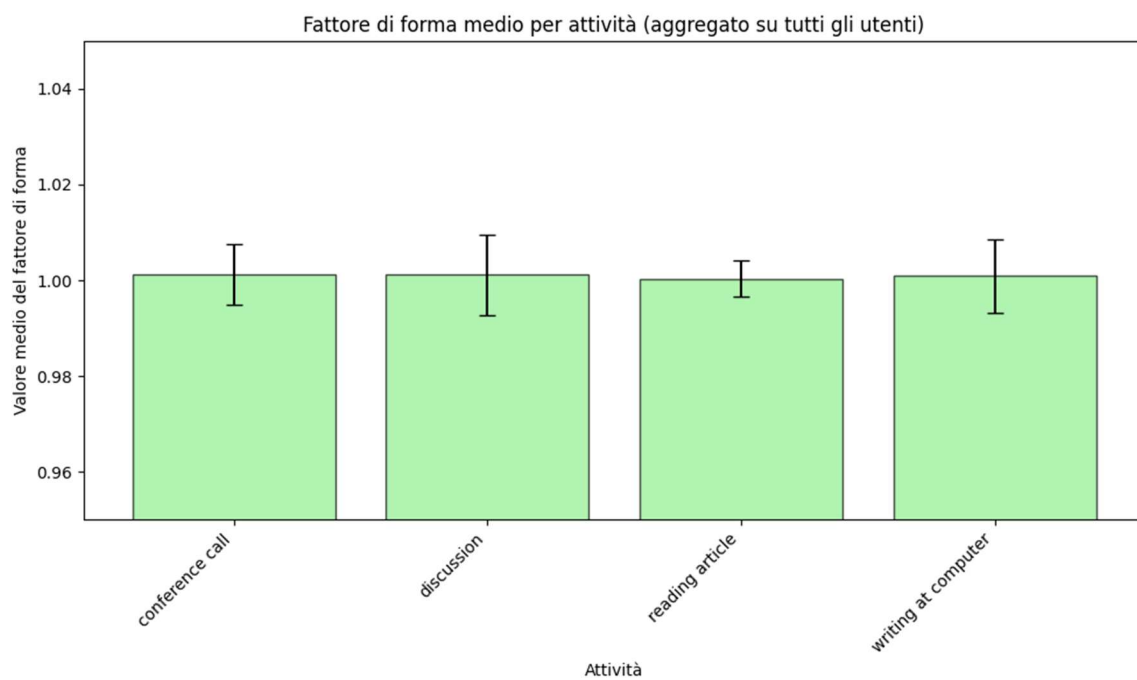


Figura 22: Valori FF intersoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) per tutti gli utenti

Inoltre, viene anche fatto la valutazione per ogni metodo sui dati grezzi, cioè senza la trasformata Wavelet per offrire un confronto visivo tra i segnali

elaborati e quelli originali, completando il processo di analisi (Figura 22,23 e 24).

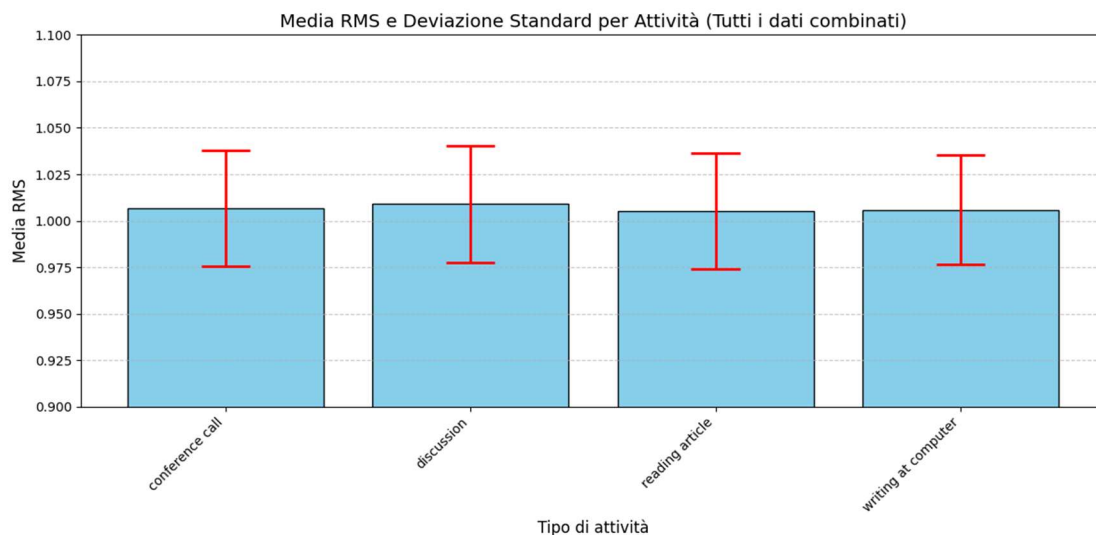


Figura 23: Valori RMS intersoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) per tutti gli utenti senza la DWT

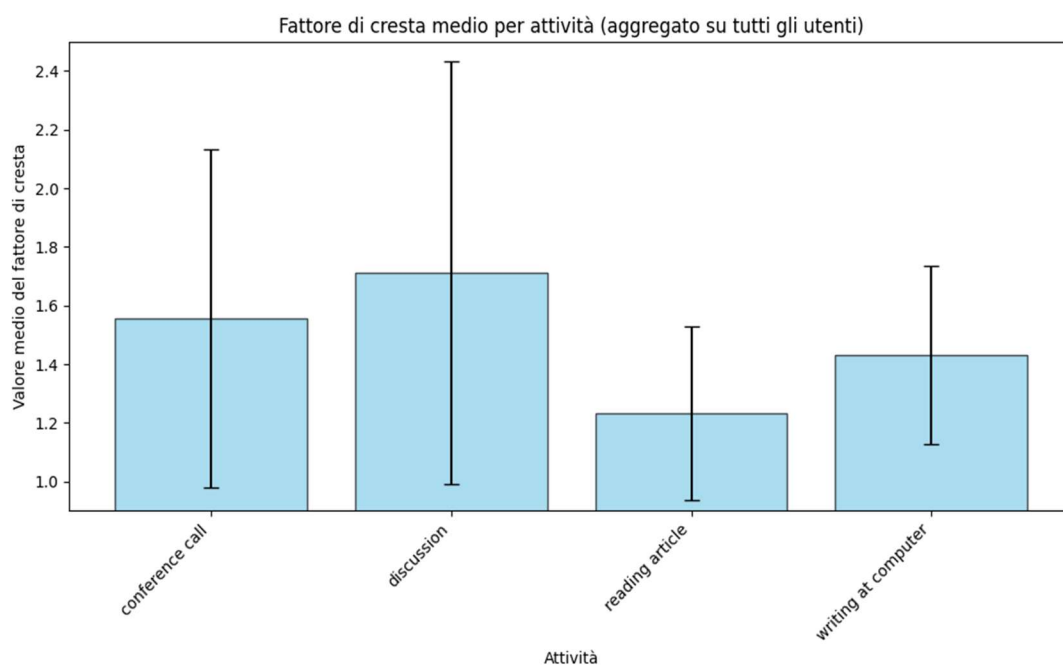


Figura 24: Valori FC intersoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) per tutti gli utenti senza la DWT

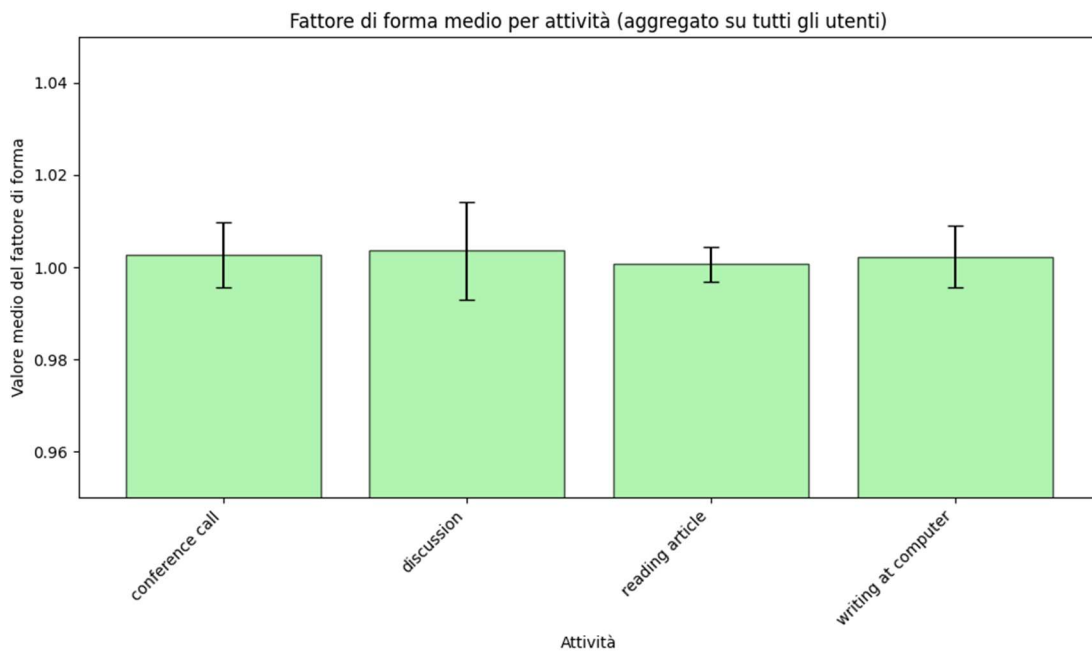


Figura 25: Valori FF intersoggettivi delle quattro attività selezionate (conversazione telefonica, discussione, leggere l'articolo, scrivere al computer) per tutti gli utenti senza la DWT

5. DISCUSSIONE

In questa sezione vengono discussi i risultati presentati nel capitolo precedente. I metodi applicati ai segnali accelerometrici mostrano risultati altamente simili tra loro, tanto da risultare quasi identici, e non si sono rivelati compatibili né nelle comparazioni intra- né intersoggetto.

Nella sezione della valutazione intersoggetto (sezione 4.3.2), i valori medi di RMS (Figura 20), FC (Figura 21) e FF (Figura 22) di ciascuna attività presentano differenze minime rispetto alle altre attività. Per il metodo RMS, la differenza tra i valori della RMS media tra le diverse attività risulta essere inferiore a 0.01 m/s^2 , con le deviazioni standard quasi uguali.

Nel caso del metodo FC (adimensionale), la differenza del valore medio tra le attività telefonare, discussione e scrivere è di circa 0.04, mentre per l'attività leggere può arrivare a una differenza di circa 0.1 rispetto alle altre attività. La deviazione standard per le attività discussione e telefonare è simile (± 0.2),

mentre si osserva una deviazione standard evidentemente minore per l'attività scrivere (circa ± 0.18) e soprattutto per l'attività leggere (± 0.16).

Infine, per il metodo FF (adimensionale), la differenza del valore medio tra le diverse attività è circa uguale a 0.002. La deviazione standard per le attività discussione e scrivere è simile (± 0.01), mentre per l'attività leggere l'articolo si osserva una deviazione standard evidentemente minore rispetto alle altre attività svolte (circa ± 0.006).

Questo andamento rimane invariato anche nella valutazione intersoggettiva senza l'applicazione della trasformata Wavelet (DWT), sia per i metodi RMS che FF (Figura 23 e 25). Tuttavia, nel caso del metodo FF (Figura 24), si osserva una notevole differenza di valore tra le attività, ma va sottolineato che questi segnali sono influenzati dal rumore (poiché la DWT non è stata applicata), con una deviazione standard generalmente più alta.

Per quanto riguarda la valutazione intrasoggettiva (sezione 4.2.1), si osservano che:

Per il metodo RMS, l'utente 1 (Figura 11) mostra una RMS media di circa 1.01 m/s^2 per l'attività "telefonare" e 1.012 m/s^2 per "discussione", mentre si registra un valore di circa 1.025 m/s^2 sia per l'attività "leggere l'articolo" che per "scrivere sul computer". La differenza tra le attività risulta quindi di ± 0.013 m/s^2 . Per l'utente 2 (Figura 12), la RMS media è di circa 0.99 m/s^2 per le attività "telefonare" e "discussione" e 1.012 m/s^2 per le altre due attività, con "scrivere sul computer" leggermente inferiore. La differenza tra le attività è di ± 0.014 m/s^2 . Al contrario dei primi due utenti, l'utente 3 (Figura 13) mostra una RMS maggiore per le attività "telefonare" e "discussione" rispetto a "leggere" e "scrivere". In particolare, si registra un valore di circa 1.01 m/s^2 per "telefonare", 1.02 m/s^2 per "discussione", e circa 0.99 m/s^2 per "leggere" e "scrivere", con "scrivere" leggermente inferiore. Si nota però una deviazione standard generalmente minore per le attività leggere l'articolo e scrivere sul computer rispetto alle altre due. Per l'utente 1, la deviazione standard è di circa ± 0.005 m/s^2 per l'attività leggere l'articolo e ± 0.012 m/s^2 per scrivere sul computer, rispetto al circa ± 0.015 m/s^2 osservato per le attività discussione e telefonare. Per l'utente 2 si osserva una situazione simile, con valori di ± 0.004 m/s^2 e ± 0.006 m/s^2 rispettivamente per leggere e scrivere, e circa ± 0.020 m/s^2 per telefonare e discussione. Infine, per l'utente 3, la deviazione standard è circa minore o uguale a ± 0.012 m/s^2 sia per leggere l'articolo sia per scrivere sul computer, mentre è di ± 0.025 m/s^2 per discussione e ± 0.020 m/s^2 per telefonare.

Per il metodo FC, la differenza del valore medio di FC tra le attività risulta essere di ± 0.1 , con una deviazione standard abbastanza variabile. In particolare, l'attività "leggere l'articolo" presenta sempre il valore medio di FC più piccolo e una deviazione standard che rimane pressoché costante tra i vari utenti (Figura 13,14 e 15).

Nel caso del metodo FF, si osserva una differenza del valore medio di FF tra le attività di circa ± 0.003 per tutti gli utenti, con una deviazione standard che rimane più stabile e invariata tra gli utenti dell'attività leggere l'articolo (Figura 16,17 e 18).

6. CONCLUSIONE

In questa tesi sono state applicate metodologie standard ai dati accelerometrici al fine di distinguere diverse attività d'ufficio. La metodologia classica che prevede il calcolo dell'indicatore temporale della radice quadrata media (RMS) si è rivelata una soluzione efficace per discriminare i livelli di attività, sia intra-soggetto che inter-soggetto. Tuttavia, sono state osservate alcune limitazioni, dovute al fatto che le attività testate erano prevalentemente statiche o quasi statiche, con variazioni minime nei segnali raccolti. Inoltre, l'assegnazione manuale delle attività ai tempi corrispondenti, se non eseguita con precisione, potrebbe aver introdotto discrepanze tra l'attività effettivamente svolta e i dati registrati. In futuro, per ottenere una discriminazione più dettagliata delle attività, sarebbe preferibile applicare algoritmi di machine learning, che consentirebbero una classificazione più accurata.

In aggiunta, per rendere il sistema più rappresentativo di scenari reali, si prevede di estendere l'analisi a contesti che coinvolgono più residenti, e in diversi ambienti indoor, contribuendo così a perfezionare soluzioni più efficaci per il comfort personale.

Nonostante queste sfide, dunque la metodologia applicata in combinazione con tecniche più avanzate ha un grande potenziale per diventare uno strumento prezioso per la valutazione e il miglioramento del comfort personale in futuro.

RICONOSCIMENTI

Alla conclusione di questa tesi, desidero esprimere la mia sincera gratitudine a tutte le persone che mi hanno supportato durante questo intenso percorso accademico.

Sono profondamente grato anche alle mie co-relatrici, la Dott.ssa Sara Casaccia e in particolare la Dott.ssa Ilaria Ciuffreda, così come al Dott. Gianluca Sartini, per il loro prezioso aiuto, i consigli fondamentali e il costante supporto che mi hanno permesso di portare a termine questa tesi.

Un ringraziamento anche al Prof. Gian Marco Revel, che ha suscitato il mio interesse per questo corso.

RIFERIMENTI

- [1] Fissore, Virginia Isabella, et al. "Indoor environmental quality and comfort in offices: a review." *Buildings* 13.10 (2023): 2490.
- [2] Caratù, Myriam, and Ilaria Pigliautile. "Transformative Service Research and impact of indoor environmental quality on workers' productivity: Potentialities of neuroscience in its assessment." *E3S Web of Conferences*. Vol. 396. EDP Sciences, 2023.
- [3] Yesica Paola Villarreal Arroyo, Rita Peñabaena-Niebles, Carmen Berdugo Correa "Influence of environmental conditions on students' learning processes: A systematic review" ,2023.
- [4] Kujundzic, Kosara, Slavica Stamatovic Vuckovic, and Ana Radivojević. "Toward regenerative sustainability: a passive design comfort assessment method of indoor environment." *Sustainability* 15.1 (2023): 840. [5] ' Office thermal environment that maximizes workers' thermal comfort and productivity .' by Shun Kawakubo, Masaki Sugiuchi, Shiro Arata. Department of Architecture, Hosei University, 2-33 Ichigaya tamachi, Shinjuku, Tokyo, 162-0843, Japan
- [6] Al Mindeel, Thara, Eftychia Spentzou, and Mahroo Eftekhari. "Energy, thermal comfort, and indoor air quality: Multi-objective optimization review." *Renewable and Sustainable Energy Reviews* 202 (2024): 114682.
- [7] Seyedrezaei, Mirmahdi, et al. "Interaction effects of indoor environmental quality factors on cognitive performance and perceived comfort of young adults in open plan offices in North American Mediterranean climate." *Building and Environment* 244 (2023): 110743.
- [8] Dimitroulopoulou, Sani, et al. "Indoor air quality guidelines from across the world: An appraisal considering energy saving, health, productivity, and comfort." *Environment International* 178 (2023): 108127.
- [9] Claudio De Capua, Gaetano Fulco, Mariacarla Lugarà and Filippo Ruffa "An Improvement Strategy for Indoor Air Quality Monitoring Systems" ,2023.
- [10] Yi, Myung-Kyu, Wai-Kong Lee, and Seong Oun Hwang. "A human activity recognition method based on lightweight feature extraction combined with pruned and quantized CNN for wearable device." *IEEE Transactions on Consumer Electronics* 69.3 (2023): 657-670.
- [11] Fan Zhou, Ruomei Wang, Hang Su* and Shen yi Xu. "A HUMAN ACTIVITY RECOGNITION MODEL BASED ON WEARABLE SENSOR" 2022.

- [12] Bhola, Geetanjali, and Dinesh Kumar Vishwakarma. "A review of vision-based indoor HAR: state-of-the-art, challenges, and future prospects." *Multimedia Tools and Applications* 83.1 (2024): 1965-2005.
- [13] M. A. Ortiz, S. R. Kurvers, and P. M. Bluysen. "A review of comfort, health, and energy use: Understanding daily energy use and wellbeing for the development of a new approach to study comfort" vol. 152, pp. 323–335, Oct. 2017.
- [14] Choi, Eun Ji, et al. "Impact of thermal control by real-time PMV using estimated occupants" personal factors of metabolic rate and clothing insulation." *Energy and Buildings* 307 (2024): 113976.
- [15] Á. Borsos, E. Zoltán, É. Pozsgai, B. Cakó, G. Medvegy, and J. Girán. "The Comfort Map—A Possible Tool for Increasing Personal Comfort in Office Workplaces" vol. 11, no. 6, p. 233, May 2021.
- [16] Lotfabadi, Pooya, and Polat Hançer. "Optimization of visual comfort: Building openings." *Journal of Building Engineering* 72 (2023): 106598.
- [17] Chen, Kai, et al. "Personal thermal comfort models based on physiological measurements—A design of experiments-based review." *Building and Environment* 228 (2023): 109919. [18] 'Personal thermal comfort models with wearable sensors' by S. Liu, S. Schiavon, H. P. Das, M. Jin, and C. J. Spanos, *Building and Environment*, vol. 162, p. 106281, Sep. 2019, doi: 10.1016/j.buildenv.2019.106281.
- [19] F. Vittori, C. Chiatti, I. Pigliautile, and A. L. Pisello. "The NEXT.ROOM: Design principles and systems trials of a novel test room aimed at deepening our knowledge on human comfort vol. 211, p. 108744, Mar. 2022.
- [20] F. Carbonari. 'DEVELOPMENT OF A NON-INVASIVE ULTRASONIC SENSOR NETWORK FOR THE MEASUREMENT OF ACTIVITIES OF PEOPLE IN INDOOR' . -2023
- [21] Tseng, Yu-Hsuan, and Chih-Yu Wen. "Hybrid Learning Models for IMU-Based HAR with Feature Analysis and Data Correction." *Sensors* 23.18 (2023): 7802.
- [22] Vi, Manh-Tuyen, et al. "Efficient Real-Time Devices Based on Accelerometer Using Machine Learning for HAR on Low-Performance Microcontrollers." *Computers, Materials and Continua* 81.1 (2024): 1729-1756.
- [23] Džaja, D., et al. "Accelerometer-based algorithm for the segmentation and classification of repetitive human movements during workouts." *Automatika: časopis za automatiku, mjerenje, elektroniku, računarstvo i komunikacije* 64.2 (2023): 211-244.
- [24] Sara Casaccia , Riccardo Naccarelli , Sara Moccia, Lucia Migliorelli , Emanuele Frontoni , Gian Marco Revel. "Development of a measurement setup to detect the level of

physical activity and social distancing of ageing people in a social garden during COVID-19 pandemic” .2021

[25] Batool, Sheeza, Muhammah Hassan Khan, and Muhammah Shahid Farid. "An ensemble deep learning model for human activity analysis using wearable sensory data." *Applied Soft Computing* (2024): 111599. [26] ‘A Random Forest Approach to Body Motion Detection: Multisensory Fusion and Edge Processing’ by Sanaz Kianoush, Member, IEEE, Stefano Savazzi , Member, IEEE, Vittorio Rampa , Member, IEEE, Leonardo Costa , and Denis Tolochenko

[27] Waghchaware, Sheetal, and Radhika Joshi. "Machine learning and deep learning models for human activity recognition in security and surveillance: a review." *Knowledge and Information Systems* (2024): 1-32.

[28] Hussain, Iqram, et al. "An explainable EEG-based human activity recognition model using machine-learning approach and LIME." *Sensors* 23.17 (2023): 7452.

[29] Shibo Zhang , Yaxuan Li , Shen Zhang , Farzad Shahabi , Stephen Xia , Yu Deng and Nabil Alshurafa. “Deep Learning in Human Activity Recognition with Wearable Sensors: A Review on Advances.2022.

[30] Farrahi, Vahid, et al. "AccNet24: A deep learning framework for classifying 24-hour activity behaviours from wrist-worn accelerometer data under free-living environments." *International Journal of Medical Informatics* 172 (2023): 105004.

[31] Ng, Johan YY, et al. "Development of a multi-wear-site, deep learning-based physical activity intensity classification algorithm using raw acceleration data." *Plos one* 19.3 (2024): e0299295.

[32] Saha, Utsab, et al. "Decoding human activities: Analyzing wearable accelerometer and gyroscope data for activity recognition." *IEEE Sensors Letters* (2024).

[33] Poli, Angelica. "Measurement and processing of multimodal physiological signals in response to external stimuli by wearable devices and evaluation of parameters influencing data acquisition." (2023).

[34] Fang, Zhaosong, et al. "Effects of different metabolic rates on thermal comfort in a warmer thermal environment." *Journal of Building Engineering* 80 (2023): 108030