Politecnico di Torino

Corso di Laurea Magistrale in Ingegneria Biomedica
A.a. 2022/2023
Sessione di Laurea Dicembre 2023

Identificazione di movimenti impulsivi dell'arto superiore mediante sensori inerziali per applicazioni di robotica collaborativa

Relatori:

Laura Gastaldi
Stefano Pastorelli
Elisa Digo
Michele Polito

Candidata:

Chiara Deledda
Matricola 239967

ABSTRACT

Nell'ambito dell'industria 5.0, la collaborazione uomo-robot riveste un ruolo di particolare importanza, in quanto combina le elevate performance di precisione, velocità e ripetibilità tipiche dei robot con la capacità decisionale degli operatori umani. Questo permette di ottimizzare la produttività ma al tempo stesso di assolvere compiti complessi che non possono essere completamente automatizzati. Poiché i robot collaborativi sono progettati per interagire con l'operatore all'interno di uno spazio di lavoro condiviso, la sicurezza rappresenta un aspetto cruciale dell'interazione uomo-robot. Generalmente, i task dell'operatore sono ben definiti e ripetitivi, ma esiste la possibilità che vengano effettuate azioni impreviste dovute a fattori esterni e a disattenzione. I movimenti impulsivi che ne conseguono possono risultare pericolosi per l'operatore esponendolo a un rischio di collisione con il robot.

L'obiettivo di questa tesi consiste nella realizzazione di una metodologia che sfrutti l'utilizzo combinato di sensori inerziali e tecniche di intelligenza artificiale per identificare l'avvenimento di movimenti impulsivi il più rapidamente possibile. A tal fine, 61 partecipanti in età lavorativa hanno effettuato un task industriale di *pick and place* con la presenza di alcuni movimenti impulsivi. Le prove sono state realizzate posizionando 5 sensori inerziali su sterno, braccia e avambracci dei partecipanti e sono state svolte secondo tre diverse configurazioni di posizionamento del soggetto rispetto al set up sperimentale. In particolare, i soggetti hanno utilizzato, a seconda del caso, l'arto destro o sinistro per portare a termine il task e una posizione frontale o laterale. Le successive analisi si sono concentrate sulle accelerazioni lineari e velocità angolari misurate con il sensore inerziale posizionato sull'avambraccio corrispondente all'arto utilizzato per l'esecuzione della prova. I movimenti effettuati sono stati prima caratterizzati da un punto di vista statistico. La distribuzione non normale dei dati ha imposto

un’analisi di tipo non parametrico con un test di Wilcoxon, che ha evidenziato differenze statisticamente significative tra movimenti normali e impulsivi in termini sia di accelerazione che di velocità angolare. Sulla base di questi risultati, una rete neurale di tipo *Long-Short Time Memory* è stata allenata per sviluppare un metodo di identificazione dei movimenti impulsivi. Una particolare attenzione è stata rivolta alla segmentazione dei segnali, in modo da restringere il più possibile l’arco temporale necessario al riconoscimento di un movimento impulsivo. Nello specifico, dopo aver scelto e testato finestre della durata temporale di 0.5 s, si è valutata la possibilità di analizzare il segnale con finestre sovrapposte, in modo tale da avvicinarsi maggiormente all’acquisizione del segnale in tempo reale. Le elevate performance di riconoscimento (accuratezza ≥ 80) hanno dimostrato l’efficacia dell’utilizzo di tecniche di intelligenza artificiale per l’identificazione di movimenti impulsivi a partire da segnali inerziali.

Indice

1. INTRODUZIONE e STATO dell'ARTE 5

1.1 Relazione tra uomo e robot 6

1.2 Sicurezza e collisioni uomo-robot 11

1.2.1 Sicurezza 11

1.2.2 Collisioni uomo-robot 14

1.3 Dispositivi indossabili per lo studio del movimento umano: i Sensori Inerziali 16

1.4 Intelligenza artificiale 19

1.5 Movimenti impulsivi 23

2. MATERIALI e METODI 33

2.1. Set up sperimentale 33

2.2 Protocollo 35

2.3 Partecipanti 38

2.4 Sensori inerziali 38

3. ELABORAZIONE e ANALISI DATI 41

3.1 Suddivisione in movimenti impulsivi e non impulsivi 41

3.2 Analisi dell'accelerazione 42

3.1.1 Calcolo del Root Mean Square (RMS) 44

3.1.2 Risultati: Confronto metodi rimozione accelerazione di gravità 45

3.3 Velocità angolare 48

3.4 Suddivisione del segnale in finestre da 0.5 s 48

3.4.1 Statistica 48

3.5 Deep Learning 50

3.6 Overlap 60

4. RISULTATI 63

4.1 Analisi dell'accelerazione 63

4.2 Suddivisione del segnale in finestre da 0.5 s 63

4.3 Deep Learning 74

4.4 Overlap 86

5. DISCUSSIONE e CONCLUSIONI 89

APPENDICE A 93

Boundlines complessive (una sola finestra da 0.5 s) 93

Boundlines sei finestre da 0.5 s 96

Scelta finestre impulsive per fase Deep Learning 108

BIBLIOGRAFIA 113

1. INTRODUZIONE e STATO dell'ARTE

Nell'ambito dell'industria 4.0 e 5.0, Il settore della robotica collaborativa ha affrontato negli ultimi decenni una forte crescita, testimoniata dalla progressiva presenza di robot collaborativi o "cobot" accanto agli operatori.

Secondo (Baratta et al., 2022), gli sviluppi tecnologici avvenuti durante la quarta rivoluzione industriale insieme alla pandemia del COVID-19 hanno portato ad un cambiamento nella vita e nel lavoro di quasi tutte le figure professionali esistenti.

Uno dei principali effetti della pandemia è stata la ridefinizione degli ambienti lavorativi in cui i lavoratori svolgevano i propri compiti. Il successivo sviluppo dell'industria 5.0, invece, pone l'operatore al centro del processo produttivo (Xu et al., 2021).

La collaborazione uomo-robot (*Human-Robot Collaboration-HRC*) si riferisce ad ambienti in cui l'operatore umano ed il robot entrano in stretto contatto, condividendo un compito e garantendo un'interazione in sicurezza, nonostante la prossimità fra le parti.

I robot collaborativi promuovono un'interazione diretta con gli operatori umani, superando la classica suddivisione del lavoro, che vede i robot confinati in gabbie di sicurezza, lontano dagli operatori. Essendo possibile per l'operatore e il robot lavorare l'uno a fianco all'altro, la produttività dell'operatore umano migliora, e stress e fatica si riducono. Le elevate performance di precisione, velocità e ripetibilità tipiche dei robot, combinate con la capacità decisionale degli operatori umani di adattarsi ad eventi imprevisti, permettono di ottimizzare la produttività ma al tempo stesso di assolvere compiti complessi che non possono essere completamente automatizzati. I cobot possono essere gestiti ed "istruiti" attraverso sistemi intuitivi per l'operatore umano, con cui condividono un

compito. Questi sistemi sono basati su realtà aumentata, programmazione tramite dimostrazione, etc. Al contrario, i robot tradizionali non collaborativi spesso richiedono ingegneri specialisti esperti di programmazione (Villani et al., 2018).

La collaborazione uomo-robot è generalmente possibile in due modi:

1. programmazione *off-line* delle attività del robot tramite dimostrazione (anche nota come guida manuale – *hand guiding* – o insegnamento cinestetico);
2. interazione *on-line* tra l'operatore e il robot, resa possibile da sistemi di sensori esterni.

Mentre la programmazione *off-line* è un metodo consolidato di collaborazione, lo sviluppo dell'interazione in tempo reale richiede ancora notevoli sforzi. Il suo successo è fortemente influenzato dal sistema di sensori esterni: se il sistema non è affidabile o presenta una latenza elevata, influisce negativamente sulle prestazioni della collaborazione (Angleraud et al., 2024).

1.1 Relazione tra uomo e robot

Nel lavoro di (Schmidtler et al., 2015), le interazioni uomo-robot (*Human-Robot Interaction-HRI*) sono state categorizzate secondo quattro criteri: spazio di lavoro, tempo di lavoro, obiettivo e contatto. Come riportato negli articoli di (Hentout et al., 2019; Wang et al., 2019), tali criteri assumono le seguenti definizioni:

- **spazio di lavoro:** operatore e robot lavorano nella stessa area senza separazione fisica o barriere virtuali;
- **tempo di lavoro:** tempo in cui il partecipante lavora all'interno dello spazio di lavoro;
- **obiettivo:** ogni componente della squadra interagente ha uno scopo da raggiungere. Esso può corrispondere o meno al compito dell'altro;

- **contatto:** poiché l'operatore e il robot operano nello stesso spazio lavorativo, possono entrare in contatto, il quale può essere occasionale e involontario (se il normale funzionamento è teso ad essere svolto senza) oppure intenzionale e volontario (se è previsto che l'operatore debba entrare in contatto col robot).

In base ai quattro criteri sopra riportati, combinando quanto descritto da (Hentout et al., 2019) e (Wang et al., 2019), l'interazione uomo-robot può essere classificata in:

1. Coesistenza Uomo-Robot (*Human-Robot Coexistence - HRCx*), anche chiamata *coazione*, è definita come la capacità di condividere lo spazio lavorativo dinamico tra esseri umani e robot, che operano svolgendo compiti che non richiedano contatto o coordinazione nelle azioni. Solitamente, la coesistenza è limitata a evitare collisioni.
2. Cooperazione Uomo-Robot (*Human-Robot Cooperation - HRCp*) opera ad un livello superiore rispetto all'*HRCx*. In questo caso, operatori e robot lavorano per uno stesso scopo e soddisfano i requisiti di tempo e spazio contemporaneamente. Alle volte l'uno deve attendere la disponibilità dell'altro agente (o degli altri agenti). La cooperazione richiede tecnologie avanzate come il feedback di forza o la visione artificiale avanzata, nonché tecniche di rilevamento atte ad evitare le collisioni.
3. Collaborazione Uomo-Robot (*Human*-Robot Collaboration - *HRC*) è caratterizzata dalla realizzazione di azioni complesse con interazione diretta tra umani e robot che portano avanti un compito congiuntamente. È permesso un contatto fisico esplicito e intenzionale con scambio di forze tra operatore e robot, ed è richiesto che i due svolgano l'attività in coordinazione e sincronia. Le azioni sono coordinate mediante lo scambio di informazioni, che può avvenire tramite comunicazione diretta (parola,

gesti, etc.) o comunicazione indiretta (direzione dello sguardo, espressioni facciali, etc.). In ogni caso, la collaborazione presuppone un'attività congiunta e orientata verso un obiettivo comune da parte delle parti coinvolte, che condividono le proprie competenze, capacità e risorse: l'operatore esegue parti del compito che richiedono capacità decisionale e destrezza, mentre il robot si occupa delle parti che non sono adatte al coinvolgimento diretto dell'operatore (compiti ripetitivi o ad alta forza, posizionamento di precisione, etc.).

Nel lavoro di (Bdiwi et al., 2017) è stato proposto un altro tipo di classificazione basato anch'esso sul livello di interazione. Secondo questo approccio l'interazione può essere classificata in quattro livelli (*Figura 1.1*):

1. **Spazio di lavoro condiviso, senza condivisione del compito**: questo livello si verifica quando l'essere umano deve lavorare in prossimità del robot a causa di spazi di lavoro limitati o flussi di processo specifici. L'operatore e il robot hanno ciascuno un compito distinto. Tuttavia, il robot o l'essere umano dovrebbero preparare i componenti del pezzo da lavorare in uno spazio intermedio, a disposizione del proprio partner. Di conseguenza, operano in uno spazio di lavoro condiviso, senza barriere fisiche. Questo spazio può essere virtualmente suddiviso in due zone: una destinata all'essere umano e l'altra al robot. L'operatore può muoversi nella propria zona, mentre il robot può muoversi liberamente solo nella sua zona alla massima velocità consentita. Nel momento in cui l'uomo entra nella zona del robot, il sistema rileva una situazione di pericolo e il robot viene immediatamente arrestato. La zona dell'operatore umano è statica, mentre la zona del robot può essere configurata come dinamica (collegata al movimento del robot) o statica (limitando il robot a una zona specifica e definita);

2. **Spazio di lavoro condiviso, condivisione del compito senza interazione fisica**: in questo livello, l'essere umano e il robot condividono un compito, ma la cooperazione è molto limitata. È possibile definire una terza zona (*Figura 1.1*, livello 2, zona 2) come *zona di cooperazione*. Non c'è contatto diretto tra l'essere umano e il robot. Il robot può muoversi verso l'essere umano solo fino a una posizione designata per assistere l'operatore come una sorta di terza mano. Può tenere saldamente un componente mentre l'operatore svolge un compito di assemblaggio. Nella zona di cooperazione, il robot dovrebbe ridurre la sua velocità in base alla distanza dall'essere umano;
3. **Spazio di lavoro condiviso, condivisione del compito** con passaggio di oggetti ("***Handing-over***"): in questo livello, il compito condiviso consiste in un passaggio diretto tra l'essere umano e il robot. Tuttavia, l'interazione fisica è completamente esclusa. Un esempio di interazione di questo livello si verifica quando il robot prende un componente/strumento necessario dalla linea di fornitura e lo consegna direttamente all'essere umano sulla linea di assemblaggio. Un'altra situazione possibile in questo livello è quando il robot afferra direttamente i componenti/attrezzi necessari dalla mano dell'essere umano. All'interno della zona di cooperazione, può essere definita una zona speciale per il passaggio di oggetti (*handing-over*). In questa zona, dovrebbe essere implementato un controllo ibrido che permette al robot di reagire al movimento della mano dell'operatore e seguirla nello spazio circostante.
4. **Spazio di lavoro condiviso, condivisione del compito con interazione fisica:** in questo livello, l'interazione fisica tra operatore e robot è indispensabile per completare il compito. Ad esempio, il robot può trasportare componenti pesanti fino all'operatore umano o a una posizione

predefinita vicino alla linea di assemblaggio, dopodiché l'operatore può guidare il robot fino a una posizione finale utilizzando la propria forza fisica.

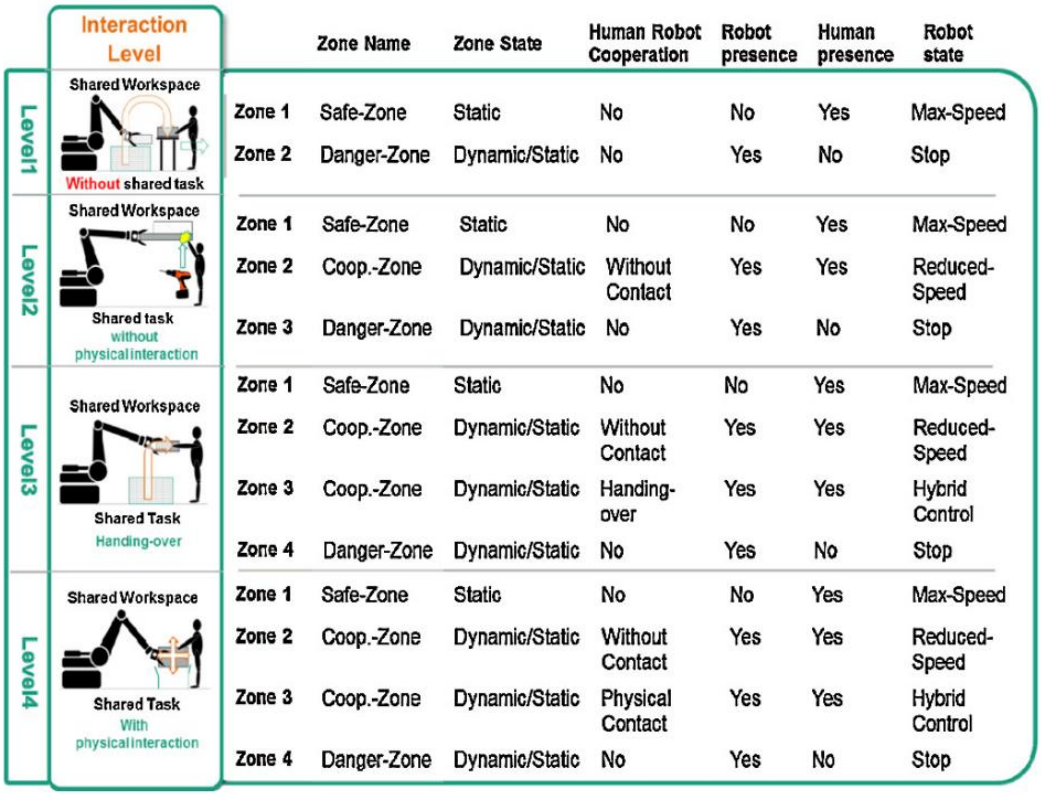

	Zone Name	Zone State	Human Robot Cooperation	Robot presence	Human presence	Robot state
Zone 1	Safe-Zone	Static	No	No	Yes	Max-Speed
Zone 2	Danger-Zone	Dynamic/Static	No	Yes	No	Stop
Zone 1	Safe-Zone	Static	No	No	Yes	Max-Speed
Zone 2	Coop.-Zone	Dynamic/Static	Without Contact	Yes	Yes	Reduced-Speed
Zone 3	Danger-Zone	Dynamic/Static	No	Yes	No	Stop
Zone 1	Safe-Zone	Static	No	No	Yes	Max-Speed
Zone 2	Coop.-Zone	Dynamic/Static	Without Contact	Yes	Yes	Reduced-Speed
Zone 3	Coop.-Zone	Dynamic/Static	Handing-over	Yes	Yes	Hybrid Control
Zone 4	Danger-Zone	Dynamic/Static	No	Yes	No	Stop
Zone 1	Safe-Zone	Static	No	No	Yes	Max-Speed
Zone 2	Coop.-Zone	Dynamic/Static	Without Contact	Yes	Yes	Reduced-Speed
Zone 3	Coop.-Zone	Dynamic/Static	Physical Contact	Yes	Yes	Hybrid Control
Zone 4	Danger-Zone	Dynamic/Static	No	Yes	No	Stop

Figura 1.1: rappresentazione dei quattro livelli di HRI proposti ed analizzati da (Bdiwi et al., 2017)

1.2 Sicurezza e collisioni uomo-robot

Fra le principali sfide nell'ambito della collaborazione uomo-robot ci sono quella di garantire la sicurezza e quella di evitare le collisioni. Dato che uno degli obiettivi intrinseci della HRC è quello di permettere il contatto diretto eliminando barriere fisiche, bisogna farlo in modo sicuro (Villani et al., 2018).

1.2.1 Sicurezza

La sicurezza rappresenta un prerequisito fondamentale nella progettazione di prodotti, macchine e sistemi, specialmente negli ambienti collaborativi in cui esseri umani e robot lavorano insieme.

Gli standard di sicurezza forniscono requisiti e linee guida di progettazione unificate che aiutano e semplificano lo sviluppo di nuovi sistemi. Dal punto di vista formale, la conformità agli standard non è obbligatoria per dimostrare la sicurezza di un sistema, ma contribuisce a ridurre gli sforzi necessari a ottenere la certificazione, come previsto nella Direttiva Macchine, che rappresenta la principale normativa europea in termini di requisiti di salute e sicurezza delle macchine. Inoltre, la conformità agli standard agevola l'avvio e la messa in funzione di nuovi sistemi (Villani et al., 2018).

Nel lavoro di (Villani et al., 2018) è stata presentata una visione generale degli standard di sicurezza, distinguendoli in tre classi:

1. *Standard di Tipo A*: raggruppa gli standard base di sicurezza per i requisiti generali che possono essere applicati alle macchine. Fanno parte di questa classe le norme ISO 12100 e IEC 61508. Esse definiscono rispettivamente la terminologia di base e la metodologia utilizzata per garantire la sicurezza delle macchine, come la valutazione dei rischi e la loro riduzione, la sicurezza funzionale dei dispositivi elettrici, elettronici e programmabili.

2. *Standard di Tipo B*: fa riferimento agli standard di sicurezza generici ed è suddiviso in due sottocategorie: B1 e B2. Gli standard di sicurezza B1 affrontano aspetti specifici della sicurezza, ad esempio la progettazione di sistemi di sicurezza a bassa complessità. Gli standard di sicurezza B2 ricoprono gli aspetti di sicurezza legati alla protezione, come la descrizione degli aspetti funzionali specifici dei dispositivi di arresto di emergenza o dei dispositivi di controllo a due mani.
3. *Standard di Tipo C*: unisce gli standard di sicurezza individuali che specificano le contromisure di sicurezza per macchine specifiche. Se sono disponibili standard di Tipo C, essi hanno la priorità rispetto agli standard di Tipo B e Tipo A.

Mentre, in riferimento alle modalità operative di collaborazione, le norme ISO 10218-1/2 ne identificano quattro (*Figura 1.2*), che nel lavoro di (Villani et al., 2018) sono stati riassunti in:

- *Safety-rated Monitored Stop* (SMS): si tratta della forma più semplice di collaborazione. In questa modalità, l'operatore svolge compiti manuali in un'area collaborativa, ossia uno spazio in cui l'essere umano e il robot possono lavorare insieme. Tuttavia, non possono farlo contemporaneamente, poiché al robot non è consentito il movimento quando l'operatore è nell'area condivisa. Alcuni esempi di collaborazione per questa modalità sono: il posizionamento manuale degli oggetti sull'*end-effector* del robot, l'ispezione visiva, i lavori di finitura o le operazioni complesse che richiedono la presenza umana. Quando l'operatore entra nell'area collaborativa, il robot passa in modalità *safe standstill*; quindi, interrompe la sua attività e attende che l'operatore lasci l'area collaborativa. Una volta che questo avviene, il robot riprende il suo lavoro dal punto in cui si era interrotto.

- *Hand Guiding* (HG): noto anche come "insegnamento diretto". In questa modalità, l'operatore entra direttamente in contatto con la macchina attraverso un dispositivo di guida che controlla il movimento del robot, “insegnandogli” i movimenti. Mentre il robot si trova all'interno dell'area collaborativa, esegue il programma in modalità automatica. Se l'operatore si avvicina a tale zona, il programma e i movimenti del robot vengono sospesi. Quando l'operatore attiva il dispositivo di insegnamento diretto, lo stato del robot passa alla funzionalità di velocità monitorata di sicurezza per permettere la movimentazione diretta del robot. Quando l'operatore rilascia il dispositivo di guida manuale, il robot ritorna alla funzionalità di arresto monitorato di sicurezza (SMS) e riprende il programma da dove si era interrotto non appena l'operatore si allontana dall'area collaborativa.
- *Speed and Position Monitoring* (SPM) o *Speed and Separation Monitoring* (SSM): permette la presenza umana nello spazio del robot attraverso sensori di monitoraggio di sicurezza. Con riferimento alla *Figura 1.2*, il robot lavora a piena velocità quando l'operatore si trova nella zona verde, a velocità ridotta nella zona gialla e si ferma quando l'operatore entra nella zona rossa. Queste aree sono controllate da scanner o da sistemi visivi. Nelle aree al di fuori della portata del robot, l'operatore non entra in contatto con esso, ma può essere messo in pericolo da un oggetto che sfugge al robot. Allora, il robot viene rallentato a una velocità di sicurezza. Se lo spazio di lavoro del robot viene violato, il robot si ferma.
- *Power and Force Limiting* (PFL): questo tipo di collaborazione impone restrizioni sulla potenza e sulla forza del cobot, in modo che l’operatore possa lavorare in prossimità del robot senza rischi. Per questo livello di collaborazione, sono necessarie apparecchiature e modelli di controllo

specifici per gestire le collisioni tra il robot e l'operatore, per evitare danni a quest'ultimo.

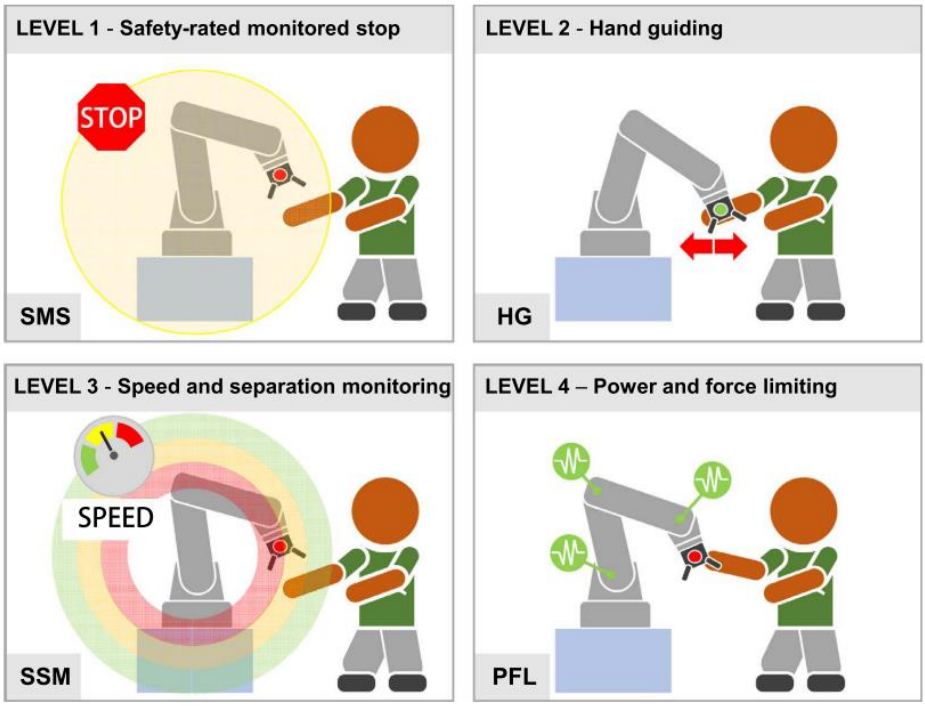

Figura 1.2: le quattro modalità operative di collaborazione incluse nelle norme ISO 10218-1/2 (Villani et al., 2018)

1.2.2 Collisioni uomo-robot

È fondamentale rilevare eventuali collisioni tra robot ed operatore prima che si verifichino gravi incidenti. Negli anni, i ricercatori hanno esplorato diverse metodologie, molte delle quali si sono concentrate sulla rilevazione in tempo reale della forza e del contatto, poiché sono direttamente correlati al verificarsi di possibili collisioni (Wang et al., 2019).

La *Figura 1.3* mostra la classificazione degli scenari di contatto diretto indesiderato tra l'operatore e il robot (Haddadin & Croft, 2016), in cui i due principali sono gli impatti non vincolati e gli impatti vincolati.

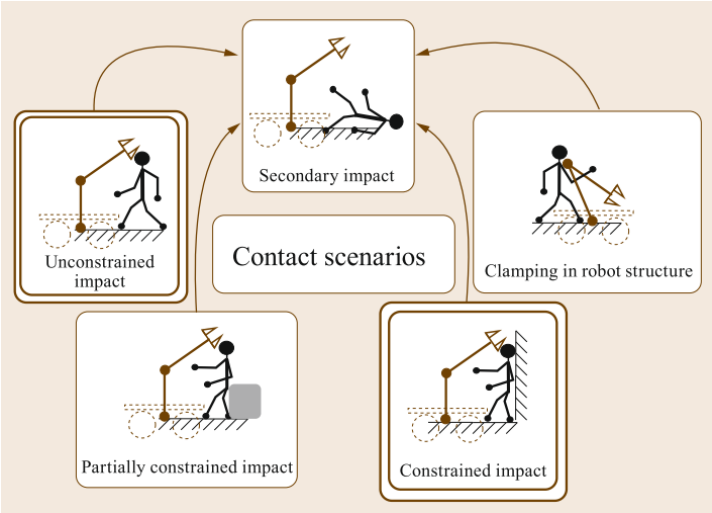

Figura 1.3: classificazione degli scenari di impatto tra robot e operatore (Haddadin & Croft, 2016).

Diversi sono stati gli approcci studiati da vari gruppi di ricercatori per evitare che l'operatore entri in collisione col cobot.

Fra questi vi sono gli approcci pre-collisioni, che utilizzano sistemi esterocettivi del robot per identificare la presenza di ostacoli o esseri umani nell'ambiente circostante; approcci post-collisioni, ossia schemi di azioni che il robot mette in atto dopo che la collisione è avvenuta, per ridurre la forza dell'impatto e di conseguenza l'entità dell'infortunio ai danni dell'operatore (Hentout et al., 2019).

Una delle fasi più importanti per la distinzione tra collisioni e contatti volontari è il rilevamento della collisione. Generalmente, l'output di questa fase è binario e determina se una collisione si sia verificata o meno. Essa può verificarsi su un punto qualsiasi della struttura del robot e deve essere rilevata nel minor tempo possibile. Fra i problemi pratici principali per questa fase vi sono la scelta del segnale da monitorare e la scelta di una soglia, per evitare che vengano segnalati falsi positivi (Haddadin & Croft, 2016). Anche nel lavoro di (Heo et al., 2019) l'attenzione è stata concentrata sul rilevamento delle collisioni, che risulta essere il primo passo per la loro gestione. La finalità di questo primo *step* era di stabilire in tempo reale se una di queste si fosse verificata. Nel momento in cui

viene rilevata una collisione, il cobot si ferma istantaneamente. Per garantire sia la sicurezza sia la produttività, la capacità di riconoscere che l'evento si sia verificato deve essere estremamente sensibile, e allo stesso tempo deve evitare falsi allarmi. Nello studio citato, gli autori hanno presentato una metodologia in cui l'identificazione delle collisioni è basata sull'utilizzo di una rete neurale profonda (*CollisionNet*), che si è dimostrata avere un'alta sensibilità alle collisioni e robustezza alla rilevazione di falsi positivi. Ha dimostrato, inoltre, di avere una potente capacità di generalizzazione sia su diversi tipi di robot, sia su diverse tipologie di movimenti.

1.3 Dispositivi indossabili per lo studio del movimento umano: i Sensori Inerziali

Affinché si possano rilevare gesti e azioni del soggetto da poter trasmettere al cobot, è necessario utilizzare dei sistemi di registrazione e trasmissione dei segnali.

I sensori inerziali o *Inertial Measument Units* (IMU) sono dispositivi che tipicamente comprendono accelerometri, giroscopi e magnetometri tri-assiali (in quest'ultimo caso si parla di MIMU) e sono comunemente utilizzati per monitorare il movimento in vari contesti, incluso quello dei dispositivi indossabili per il monitoraggio del movimento umano.

In particolare, gli accelerometri misurano l'accelerazione lineare di un soggetto lungo uno o più assi, permettendo di determinarne l'accelerazione totale. I giroscopi misurano la velocità angolare, permettendo di monitorare la rotazione di un soggetto o di un suo segmento corporeo.

Tali sensori sono spesso utilizzati in combinazione e vengono posizionati in determinati distretti corporei per raggiungere una quanto più completa comprensione dei movimenti di un soggetto nello spazio tridimensionale. Inoltre,

hanno svariati vantaggi, quali: basso costo, ingombro ridotto, controllo in modalità wireless, spazio illimitato di acquisizione e possibilità di svincolarsi dall'ambiente del laboratorio.

Ad esempio, fra le applicazioni in cui i sensori inerziali vengono ampiamente utilizzati vi è l'ambito sportivo. Nel lavoro di (Hussain et al., 2022) sono stati utilizzati i segnali in uscita da un unico sensore inerziale posto a livello dello sterno per riconoscere vari esercizi con pesi liberi in palestra. Mentre, nello studio di (Zhao et al., 2024) sono stati posizionati undici sensori sul corpo di atleti, ed è stato messo a punto un algoritmo per riconoscere sei differenti attività della ginnastica.

Un altro ambito in cui i sensori inerziali sono particolarmente utilizzati è quello medico e riabilitativo. Nel lavoro di (Sánchez-Fernández et al., 2023) sono stati analizzati i segnali raccolti da un sensore IMU posizionato sul dorso della mano di pazienti affetti da morbo di Parkinson durante l'esecuzione di lenti movimenti *finger-to-nose*, per valutare il tremore motorio dell'arto interessato. Oppure, nell'articolo di (Vanmechelen et al., 2020) è stato valutato se i sensori inerziali possano essere utilizzati per individuare variazioni nei modelli di movimento in pazienti affetti da paralisi cerebrale discinetica durante l'esecuzione di un'estensione in avanti, confrontandoli con quelli effettuati da bambini non affetti da tale patologia.

Considerando l'ambito industriale in quanto quello di interesse della presente tesi, l'uso di sensori inerziali è rilevante in contesti come l'HRI dove la comprensione dei movimenti e delle azioni umane è cruciale per garantire una collaborazione sicura ed efficace tra robot e operatori. I sensori inerziali sono già stati utilizzati per monitorare le attività di operatori in diverse linee di assemblaggio. Ad esempio, nel lavoro di (Koskimäki et al., 2009), un unico sensore inerziale IMU è stato posizionato sul polso attivo di un lavoratore (*Figura 1.4*)

durante lo svolgimento di quattro attività: martellare, avvitare con un cacciavite, utilizzare una chiave inglese e fissare viti con un trapano elettrico.

Figura 1.4: posizionamento del sensore inerziale utilizzato in (Koskimäki et al., 2009)

Invece, nello studio di (Pesenti et al., 2023) sono stati utilizzati cinque sensori inerziali, posizionati su sterno, polsi e cosce di sei soggetti (*Figura 1.5 a)*). Gli autori si sono posti come obiettivo un utilizzo più ampio degli esoscheletri in scenari industriali. A tale scopo hanno presentato i risultati ottenuti tramite un approccio basato su *Deep Learning* sfruttando, appunto, i dati raccolti con i sensori inerziali, che risulterebbero facili da incorporare in qualsiasi esoscheletro industriale. I dati relativi ad azioni tipiche dei lavoratori dell'industria sono stati raccolti tramite due protocolli sperimentali designati appositamente: uno per la stima del carico sollevato (*Figura 1.5 b.1)*), l'altro per il riconoscimento dell'attività svolta dal lavoratore (*Figura 1.5 b.2)*).

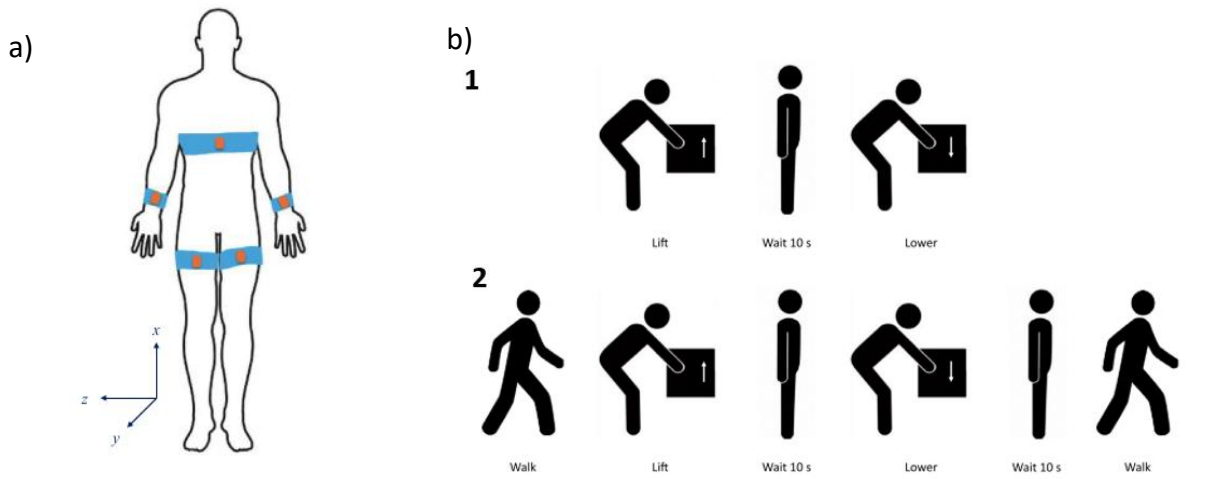

Figura 1.5: a) posizionamento dei sensori inerziali; b) protocolli sperimentali utilizzati per l'acquisizione dei dati (Pesenti et al., 2023)

1.4 Intelligenza artificiale

L'intelligenza artificiale (IA) è uno degli strumenti più utilizzati per distinguere vari tipi di attività grazie all'utilizzo di classificatori. Per fornire le prestazioni richieste, i sistemi basati sull'IA devono acquisire ed elaborare conoscenza in riferimento al compito da eseguire. Sono, quindi, chiamati a fornire prestazioni che tipicamente sono prerogative dell'intelligenza umana, come la deduzione, il ragionamento, la particolarizzazione, la generalizzazione, la valutazione di ipotesi e l'apprendimento (*Intelligenza Artificiale*, 2008).

L'IA comprende diversi approcci, uno fra i più utilizzati è il ***Machine Learning*** (ML), ossia apprendimento automatico. Il ML utilizza un sottoinsieme di dati per generare un algoritmo e apprende da essi (impiegando combinazioni di caratteristiche e pesi nuovi), a differenza della programmazione classica, in cui un algoritmo viene semplicemente eseguito. Fra i metodi più utilizzati per l'apprendimento vi sono l'apprendimento supervisionato e l'apprendimento non supervisionato.

- Nel caso dell'apprendimento supervisionato, il modello viene allenato su un insieme di dati di addestramento (*training*) già etichettato, di cui, pertanto,

è già noto l'*output*. In seguito, il modello può fare previsioni su nuovi dati che non erano stati inclusi nel *data set* con cui è stato addestrato.

- Per quanto riguarda l'apprendimento non supervisionato, esso mira ad individuare pattern in un insieme di dati in *input* da categorizzare, senza che vengano forniti gli *output* etichettati (Choi et al., 2020).

Il *Machine Learning* è, quindi, spesso utilizzato quando occorre riconoscere e distinguere movimenti o attività. Ad esempio, nel lavoro di (Chelli & Patzold, 2019) sono stati sviluppati dei sistemi per il riconoscimento di cadute e di attività di vita quotidiana. Gli autori hanno utilizzato i dati di accelerazione lineare e velocità angolare raccolti da (Anguita et al., 2013) e (Ojetola et al., 2015) per testare le performance di quattro algoritmi di classificazione tipici del ML, quali reti neurali artificiali (ANN), *k-nearest neighbors* (kNN), *quadratic support vector machine* (QSVM) ed *ensemble bagged tree* (EBT). Un risultato interessante che hanno ottenuto è che tramite QSVM ed EBT non sono stati riscontrati né falsi negativi, né falsi positivi. Nello studio di (Özdemir & Barshan, 2014) l'obiettivo era lo stesso dello studio precedentemente citato, ma sono state utilizzate sei tecniche di ML: kNN, *least squares method* (LSM), *support vector machine* (SVM), *bayesan decision making* (BDM), *dynamic time warping* (DTW) e ANN. In questo caso, gli autori hanno ritenuto affidabili classificatori come il kNN e LSM, in quanto il kNN ha la migliore accuratezza (99.91%) ed inoltre ogni caduta reale è stata classificata correttamente; mentre l'LSM classifica bene le cadute effettivamente avvenute.
Nel già citato studio di (Koskimäki et al., 2009), gli autori hanno utilizzato il kNN per il riconoscimento in tempo reale delle quattro attività svolte dall'operatore, sfruttando i dati di accelerazione lineare e velocità angolare estratti dal sensore inerziale che il soggetto indossava sull'avambraccio dell'arto attivo.

Un significativo passo avanti rispetto al ML e alle ANN è rappresentato dall'evoluzione verso reti neurali sempre più profonde (*deep neural networks*) con

capacità di apprendimento migliorate, che vengono riassunte sotto il termine ***Deep Learning*** (DL) o apprendimento profondo. Queste reti neurali si differenziano dalle ANN, in quanto constano di più livelli nascosti e più funzioni di attivazione contenute in un neurone (concepito in modo simile alle strutture del cervello umano) e sono in grado di aggiornare i pesi (ossia le connessioni tra i vari neuroni) durante l'addestramento (Janiesch et al., 2021).

Fra le reti neurali profonde più utilizzate vi sono le reti neurali ricorrenti (*Recurrent Neural Networks* – RNN), che sono particolarmente efficaci nel lavorare con dati temporali o sequenziali che variano in lunghezza e nella risoluzione di problemi come la classificazione di segnali naturali, l'analisi video etc. Una RNN è una struttura del DL che utilizza informazioni passate per migliorare le prestazioni della rete sugli *input* attuali e futuri. Una sua peculiarità è la presenza di uno stato nascosto e di cicli.

Nella pratica, le RNN riscontrano un problema nell'apprendimento di dipendenze a lungo termine. Di fatti, sono generalmente addestrate tramite la *backpropagation*, in cui possono riscontrare un problema di gradiente che "svanisce" o che "esplode". Questa problematica ha come risultato il fatto che i pesi della rete possono essere o molto grandi o molto piccoli, ponendo un limite all'efficacia dell'apprendimento nel caso di relazioni a lungo termine. Una particolare tipologia di RNN che pone soluzione a questo limite è la rete *Long Short-Term Memory* – LSTM (Memoria a breve e lungo termine). Questo tipo di rete utilizza porte supplementari per avere un controllo sulle informazioni che da uno stato nascosto arrivano allo stato nascosto successivo. Questo permette alla rete di apprendere le relazioni a lungo termine in modo più efficace (What Is a Recurrent Neural Network?).

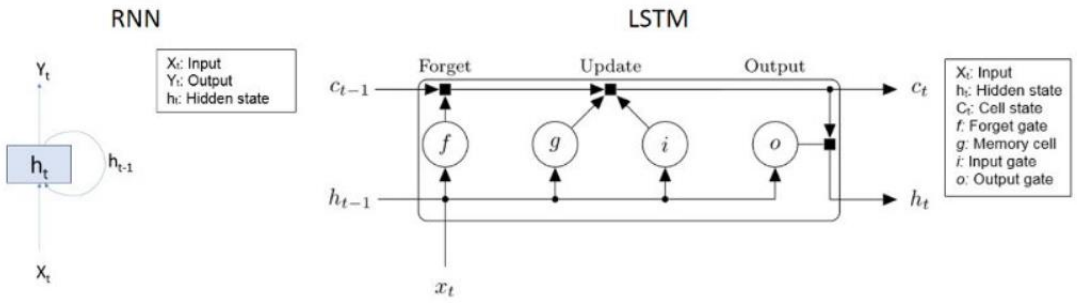

Figura 1.6: *confronto schematizzazione RNN e reti LSTM* (What Is a Recurrent Neural Network?)

Nello studio di (Muñoz-Organero et al., 2019) è stata utilizzata una rete LSTM per confrontare pattern di movimento tipici di soggetti in età pediatrica con ADHD[1] (separatamente sotto terapia e senza terapia) con soggetti in età pediatrica con sviluppo tipico (gruppo di controllo). In particolare, hanno analizzato i dati raccolti nell'arco di 24 h tramite quattro sensori inerziali posizionati sui polsi e sulle caviglie. I dati di accelerazione raccolti dai soggetti con sviluppo tipico sono stati utilizzati per l'addestramento della rete. Una volta addestrata, i dati raccolti da altri soggetti con sviluppo tipico, da soggetti con ADHD in terapia e da soggetti con ADHD non sotto trattamento sono stati usati per validare la rete. Gli autori hanno rilevato differenze statisticamente significative tra i vari gruppi. In particolare, per movimenti di media intensità, i pattern di movimento appresi dalla rete (effettuati dai soggetti del gruppo di controllo), non sono stati in grado di riconoscere caratteristiche simili nel gruppo di soggetti con ADHD non sottoposti a terapia, mentre hanno mostrato una migliore predizione nel caso dei soggetti con ADHD trattati.

Il lavoro di (Watanabe & Kimura, 2020) ha avuto come scopo il riconoscimento dell'utente di uno smartphone tramite l'analisi del cammino,

[1] "Il disturbo da deficit di attenzione/iperattività [ADHD] è una sindrome caratterizzata da difficoltà di attenzione, di controllo dell'impulsività e del livello di attività" (Sulkes, 2022).

utilizzando appunto i dati raccolti tramite smartphone. Allo scopo hanno utilizzato due tipi di reti: *Deep Recurrent Neural Networks* (DRNN) e LSTM. L'utilizzo delle due reti neurali ha permesso di identificare i diversi soggetti, seppur con accuratezza inferiore rispetto ai più utilizzati riconoscimento facciale e impronta digitale.

1.5 Movimenti impulsivi

L'interazione fisica ravvicinata tra operatore e robot è un processo complesso in continua evoluzione. Pertanto, gli approcci proposti per far sì che il robot possa tener conto dell'incertezza e dell'imprevedibilità di eventi/movimenti che potrebbero intercorrere sono diversi.

Come anticipato nel paragrafo 1.2.2, è di fondamentale importanza evitare collisioni e contatti non previsti fra robot ed operatore per salvaguardare l'incolumità e sicurezza di quest'ultimo.

Nello studio di (Lasota & Shah, 2015) è stata presentata una tecnica di pianificazione del movimento adattiva chiamata "*human-aware motion planning*", progettata per evitare conflitti di movimento in situazioni di interazione ravvicinata. Con il robot adattivo, la collaborazione umano-robot è stata più efficiente, con tempi di esecuzione più brevi, maggiore movimento simultaneo.

Nel lavoro di (Görür et al., 2018) è stata considerata anche la variabilità dello stato mentale umano durante la collaborazione, valutando disponibilità, intenti e capacità legate al compito. Attraverso questi, hanno cercato di stabilire se l'operatore avesse bisogno dell'intervento del robot, con l'obiettivo di aumentare l'efficienza e l'affidabilità della collaborazione. La novità del modello proposto risiede nella capacità di gestire comportamenti umani imprevisti che potrebbero influenzare le prestazioni della collaborazione. L'obiettivo è stato, da un lato, dimostrare che anticipare e considerare tale variabilità umana aumenta l'efficienza complessiva e la naturalezza dell'HRC, dall'altro, sviluppare un robot in

grado di intervenire e assistere l'essere umano in modo corretto e non invasivo, anticipando quando è necessario intervenire.

Diversamente, il riconoscimento da parte del robot di movimenti improvvisi causati dall'operatore non è stato oggetto di vasto interesse da parte della ricerca.

Sulla base delle osservazioni finora riportate, l'obiettivo della presente tesi è quello di realizzare una metodologia che riconosca eventuali movimenti impulsivi compiuti dall'operatore, per evitare che lo stesso entri in collisione col cobot con cui sta svolgendo un compito. Questo è stato fatto pianificando un protocollo sperimentale e realizzando uno specifico set up sperimentale correlato, raccogliendo i dati tramite sensori inerziali, elaborandoli a livello statistico e verificando se le reti neurali sviluppate fossero in grado di riconoscere e classificare correttamente i suddetti movimenti.

Di seguito è riportata una tabella riassuntiva (*Tabella 1.1*) degli articoli di letteratura scientifica citati in questo primo capitolo:

TITOLO	AUTORI	ANNO	OBIETTIVO	METODO	CONCLUSIONI
"Human Robot Collaboration in Industry 4.0: a literature review"	Baratta Alessio, Cimino Antonio, Gnoni Maria Grazia, Longo Francesco	2022	Disamina del concetto di HRC come guida dell'industria 4.0 e 5.0. Individuazione dei maggiori campi di ricerca (sicurezza, ergonomia, assemblaggio e saldatura, medico, agricoltura, istruzione)	Ricerca bibliografica	
"Industry 4.0 and Industry 5.0—Inception, conception and perception"	Xu Xun, Lu Yuqian, Vogel-Heuser Birgit, Wang Lihui	2021	Stabilire i propositi comuni dell'Industria 4.0 e 5.0 e far luce sugli scopi che li differenziano	Ricerca bibliografica	
"Survey on human–robot collaboration in industrial	Villani Valeria, Pini Fabio, Leali Francesco, Secchi Cristian	2018	Analizzare lo stato dell'arte in riferimento all'HRC, in particolare per quanto concerne	Ricerca bibliografica	

settings: Safety, intuitive interfaces and applications"			gli standard di sicurezza per applicazioni industriali; il punto di vista dell'operatore umano in termini di interazione fisica e carico di lavoro cognitivo		
"Sensor-based human–robot collaboration for industrial tasks"	Angleraud Alexandre, Ekrekli Akif, Samarawickrama Kulunu, Sharma Gaurang, Pieters Roel	2024	Dare evidenza del fatto che l'interazione uomo-robot può beneficiare dell'uso di modelli di percezione visiva per identificare oggetti, obiettivi, persone e azioni compiute.	Sviluppo di un metodo da applicare al contesto industriale, focalizzato su tre differenti strumenti di percezione visiva: rilevazione dello scheletro umano; riconoscimento delle azioni dell'operatore; rilevamento di oggetti e target dell'assemblaggio. Il task industriale studiato è l'assemblaggio di un motore diesel.	I modelli di percezione basati su DL possono essere addestrati e implementati con facilità in ambienti robotici, ottenendo risultati affidabili di rilevamento e riconoscimento. Inoltre, è possibile utilizzare insieme diversi modelli di percezione, consentendo la fusione di diversi sensori o l'uso di moduli di rilevamento diversi in parallelo.
"Human Centered Assistance Applications for the working environment of the future"	Schmidtler Jonas, Knott Verena, Hölzel Christin, Bengler Klaus	2015	Migliorare le condizioni lavorative adattando i sistemi di assistenza collaborativa in base all'accettazione e al benessere umano attraverso tre soluzioni tecniche: esoscheletri (aiuto al sollevamento di carichi pesanti), robot collaborativi (Cobot) e ortesi (Guanto di assemblaggio).	Approfondita analisi della letteratura scientifica riguardante discipline cognitive, antropometriche, biomeccaniche e fisiologiche. Tali conoscenze permettono l'analisi respiratoria, il monitoraggio del movimento, la misurazione della forza e la simulazione.	L'essere umano, con le sue abilità, versatilità e conoscenze, rimarrà il fattore chiave di successo nei futuri ambienti di lavoro. Pertanto, è necessario sviluppare approcci integrati che supportino l'essere umano per migliorare le prestazioni complessive ed affrontare sfide come il cambiamento demografico, forza lavoro diversificata e lavori ad alto stress.

"Human–robot interaction in industrial collaborative robotics: a literature review of the decade 2008–2017"	Hentout Abdelfetah, Aouache Mustapha, Maoudj Abderraouf, Akli Isma	2019	Fornire informazioni sufficienti per illustrare il quadro generale dello stato dell'arte nell'ambito dell'interazione uomo-robot nel settore industriale.	Analisi accurata di più di 300 articoli che presentano soluzioni sui problemi relativi all'HRI, pubblicati tra il 2008 e il 2017.	L'HRI è essenziale per lo sviluppo delle industrie del futuro e deve considerare aspetti come sicurezza, flessibilità e intuizione nell'utilizzo. I cobot devono essere sicuri, ridurre lo sforzo umano e sfruttare l'esperienza umana per sviluppare sistemi flessibili.
"Symbiotic human-robot collaborative assembly"	Wang L., Gao R., Váncza J., Krüger J., Wang X.V., Makris S., Chryssolouris G.	2019	Analizzare accuratamente l'HRC, in termini di: definizioni e caratteristiche; tecnologie esistenti per il monitoraggio e la comunicazione nell'HRC; standard di sicurezza e sistemi per evitare collisioni; soluzioni per la pianificazione e per l'assegnazione dei task, basate sul DL; controllo del robot senza programmazione con algoritmi basati sulle onde cerebrali; tecniche e sistemi per l'assistenza ai lavoratori.	Ricerca bibliografica	
"A new strategy for ensuring human safety during various levels of interaction with industrial robots"	Bdiwi Mohamad, Pfeifer Marko, Sterzing Andreas	2017	Presentare una nuova strategia per migliorare e garantire la sicurezza dell'operatore nelle diverse fasi dell'HRI. Creare un algoritmo per classificare le situazioni di pericolo durante l'HRI.	Dopo una breve analisi dello stato dell'arte, gli autori propongono una nuova strategia di classificazione in base al livello di interazione, con nuove funzioni di sicurezza in diverse situazioni (es.: operatore coperto dal robot).	È di fondamentale importanza l'integrazione di varie funzioni di sicurezza ed algoritmi per eseguire i task in modo sicuro ed efficiente.

"Erratum to: Physical Human-Robot Interaction"	Haddadin Sami, Croft Elizabeth	2016	Fornire una panoramica sullo stato dell'arte circa la collaborazione uomo-robot. Si trattano argomenti come la sicurezza dell'operatore; gli standard di sicurezza; le basi per la progettazione di cobot; le tecniche per la pianificazione del movimento e per la collaborazione nelle azioni.	Ricerca bibliografica	
"Collision detection for Industrial collaborative robots: A deep learning approach"	Heo Young Jin, Kim Dayeon, Lee Woongyong, Kim Hyoungkyun, Park Jonghoon, Chung Wan Kyun	2019	Proporre una struttura per la rilevazione delle collisioni, basata su un approccio di DL.	Sono stati acquisiti i segnali dei giunti del robot e le *label* effettive delle collisioni durante l'esecuzione di movimenti ripetitivi. Una rete CNN è stata allenata coi dati raccolti. L'accuratezza del nuovo metodo (*CollisionNet*) è stata confrontata con un metodo che stima il momento esterno.	Si è dimostrato che la progettazione e l'implementazione di un nuovo metodo per il rilevamento delle collisioni in *real-time* per un robot che utilizza le DNNs è possibile. Nelle valutazioni quantitative, il metodo proposto ha mostrato una precisione affidabile e la possibilità di essere applicato ai robot industriali.
"Sensor-Based Gym Physical Exercise Recognition: Data Acquisition and Experiments"	Hussain Afzaal, Zafar Kashif, Baig Abdul Rauf, Almakki Riyad, AlSuwaidan Lulwah, Khan Shakir	2022	Presentare una tecnica basata sull'utilizzo di sensori indossabili per l'acquisizione dati di specifici esercizi in palestra, e sull'utilizzo di diverse reti LSTM per il loro riconoscimento.	Sono stati raccolti i dati di 42 tipi di esercizi, tramite un accelerometro tri-assiale posizionato sul petto dei soggetti. Per l'analisi dei dati sono state utilizzate finestre da 4 s, con e senza *overlap*, e i dati sono stati etichettati a seconda dell'attività eseguita, per poi allenare le reti	È possibile utilizzare dispositivi indossabili e algoritmi di apprendimento per monitorare i tipi di attività fisica e l'intensità in tempo reale. Il sistema è migliorabile utilizzando più sensori, ricercando classificatori migliori, ampliando la

				neurali.	*feature extraction* dei dati grezzi.
"Image expression of time series data of wearable IMU sensor and fusion classification of gymnastics action"	Zhao Yuliang, Dong Fanghecong, Sun Tianang, Ju Zhongjie, Yang Le, Shan Peng, Li Lianjiang, Lv Xiaoyong, Lian Chao	2024	Affrontare le questioni legate alla fusione delle caratteristiche e alla *feature exctraction* dei dati dei sensori proponendo un framework innovativo per il riconoscimento delle azioni ginniche, che combina tecniche di trasformazione di dati temporali in immagini con un modello convoluzionale a tre canali chiamato ViTGS.	Raccolta tramite 11 IMU di dati di accelerazione e velocità angolare, relativi a 6 esercizi di ginnastica. Applicazione di tre metodi per trasformare dati di serie temporali in immagini (*Gramian Angular Field*, *Recurrence Plot* e *Markov Transition Field*)	Tale metodo può coadiuvare allenatori e atleti nella valutazione delle azioni in tempo reale, migliorando l'efficacia dell'allenamento e della performance competitiva.
"Kinetic tremor analysis using wearable sensors and fuzzy inference systems in Parkinson's disease"	Sánchez-Fernández Luis Pastor, Sánchez-Pérez Luis Alejandro, Concha-Gómez Paula Denisse, Shaout Adnan	2023	Proporre un nuovo metodo basato sulla logica fuzzy per la valutazione di pazienti affetti da morbo di Parkinson	Tramite un sensore inerziale posizionato sul dorso della mano di 57 pazienti e di 8 soggetti del gruppo di controllo, sono stati raccolti i segnali di movimenti *finger-to-nose*. Il sistema proposto basato sul modello fuzzy viene confrontato col MDS-UPDRS. Vengono considerati necessari parametri come l'ampiezza del tremore nelle differenti fasi del movimento, la frequenza del tremore e la frequenza dei movimenti volontari.	Le valutazioni di esaminatori esperti sono soggettive ed influenzate da fattori esterni. Questo porta ad ottenere differenze nei valori tra il modello e le valutazioni di esaminatori. Il modello proposto può restituire risultati più accurati e inalterabili. E potrebbe essere utile agli specialisti nel miglioramento dei trattamenti farmacologici da somministrare ai pazienti.
"Upper limb movement characteristics of children and youth with dyskinetic	Vanmechelen I., Bekteshi S., Konings M., Feys H., Desloovere K, Aerts J.M., Monbaliu E.	2020	Verificare se i sensori inerziali possano essere impiegati per l'identificazione di pattern in pazienti con paralisi cerebrale	14 pazienti con DCP e 14 ragazzi sani hanno eseguito per 10 volte un'estensione in	La variabilità dei movimenti dei pazienti con DCP si riflette sui valori RMS considerati. I risultati dello

cerebral palsy – A sensor approach"			discinetica (DCP) durante un movimento di estensione in avanti.	avanti. I segnali dei movimenti sono stati acquisiti con sensori inerziali su sterno, scapola, braccio, avambraccio e mano. È stata effettuata un'analisi statistica per valutare differenze fra i due gruppi di partecipanti.	studio dimostrano che i sensori inerziali possono essere utilizzati come alternativa portatile per studiare i complessi schemi di movimento tipici dei pazienti con DCP.
"Activity recognition using a wrist-worn inertial measurement unit: a case study for industrial assembly lines"	Koskimäki Heli, Huikari Ville, Siirtola Pekka, Laurinen Perttu, Röning Juha	2009	Descrivere un approccio per monitorare e riconoscere le attività svolte da un lavoratore per istruirlo in una specifica attività e garantire che tutti i task necessari siano svolti prima che il prodotto proceda sulla linea di assemblaggio.	I dati di accelerazione e velocità angolare acquisiti tramite un sensore inerziale posizionato sul polso attivo di un lavoratore sono elaborati per calcolare valori statistici; caratteristiche nel dominio della frequenza e fattori di correlazione. Il classificatore kNN viene utilizzato per il riconoscimento delle attività.	L'elevata accuratezza (88.2%) raggiunta nel riconoscimento di attività base del lavoratore in tempo reale mostra come il kNN sia un metodo che si può utilizzare concretamente nel riconoscere task in ambito industriale.
"IMU-based human activity recognition and payload classification for low-back exoskeletons"	Pesenti Mattia, Invernizzi Giovanni, Mazzella Julie, Bocciolone Marco, Pedrocchi Alessandra, Gandolla Marta	2023	Proporre un approccio basato su rete LSTM e sensori inerziali per dotare gli esoscheletri industriali con sistemi per il riconoscimento delle attività umane e compensazione adattiva del carico.	Sviluppando due protocolli sperimentali con azioni tipiche di lavoratori del settore industriale, sono stati acquisiti i segnali di 5 sensori inerziali. Una rete LSTM è stata utilizzata per la classificazione.	Sono risultati degli F1 score del 90.80% per il riconoscimento dell'attività e dell'87.14% per la stima del carico. Pertanto, tali algoritmi potrebbero essere utili per sfruttare il potenziale degli esoscheletri per ottenere un'ottima HRI.
"Introduction to Machine Learning, Neural Networks, and Deep Learning"	Choi Rene Y., Coyner Aaron S., Kalpathy-Cramer Jayashree, Chiang Michael F., Campbell J. Peter	2020	Presentare una panoramica dei metodi di ML e del loro utilizzo nella ricerca medica.	Ricerca bibliografica	

"A Machine Learning Approach for Fall Detection and Daily Living Activity Recognition"	Chelli Ali, Pätzold Matthias	2019	Proporre un framework di ML per l'identificazione di cadute e il riconoscimento di attività giornaliere.	Partendo dai dati raccolti da altri gruppi di ricerca, gli autori utilizzano i segnali di accelerazione e velocità angolare per riconoscere 7 attività diverse, incluse cadute e attività giornaliere. Vengono confrontati i risultati di 4 algoritmi di classificazione (ANN, kNN, QSVM, EBT).	Un sistema robusto di riconoscimento delle cadute è essenziale per sostenere la vita indipendente degli anziani. L'accuratezza nel riconoscimento di cadute con QSVM e EBT raggiunge il 100%, senza falsi positivi o falsi negativi.
"Machine learning and deep learning"	Janiesch Christian, Zschech Patrick, Heinrich Kai	2021	Riassumere le basi del ML e del DL per generare un'ampia comprensione della metodica alla base degli attuali sistemi intelligenti.	Ricerca bibliografica	
"Detecting Falls with Wearable Sensors Using Machine Learning Techniques"	Özdemir Ahmet Turan, Barshan Billur	2014	Riconoscere in modo accurato e robusto le cadute mentre si svolgono attività giornaliere, tramite sensori indossabili e tecniche di ML.	Sei sensori inerziali wireless sono stati posizionati su testa, petto, vita, polso destro, coscia destra e caviglia destra di 14 volontari. I dati raccolti dal sensore posizionato in vita sono stati elaborati e ridotti per distinguere le cadute dalle normali attività giornaliere, tramite 6 algoritmi di classificazione (kNN, LSM, SVM, BDM, DTW, ANN).	I metodi basati su kNN e LSM sono ritenuti classificatori affidabili in quanto non tralasciano alcuna caduta. Inoltre, hanno anche requisiti computazionali per training e testing accettabili, e questo li rende utilizzabili anche per applicazioni in tempo reale.
"Using Recurrent Neural Networks to Compare Movement Patterns in ADHD and Normally	Muñoz-Organero Mario, Powell Lauren, Heller Ben, Harpin Val, Parker Jack	2019	Proporre ed allenare una RNN (LSTM) per caratterizzare i modelli di movimenti di bambini sani e utilizzare la rete così addestrata per valutare le differenze nei movimenti dei	Ogni bambino è stato monitorato per 24 h tramite 4 accelerometri tri-assiali posizionati su polsi e caviglie.	Mentre i modelli di movimento per i bambini con ADHD non trattati con farmaci mostrano differenze più elevate rispetto a quelli dei

Developing Children Based on Acceleration Signals from the Wrist and Ankle"			bambini con ADHD (trattati e non trattati farmacologicamente).		partecipanti in sviluppo normale, tali differenze sono statisticamente significative solo per i movimenti di intensità media. Invece, i partecipanti con ADHD trattati mostrano comportamenti statisticamente differenti per i movimenti a bassa intensità.
"Gait identification and authentication using LSTM based on 3-axis accelerations of smartphone"	Watanabe Yuji, Kimura Masaki	2020	Valutare se l'utilizzo di DRNN e LSTM per identificare e autenticare gli utenti dall'analisi del cammino sia più efficace nell'identificazione del soggetto rispetto ad una tecnica di *machine learning* (*random forest*)	Dopo la creazione delle reti DRNN e LSTM, vengono dati in ingresso alle stesse i dati di accelerazione (acquisiti con smartphone) di diversi partecipanti, consentendone l'analisi.	L'utilizzo delle due reti utilizzate dimostra l'identificazione dei diversi soggetti in modo migliore rispetto alle *random forest*. Nonostante ciò, questo metodo non ha ottenuto i risultati di identificazione dell'utente dati da impronta digitale o riconoscimento facciale.
"Analyzing the Effects of Human-Aware Motion Planning on Close-Proximity Human–Robot Collaboration"	Lasota Przemyslaw A., Shah Julie A.	2015	Investigare la reazione umana all'adattamento del robot a livello del movimento, al fine di valutarne l'impatto sulla coesione del team, la soddisfazione dell'individuo e la percezione di sicurezza e comfort.	I partecipanti hanno collaborato con un robot che incorpora lo "*human-aware motion planning*" e con un robot di base che utilizza un movimento verso il percorso più breve. La coesione del team è stata valutata attraverso un insieme di metriche quantitative, mentre la soddisfazione umana e la percezione di	Con il robot adattivo, i partecipanti hanno completato l'attività più rapidamente, con un aumento dei movimenti simultanei, una riduzione del tempo di inattività umano, una diminuzione del tempo di inattività del. Le risposte ai questionari indicano che i partecipanti si sentivano più sicuri e a loro agio

				sicurezza e comfort sono state valutate attraverso questionari.	quando collaboravano con un robot adattivo.
"Social Cobots: Anticipatory Decision-Making for Collaborative Robots Incorporating Unexpected Human Behaviors"	Görür O. Can, Rosman Benjamin, Sivrikaya Fikret, Albayrak Sahin	2018	Indagare un sistema che consenta al robot di anticipare lo stato mentale del soggetto e intervenire di conseguenza, offrendo assistenza quando necessario durante l'esecuzione di un'operazione.	Si sviluppa uno scenario di collaborazione tra operatore e robot con l'obiettivo di ispezionare diversi prodotti stampati in 3D. Vengono creati modelli di diversi tipi di lavoratori umani, i quali interagiscono autonomamente con due pianificatori di robot distinti.	Nella simulazione, i cobot sono in grado di prevedere e gestire situazioni particolari, conducendo ad una collaborazione più efficiente e naturale quando l'essere umano coinvolto manifesta determinati comportamenti.

Tabella 1.1: titolo, autori, anno di pubblicazione, obiettivi, metodi e conclusioni degli articoli citati in questo primo capitolo.

2. MATERIALI e METODI

Per l'acquisizione dei dati è stato ideato un protocollo specifico (descritto nel paragrafo 2.2) per simulare un ambiente lavorativo tipico del settore industriale.
In particolare, si è trattato di *task* di *pick and place*, in cui al soggetto partecipante è stato richiesto di afferrare una pallina da golf e di posizionarla in un foro, effettuando il movimento nel modo più regolare e fluido possibile, senza scatti (movimenti non impulsivi). È stata prevista, inoltre, la possibilità che si verifichino dei movimenti che simulino eventuali azioni impreviste dovute a distrazioni o a fattori esterni (movimenti impulsivi).

2.1. Set up sperimentale

Per poter svolgere il test, è stato allestito un set up sperimentale ideato appositamente per lo scopo (Digo et al., 2023; Polito et al., 2023), riportato in *Figura 2.1*.

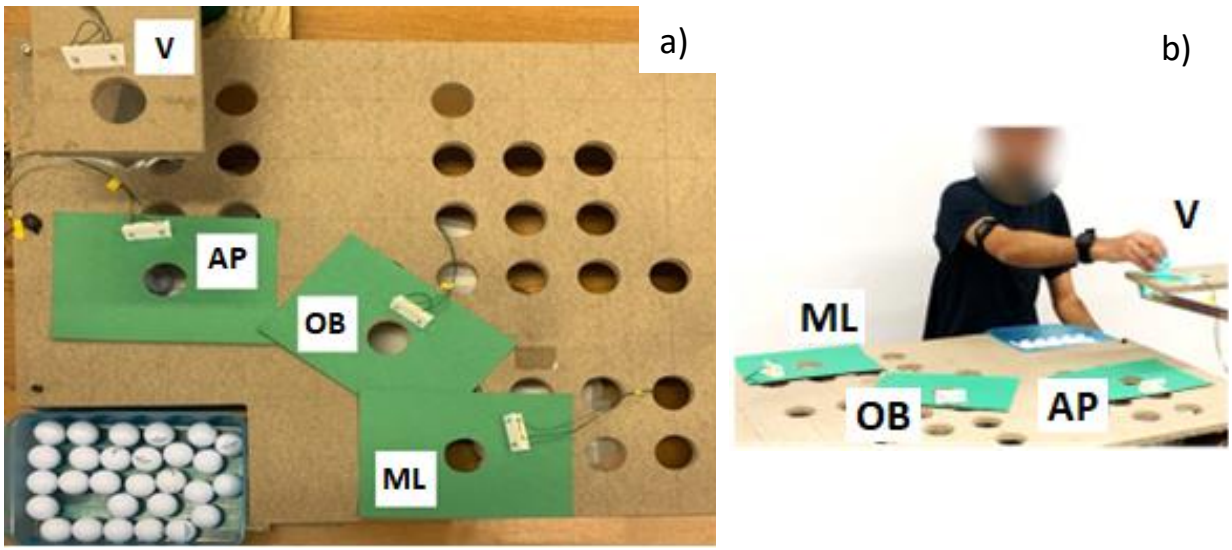

Figura 2.1: a) vista dall'alto del set up sperimentale; b) vista frontale del set up sperimentale mentre un soggetto esegue la prova frontale con braccio destro.

Esso è costituito da:

a) un tavolo;
b) uno sgabello;
c) un ripiano di truciolato con unico foro da 6 cm di diametro;
d) un piano di truciolato con 30 fori da 6 cm di diametro;
e) quattro piedini di 10 cm di altezza per tenere rialzato il suddetto piano di truciolato;
f) un contenitore di dimensioni 22 cm x 33 cm x 7 cm;
g) uno scivolo di alluminio di 1 m di lunghezza per permettere lo scorrimento delle palline inserite nel foro del ripiano c) all'interno di un contenitore a bocca di lupo delle dimensioni 12.8 cm x 20.4 cm x 9.6 cm;
h) tre contenitori posizionati tra il piano di a) e il piano di d);
i) trenta palline da golf da 43 mm di diametro poste all'interno del contenitore f);
j) otto luci LED: quattro rosse e quattro verdi;
k) quattro supporti per luci LED, realizzati con stampante 3D;
l) tre cartoncini di colore verde per identificare il foro in cui inserire la pallina, a seconda delle misure antropometriche del soggetto.

Le distanze tra i fori e la scatola sono state variate per consentire al soggetto di rilasciare la pallina da golf nei fori con una distanza ottimale, permettendo di estendere il braccio senza sforzi. Una quarta postazione è stata creata sul ripiano posizionato sopra il tavolo, utilizzando due aste per il supporto laterale (sigla V, *Figura 2.1*).

I LED presenti sul tavolo sono stati collegati a una scheda Arduino Nano con microcontrollore ATmega328 (riportata in *Figura 2.2*). La scheda Arduino è stata connessa al computer tramite un cavo USB, consentendo l'accesso al software Arduino. Quest'ultimo, attraverso l'implementazione di istruzioni apposite (insieme

ad altre implementate su Matlab®), ha gestito l'accensione dei LED e di un *buzzer* (segnale sonoro).

Nello specifico, i codici implementati hanno permesso l'accensione dei LED verdi (che identificano i movimenti non impulsivi) con una frequenza di 20 bpm, ossia uno ogni 3 s, e dei LED rossi e del *buzzer* (che identificano i movimenti impulsivi). Questi ultimi sono stati attivati dopo 0.5 s dall'accensione del LED verde del movimento interessato. In totale, durante ciascuna prova, sono stati svolti 30 movimenti, di cui 26 non impulsivi e 4 impulsivi. I codici sono stati implementati in modo che i primi cinque movimenti fossero esclusivamente non impulsivi e che dei quattro movimenti impulsivi almeno due fossero dovuti all'attivazione del *buzzer*.

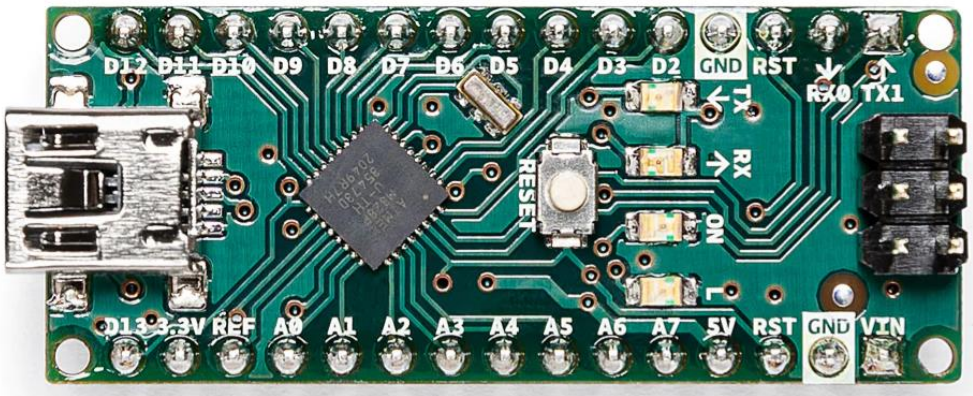

Figura 2.2: scheda Arduino Nano, con microcontrollore ATmega328

2.2 Protocollo

Nella *Figura 2.1*, sono mostrate le possibili direzioni verso cui muovere la pallina, a seconda dell'accensione dei LED:

- Antero-posteriore (**AP**);
- Obliqua (**OB**);
- Medio-Laterale (**ML**);
- Verticale (**V**)

Le fasi in cui è possibile suddividere il protocollo sono quattro:

1. Fase 1: raccolta dei dati antropometrici (altezza, peso, lunghezza del braccio e lunghezza dell'avambraccio).
2. Fase 2: posizionamento di cinque sensori MIMU sulla parte superiore del corpo tramite fasce elastiche (come spiegato nel paragrafo 2.4) e spiegazione del test previsto per l'esecuzione delle prove al soggetto.
3. Fase 3: simulazione della prova per consentire al soggetto di familiarizzare con il task e con la strumentazione. Durante questa fase, non sono stati registrati i dati, ma sono state valutate le corrette distanze del soggetto dal tavolo ed è stato deciso quali fori utilizzare in modo che il soggetto allunghi il braccio senza sforzo (muovendosi nelle direzioni richieste dai vari task). Inoltre, il soggetto ha potuto prendere confidenza col ritmo di accensione dei LED.
4. Fase 4: prova effettiva della durata di 90 s, durante la quale è avvenuta la raccolta dei dati. In questa fase, il soggetto è stato chiamato a svolgere 30 movimenti nella direzione indicata dal LED acceso e a rilasciare la pallina all'interno del foro corrispondente.

La Fase 4 è stata ripetuta in tre configurazioni:

a) Prova 1 (a cui successivamente ci si riferirà con la dicitura FR_r): soggetto seduto frontalmente al tavolo, utilizzando il braccio destro per effettuare i movimenti;

b) Prova 2 (a cui successivamente ci si riferirà con la dicitura FR_l): soggetto seduto frontalmente al tavolo, utilizzando il braccio sinistro per effettuare i movimenti;

c) Prova 3 (a cui successivamente ci si riferirà con la dicitura LA_l): soggetto seduto lateralmente rispetto al tavolo, utilizzando il braccio sinistro per effettuare i movimenti.

Come accennato, ogni prova prevedeva un totale di 30 movimenti da eseguire (26 non impulsivi, 4 impulsivi). Durante lo svolgimento di ogni prova, Il soggetto si trovava a dover rispondere a tre possibili evenienze:

- Accensione del LED verde (*Figura 2.3 a)*): il soggetto afferrava una pallina da golf, e con un movimento regolare e senza scatti portava l'arto verso il foro indicato dal LED acceso, e rilasciava la pallina;
- Attivazione del *buzzer* (*Figura 2.3 b)*): dopo 0.5 s dall'attivazione di un LED verde, mentre il soggetto si muoveva come descritto al punto precedente, è stato riprodotto un segnale acustico. In questo caso il soggetto doveva alzare il braccio attivo in direzione verticale nel modo più repentino possibile, lasciando perdere l'istruzione precedentemente data dal LED verde;
- Accensione del LED rosso ((*Figura 2.3 c)*): dopo 0.5 s dall'attivazione di un LED verde, mentre il soggetto si muoveva come descritto precedentemente, veniva acceso un LED rosso in una direzione diversa da quella indicata dal LED verde. In questo caso il soggetto doveva velocizzare il movimento del braccio attivo verso il nuovo foro indicato, rilasciando la pallina, lasciando perdere l'istruzione precedentemente data dal LED verde;

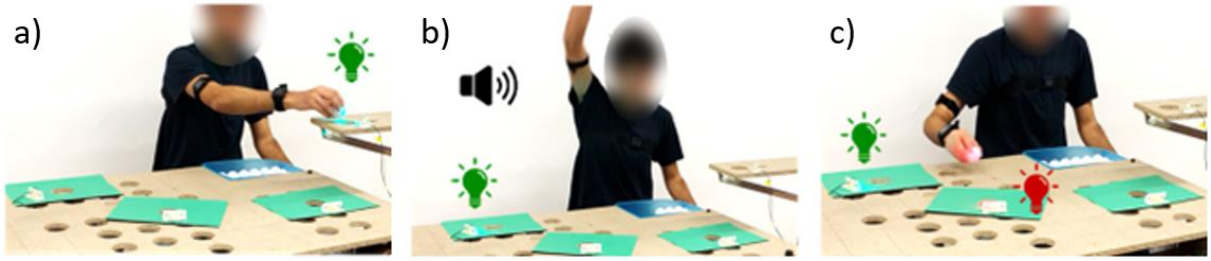

Figura 2.3: a) accensione del LED verde (il soggetto porta la pallina da golf verso il foro indicato); b) accensione del LED verde seguito dal segnale acustico (appena il soggetto sente il segnale porta il braccio in uso verso l'alto); c) accensione del LED verde seguita dall'accensione del LED rosso (non appena il soggetto si rende conto dell'accensione del LED rosso porta, nel modo più repentino possibile, la pallina da golf verso il foro indicato da quest'ultimo)

2.3 Partecipanti

Per lo svolgimento dei test, sono stati reclutati 61 soggetti di età e genere diversi, i quali hanno firmato il consenso informato approvato dal Comitato Etico per la Ricerca del Politecnico di Torino. La raccolta dati ha avuto luogo in differenti giornate. Di seguito è riportata la *Tabella 2.1,* che sintetizza le caratteristiche principali dei soggetti:

Genere	**Età (anni)**	**Altezza (m)**	**Peso (kg)**	**BMI (kg/m^2)**	**Arto dominante**	**Lunghezza avambraccio (cm)**	**Lunghezza braccio (cm)**
25 F, 36 M	28.43±6.46	1.73±0.08	67.48±10.49	22.48±2.23	52 dx, 9 sx	29.17±2.30	34.05±2.68

Tabella 2.1: dati complessivi dei 61 soggetti. Per quanto riguarda altezza, peso, BMI, lunghezza avambraccio e lunghezza braccio sono riportati i valori medi ± deviazione standard inter-soggetto.

2.4 Sensori inerziali

La strumentazione utilizzata per la raccolta dati dei movimenti effettuati dai partecipanti consisteva in un sistema di sensori inerziali Opal™ prodotti da APDM WEARABLE TECHNOLOGIES INC. I sensori utilizzati sono gli Opal V2R (APDM - Wearable Technologies), ossia sensori wireless di piccole dimensioni, che impiegano MEMS (sistemi micro-elettromeccanici), per il rilevamento dei parametri cinematici dei movimenti. Sono dotati di due accelerometri tri-assiali (range: ±16 g; ±200 g), un giroscopio tri-assiale (range: ± 2000 deg/s) e un magnetometro tri-assiale (range: ±8 Gauss).

Poiché l'analisi aveva come focus la parte superiore del corpo, tramite fasce elastiche dotate di velcro sono stati fissati cinque sensori inerziali ai seguenti distretti corporei:

- a livello dello sterno;
- sulla parte superiore del braccio destro, appena sotto il muscolo deltoide;

- sulla parte superiore del braccio sinistro, appena sotto il muscolo deltoide;
- sull'avambraccio destro, nella parte distale, in corrispondenza del polso;
- sull'avambraccio sinistro, nella parte distale, in corrispondenza del polso.

È stata scelta una frequenza di campionamento pari a 200 Hz, ed è stato utilizzato il software proprietario Motion Studio.

3. ELABORAZIONE e ANALISI DATI

A seguito dell'acquisizione dati, avvenuta come descritto nel capitolo precedente, si è passati alla fase di elaborazione, che è stata condotta su Matlab® (Mathworks, USA). Sono stati ricavati le accelerazioni, le velocità angolari e gli orientamenti dai sensori MIMU posizionati sull'avambraccio attivo, cioè il destro (rFA) per la prova FR_r e il sinistro (lFA) per le prove FR_l e LA_l. Inoltre, sono stati salvati da Arduino i tempi di attivazione dei LED (verdi e rossi), del *buzzer* e i relativi pin (ossia i valori numerici associati all'accensione dei LED, a seconda di direzione e colore). I dati ricavati dai due sistemi sono stati ordinati all'interno di una struttura s, come riportato in *Figura 3.1*.

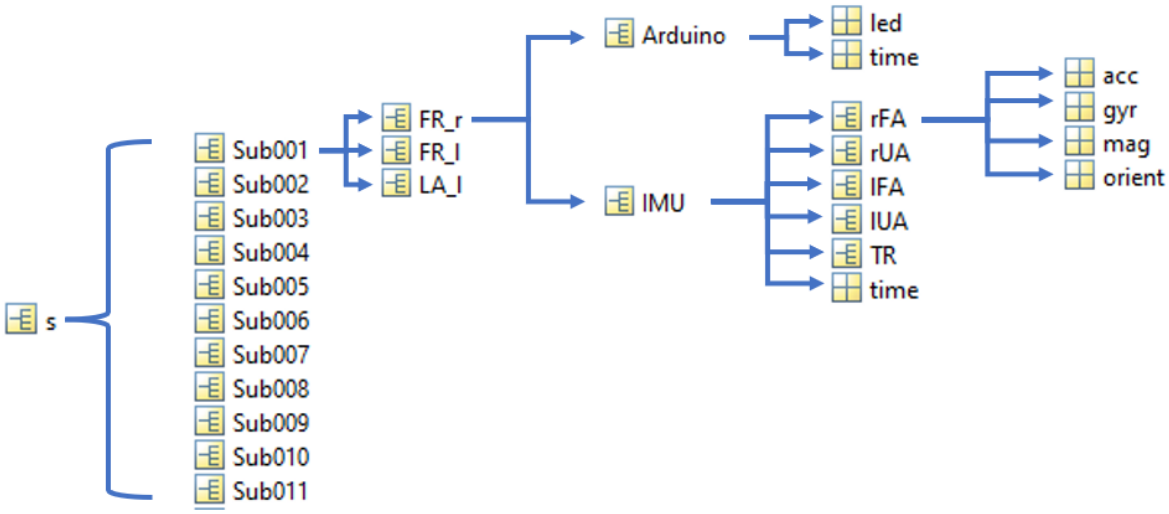

Figura 3.1: schematizzazione dell'organizzazione della struttura s. Ogni soggetto è caratterizzato dalla stessa ripartizione dei dati.

Prima di procedere con le effettive analisi, si sono resi necessari altri passaggi intermedi.

3.1 Suddivisione in movimenti impulsivi e non impulsivi

Per suddividere i movimenti in impulsivi e non impulsivi è stato necessario, in primo luogo, suddividere i 30 movimenti in 30 finestre della durata di 3 s ciascuna.

Poiché le frequenze di campionamento dei due sistemi utilizzati (Arduino e sensori inerziali) erano differenti (20 bpm e 200 Hz, rispettivamente), i tempi riferiti alle attivazioni dei LED e del *buzzer* ricavati da Arduino e i tempi ricavati dal sistema Opal non erano esattamente coincidenti. Tramite la regola della distanza minima tra due punti, sono stati ricavati i valori dei tempi del sistema Opal più vicini ai valori dei tempi di attivazione registrati da Arduino. Sono stati così ottenuti i vettori che contenevano i valori dei tempi di inizio e fine delle finestre, rendendo possibile la suddivisione in 30 finestre.

In seguito, è avvenuta la ripartizione delle finestre in impulsive e non impulsive a seconda dei valori salvati nel vettore 'led' di 'Arduino' (in riferimento alla *Figura 3.1*). In particolare, nel caso dei movimenti impulsivi, per considerare sempre finestre della stessa durata, è stato scelto come tempo di inizio quello relativo all'attivazione del LED verde che precedeva di 0.5 s l'accensione del LED rosso o *buzzer* in questione. Mediante tale suddivisione, dunque, sono state create due matrici per ogni soggetto: una matrice contenente i segnali dei movimenti non impulsivi (di dimensioni 26x600) e una matrice contenente i segnali dei movimenti impulsivi (di dimensioni 4x600).

3.2 Analisi dell'accelerazione

Poiché i sensori MIMU hanno acquisito i segnali lungo tre direzioni, è stata calcolata la norma dell'accelerazione, istante per istante, secondo la (1):

$$\overline{\boldsymbol{a(t)}} = \sqrt{\boldsymbol{a_x(t)^2 + a_y(t)^2 + a_z(t)^2}} \qquad (1)$$

Prima di questo passaggio, però, poiché l'accelerazione totale è data dalla somma del contributo dell'accelerazione di gravità e del contributo dell'accelerazione del "corpo" preso in esame, si è proceduto alla rimozione della

componente dell'accelerazione di gravità, attraverso due metodologie, i cui rispettivi passaggi sono riportati di seguito:

A. **Metodo matematico**:
    - Da ogni sensore sono stati ricavati i quaternioni.
    - È stata calcolata la matrice che rappresentava l'orientamento di ogni sensore rispetto al sistema di riferimento globale, tramite il comando Matlab *quat2rotm*.
    - È stato ottenuto il vettore gravità riferito al sistema di riferimento locale, tramite la trasposizione della matrice calcolata al punto precedente e pre-moltiplicazione per il vettore gravità espresso secondo il sistema di riferimento terrestre.
    - Da ognuno dei vettori di accelerazione ottenuti lungo le tre direzioni è stato sottratto il vettore al punto precedente.
B. **Metodo Chelli-Pätzold**, utilizzato da (Chelli & Patzold, 2019):
    - Il contributo dovuto all'accelerazione di gravità varia molto lentamente. Questo implica che nel dominio della frequenza si aggiri intorno a 0 Hz, a differenza del contributo dei movimenti effettuati dal corpo, che hanno frequenza superiore a 0 Hz. Pertanto, è stato implementato un filtro passa-alto *Chebyshev* di Tipo II, con *stopband attenuation* pari a 60 dB e *stopband frequency* pari a 0.4 Hz, con un ordine pari a 5.
    - Tale filtro è stato applicato in doppia passata alle tre componenti dell'accelerazione (x, y, z).

Successivamente, i segnali norma dell'accelerazione di tutti soggetti e per ogni prova, da cui è stato rimosso il contributo dell'accelerazione di gravità con i due metodi, sono stati suddivisi, come descritto nel paragrafo 3.1, in 30 finestre da 3 s ciascuna e in movimenti impulsivi e non impulsivi.

3.1.1 Calcolo del Root Mean Square (RMS)

Per valutare se ci fossero differenze nei valori assunti dall'accelerazione nei due tipi di movimenti, è stato calcolato il valore quadratico medio (*Root Mean Square*-RMS) per ogni finestra della durata di 3 s, secondo la seguente formula (2):

$$a_{RMS} = \sqrt{\frac{1}{N}\sum_{n=1}^{N}|a_n|^2} \qquad (2),$$

in cui N è pari a 600, e a_n è il valore della norma dell'accelerazione assunto ad un determinato tempo.

In seguito, per ottenere un unico valore per ogni soggetto è stato calcolato il valor medio, rispettivamente per movimenti non impulsivi e impulsivi, secondo la (3):

$$\mu = \frac{1}{N}\sum_{i=1}^{N} A_i \qquad (3),$$

in cui A_i è il valore a_{RMS} calcolato per i vari movimenti, ed N è pari al numero dei movimenti totali considerati per ogni soggetto (N = 26 per i movimenti non impulsivi, N = 4 per i movimenti impulsivi).

I valori così ottenuti sono stati raccolti in due differenti matrici, a seconda del metodo utilizzato per la rimozione dell'accelerazione di gravità, di dimensioni 61x6, così organizzate:

- Numero righe pari al numero dei soggetti;
- Colonna 1: valori RMS medi dell'accelerazione dei movimenti non impulsivi per la prova FR_r;
- Colonna 2: valori RMS medi dell'accelerazione dei movimenti impulsivi per la prova FR_r;
- Colonna 3: valori RMS medi dell'accelerazione dei movimenti non impulsivi per la prova FR_l;
- Colonna 4: valori RMS medi dell'accelerazione dei movimenti impulsivi per la prova FR_l;

- Colonna 5: valori RMS medi dell'accelerazione dei movimenti non impulsivi per la prova LA_I;
- Colonna 6: valori RMS medi dell'accelerazione dei movimenti impulsivi per la prova LA_I.

In questo modo si è potuto procedere al confronto dei valori RMS medi calcolati partendo dai segnali il cui contributo dell'accelerazione di gravità è stato eliminato attraverso i due metodi descritti in precedenza. In particolare, con 'RMS mat' vengono indicati i valori RMS medi ottenuti rimuovendo l'accelerazione di gravità col "Metodo matematico", mentre con 'RMS CP' sono indicati quelli ottenuti con il "Metodo Chelli-Pätzold".

3.1.2 Risultati: Confronto metodi rimozione accelerazione di gravità

In *Figura 3.2* sono riportati i grafici ottenuti per le tre configurazioni in cui sono state svolte le prove. Sull'asse delle ascisse sono riportati i valori 'RMS CP', mentre sull'asse delle ordinate i valori 'RMS mat'. I movimenti non impulsivi sono contraddistinti dai pallini di colore verde, invece i movimenti impulsivi in pallini di colore rosso

a)

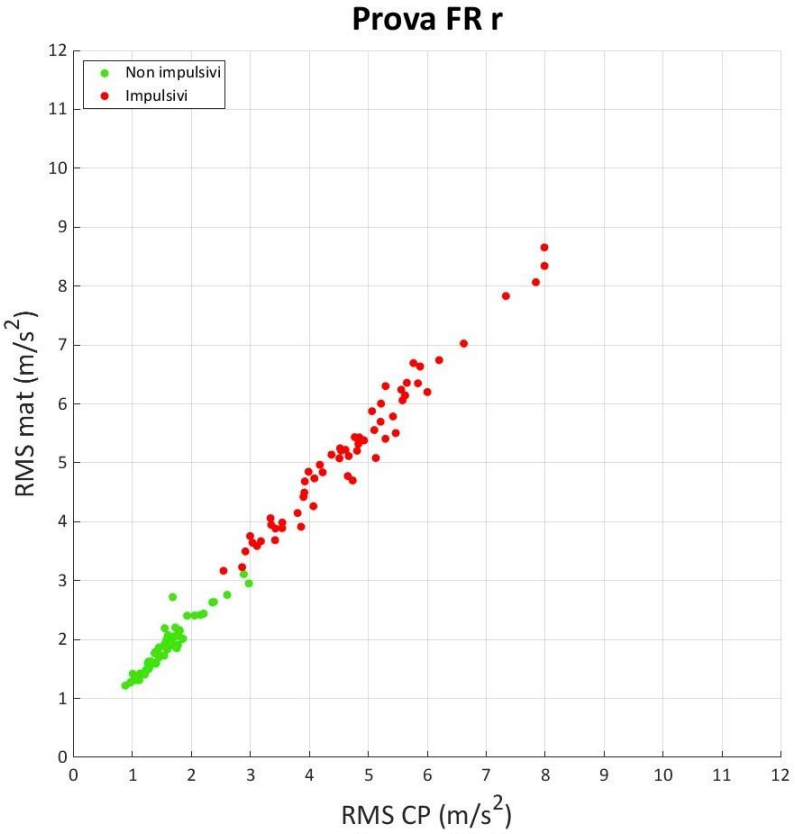
Prova FR r
Non impulsivi
Impulsivi
RMS mat (m/s^2)
RMS CP (m/s^2)
0
1
2
3
4
5
6
7
8
9
10
11
12

b)

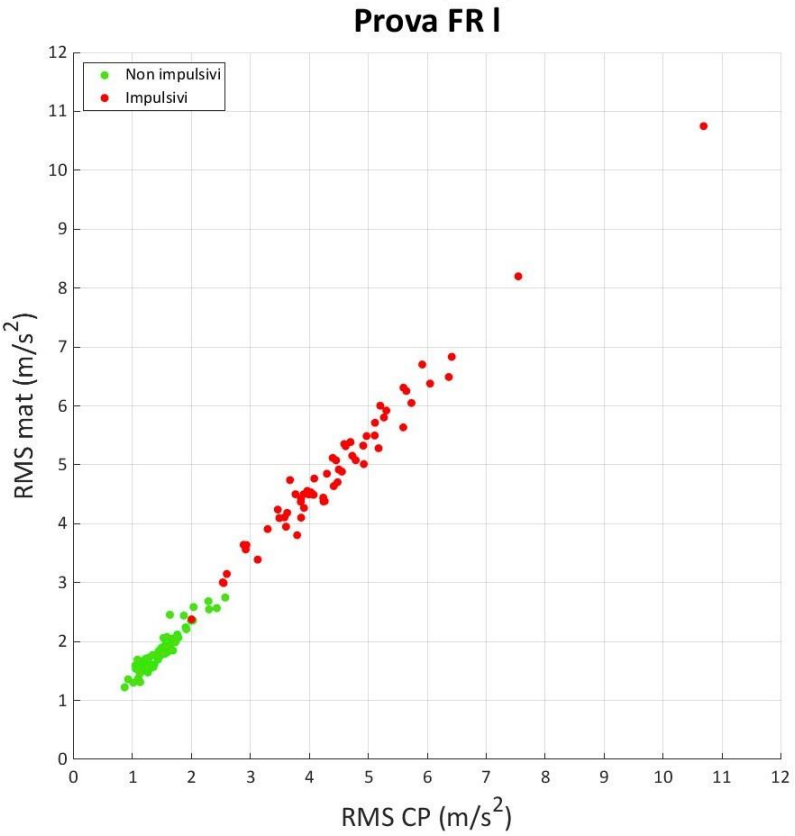
Prova FR l
Non impulsivi
Impulsivi
RMS mat (m/s^2)
RMS CP (m/s^2)
0
1
2
3
4
5
6
7
8
9
10
11
12

c)

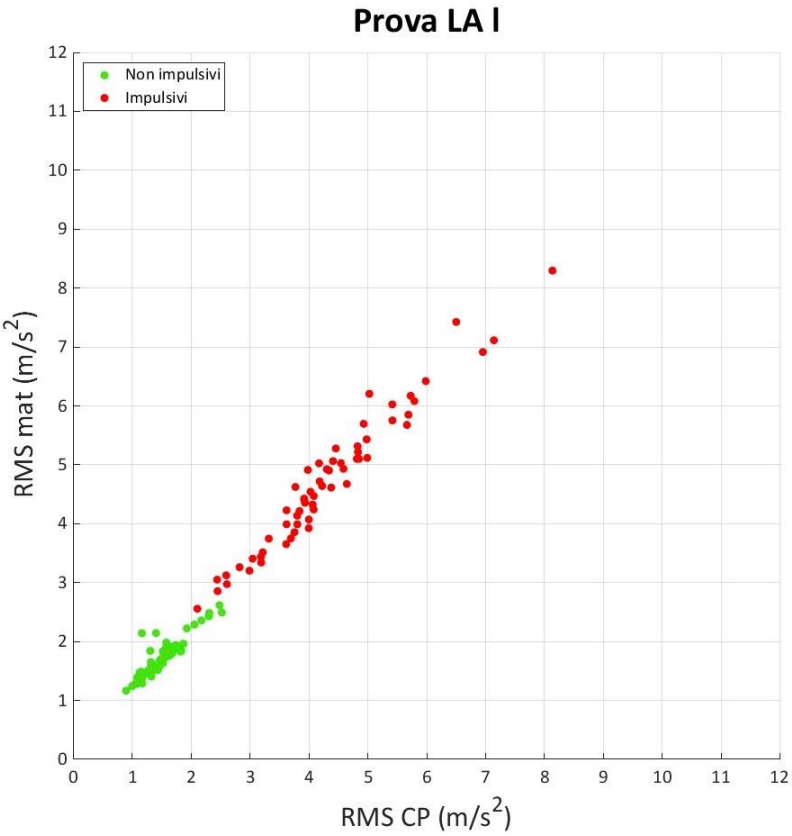

Figura 3.2: confronto dei due metodi di rimozione dell'accelerazione di gravità tramite i valori RMS di tutti i soggetti, per movimenti non impulsivi (in verde) ed impulsivi (in rosso). a) Prova frontale con braccio destro; b) Prova frontale con braccio sinistro; c) Prova laterale con braccio sinistro.

Dall'osservazione dei grafici in *Figura 3.2*, è stato notato che i valori 'RMS CP' e 'RMS mat' sono sostanzialmente confrontabili. Pertanto, per le analisi successive, è stato deciso di considerare solamente il segnale dell'accelerazione in cui la rimozione dell'accelerazione di gravità è avvenuta tramite il metodo matematico.

Per valutare se ci fossero differenze nei valori assunti dagli RMS medi dell'accelerazione nei due tipi di movimento, si è proceduto a verificarne la variabilità, tramite il calcolo del valore medio (con la formula (3), in cui A_i è il valore degli RMS medi raccolti nella matrice descritta in precedenza, con N pari a 61) e il calcolo della deviazione standard (formula (4)) applicata agli stessi valori degli RMS medi di cui si è calcolato il valor medio):

$$\sigma = \sqrt{\frac{\sum_{i=1}^{n}(x_i - \mu)}{n}} \qquad (4)$$

3.3 Velocità angolare

Successivamente, dai dati acquisiti dai sensori inerziali è stata presa in considerazione la velocità angolare lungo le tre direzioni. Similmente a quanto fatto per l'accelerazione, è stata calcolata la norma, partendo dalle tre componenti, secondo la (5):

$$\overline{\boldsymbol{\omega}(\boldsymbol{t})} = \sqrt{\boldsymbol{\omega}_{\boldsymbol{x}}(\boldsymbol{t})^2 + \boldsymbol{\omega}_{\boldsymbol{y}}(\boldsymbol{t})^2 + \boldsymbol{\omega}_{\boldsymbol{z}}(\boldsymbol{t})^2} \qquad (5)$$

Anche nel caso della velocità angolare i movimenti sono stati suddivisi, come descritto nel paragrafo 3.1, in 30 finestre da 3 s ciascuna e in movimenti impulsivi e non impulsivi.

3.4 Suddivisione del segnale in finestre da 0.5 s

Per le successive analisi dei segnali, con lo scopo di ridurre la finestra temporale considerata e avvicinarsi ad una situazione di analisi dei dati in tempo reale, è stato deciso di effettuare un'ulteriore ripartizione dei segnali in finestre di durata pari a 0.5 s. In questo modo ogni movimento di 3 s è stato suddiviso in sei finestre da 0.5 s, come segue:

- finestra 1: da 0 a 0.5 s;
- finestra 2: da 0.5 a 1 s;
- finestra 3: da 1 a 1.5 s;
- finestra 4: da 1.5 a 2 s;
- finestra 5: da 2 a 2.5 s;
- finestra 6: da 2.5 a 3 s.

3.4.1 Statistica

Per ogni finestra di ogni movimento è stato calcolato il valore medio che il modulo dell'accelerazione e il modulo della velocità angolare assumevano in tale intervallo (applicando la formula (3), dove A_i assume, a seconda del caso, i valori

del modulo dell'accelerazione o della velocità angolare, ed N=100). In seguito, è stato calcolato il valor medio totale per ogni movimento, per entrambe le grandezze, mediando i sei valori ottenuti al passo precedente. Infine, sono stati mediati i valori per il numero di movimenti (in riferimento alla formula (3), N=26, per i movimenti non impulsivi; N=4 per i movimenti impulsivi).

Ottenuti tali valori, sono stati diagrammati in tre grafici in totale (uno per prova) ed è stata condotta un'analisi statistica. Dapprima è stato verificato se l'insieme dei dati appartenenti ai due tipi di movimenti, per ogni prova, appartenessero alla famiglia della distribuzione normale, tramite il comando *lillietest* su Matlab. Dalla documentazione della funzione (Lillietest - Lilliefors Test), si legge che essa restituisce un valore (*h*) dato dalla decisione del test rispetto all'ipotesi nulla, ossia che l'insieme di dati in ingresso appartengano ad una distribuzione normale; e il *p-value*, a seconda della sintassi scelta. Quando *h=1* il test rifiuta tale ipotesi ad un livello di significatività del 5%, se *h=0* il test non riesce a rifiutare l'ipotesi nulla. Per confermare o smentire i risultati di tale funzione, è stato utilizzato il comando *normplot*, che, graficamente, dà un riscontro immediato: se i dati si sovrappongono alla retta della distribuzione normale, si considerano distribuiti normalmente; altrimenti si considerano non appartenenti a tale distribuzione.

Il risultato delle verifiche effettuate è stato che i dati non possano essere considerati distribuiti normalmente. Pertanto, si è proceduto con il test non parametrico di Wilcoxon per verificare se ci fossero differenze statisticamente significative tra movimenti impulsivi e non impulsivi, tramite il calcolo del *p-value*.

Successivamente, i movimenti impulsivi sono stati suddivisi in visivi e sonori (a seconda del valore assunto nel vettore 'led', *Figura 3.1*). Similmente a quanto fatto precedentemente, anche in questo caso sono state calcolate le medie, ed è stato effettuato il test di Wilcoxon per verificare se ci fossero ancora differenze

statisticamente significative tra movimenti non impulsivi e impulsivi visivi, tra non impulsivi e impulsivi sonori, e tra impulsivi visivi e impulsivi sonori.

In seguito, i vari movimenti sono stati suddivisi in base alla direzione indicata dal LED (*Figura 2.1*) in AP, OB, ML, V e, nel caso di attivazione del *buzzer* per gli impulsivi, anche in SONORO. È stata, così, svolta un'analisi intra-soggetto volta a trovare il segnale medio (istante per istante) per ogni direzione, soggetto e prova.

Dai risultati ottenuti, è stata poi svolta l'analisi inter-soggetto e valutata la variabilità di tali segnali tramite il calcolo, istante per istante, della media (formula (3)) e della deviazione standard (formula (4)).

Dapprima raggruppando tutti i risultati in una sola finestra da 0.5 s; e successivamente per le sei finestre suddivise come descritto all'inizio del presente paragrafo sovrapponendo i segnali dei movimenti impulsivi e non impulsivi. È stato fatto lo stesso tipo di rappresentazione su sei finestre anche per i segnali impulsivi registrati durante l'attivazione del *buzzer*.

3.5 Deep Learning

Come evidenziato nel capitolo introduttivo, una tipologia specifica di RNN è la rete LSTM, che permette l'apprendimento di dipendenze a lungo termine in modo efficace, ed è spesso utilizzata per segnali che variano nel tempo. Si è deciso di utilizzare proprio questo tipo di rete per riuscire a distinguere movimenti impulsivi e non impulsivi.

Prima della creazione e dell'addestramento di tale rete, i segnali del modulo dell'accelerazione, del modulo della velocità angolare e del tempo, per ogni prova e soggetto, sono stati segmentati in finestre della durata di 0.5 s e ogni finestra è stata salvata all'interno di vettori cella. In questo modo ogni cella consta di tre colonne: la prima raccoglie i dati dell'accelerazione, la seconda i dati relativi alla

velocità angolare e la terza i dati del tempo. Parallelamente, è stato creato un vettore *label* che, per ogni finestra da 0.5 s, contenesse la classe di appartenenza del tipo di movimento:

- *label* = 0 per i movimenti non impulsivi;
- *label* = 1 per i movimenti impulsivi.

Dopodiché, i vettori ottenuti dalle tre prove eseguite da ogni soggetto, contenenti rispettivamente i segnali finestrati e le *label*, sono stati raggruppati in singoli vettori. Infine, i dati di tutti i soggetti così organizzati sono stati riuniti in matrici, andando a comporre il "DATA SET 1".

Per far sì che la rete funzioni nel modo corretto, essa deve essere allenata. Una delle tecniche più classiche utili allo scopo prevede che il *data set* a disposizione (o una sua porzione) venga suddiviso in tre gruppi: *training set* che serve per allenare la rete; *validation set* che serve per valutare se la rete sia in grado di prevedere i risultati in modo corretto; *test set* che serve per verificare le performance del modello, e se, quindi, sia in grado di generalizzare su nuovi dati.

L'ottenimento di esperienza da parte della rete consiste nel regolare i pesi da attribuire alle varie connessioni della rete stessa, comparando l'iniziale classificazione (arbitraria, almeno inizialmente) con quello che suggerisce l'apprendimento. Nel caso di *training* supervisionato, a ogni dato in ingresso corrisponde un risultato. Dal confronto tra i valori calcolati dalla rete e i valori corretti, viene stabilito il livello di errore per ogni nodo, che viene impiegato nell'aggiustamento dei pesi nei livelli nascosti della rete per far sì che si ottengano i risultati desiderati. Tale processo viene effettuato in maniera iterativa, in modo tale che la regolazione dei pesi associati con i valori forniti in input venga ripetuta più volte, facendo sì che la rete impari ad aggiustare i pesi per produrre il giusto output (*Come Funziona e Come è Possibile Migliorare l'addestramento Delle Reti Neurali*, 2020).

Generalmente, la maggior parte del *data set* viene utilizzato per il *training*, in quanto più dati vengono messi a disposizione dell'apprendimento della rete, migliore sarà la sua capacità di apprendimento. Tuttavia, una suddivisione in tre parti del *data set* andrebbe inevitabilmente a ridurre il numero di dati su cui allenare la rete, pertanto, spesso si decide di implementare una metodologia nota come *k-fold cross validation*. Nello specifico di questo lavoro, si è scelto un numero di "pieghe" pari a 5, permettendo di dividere virtualmente il *training set* in cinque gruppi con lo stesso numero di dati. Tramite questo approccio, il *training set* è suddiviso in due sottogruppi (*Figura 3.3*):

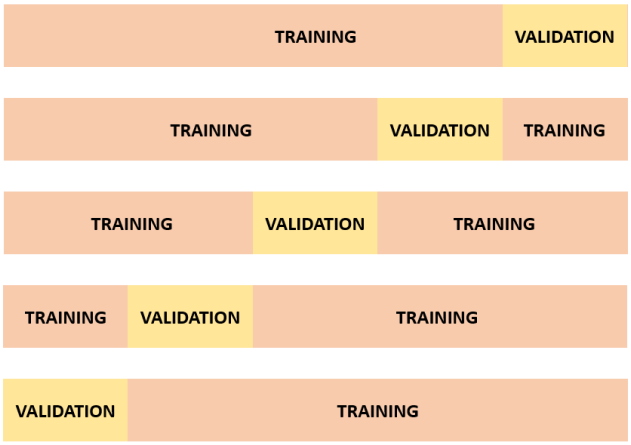

Figura 3.3: schematizzazione della suddivisione del training set con l'implementazione del five-fold cross validation.

- Uno è costituito dalle (k-1) pieghe, quindi dai 4/5 del *training set*, e viene utilizzato per allenare la rete;
- il restante quinto dei dati viene utilizzato per validare la rete allenata.

Come schematizzato in *Figura 3.3*, tale metodo è ripetuto per cinque volte: ad ogni iterazione cambia la porzione di dati su cui viene effettuato il *training* e, di conseguenza, quella su cui viene effettuata la validazione (Cross-Validation: Evaluating Estimator Performance).

Al termine di ogni iterazione viene valutata l'accuratezza con cui vengono classificati i dati di validazione, ossia quando i valori predetti sono uguali ai valori

veri, e viene scelta la rete con accuratezza migliore per utilizzarla nella classificazione dei dati del *test set*.

Nello specifico di questa tesi, poiché l'obiettivo è il riconoscimento di movimenti impulsivi, non è stato utilizzato interamente il "DATA SET 1", ma un nuovo *data set* di interesse ("DATA SET 2"), costruito sulla base di un numero di finestre impulsive ridotto rispetto a quello di partenza. Tale scelta è stata fatta in base alla diversità delle finestre dei movimenti impulsivi rispetto alle corrispondenti finestre dei movimenti non impulsivi, servendosi dell'analisi statistica (Wilcoxon) e dei *box plot*. Per poter fare questo, i vari movimenti da 3 s sono stati suddivisi in sei finestre da 0.5 s:

- finestra 1: da 0 a 0.5 s;
- finestra 2: da 0.5 a 1 s;
- finestra 3: da 1 a 1.5 s;
- finestra 4: da 1.5 a 2 s;
- finestra 5: da 2 a 2.5 s;
- finestra 6: da 2.5 a 3 s.

Per ogni finestra di ogni movimento è stato calcolato il valore medio che il modulo dell'accelerazione e il modulo della velocità angolare (applicando la formula (3), dove A_i assume, a seconda del caso, i valori del modulo dell'accelerazione o della velocità angolare, ed N = 100) assumevano in tale intervallo. In seguito, per ottenere un vettore di sei valori medi per ogni soggetto, e per le due tipologie di movimenti, è stato calcolato il valore medio dei valori medi di accelerazione e velocità angolare di tutte le finestre 1 non impulsive, il valore medio dei valori medi di accelerazione e velocità angolare di tutte le finestre 2 non impulsive e così via, facendo lo stesso anche per i movimenti impulsivi.

Inizialmente, si è scelto di considerare come impulsive le finestre 2, 3, 4 creando il "DATA SET 2.A"; mentre, in un secondo momento, per valutare se le performance

delle reti migliorassero, sono state considerate impulsive le finestre 2 e 3, creando il "DATA SET 2.B".

Prima di procedere alla fase di *training*, è stato calcolato il numero di finestre impulsive totali dei "DATA SET 2.A" e "DATA SET 2.B". In seguito, è stato considerato un egual numero di finestre non impulsive scelte in modo casuale tra tutti i soggetti e tutte le prove, andando a creare un set di dati ulteriormente ridotto, avendo l'accortezza di utilizzare un numero simile di finestre impulsive provenienti dalle tre configurazioni sperimentali ("DATA SET 3.A" e "DATA SET 3.B"). Di questi "DATA SET 3", l'80% è stato utilizzato per la fase di *training*, il restante 20% come *test set*. I vari passaggi delle modifiche al *data set* considerato, fin qui descritti, sono rappresentati graficamente in *Figura 3.4*.

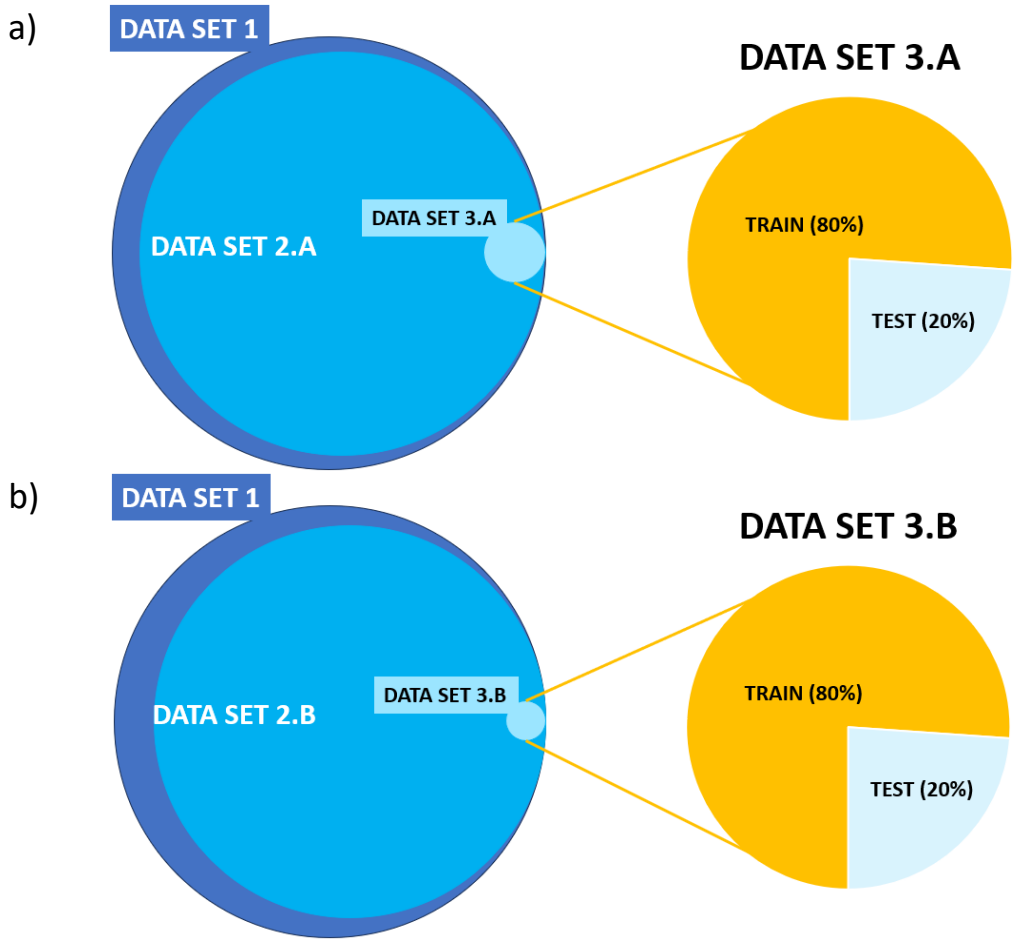

Figura 3.4: schematizzazione grafica (in proporzione) delle riduzioni del data set dovute alla scelta delle finestre impulsive dal "DATA SET 1" ai "DATA SET 3.A e 3.B". a) Finestre impulsive considerate: 2, 3 e 4. b) Finestre impulsive considerate: 2 e 3.

Come precedentemente anticipato, i dati del *training set* sono stati ulteriormente divisi in due sottogruppi per poter utilizzare il *five-fold cross validation*. Per far sì che la rete venisse allenata e poi validata su un egual numero di finestre impulsive e non impulsive di volta in volta, i dati sono stati organizzati alternando finestre non impulsive e finestre impulsive.

I vettori utilizzati per le varie fasi di *training*, *validation* e *test* sono caratterizzati di seguito:

- *TrainData*: è un vettore cella che contiene i dati dei 4/5 del *training set*, e su questo viene allenata la rete;
- *TrainLabel*: è un vettore di tipo categorico e contiene i label delle finestre contenute in *TrainData*;
- *ValidationData*: è un vettore cella che contiene i dati del gruppo k di turno, utilizzato per la validazione della rete;
- *ValidationLabel*: è un vettore di tipo categorico e contiene i label delle finestre contenute in *ValidationData;*
- *TestData*: è un vettore cella che contiene i dati non utilizzati nella fase di training ed è utilizzato per testare la rete;
- *TestLabel*: è un vettore di tipo categorico e contiene i label delle finestre contenute in *TestData.*

La creazione della rete può avvenire sia tramite un tool di Matlab®, il *Deep Network Designer*, come riportato nella documentazione di Matlab® (Create Simple Sequence Classification Network Using Deep Network Designer), sia tramite istruzioni nella *Command Window*. È stata scelta quest'ultima opzione ed è stata creata tramite i comandi riportati in *Figura 3.5*:

```
layers = [ ...
    sequenceInputLayer(inputSize)
    lstmLayer(numHiddenUnits,OutputMode="last")
    dropoutLayer(0.5)
    fullyConnectedLayer(numClasses)
    softmaxLayer
    classificationLayer];
```

Figura 3.5: istruzioni Matlab® per la creazione dei layer che costituiscono la rete.

I livelli da cui è costituita la rete sono sei:

- Il primo (*sequenceInputLayer)* immette i dati di sequenza o serie temporali con il numero di feature utili per la classificazione (*inputSize*);
- il livello denominato *lstmLayer* apprende le dipendenze a lungo termine tra le fasi temporali dei dati della sequenza ed è caratterizzato da *numHiddenUnits*, ossia il numero di unità nascoste, posto pari a 100;
- il *dropoutLayer*, in cui il *dropout* è stato posto pari a 0.5;
- un livello *fullyConnectedLayer*, in cui si definiscono il numero delle classi totali utilizzate per la classificazione (*numClasses*), pari a 2;
- il livello *softmaxLayer*;
- infine, il *classificationLayer*.

Per poter trovare la rete migliore e quali segnali fossero più utili per ottenere una buona classificazione sono state create quattro diverse reti, con specifiche differenti (in *Figura 3.6* sono riportate anche le opzioni per l'addestramento della rete nel caso specifico della Rete 4, ma per le altre reti sono state impostate in modo analogo, come spiegato di seguito):

1. **Rete 1**: con *inputSize* pari a 1, in cui sono dati in ingresso alla rete i soli valori di accelerazione. È caratterizzata da un *MaxEpochs* pari a 20;
2. **Rete 2**: con *inputSize* pari a 1, in cui sono dati in ingresso alla rete i soli valori di velocità angolare. È caratterizzata da un *MaxEpochs* pari a 20;
3. **Rete 3**: con *inputSize* pari a 1, in cui sono dati in ingresso alla rete i soli valori di velocità angolare. È caratterizzata da un *MaxEpochs* pari a 50;

4. **Rete 4:** con *inputSize* pari a 2, in quanto sono dati in ingresso alla rete i valori di accelerazione e velocità angolare. È caratterizzata da un *MaxEpochs* pari a 20.

Per ognuna delle quattro reti, un'opzione che è stata mantenuta fissa è il *MiniBatchSize*, posto pari a 27.

In *Figura 3.6* sono riportati tutti i comandi utilizzati per la creazione della Rete 4, le opzioni per il suo *training* ed il comando per il suo addestramento (*trainNetwotk*).

```
inputSize = 2;
numHiddenUnits = 100;
numClasses = 2;
miniBatchSize=27;


for k=1:5
    val_idx = idx_train_new((k-1)*n_el_k+1:(k-1)*n_el_k+n_el_k);
    train_idx = setdiff(idx_train_new,val_idx,'stable');
    TrainData = w_p_no_time(train_idx);
    ValidationData = w_p_no_time(val_idx);
    TrainLabel = categorical(label_new(train_idx));
    ValidationLabel = categorical(label_new(val_idx));

    layers = [ ...
        sequenceInputLayer(inputSize)
        lstmLayer(numHiddenUnits,OutputMode="last")
        dropoutLayer(0.5)
        fullyConnectedLayer(numClasses)
        softmaxLayer
        classificationLayer];


    miniBatchSize = 27;
    options = trainingOptions('adam', ...
    'ExecutionEnvironment','cpu', ...
    'MaxEpochs',20, ...
    'MiniBatchSize',miniBatchSize, ...
    'ValidationData',{ValidationData,ValidationLabel}, ...
    'GradientThreshold',2, ...
    'Shuffle','every-epoch', ...
    'Verbose',false, ...
    'Plots','training-progress');

    [net(k), info(k)] = trainNetwork(TrainData,TrainLabel,layers,options);
    val_acc(k)=info(k).FinalValidationAccuracy;

end
```

Figura 3.6: istruzioni Matlab® che sono servite per la creazione e il training con five-fold cross validation di una delle reti LSTM utilizzata e per la definizione delle opzioni di addestramento. Le altre reti sono state create in modo analogo, variando i valori di alcuni dei parametri, quali inputSize e MaxEpochs.

Successivamente all'addestramento di ogni rete, si è proceduto al *test*, utilizzando il 20% dei "DATA SET 3", contenuto in *TestData*, come spiegato precedentemente, tramite il comando *classify* (*Figura 3.7*).

```
[YPred, scores] = classify(net_LSTM,TestData,'MiniBatchSize',miniBatchSize);
```

Figura 3.7: istruzione Matlab® per la classificazione del test set, in cui net_LSTM è la rete che, a seguito del training effettuato col five-fold cross validation, ha ottenuto l'accuratezza migliore.

Il vettore *YPred* è un vettore di tipo categorico che contiene i valori predetti delle classi di appartenenza dei dati di test, sconosciuti alla rete addestrata; mentre *scores* è una matrice con lo stesso numero di righe di *YPred* e un numero di colonne pari al numero di classi possibili (2), in cui sono salvati i punteggi percentuali con cui la rete predice la classe: se nella prima colonna lo *score* è maggiore di 0.5 il valore di *YPred* è posto pari a 0 (movimento non impulsivo); al contrario, se lo *score* della seconda colonna è maggiore di 0.5, *YPred* è categorizzato come 1 (movimento impulsivo).

Tramite il confronto dei risultati ottenuti con *YPred* e le vere *label* presenti in *TestLabel* è stata costruita la *confusion matrix*, uno strumento utile per la valutazione delle performance dei modelli di classificazione. Poiché le classi possibili, in questo caso, erano due (0 e 1), tale matrice ha dimensioni 2x2. In particolare, le righe sono rappresentative delle classi effettive, viceversa, le colonne rappresentano le classi predette. In riferimento alla *Figura 3.8*, si definisce il significato del contenuto di ogni riquadro:

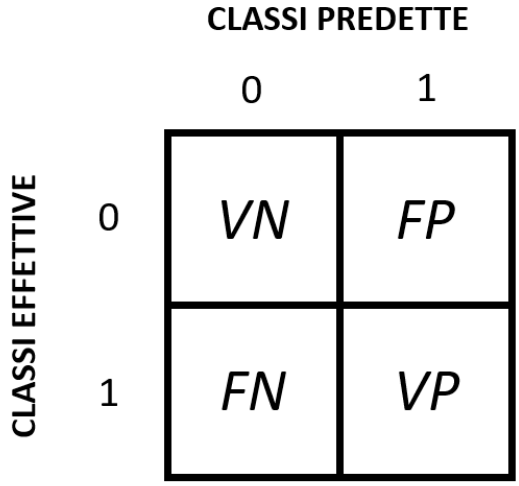

Figura 3.8: organizzazione della confusion matrix.

- *VN* (Veri Negativi) rappresenta il numero di finestre appartenenti a movimenti non impulsivi che sono state classificate nel modo corretto;
- *FP* (Falsi Positivi): rappresenta il numero di finestre che, pur appartenendo a movimenti non impulsivi, sono state classificate erroneamente come impulsive;
- *FN* (Falsi Negativi): rappresenta il numero di finestre che, pur appartenendo a movimenti impulsivi, sono state classificate come non impulsive;
- *VP* (Veri Positivi): rappresenta il numero di finestre appartenenti a movimenti impulsivi che sono state classificate nel modo corretto.

Grazie a tali valori, sono state valutate le performance dei quattro modelli sviluppati per il riconoscimento dei movimenti impulsivi tramite cinque indicatori:

- Accuratezza: indica il numero di corretti classificati rispetto al numero totale di osservazioni (formula (6)):

$$Accuratezza_{\%} = \frac{VN+VP}{VN+FP+FN+VP} \times 100 \qquad (6)$$

- Precisione: indica il numero di finestre impulsive correttamente classificate rispetto al numero totale di finestre che la rete ha classificato come impulsive (formula (7)):

$$Precisione_{\%} = \frac{VP}{FP+VP} \times 100 \qquad (7)$$

- Recall: indica il numero delle finestre impulsive classificate correttamente rispetto al numero totale delle finestre effettivamente impulsive (formula (8)):

$$Recall_{\%} = \frac{VP}{FN+VP} \times 100 \qquad (8)$$

- F1 Score: è un indicatore calcolato a partire da precisione e recall (formula (9)):

$$F1\ Score_{\%} = 2 \times \frac{Precisione \times Recall}{Precisione+Recall} \times 100 \quad (9)$$

- Specificità: indica il numero di finestre non impulsive che la rete ha classificato correttamente rispetto al numero totale delle effettive finestre non impulsive (formula (10)):

$$Specificità_{\%} = \frac{VN}{VN+FP} \times 100 \qquad (10)$$

Infine, è stato svolto il *test* su tutto il "DATA SET 2.A" e "DATA SET 2.B", privato dell'80% del "DATA SET 3.A" e "DATA SET3.B", rispettivamente, includendo, quindi, tutte le finestre impulsive e non impulsive non incluse nel *training* delle reti sviluppate, per simularne le performance in situazioni reali, in cui l'eventualità che si verifichi un movimento impulsivo è ridotta rispetto ai compiti che l'operatore deve compiere durante il normale svolgimento dell'attività lavorativa.

3.6 Overlap

Un ultimo passaggio è stato effettuato per avvicinarsi quanto più possibile all'acquisizione dei dati in tempo reale, per una futura applicazione in ambito industriale. Oltre ad aver suddiviso i segnali in finestre da 0.5 s, è stata prevista la possibilità di utilizzare un *overlap*, ossia una sovrapposizione, tra finestre successive, procedendo di campione in campione sul segnale.

A tal proposito, si è ancora ad una fase preliminare, in quanto l'attenzione si è concentrata sui soli movimenti impulsivi. Si è proceduto con le seguenti due fasi:

1. dal DATA SET 1 sono state isolate le finestre 1 e 2 di tutti i movimenti impulsivi, per ogni soggetto e prova. È stato modificato il valore *label* delle finestre 1 da 1 a 0 (in quanto in realtà nel lasso di tempo che intercorreva tra 0 e 0.5 s l'attivazione del LED rosso non era ancora avvenuta), mentre per le finestre 2 è rimasto pari a 1. I dati relativi ad accelerazione e velocità angolare delle finestre isolate sono stati fatti classificare dalla rete che in fase di *training* ha ottenuto l'accuratezza maggiore. In particolare, la Rete 4, con input accelerazione e velocità angolare, allenata considerando come impulsive le finestre 2 e 3. È stato poi verificato che le finestre 1 e 2, a coppie, fossero state classificate nel modo corretto, ossia finestra 1 con *label* = 0 e finestra 2 con *label* = 1. Tutte le coppie che, invece, non sono state classificate in tal modo sono state scartate dalla fase successiva.
2. Ogni coppia di finestre correttamente classificata è stata unita a formare un unico segnale della durata totale di 1 s (200 campioni). Si è proceduto, quindi, alla classificazione di tali segnali, considerando di volta in volta, come inizio della porzione da classificare (della durata prefissata di 0.5 s), il campione successivo a quella classificata precedentemente, senza, però, ripetere la classificazione sulle finestre 1 e 2 (classificate nella fase 1). Sono stati, dunque, ottenuti i valori delle classi predette dalla rete e gli scores per ognuna delle coppie (come descritto in precedenza in questo capitolo).

Infine, è stato identificato, mediamente, il valore dell'indice corrispondente alla fine della prima finestra mobile di 0.5 s che serviva alla rete per identificare stabilmente quando si trovava di fronte ad un movimento impulsivo.

4. RISULTATI

4.1 Analisi dell'accelerazione

Di seguito, si riporta in *Tabella 4.1*, la variabilità dei movimenti non impulsivi ed impulsivi nelle tre prove, tramite il calcolo del valor medio e della deviazione standard dei valori 'RMS mat', calcolati per finestre temporali di 3 s.

	PROVA					
	FR r		FR l		LA l	
	Non impulsivi	Impulsivi	Non impulsivi	Impulsivi	Non impulsivi	Impulsivi
MEDIA ± STD $(^{m}/_{s^2})$	1,88 ± 0,44	5,25 ± 1,25	1,85 ± 0,36	4,94 ± 1,29	1,75 ± 0,33	4,71 ± 1,18

Tabella 4.1: valor medio ± deviazione standard dei valori 'RMS mat' dei movimenti suddivisi in non Impulsivi e impulsivi per le tre prove eseguite dai 61 soggetti.

4.2 Suddivisione del segnale in finestre da 0.5 s

A titolo esemplificativo, in *Figura 4.1*, è riportato il grafico relativo al soggetto 3, prova FR_r, per mostrare la suddivisione in finestre da 0.5 s dei segnali (norma) accelerazione e velocità angolare, insieme alle attivazioni dei LED verdi e rossi/*buzzer*.

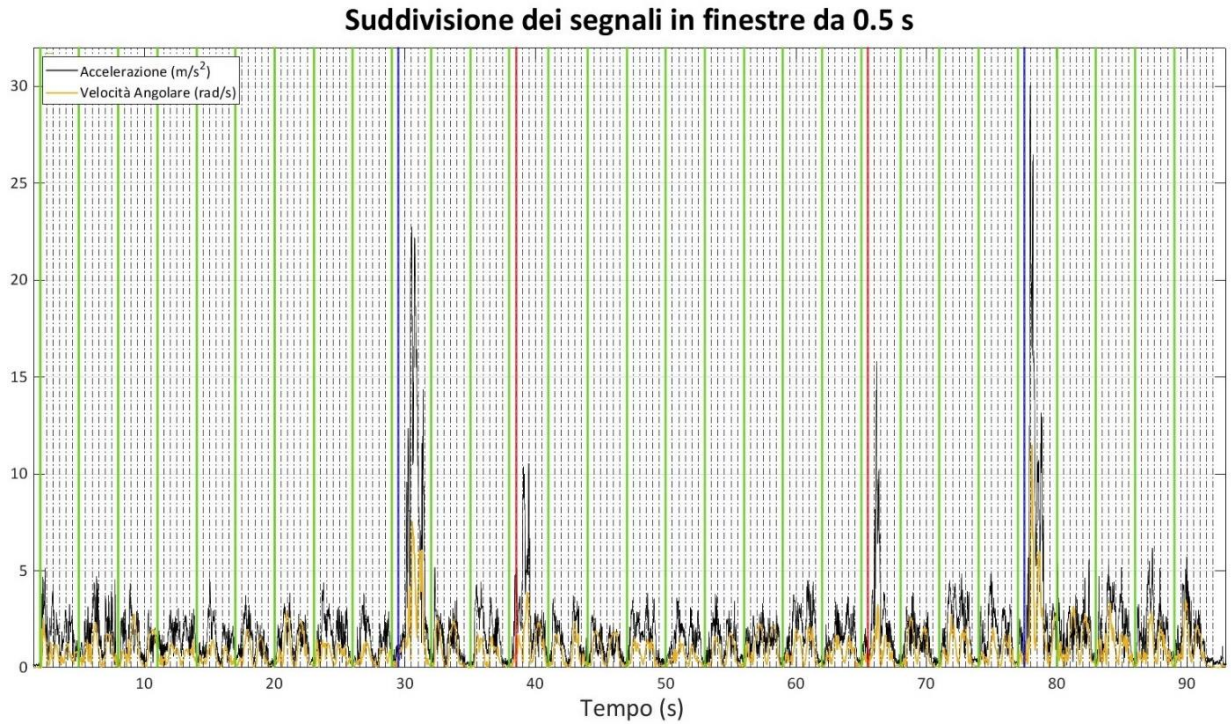

Figura 4.1: esempio di suddivisione dei segnali con finestre da 0.5 s (linee verticali tratteggiate). In nero è riportato il segnale norma dell'accelerazione, in giallo il segnale norma della velocità angolare. Le linee verdi verticali corrispondono alle attivazioni dei LED verdi, quelle rosse alle attivazioni dei LED rossi e quelle blu all'attivazione dei segnali acustici.

Di seguito, in *Figura 4.2*, sono riportati i grafici ottenuti per le tre prove, calcolando la media complessiva, per finestre da 0.5 s, dell'accelerazione e della velocità angolare:

a)

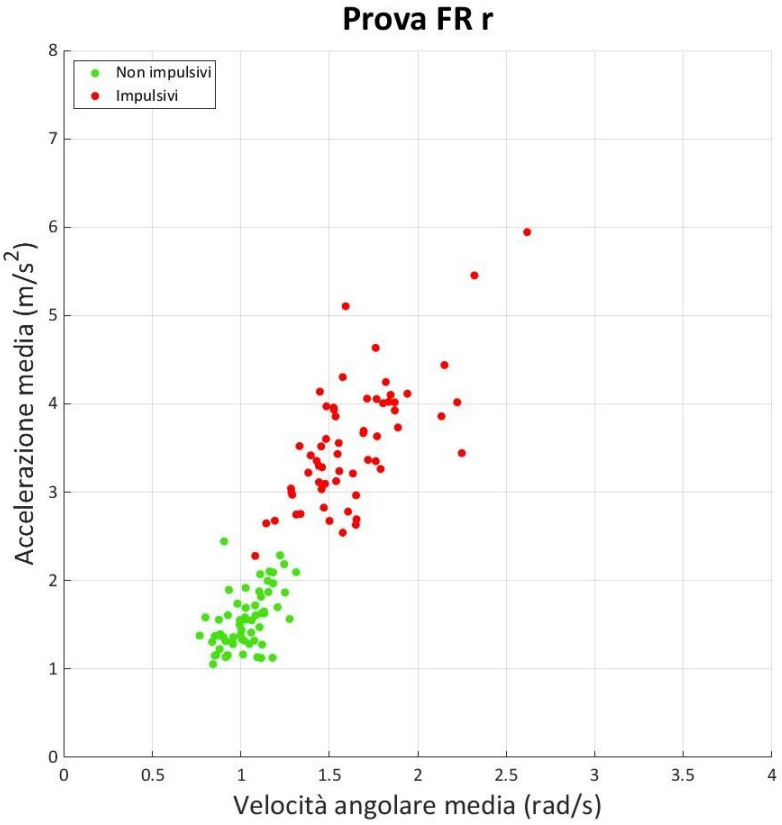
Prova FR r
Non impulsivi
Impulsivi
Accelerazione media (m/s^2)
Velocità angolare media (rad/s)
0
0.5
1
1.5
2
2.5
3
3.5
4
1
2
3
4
5
6
7
8

b)

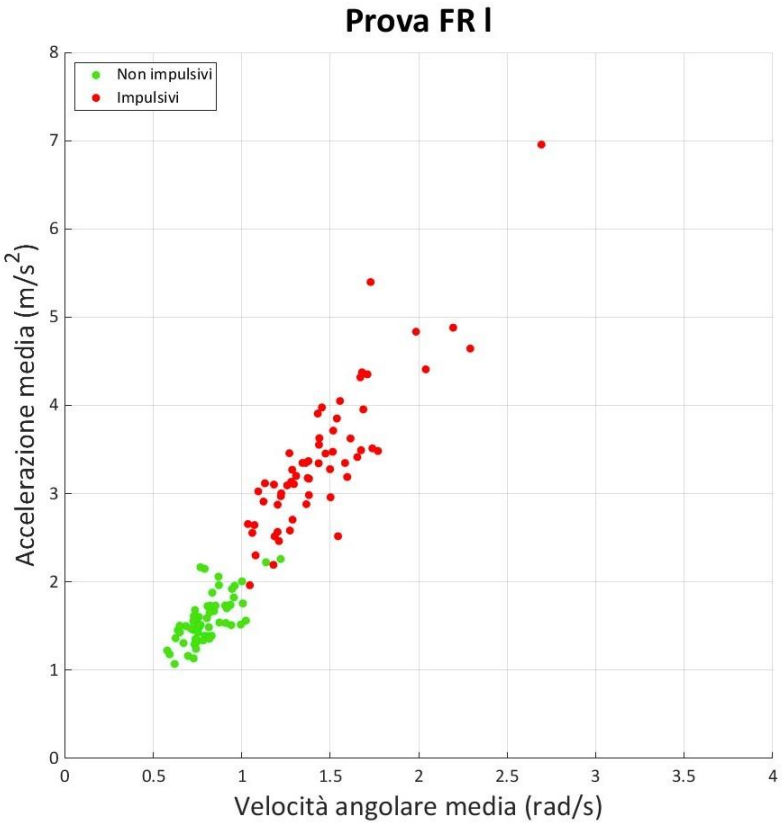
Prova FR l
Non impulsivi
Impulsivi
Accelerazione media (m/s^2)
Velocità angolare media (rad/s)
0
0.5
1
1.5
2
2.5
3
3.5
4
1
2
3
4
5
6
7
8

c)

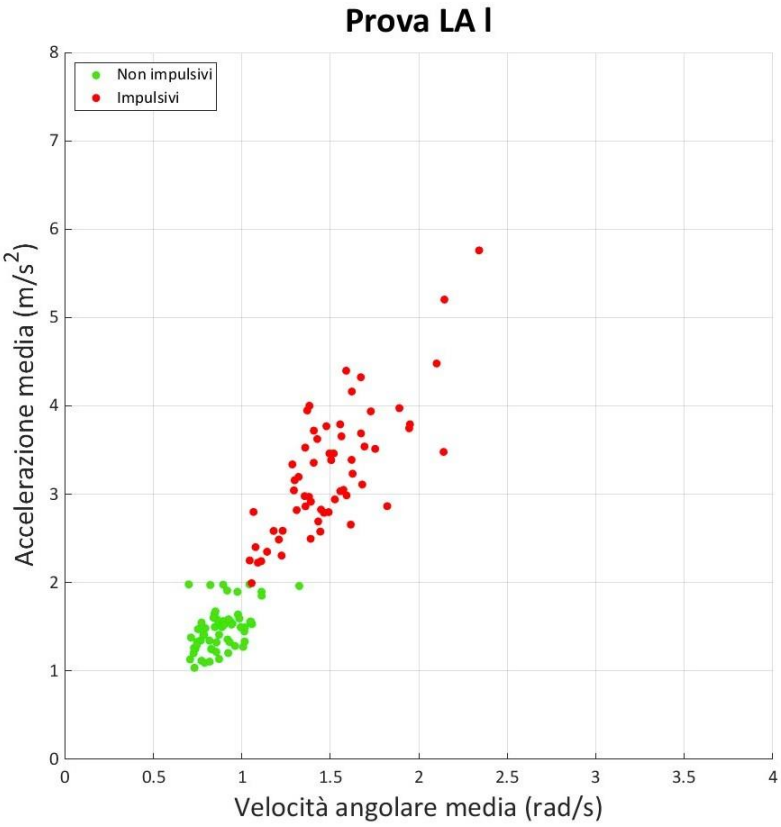

Figura 4.2: distribuzioni dei valori medi complessivi di accelerazione (asse y) e velocità angolare (asse x) per finestre da 0.5 s. a) Prova FR_r, b) Prova FR_l, c) Prova LA_l. In verde sono riportati i valori dei movimenti non impulsivi, in rosso i valori dei movimenti impulsivi.

È riportata, inoltre, la *Tabella 4.2* che riassume i *p-value* ottenuti col test non parametrico di Wilcoxon confrontando i movimenti non impulsivi e impulsivi, per tutte e tre le prove:

	Non Impulsivi vs Impulsivi	
	Accelerazione media	**Velocità angolare media**
	p-value	*p-value*
Prova FR r	1,84E-21	1,42E-20
Prova FR l	2,59E-21	4,90E-21
Prova LA l	1,67E-21	8,35E-21

Tabella 4.2: p-value ottenuti con il test di Wilcoxon, confrontando i valori di accelerazione media e velocità angolare media dei movimenti non impulsivi e impulsivi.

Successivamente, i movimenti impulsivi sono stati suddivisi in visivi e sonori, anche in questo caso sono state calcolate le medie, ed è stato effettuato il test di Wilcoxon per verificare se ci fossero ancora differenze statisticamente significative tra movimenti non impulsivi e impulsivi visivi, tra non impulsivi e impulsivi sonori, e tra impulsivi visivi e impulsivi sonori. I grafici delle tre prove sono riportati in *Figura 4.3*:

a)

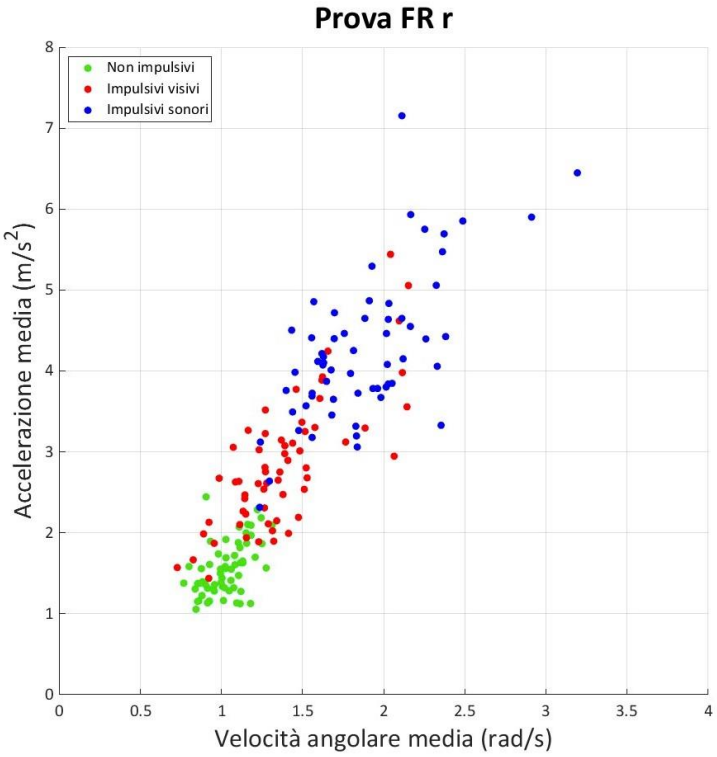

b)

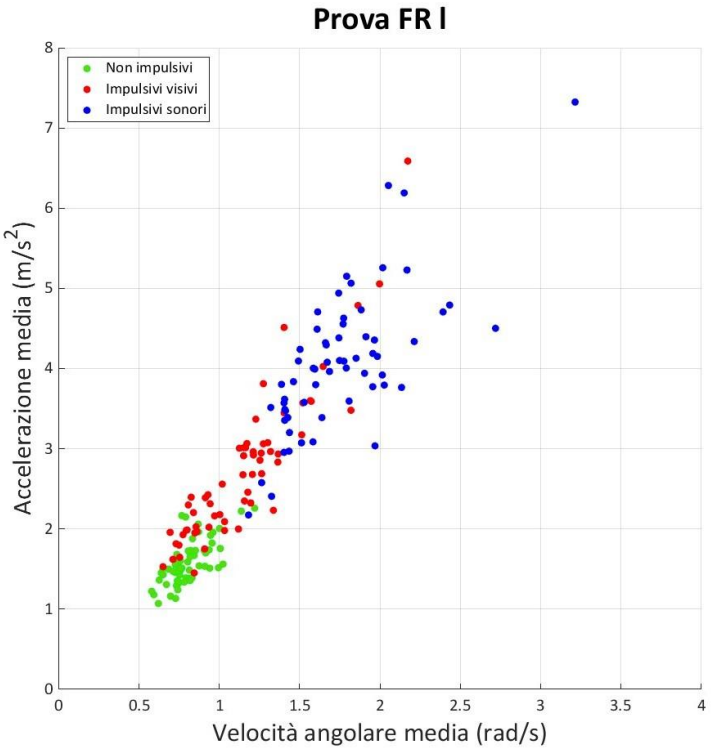

c)

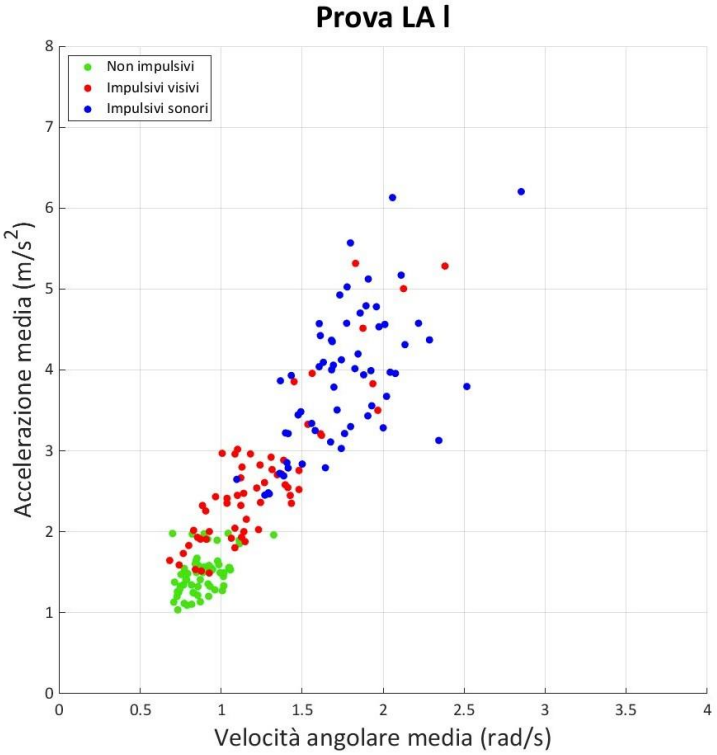

Figura 4.3: distribuzioni dei valori medi complessivi di accelerazione (asse y) e velocità angolare (asse x) per finestre da 0.5 s. a) Prova FR_r, b) Prova FR_l, c) Prova LA_l. In verde sono riportati i valori dei movimenti non impulsivi, in rosso i valori dei movimenti impulsivi dovuti all'accensione dei LED rossi, in blu i valori dei movimenti impulsivi dovuti all'attivazione del buzzer.

Mentre i risultati del test di Wilcoxon dei vari confronti, prima esplicitati, sono riportati in *Tabella 4.3*:

a)

	Non Impulsivi vs Impulsivi Visivi	
	Accelerazione media	**Velocità angolare media**
	p-value	*p-value*
Prova FR r	4,17E-18	7,07E-12
Prova FR l	4,76E-17	9,02E-11
Prova LA l	4,36E-18	5,99E-11

b)

	Non Impulsivi vs Impulsivi Sonori	
	Accelerazione media	**Velocità angolare media**
	p-value	*p-value*
Prova FR r	1,75E-21	2,59E-21
Prova FR l	1,84E-21	1,75E-21
Prova LA l	1,67E-21	2,24E-21

c)

	Impulsivi Visivi vs Impulsivi Sonori	
	Accelerazione media	**Velocità angolare media**
	p-value	*p-value*
Prova FR r	7,67E-14	1,29E-11
Prova FR l	4,48E-13	4,35E-15
Prova LA l	2,97E-12	1,48E-12

Tabella 4.3: p-value ottenuti con il test di Wilcoxon, confrontando i valori di accelerazione media e velocità angolare media di a) movimenti non impulsivi e movimenti impulsivi dovuti all'accensione dei LED rossi, b) movimenti non impulsivi e movimenti impulsivi dovuti all'attivazione del buzzer, c) movimenti impulsivi dovuti all'accensione dei LED rossi e movimenti impulsivi dovuti all'attivazione del buzzer.

Come anticipato nel capitolo 3, i vari movimenti sono stati suddivisi in base alla direzione indicata dal LED (*Figura 2.1*) in AP, OB, ML, V e, nel caso di attivazione del *buzzer* per gli impulsivi, anche in SONORO.

Dapprima, in *Figura 4.4,* si riportano i grafici complessivi risultanti per i soli movimenti non impulsivi (della prova FR_r) e per una sola finestra da 0.5 s, in cui la curva centrale rappresenta la media, istante per istante, dei segnali medi di accelerazione e velocità angolare ottenuti dall'analisi intra-soggetto e i bordi

rappresentano la deviazione standard calcolata istante per istante degli stessi segnali medi ottenuti dall'analisi intra-soggetto, ottenendo, quindi, risultati inter-soggetto.

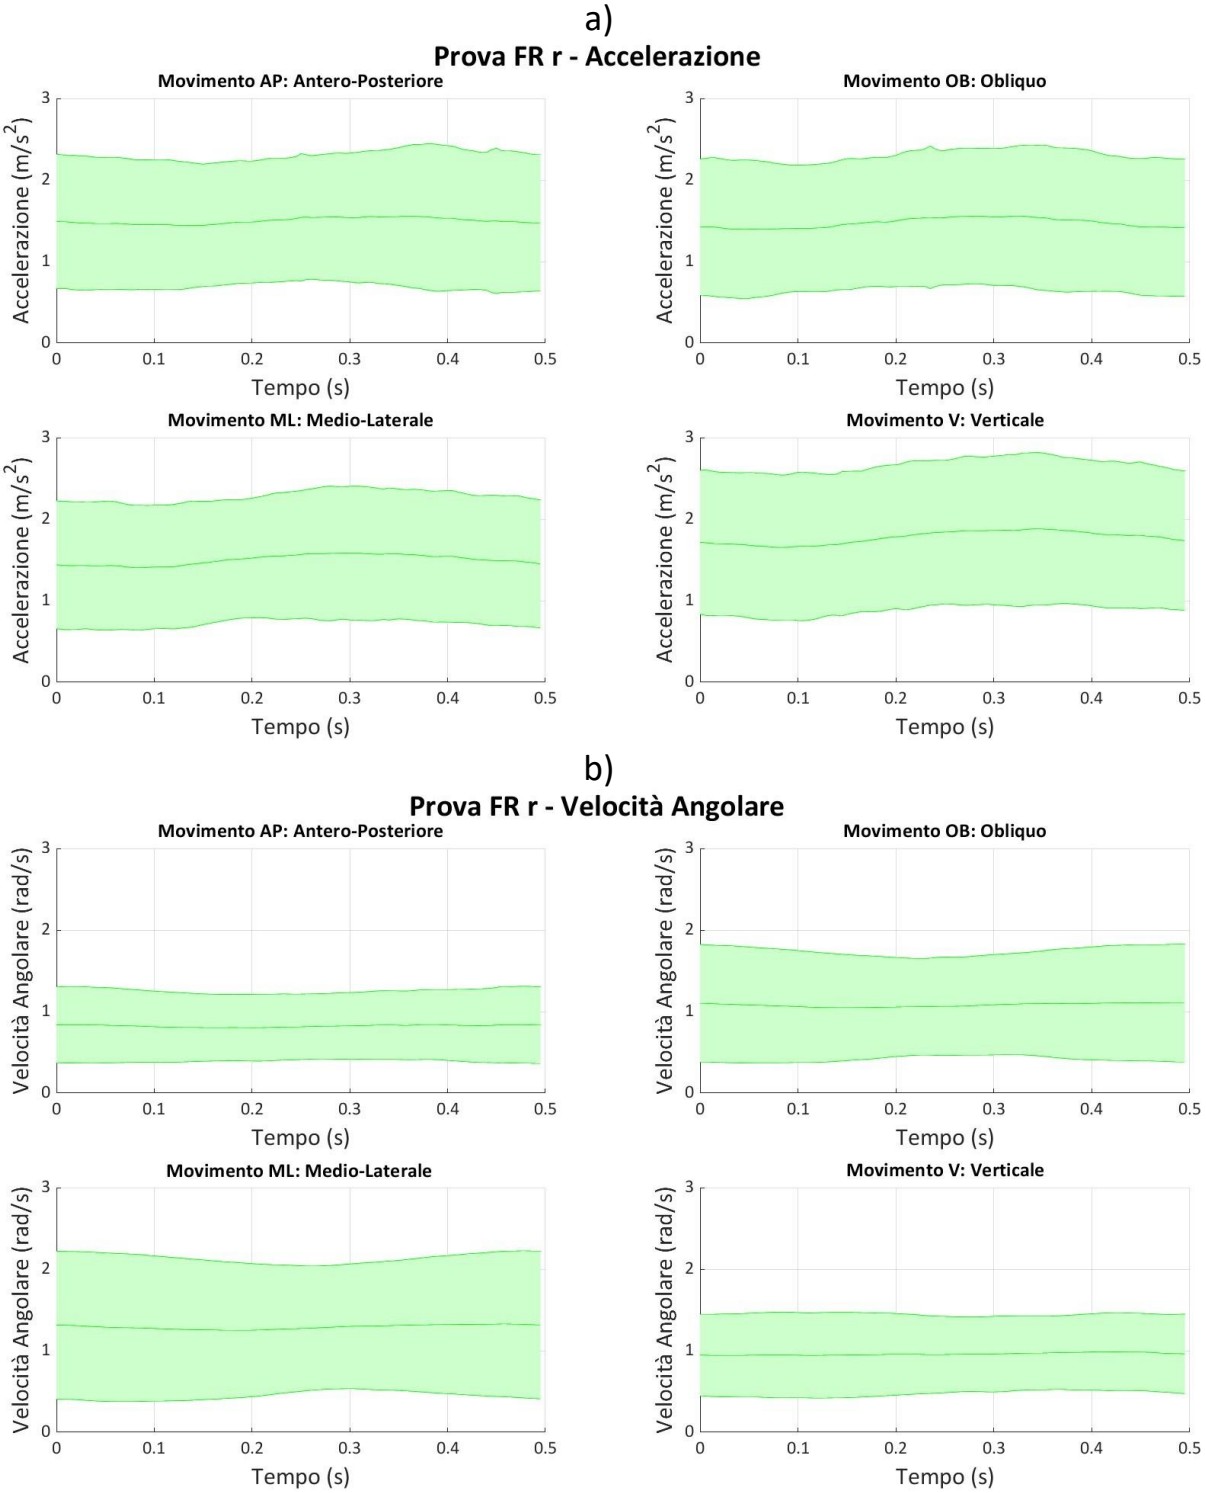

Figura 4.4: boundlines complessive della prova FR_r per una finestra da 0.5 s. a) Risultati per il segnale dell'accelerazione, b) risultati per il segnale della velocità angolare.

Successivamente, è stata condotta un'analisi simile, ma per le sei finestre suddivise come descritto nel paragrafo 3.4, sovrapponendo i segnali dei movimenti impulsivi e non impulsivi. In questo caso, si riportano in *Figura 4.5* i grafici relativi al segnale accelerazione della prova FR_r.

a)

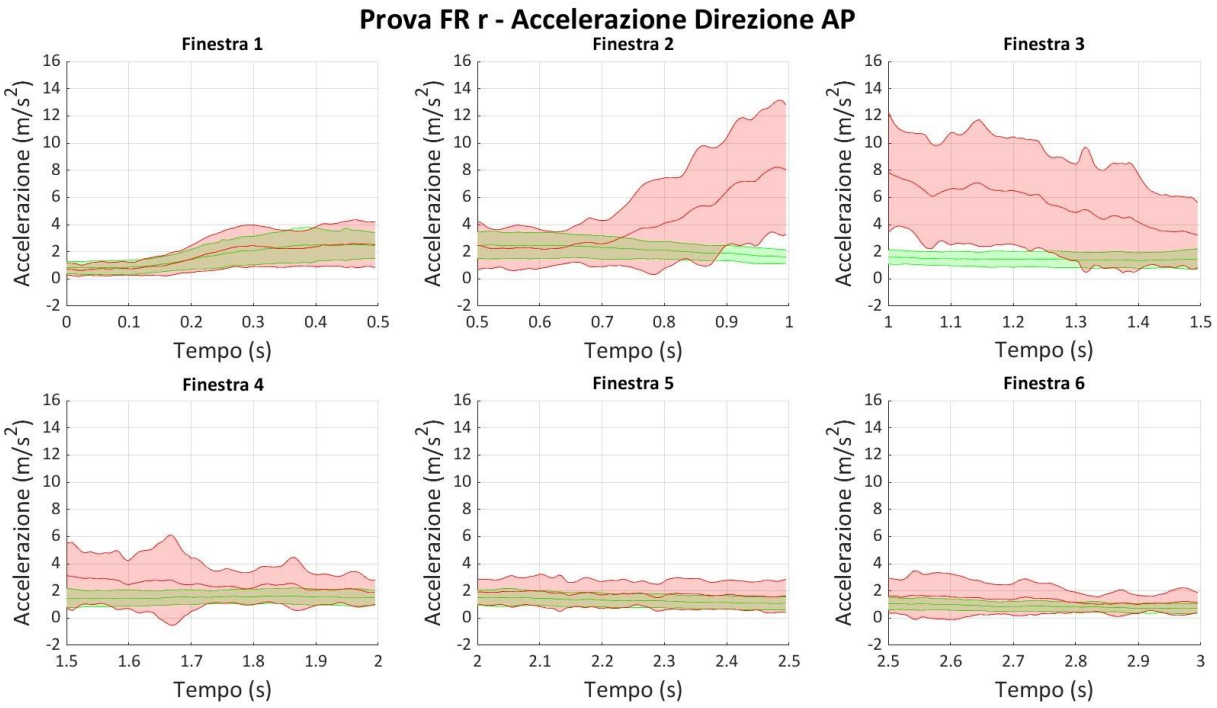

b)

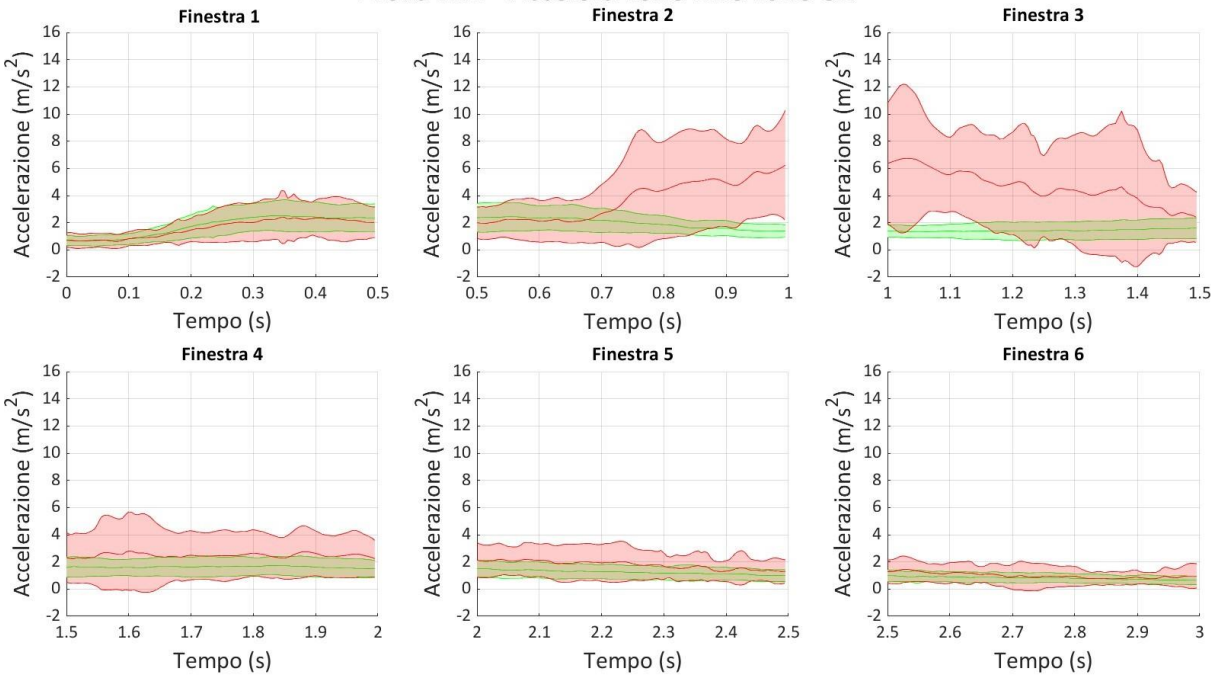

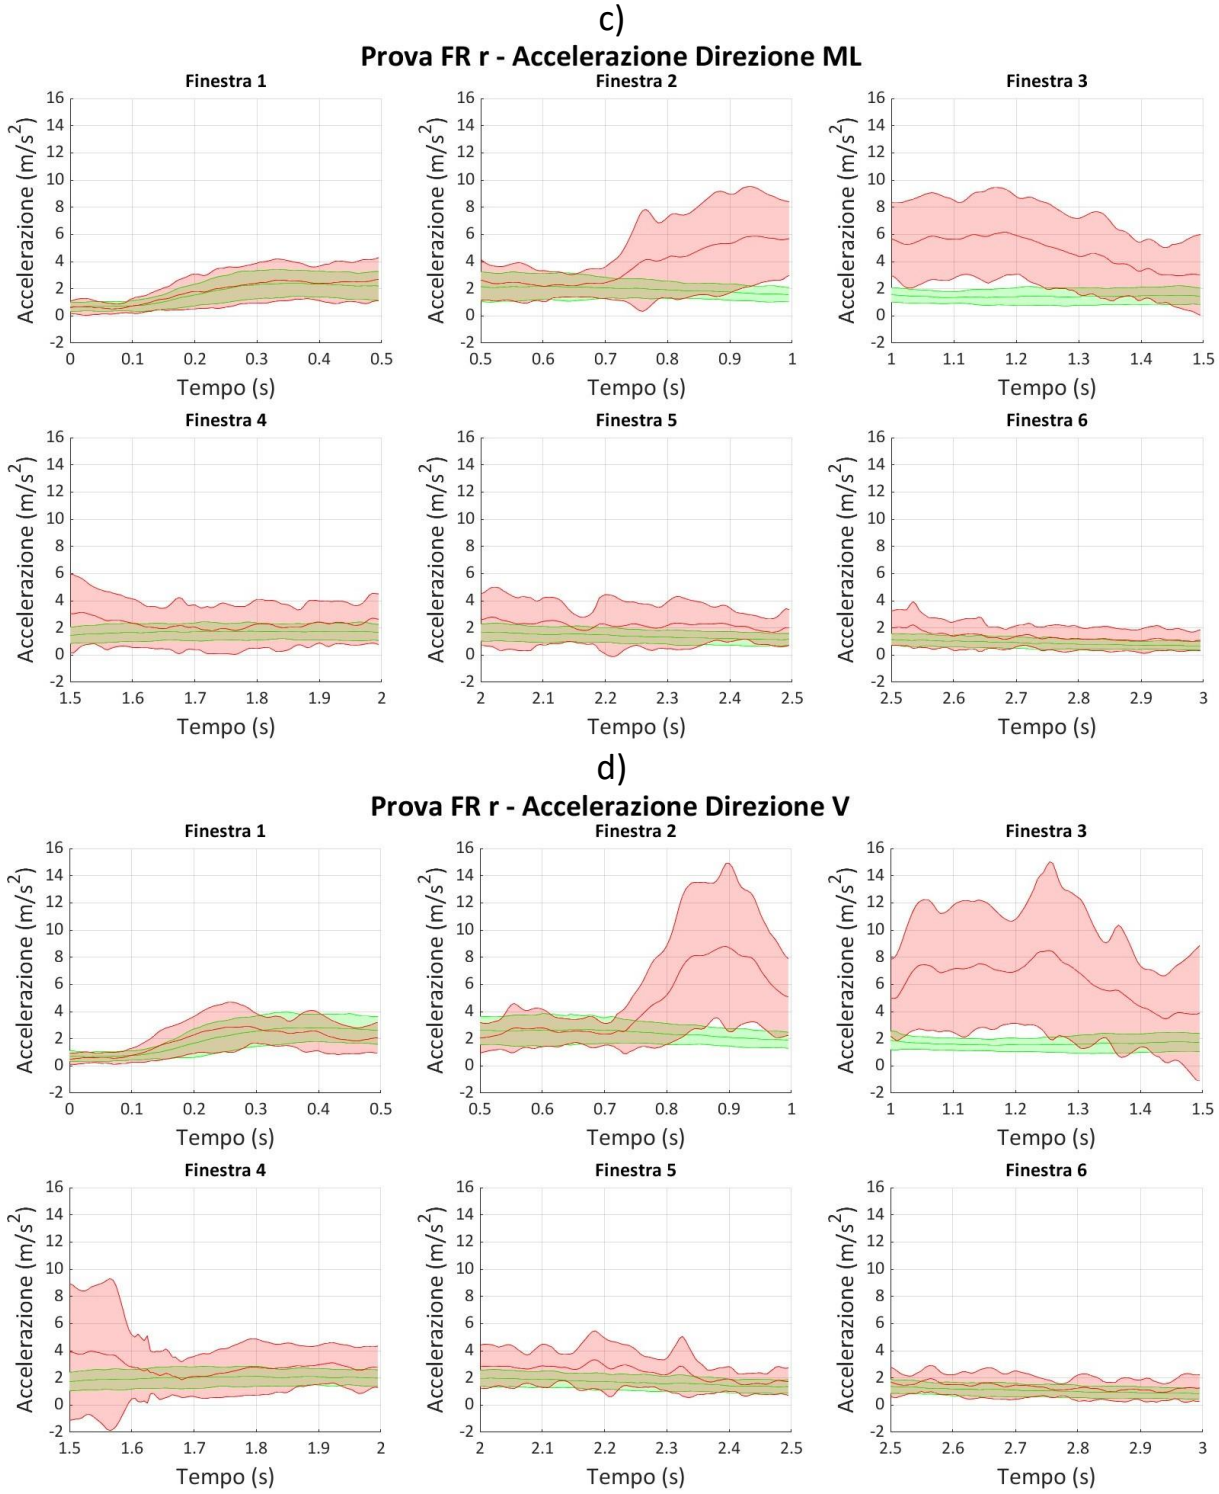

Figura 4.5: boundlines per il segnale accelerazione della prova FR_r con movimenti non impulsivi (in verde) e movimenti impulsivi (in rosso) sovrapposti per le differenti direzioni dei movimenti. a) Direzione AP, b) Direzione OB, c) Direzione ML, d) Direzione V.

Si riporta, infine, lo stesso tipo di grafico del segnale accelerazione su sei finestre ottenuto per i movimenti impulsivi avvenuti a seguito dell'attivazione del *buzzer*, durante la prova FR_r (*Figura 4.6*):

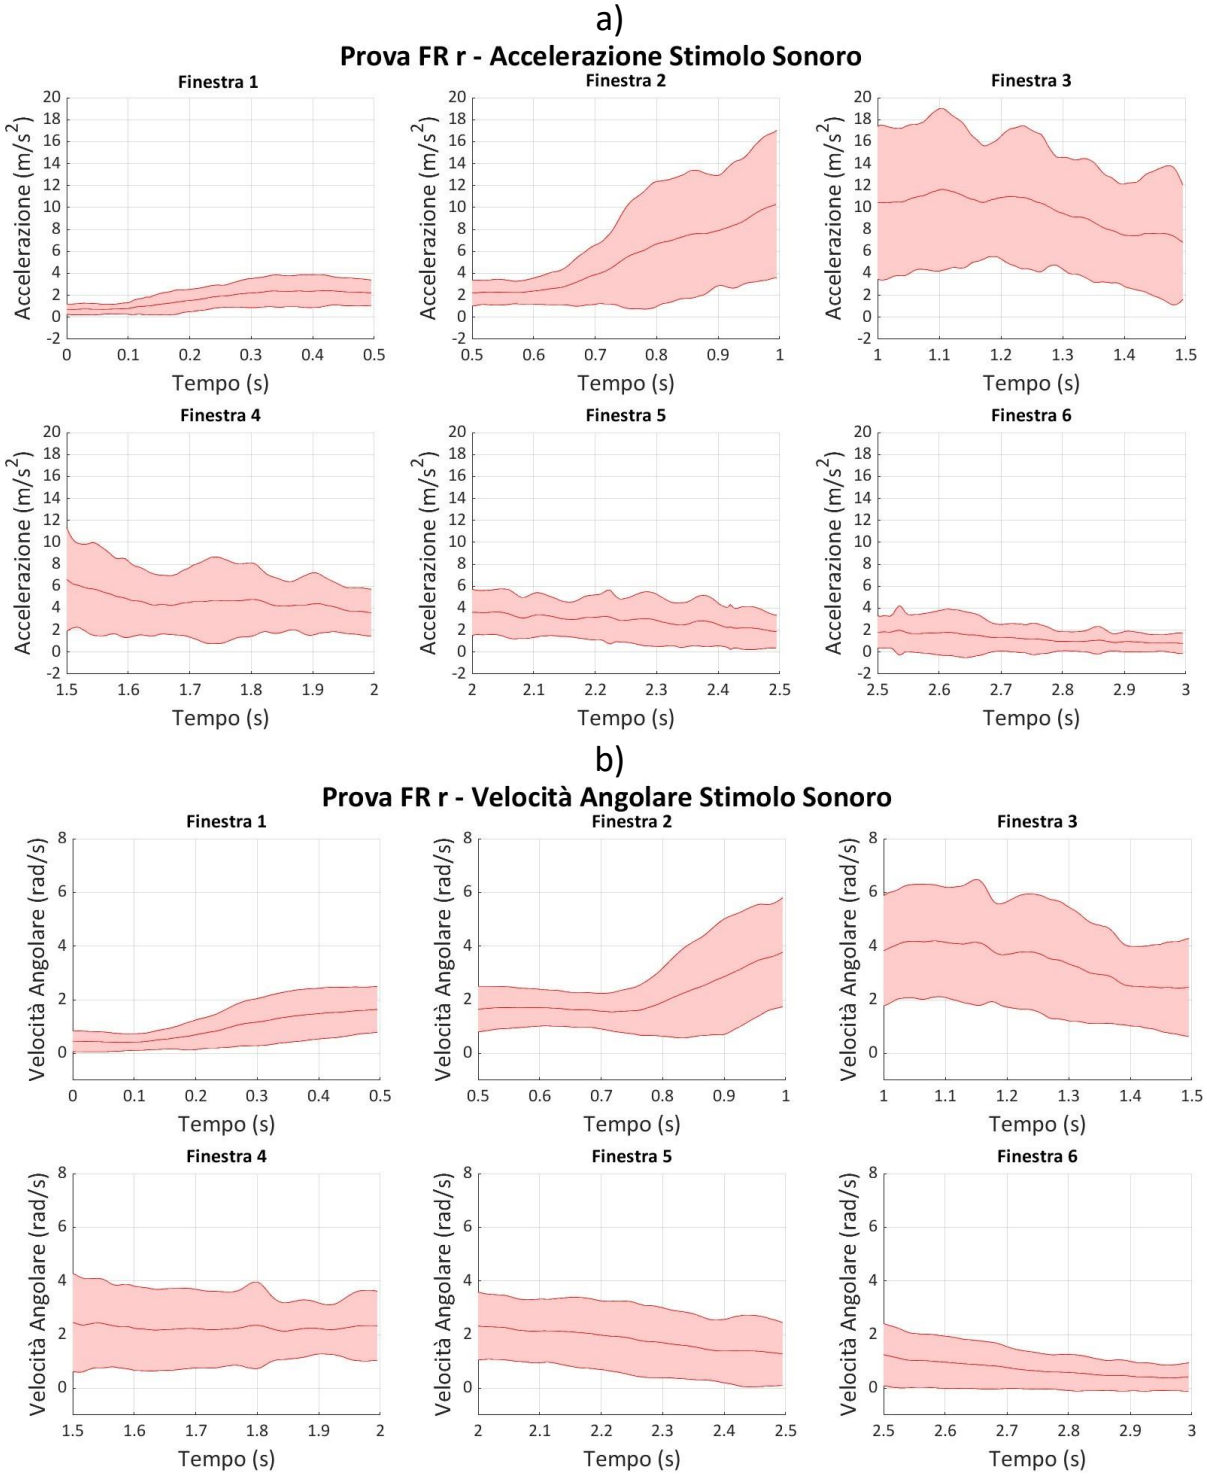

Figura 4.6: boundlines della prova FR_r con movimenti impulsivi dovuti all'attivazione del buzzer. a) Segnale accelerazione; b) Segnale velocità angolare.

4.3 Deep Learning

In *Figura 4.7* sono riportati i valori medi di accelerazione (sull'asse y) e i valori medi della velocità angolare (asse x) distinguendo le sei finestre in cui è divisibile ogni movimento da 3 s.

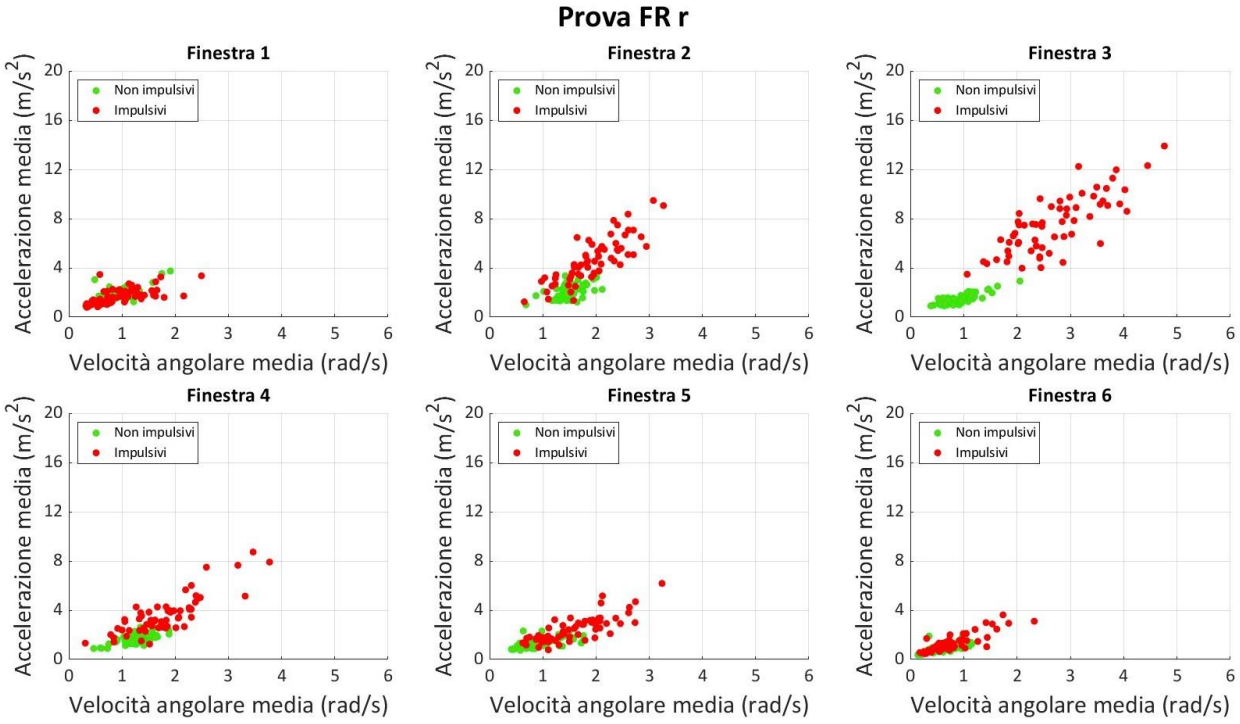

Figura 4.7: distribuzione dei valori medi di accelerazione e velocità angolare, per la prova FR_r, a seconda della finestra da 0.5 s inclusa all'interno di un movimento da 3 s.

I risultati, per la prova FR_r, dell'analisi statistica (*Tabella 4.4*) e dei box plot (*Figura 4.8*), ottenuti utilizzando gli stessi dati diagrammati in *Figura 4.7*, per scegliere quali finestre considerare impulsive per l'addestramento delle reti sono riportati di seguito.

	Accelerazione media	Velocità angolare media
	p-value	*p-value*
FINESTRA 1	0,6086	0,7900
FINESTRA 2	2,08E-15	1,49E-07
FINESTRA 3	1,67E-21	1,35E-20
FINESTRA 4	1,69E-15	1,67E-07
FINESTRA 5	5,41E-11	6,57E-09
FINESTRA 6	0,0046	0,0581

Tabella 4.4: p-value ottenuti con il test di Wilcoxon, confrontando i valori di accelerazione media e velocità angolare media dei movimenti non impulsivi e dei movimenti impulsivi per la prova FR_r.

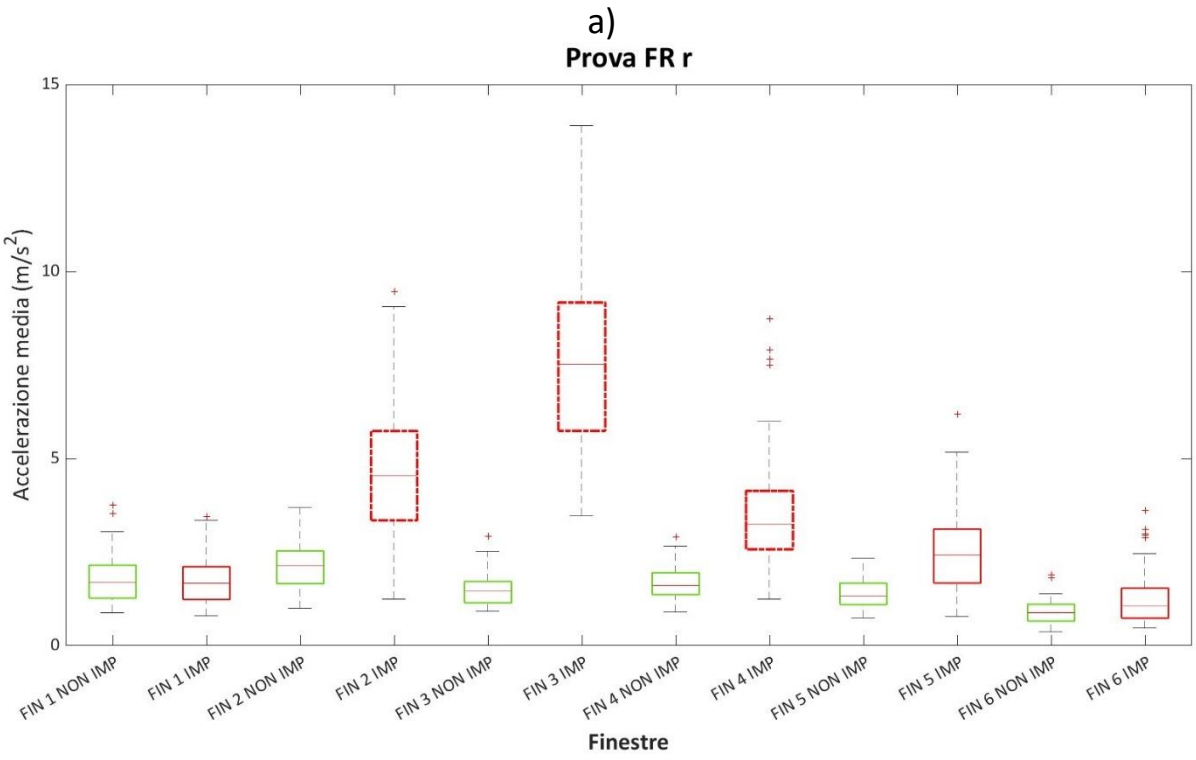

b)

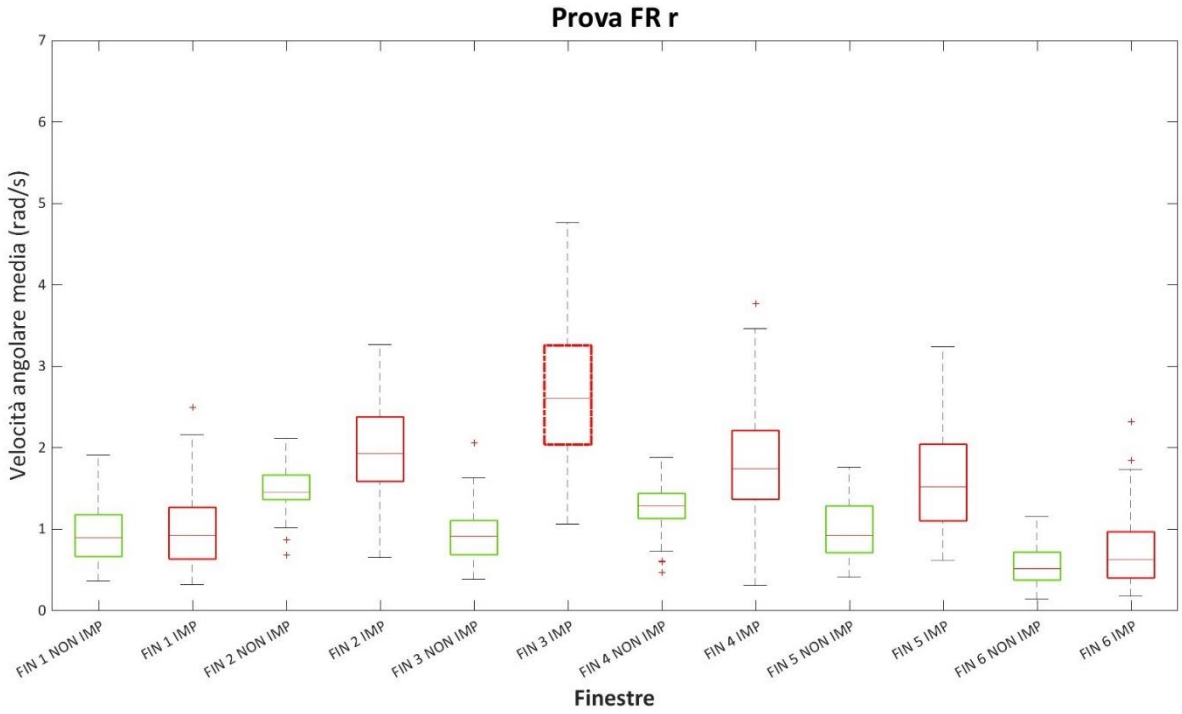

Figura 4.8: box plot dei valori medi a) dell'accelerazione e b) della velocità angolare, entrambi per la prova FR_r.

I grafici e le tabelle omessi in questa prima parte del capitolo sono riportati in Appendice A.

In *Figura 4.9* è presentata la numerosità del "DATA SET 3.A" (valida per l'addestramento di tutte le reti create) in termini di finestre non impulsive e impulsive, suddividendo in *training set* (a sua volta suddiviso in *training* effettivo e *validation*) e *test set*:

Totale finestre impulsive: 2196

Totale finestre: 4392 (2196 IMP + 2196 NON IMP)

TRAINING SET: 3510

- ❖Training effettivo: 2808 (1404 IMP + 1404 NON IMP)
- ❖Validation (ogni gruppo 'k'): 702 (351 IMP + 351 NON IMP)

TEST SET: 882 (441 IMP + 441 NON IMP)

Figura 4.9: numero di finestre considerate nel DATA SET 3.A, considerando come impulsive le finestre 2,3,4.

Nella *Figura 4.10* è riportata la *confusion matrix* risultante dal *test* utilizzando la **Rete 1** e le relative *performance* in termini di accuratezza, precisione, recall, F1 score e specificità. In particolare, è stata utilizzata la rete che, durante la fase di addestramento, ha ottenuto l'accuratezza migliore (in questo caso pari a 84,62%).

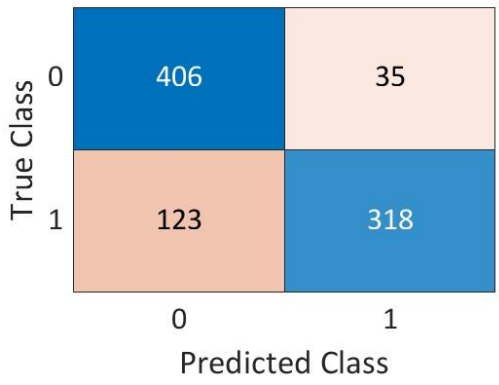

a)

$$\textbf{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \textbf{82,09\%}$$

$$\textbf{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \textbf{90,08\%}$$

$$\textbf{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \textbf{72,11\%}$$

$$\textbf{F1 Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \textbf{80,10\%}$$

$$\textbf{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \textbf{92,06\%}$$

b)

Figura 4.10: a) confusion matrix; b) performance della Rete 1, utilizzando il "DATA SET 3.A".

In *Figura 4.11*, analogamente alla *Figura 4.10*, sono riportati i risultati della **Rete 2**. In particolare, è stata utilizzata la rete che, durante la fase di addestramento, ha ottenuto l'accuratezza migliore (in questo caso pari a 78,49%):

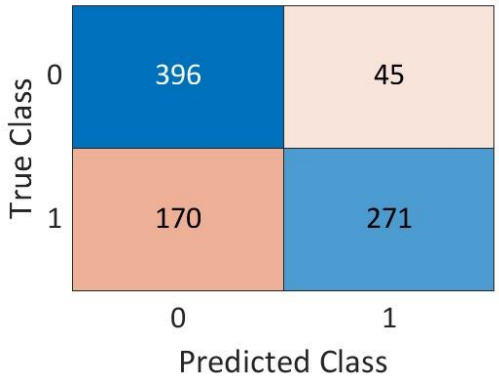

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{75{,}62\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{85{,}76\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{61{,}45\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{71{,}60\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{89{,}80\%}$$

b)

Figura 4.11: a) confusion matrix; b) performance della Rete 2, utilizzando il "DATA SET 3.A".

Lo stesso tipo di risultati viene riportato in *Figura 4.12* per la **Rete 3**. In particolare, è stata utilizzata la rete che, durante la fase di addestramento, ha ottenuto l'accuratezza migliore (in questo caso pari a 80,34%):

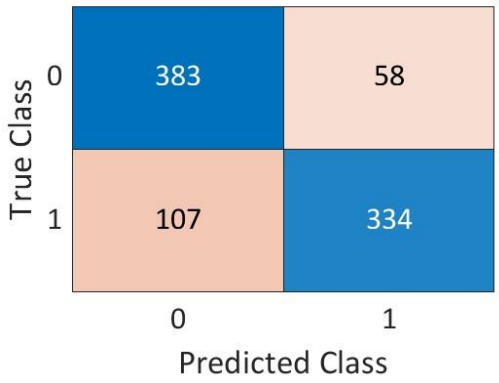

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{81{,}29\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{85{,}20\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{75{,}74\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{80{,}19\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{86{,}85\%}$$

b)

Figura 4.12: a) confusion matrix; b) performance della Rete 3, utilizzando il "DATA SET 3.A".

E, infine, per la **Rete 4** (*Figura 4.13*). In particolare, è stata utilizzata la rete che, durante la fase di addestramento, ha ottenuto l'accuratezza migliore (in questo caso pari a 86,04%):

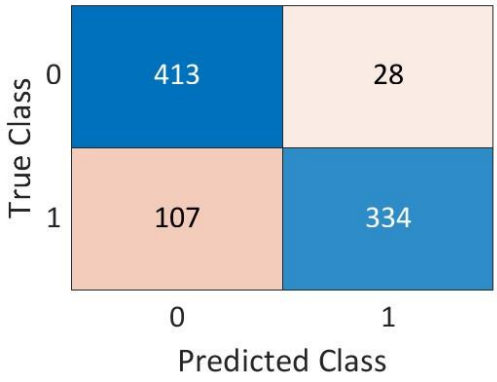

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{84{,}69\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{92{,}27\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{75{,}74\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione * Recall}{Precisione + Recall} \times 100 = \boldsymbol{83{,}19\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{93{,}65\%}$$

b)

Figura 4.13 a) confusion matrix; b) performance della Rete 4, utilizzando il "DATA SET 3.A".

Come anticipato nel capitolo 3, sono state poi considerate come impulsive le finestre 2 e 3.

In *Figura 4.14* è presentata la numerosità dei "DATA SET 3.B" (valida per l'addestramento di tutte le reti create) in termini di finestre non impulsive e impulsive, suddividendo in *training set* (a sua volta suddiviso in *training* effettivo e *validation*) e *test set*:

Totale finestre impulsive: 1464

Totale finestre: 2928 (1464 IMP + 1464 NON IMP)

TRAINING SET: 2340

- ❖Training effettivo: 1872 (936 IMP + 936 NON IMP)
- ❖Validation (ogni gruppo k): 468 (234 IMP + 234 NON IMP)

TEST SET: 588 (294 IMP + 294 NON IMP)

Figura 4.14: numero di finestre considerate nel DATA SET 3.B, considerando come impulsive le finestre 2 e 3.

Nella *Figura 4.15* è riportata la *confusion matrix* risultante dal *test* utilizzando la **Rete 1** e le relative *performance* in termini di accuratezza, precisione, recall, F1

score e specificità. In particolare, è stata utilizzata la rete che, durante la fase di addestramento, ha ottenuto l'accuratezza migliore (in questo caso pari a 91,45%).

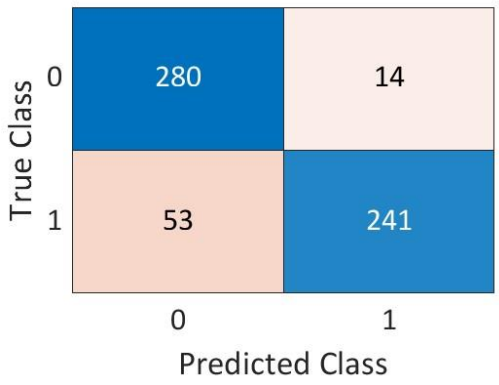

a)

$$\boldsymbol{Accuratezza_{\%}} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{88{,}61\%}$$

$$\boldsymbol{Precisione_{\%}} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{94{,}51\%}$$

$$\boldsymbol{Recall_{\%}} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{81{,}97\%}$$

$$\boldsymbol{F1\ Score_{\%}} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{87{,}80\%}$$

$$\boldsymbol{Specificità_{\%}} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{95{,}24\%}$$

b)

Figura 4.15: a) confusion matrix; b) performance della Rete 1, utilizzando il "DATA SET 3.B".

In *Figura 4.16*, sono riportati i risultati della **Rete 2**. In particolare, è stata utilizzata la rete che, durante la fase di addestramento, ha ottenuto l'accuratezza migliore (in questo caso pari a 84,40%):

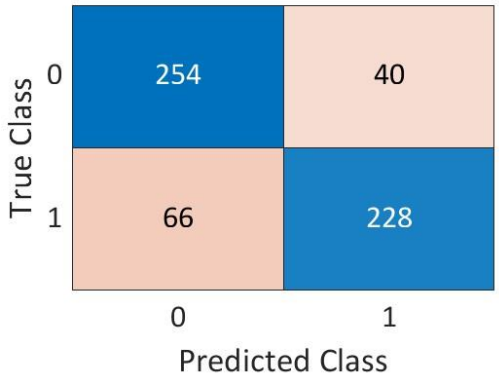

a)

$$\boldsymbol{Accuratezza_{\%}} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{81{,}97\%}$$

$$\boldsymbol{Precisione_{\%}} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{85{,}07\%}$$

$$\boldsymbol{Recall_{\%}} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{77{,}55\%}$$

$$\boldsymbol{F1\ Score_{\%}} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{81{,}14\%}$$

$$\boldsymbol{Specificità_{\%}} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{86{,}39\%}$$

b)

Figura 4.16: a) confusion matrix; b) performance della Rete 2, utilizzando il "DATA SET 3.B".

Lo stesso tipo di risultati viene riportato in *Figura 4.17* per la **Rete 3**. In particolare, è stata utilizzata la rete che, durante la fase di addestramento, ha ottenuto l'accuratezza migliore (in questo caso pari a 86,11%):

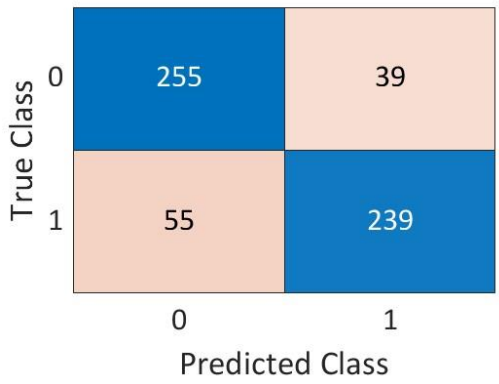

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{84{,}01\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{85{,}97\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{81{,}29\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{83{,}57\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{86{,}73\%}$$

b)

Figura 4.17: a) confusion matrix; b) performance della Rete 3, utilizzando il "DATA SET 3.B".

E, infine, per la **Rete 4** (*Figura 4.18*). In particolare, è stata utilizzata la rete che, durante la fase di addestramento, ha ottenuto l'accuratezza migliore (in questo caso pari a 91,88%):

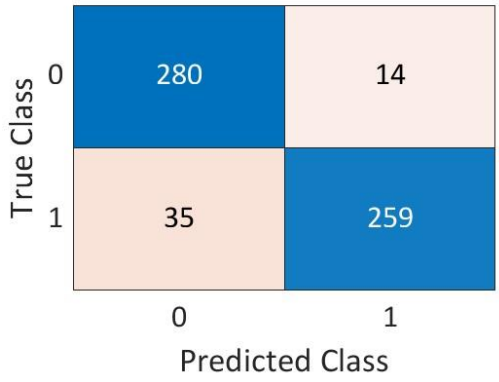

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{91{,}67\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{94{,}87\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{88{,}10\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{91{,}36\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{95{,}24\%}$$

b)

Figura 4.18 a) confusion matrix; b) performance della Rete 4, utilizzando il "DATA SET 3.B".

Successivamente, è stato effettuato il *test* sul "DATA SET 2.A", escludendo le finestre su cui le reti sono state addestrate, senza addestrarle nuovamente.

In *Figura 4.19*, si riporta la quantità di finestre non impulsive e impulsive utilizzate nei vari nuovi *test*, utilizzando le quattro reti create e addestrate considerando come impulsive le finestre 2, 3 e 4:

TEST SET: 27234

- ✓ IMPULSIVE: 441
- ✓ NON IMPULSIVE: 26793

Figura 4.19: numero di finestre considerate per testare in un altro modo le reti, considerando come impulsive le finestre 2, 3 e 4.

Nella *Figura 4.20* è riportata la *confusion matrix* risultante dal *test* utilizzando la **Rete 1** e le relative *performance* in termini di accuratezza, precisione, recall, F1 score e specificità.

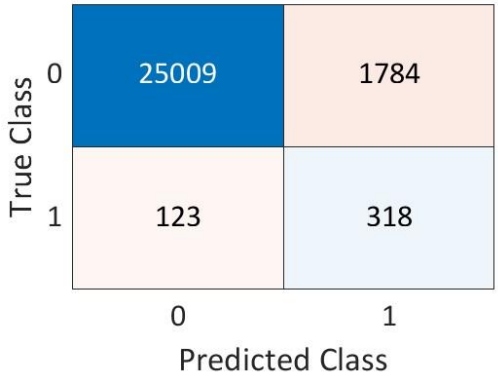

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{93{,}00\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{15{,}13\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{72{,}11\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{25{,}01\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{93{,}34\%}$$

b)

Figura 4.20 a) confusion matrix; b) performance della Rete 1, utilizzando il nuovo test set.

In *Figura 4.21*, sono riportati i risultati della **Rete 2**.

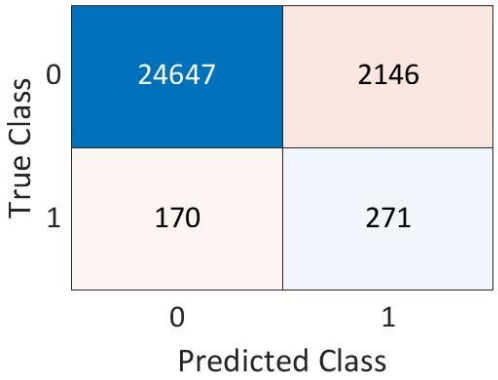

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{91{,}50\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{11{,}21\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{61{,}45\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{18{,}96\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{91{,}99\%}$$

b)

Figura 4.21 a) confusion matrix; b) performance della Rete 2, utilizzando il nuovo test set.

In *Figura 4.22*, sono riportati i risultati della **Rete 3**.

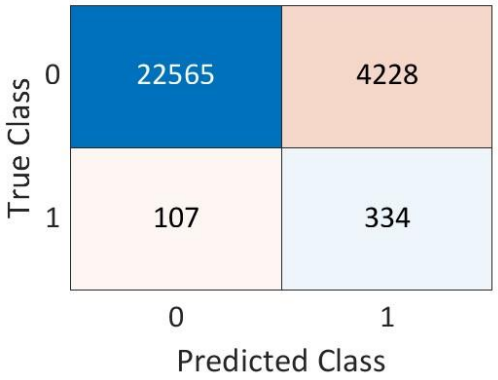

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{84{,}08\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{7{,}32\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{75{,}74\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{13{,}35\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{84{,}22\%}$$

b)

Figura 4.22 a) confusion matrix; b) performance della Rete 3, utilizzando il nuovo test set.

In *Figura 4.23*, sono riportati i risultati della **Rete 4**.

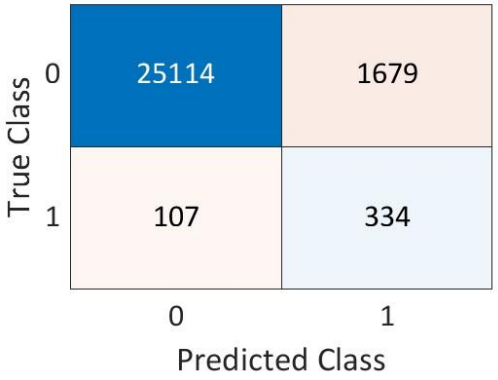

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{93{,}44\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{16{,}59\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{75{,}74\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{27{,}22\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{93{,}73\%}$$

b)

Figura 4.23 a) confusion matrix; b) performance della Rete 4, utilizzando il nuovo test set.

Infine, è stato effettuato il *test* sul "DATA SET 2.B", escludendo le finestre su cui le reti sono state addestrate, senza addestrarle nuovamente.

In *Figura 4.24*, si riporta la quantità di finestre non impulsive e impulsive utilizzate nei vari nuovi *test*, utilizzando le quattro reti create e addestrate considerando come impulsive le finestre 2 e 3:

TEST SET : 27672

- ✓ IMPULSIVE: 294
- ✓ NON IMPULSIVE: 27378

Figura 4.24: numero di finestre considerate per testare in un altro modo le reti, considerando come impulsive le finestre 2 e 3.

Nella *Figura 4.25* è riportata la *confusion matrix* risultante dal *test* utilizzando la **Rete 1** e le relative *performance* in termini di accuratezza, precisione, recall, F1 score e specificità.

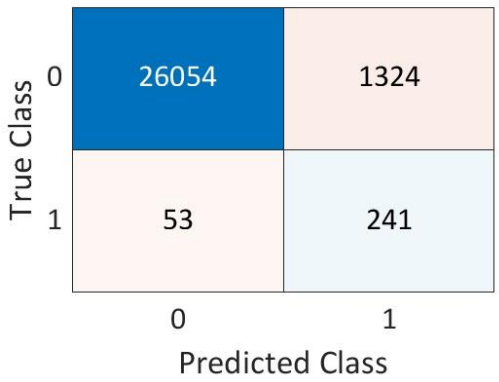

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{95{,}02\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{15{,}40\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{81{,}97\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{25{,}93\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{95{,}16\%}$$

b)

Figura 4.25 a) confusion matrix; b) performance della Rete 1, utilizzando il nuovo test set.

In *Figura 4.26*, sono riportati i risultati della **Rete 2**.

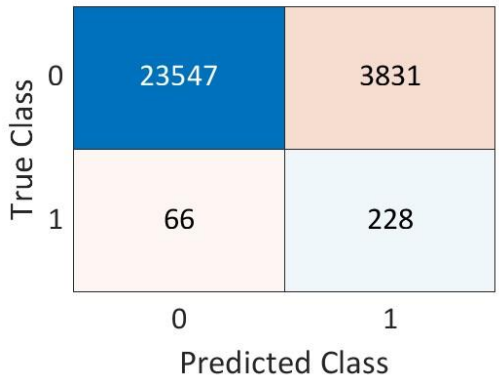

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{85,92\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{5,62\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{77,55\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{10,48\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{86,01\%}$$

b)

Figura 4.26 a) confusion matrix; b) performance della Rete 2, utilizzando il nuovo test set.

In *Figura 4.27*, sono riportati i risultati della **Rete 3**.

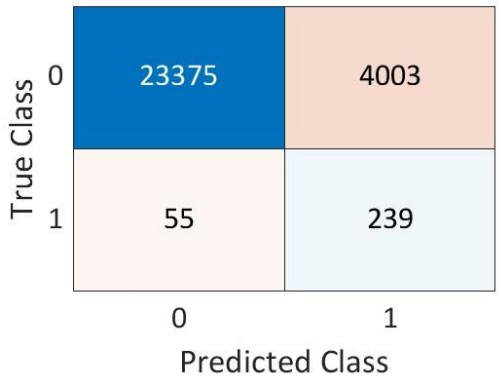

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{85,34\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{5,63\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{81,29\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{10,54\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{85,38\%}$$

b)

Figura 4.27 a) confusion matrix; b) performance della Rete 3, utilizzando il nuovo test set.

In *Figura 4.28*, sono riportati i risultati della **Rete 4**.

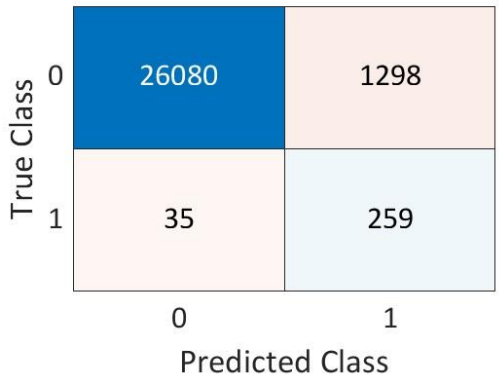

a)

$$\boldsymbol{Accuratezza}_{\%} = \frac{VN+VP}{VN+FP+VP+FN} \times 100 = \boldsymbol{95,18\%}$$

$$\boldsymbol{Precisione}_{\%} = \frac{VP}{FP+VP} \times 100 = \boldsymbol{16,63\%}$$

$$\boldsymbol{Recall}_{\%} = \frac{VP}{FN+VP} \times 100 = \boldsymbol{88,10\%}$$

$$\boldsymbol{F1\ Score}_{\%} = 2 * \frac{Precisione*Recall}{Precisione+Recall} \times 100 = \boldsymbol{27,98\%}$$

$$\boldsymbol{Specificità}_{\%} = \frac{VN}{VN+FP} \times 100 = \boldsymbol{95,26\%}$$

b)

Figura 4.28 a) confusion matrix; b) performance della Rete 4, utilizzando il nuovo test set.

4.4 Overlap

Per la fase 1 di quest'ultimo passaggio, sono state considerate in totale un numero di finestre impulsive pari a 1464, tenendo conto delle sole finestre 1 e 2 relative a tutti i soggetti e tutte le prove. Delle 732 coppie, 549 sono state classificate nel modo corretto dalla rete utilizzata per la classificazione (la Rete 4, addestrata considerando impulsive le finestre 2 e 3).

Come descritto nel paragrafo 3.6, a questa prima fase ne è seguita un'altra, in cui è stato effettuato il vero e proprio *overlap* sulle coppie correttamente classificate al punto precedente, che sono state unite in un unico segnale della durata complessiva di 1 s. Sono stati ottenuti i valori delle classi predette dalla rete e gli *scores* per ognuna delle coppie.

Infine, è stato identificato il valore medio dell'indice corrispondente alla fine della prima finestra mobile di 0.5 s che serviva alla rete per identificare stabilmente quando si trovava di fronte ad un movimento impulsivo. Tale indice è risultato essere pari a 158, corrispondente a 0.785 s, considerando segnali di 1 s.

A titolo esemplificativo, si riporta in *Figura 4.29* un grafico in cui sono stati riportati i segnali di accelerazione e velocità angolare di una coppia di finestre 1 e 2, a cui sono state sovrapposte alcune delle finestre classificate dalla rete, in particolare, la prima finestra riportata in rosso è proprio la prima che mediamente la rete ha riconosciuto stabilmente come movimento impulsivo.

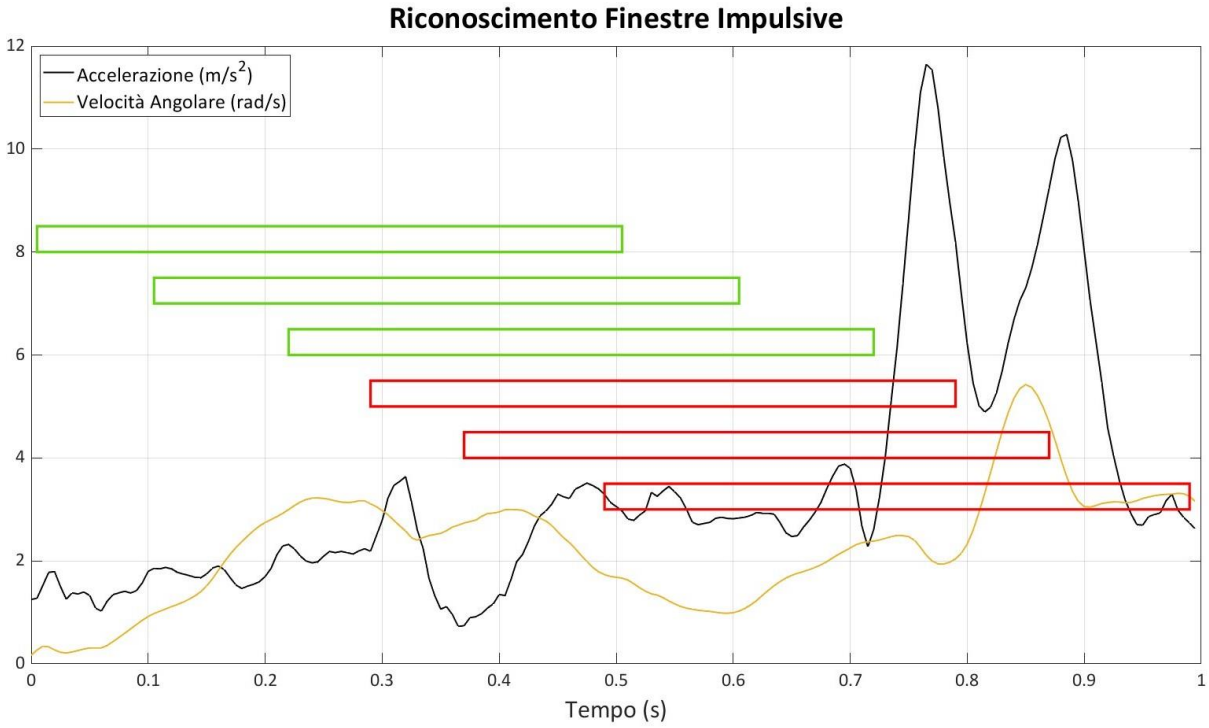

Figura 4.29: grafico in cui insieme ai segnali di accelerazione e velocità angolare di una coppia di finestre 1 e 2, sono riportate alcune delle finestre con cui è stata effettuata l'analisi con l'overlap. In verde sono rappresentate le finestre che riconoscono movimenti non impulsivi, in rosso le finestre che riconoscono movimenti impulsivi.

5. DISCUSSIONE e CONCLUSIONI

Dall'analisi dell'accelerazione e in particolare della variabilità dei movimenti non impulsivi e impulsivi riportata in *Tabella 4.1*, è possibile affermare che, anche considerando il segnale ripartito in 30 finestre da 3 s ciascuna, i due tipi di movimenti risultano ben distinti sia dal punto di vista dei valori medi che della deviazione standard. Infatti, i valori medi per i movimenti non impulsivi nelle tre prove non superano i 2 m/s^2 e anche la deviazione standard di tali movimenti risulta bassa (al massimo pari a 0.44 m/s^2). Mentre, in riferimento ai movimenti impulsivi, essi sono caratterizzati da un valore medio più elevato (>2.5 volte rispetto al valore medio dei movimenti non impulsivi) e da una deviazione standard più ampia.

La durata della finestra temporale utilizzata, ossia 0.5 s, come visibile in *Figura 4.1*, ha permesso di ottenere un'analisi dei dati ottimale rispetto all'obiettivo della presente tesi.

Dall'analisi statistica (*Tabella 4.2*), eseguita utilizzando i valori medi complessivi assunti da accelerazione e velocità angolare nelle tre prove, si può asserire che i movimenti non impulsivi e impulsivi hanno differenze statisticamente significative, in quanto il *p-value* risulta ≤ 0.05, valore impostato come livello di significatività. È possibile giungere alla stessa conclusione quando i movimenti impulsivi sono stati suddivisi in visivi e sonori. In particolare, si ha differenza statisticamente significativa tra movimenti non impulsivi e impulsivi visivi, tra movimenti non impulsivi e impulsivi sonori e tra movimenti impulsivi visivi e impulsivi sonori (*Tabella 4.3*).

Dalla *Figura 4.4* si può evincere che, mediamente, nel caso dei movimenti non impulsivi, per finestre di durata 0.5 s, i soggetti abbiano effettivamente

effettuato il task come richiesto, ossia in modo fluido e senza scatti, per tutte le direzioni.

Invece, dalla *Figura 4.5*, per tutte le direzioni, si può dire che ci sono delle evidenti differenze tra movimenti non impulsivi e impulsivi, soprattutto nelle finestre 2 e 3. Inoltre, i movimenti impulsivi sono caratterizzati da una variabilità maggiore rispetto a quella che caratterizza i movimenti non impulsivi.

Per quanto riguarda i solo movimenti impulsivi dovuti all'attivazione del *buzzer* (*Figura 4.6*), essi sono caratterizzati da picchi più elevati nei valori assunti dall'accelerazione, arrivando a toccare circa i 20 m/s^2. Inoltre, le finestre 2, 3 e 4 sono caratterizzate da una variabilità maggiore. Infatti, la fascia entro cui sono compresi i segnali è più ampia.

In riferimento all'analisi statistica (*Tabella 4.4*) e ai *box plot* (*Figura 4.8*), insieme agli analoghi per le altre prove riportati in Appendice A, si sono registrate differenze tra movimenti non impulsivi e impulsivi per le finestre 2, 3, 4 e 5. Pertanto, la scelta delle finestre considerate impulsive nella fase del DL, ossia dapprima utilizzando le finestre 2, 3 e 4 e, successivamente, le finestre 2 e 3, è supportata da questi risultati.

Le *confusion matrix* e i relativi valori assunti dagli indicatori utilizzati per valutare le performance delle reti evidenziano che, nel caso in cui si considerino come impulsive le finestre 2, 3 e 4, si hanno in generale delle buone performance (accuratezza > 80%, fatta eccezione per la Rete 2), ma il numero di falsi negativi risulta elevato. Infatti, il numero di finestre impulsive che sono state classificate erroneamente come non impulsive è sempre > 100. Se si riporta la situazione all'ambito industriale, vorrebbe dire che il cobot non riconoscerebbe per più di 100 volte un movimento impulsivo come tale, generando collisione con l'operatore con cui collabora. Inoltre, il recall dà una misura di quanto bene siano stati

classificati i movimenti impulsivi, che è l'obiettivo di tale tesi. Per tutte e quattro le reti create, esso è sempre inferiore all'80%.
Pertanto, in seguito, si sono considerate come impulsive le finestre 2 e 3. I risultati, in questo caso, sono migliori: si registrano accuratezze sempre > 80%, come anche il recall, ad eccezione della Rete 2.

In seguito, per simulare un'applicazione reale, è stato eseguito il *test* su un più ampio numero di finestre. Ma, data l'elevata numerosità di finestre non impulsive incluse in questo caso rispetto all'esiguo numero di finestre impulsive rimaste (non utilizzate nel *training*), i risultati sono molto sbilanciati, soprattutto considerando la precisione e l'F1 score.

I risultati ottenuti con l'overlap sono interessanti, soprattutto perché tale tecnica risulterebbe molto utile per l'applicazione in tempo reale.

Per migliorare i risultati ottenuti in questa tesi, si potrebbe pensare di utilizzare delle reti più profonde, andando ad aggiungere nuovi livelli rispetto a quelli utilizzati qui e aggiustare altri parametri caratteristici.
Inoltre, si potrebbe applicare l'*overlap* a tutto il segnale, per simulare effettivamente un'acquisizione in tempo reale.

APPENDICE A

Nella presente sezione sono riportati i grafici che sono stati omessi nel capitolo 4.

Boundlines complessive (una sola finestra da 0.5 s)

I grafici relativi alla prova FR_I sono riportati in *Figura A.1*:

a)

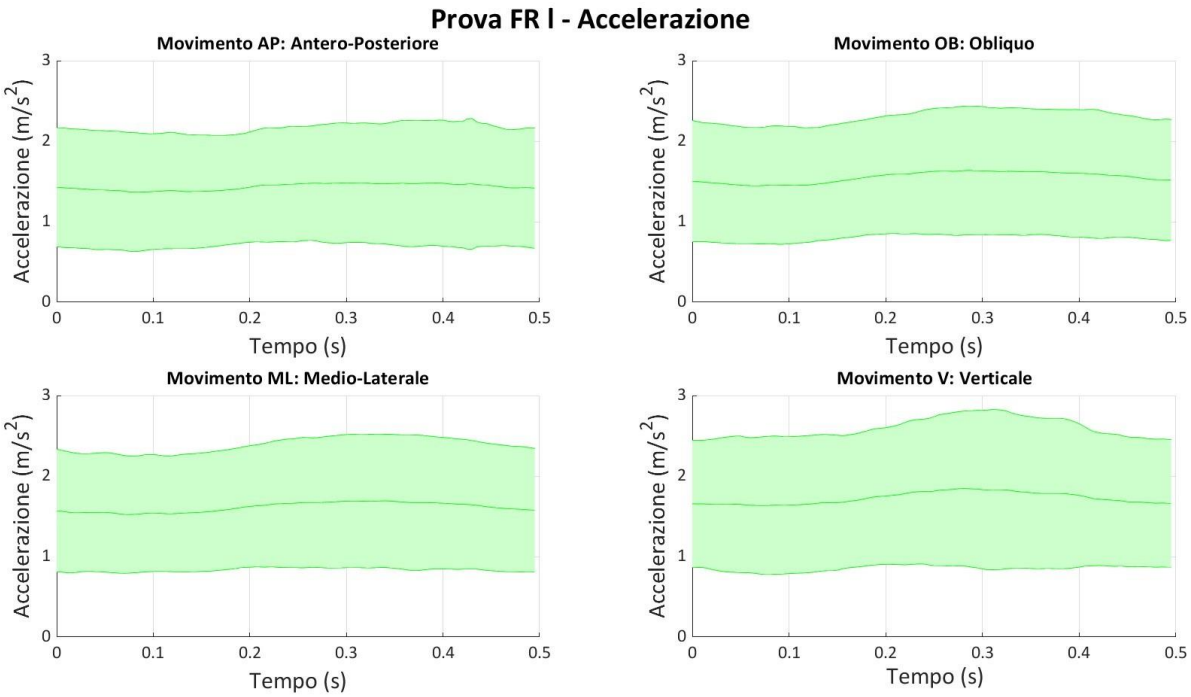

b)

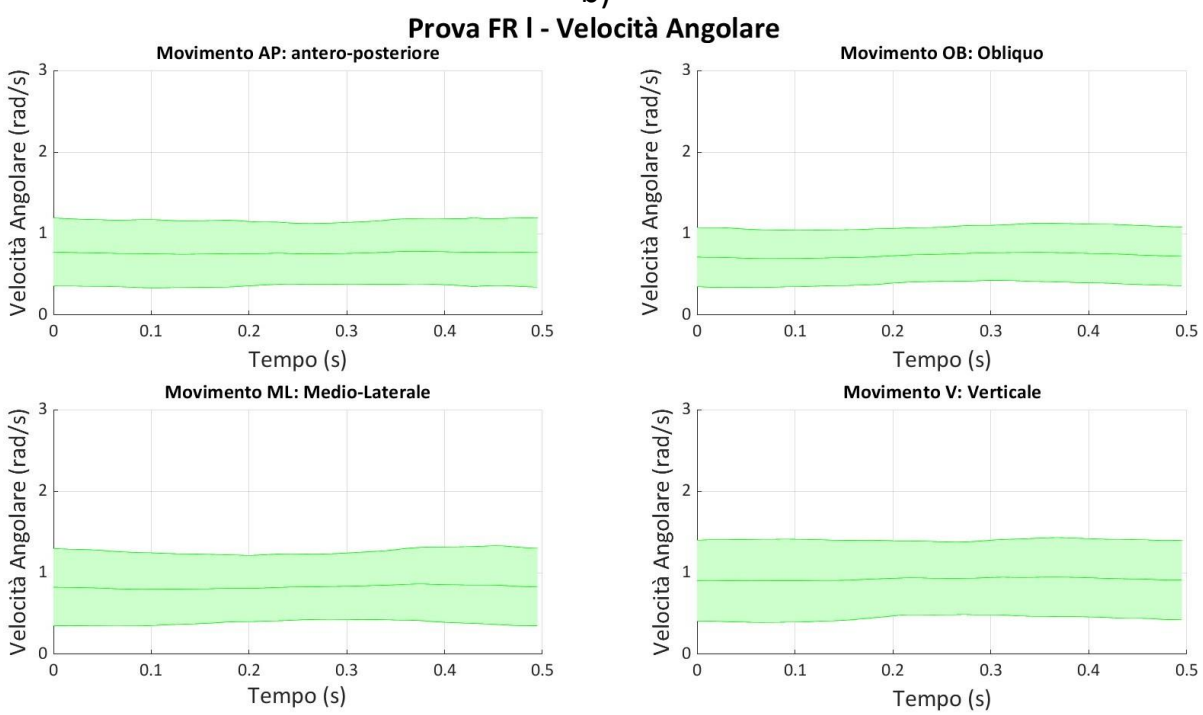

Figura A.1: boundlines complessive della prova FR_l per una finestra da 0.5 s. a) Risultati per il segnale dell'accelerazione, b) risultati per il segnale della velocità angolare.

I grafici relativi alla prova LA_l sono riportati in *Figura A.2*:

a)

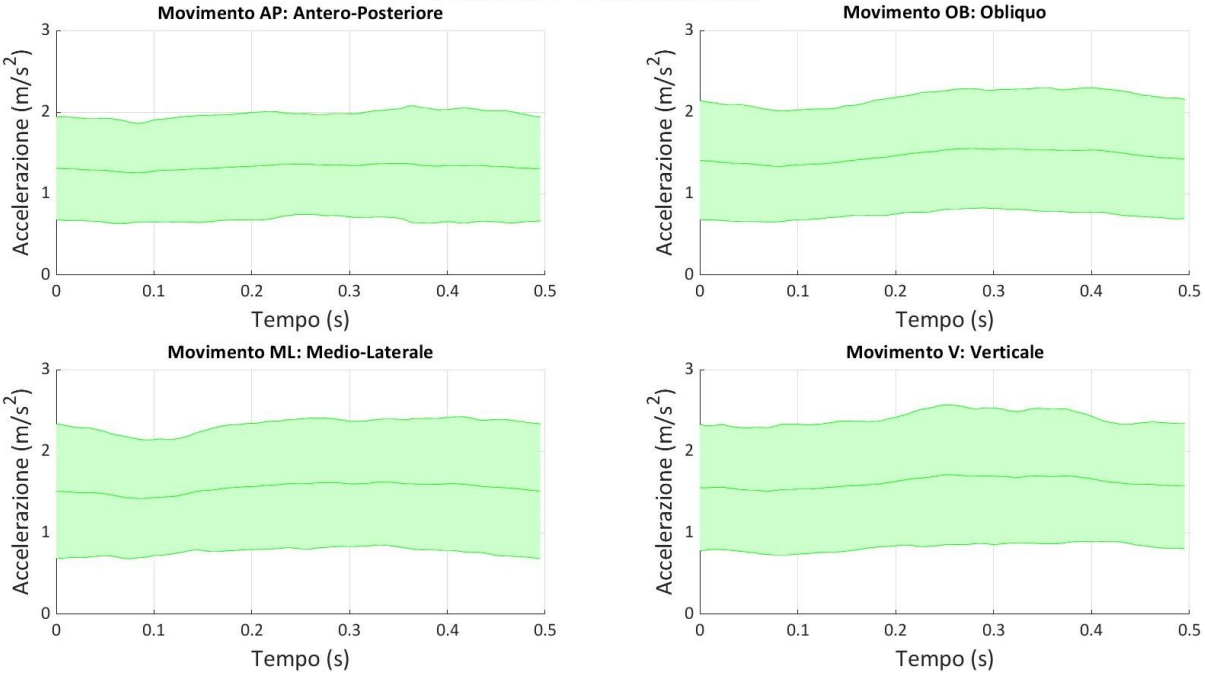

b)

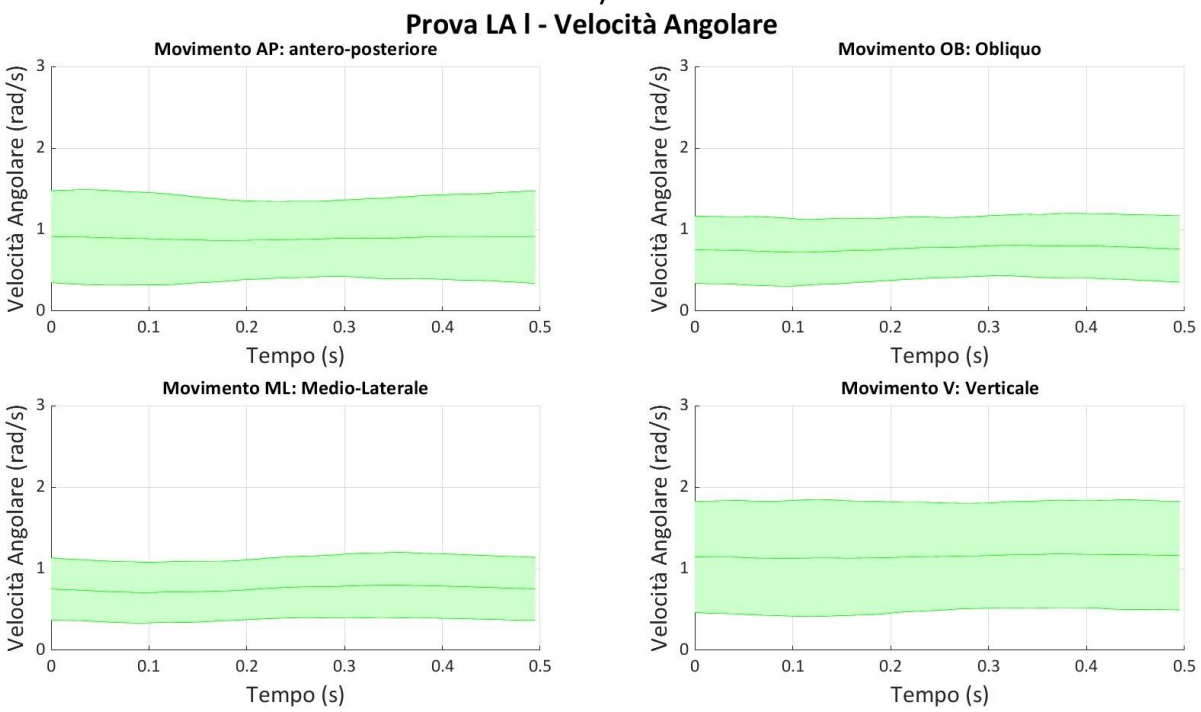

Figura A.2: boundlines complessive della prova LA_l per una finestra da 0.5 s. a) Risultati per il segnale dell'accelerazione, b) risultati per il segnale della velocità angolare.

Boundlines sei finestre da 0.5 s

I grafici relativi alla velocità angolare per la prova FR_r sono riportati in *Figura A.3*:

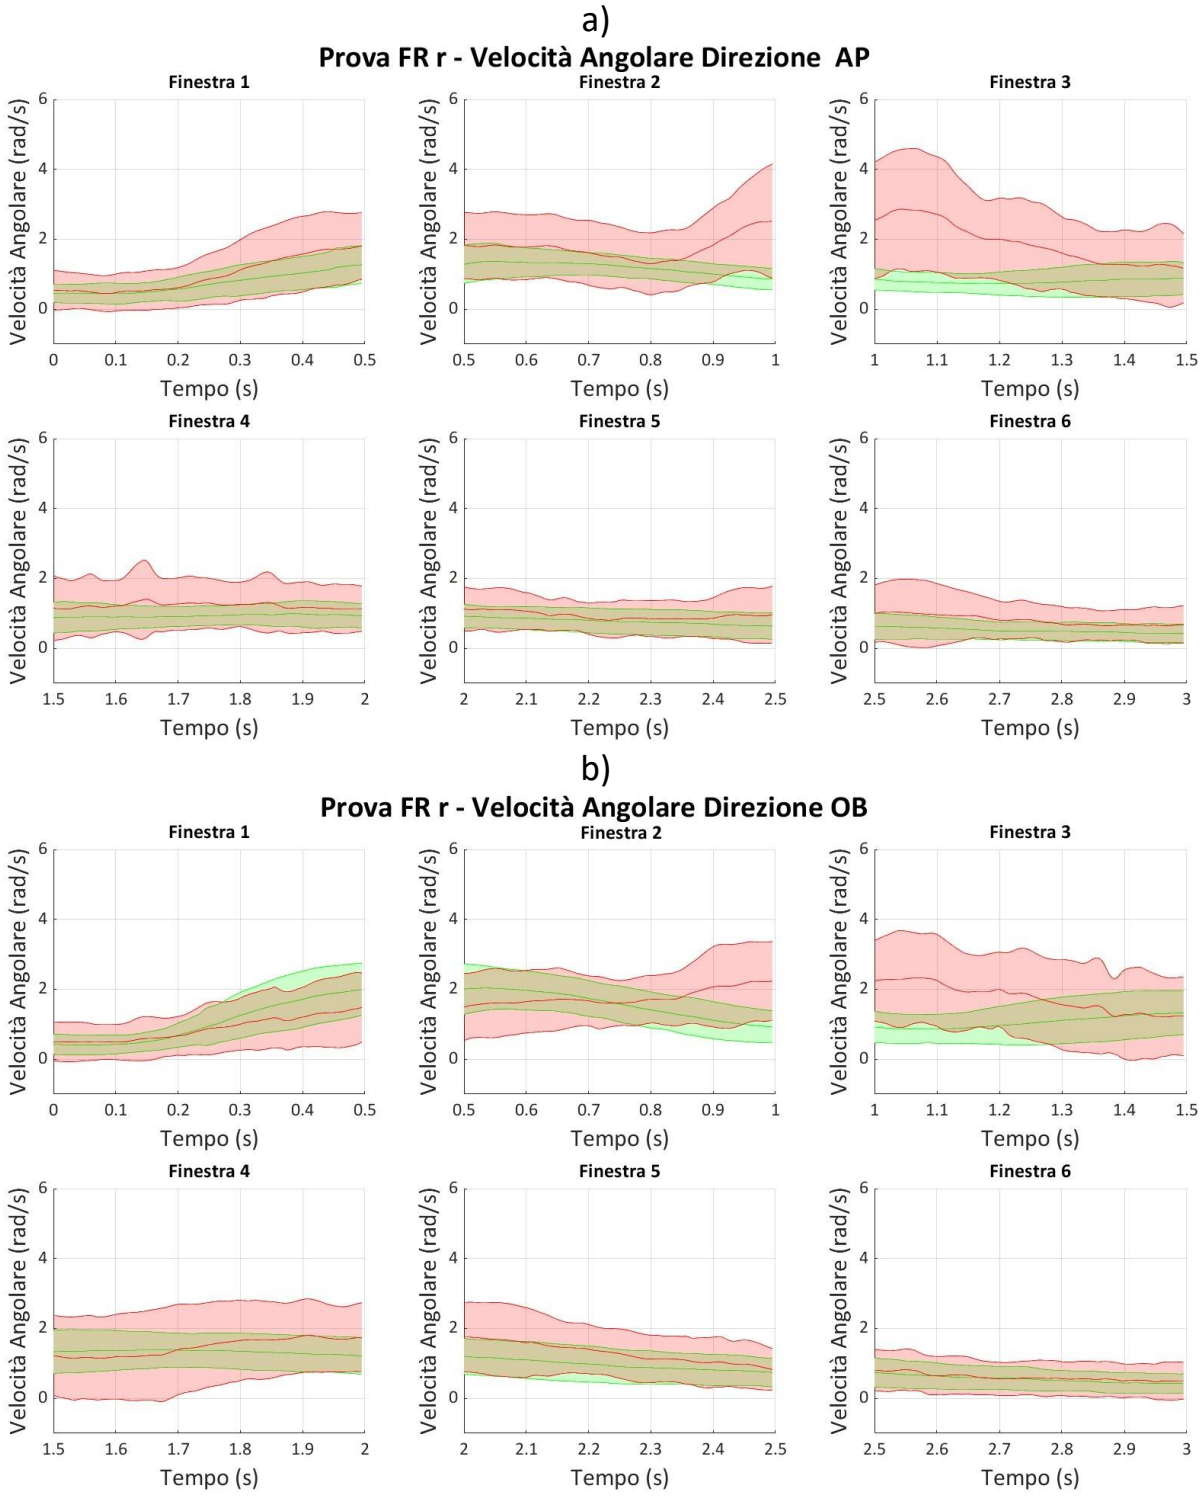

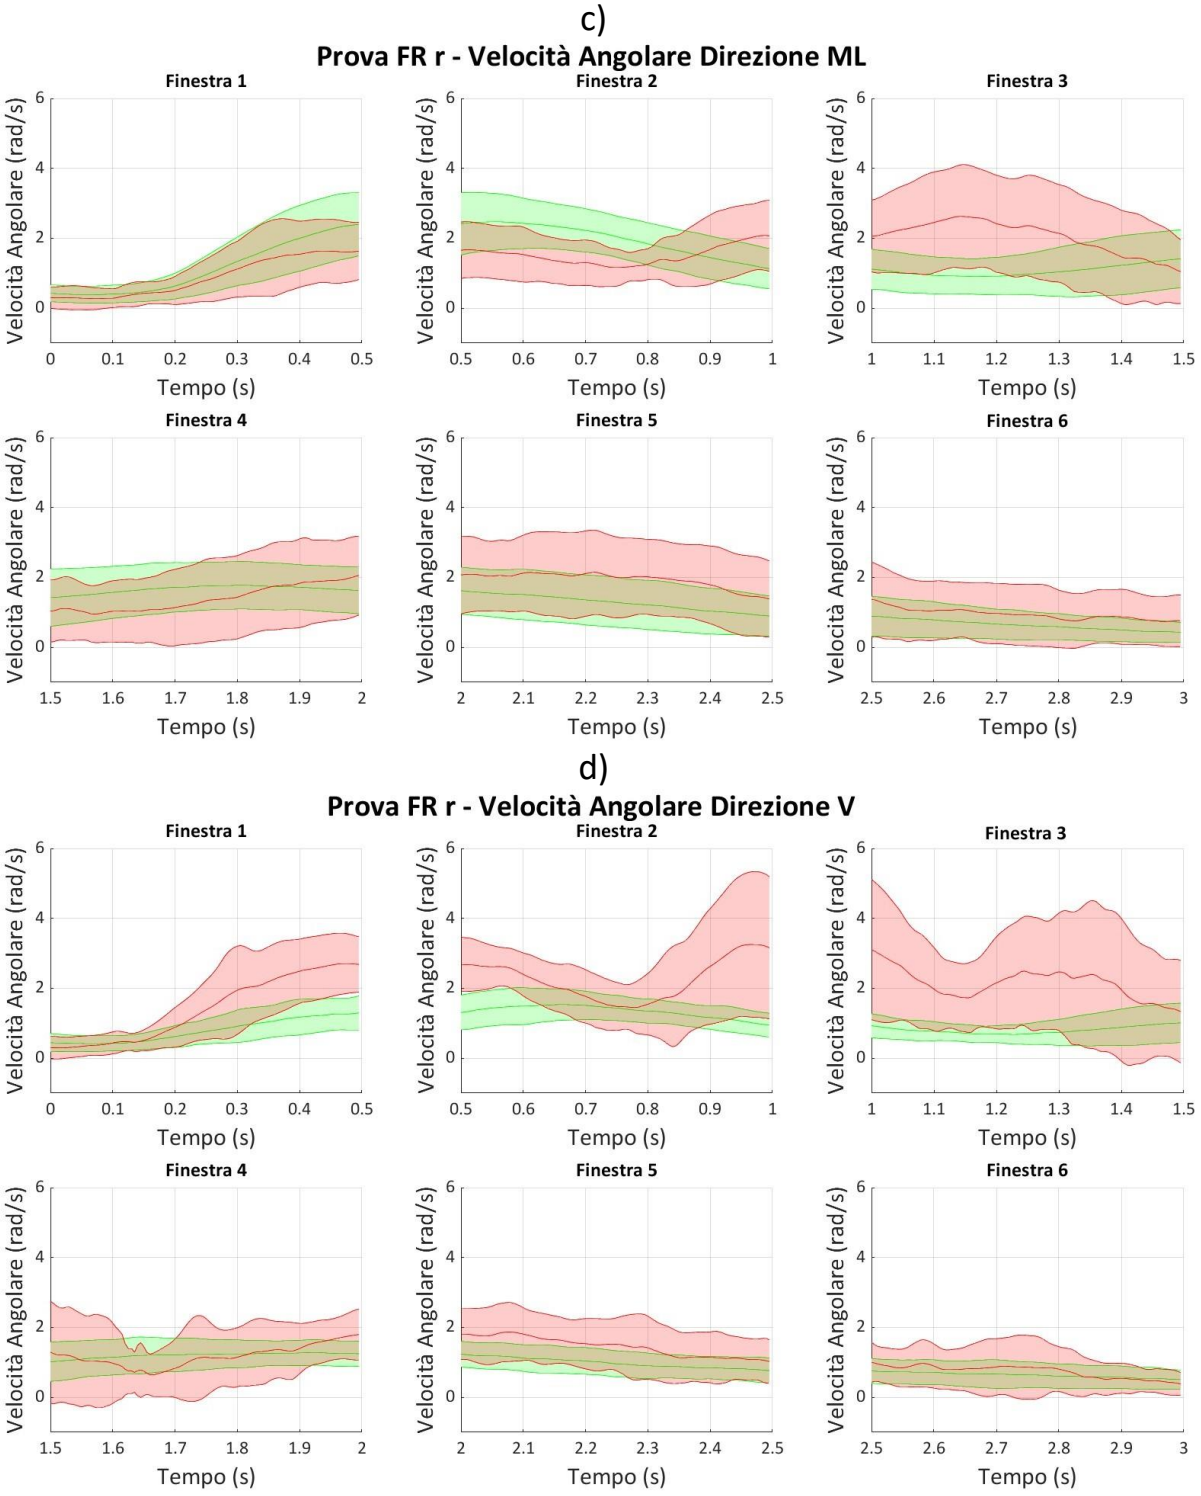

Figura A.3: boundlines per il segnale velocità angolare della prova FR_r con movimenti non impulsivi (in verde) e movimenti impulsivi (in rosso) sovrapposti per le differenti direzioni dei movimenti. a) Direzione AP, b) Direzione OB, c) Direzione ML, d) Direzione V.

I grafici relativi all'accelerazione per la prova FR_I sono riportati in *Figura A.4*:

a)

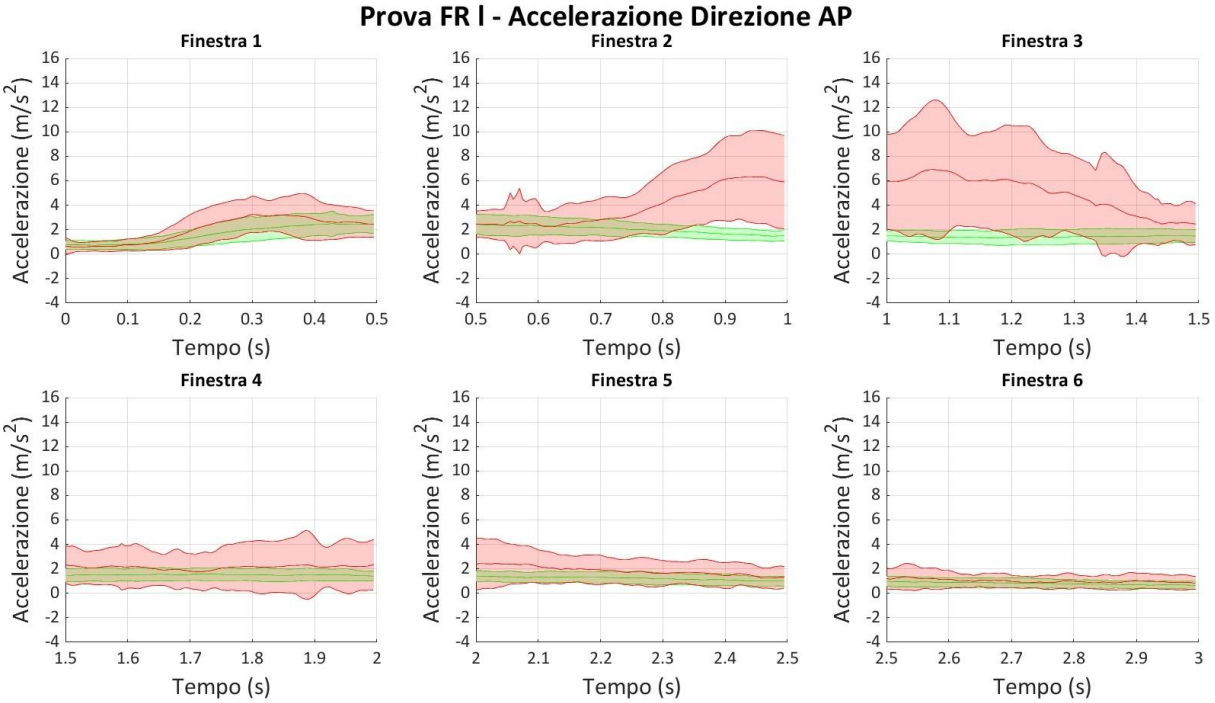

b)

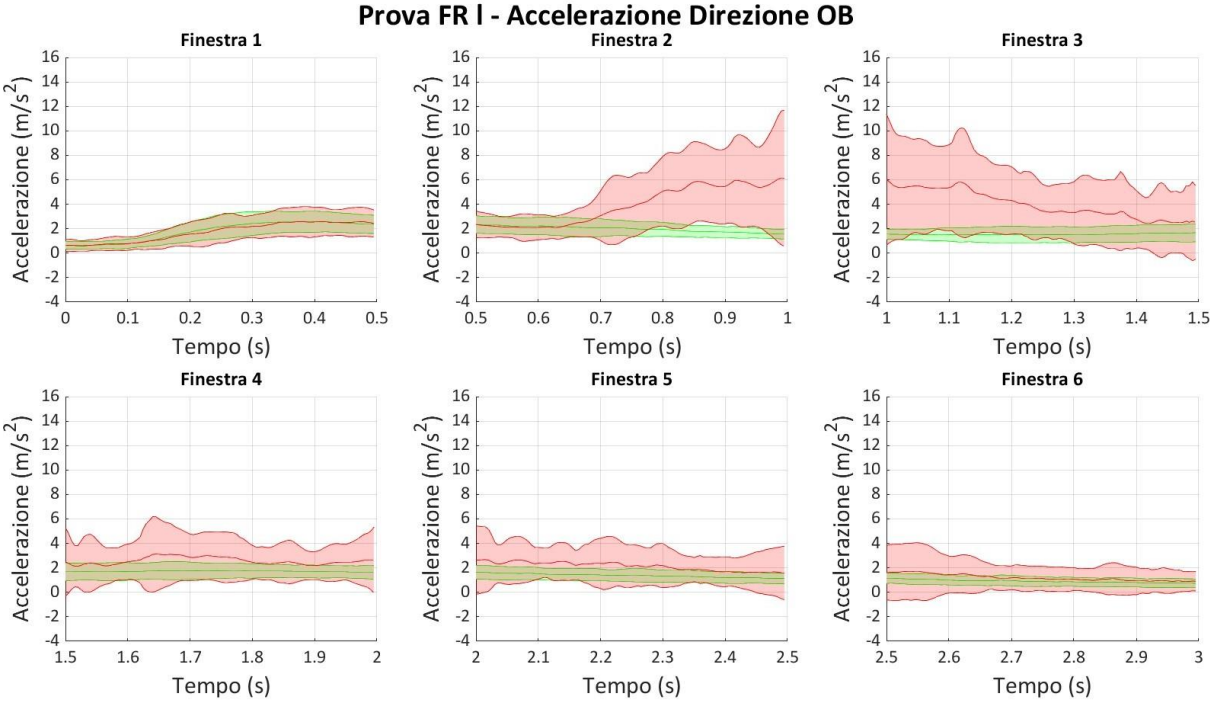

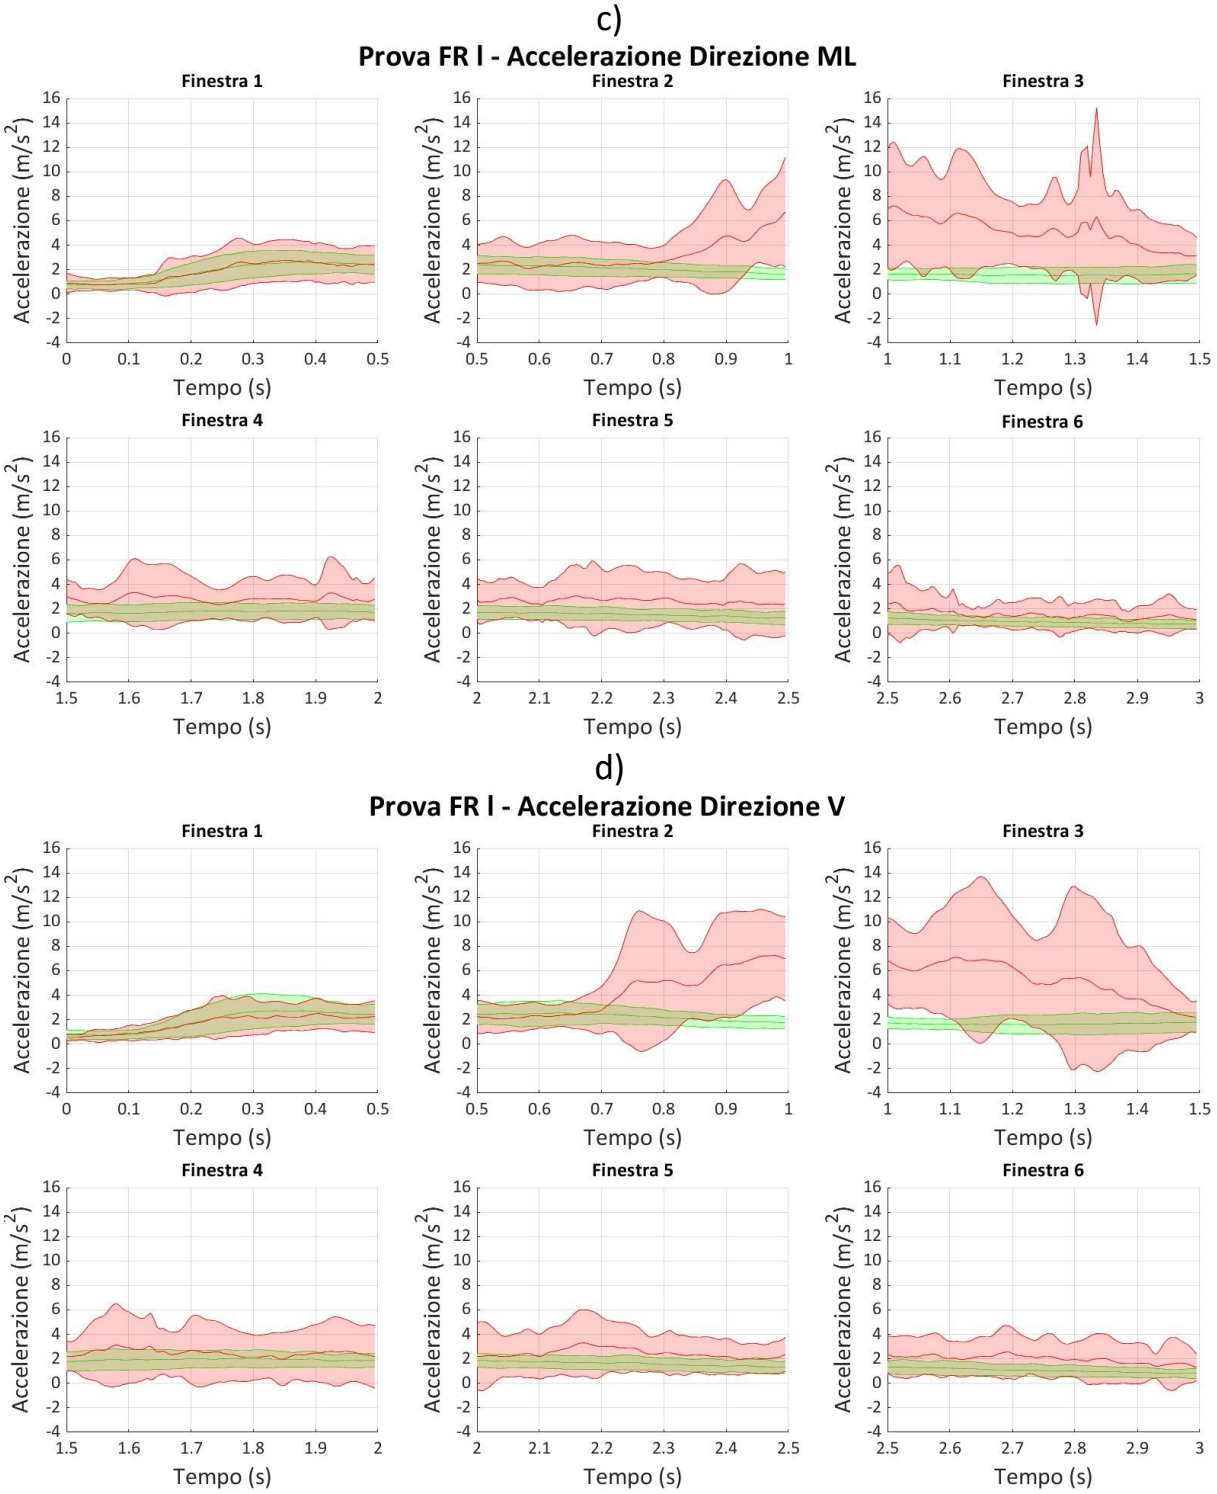

Figura A.4: boundlines per il segnale accelerazione della prova FR_I con movimenti non impulsivi (in verde) e movimenti impulsivi (in rosso) sovrapposti per le differenti direzioni dei movimenti. a) Direzione AP, b) Direzione OB, c) Direzione ML, d) Direzione V.

I grafici relativi alla velocità angolare per la prova FR_I sono riportati in *Figura A.5*:

a)

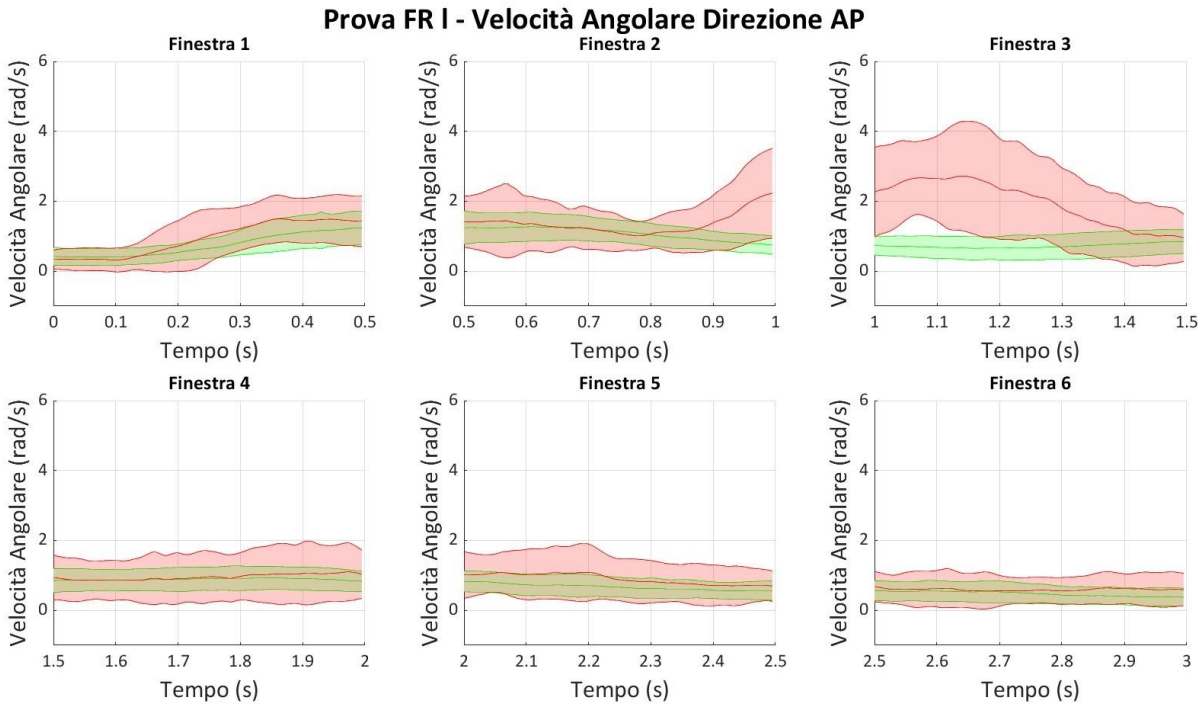

b)

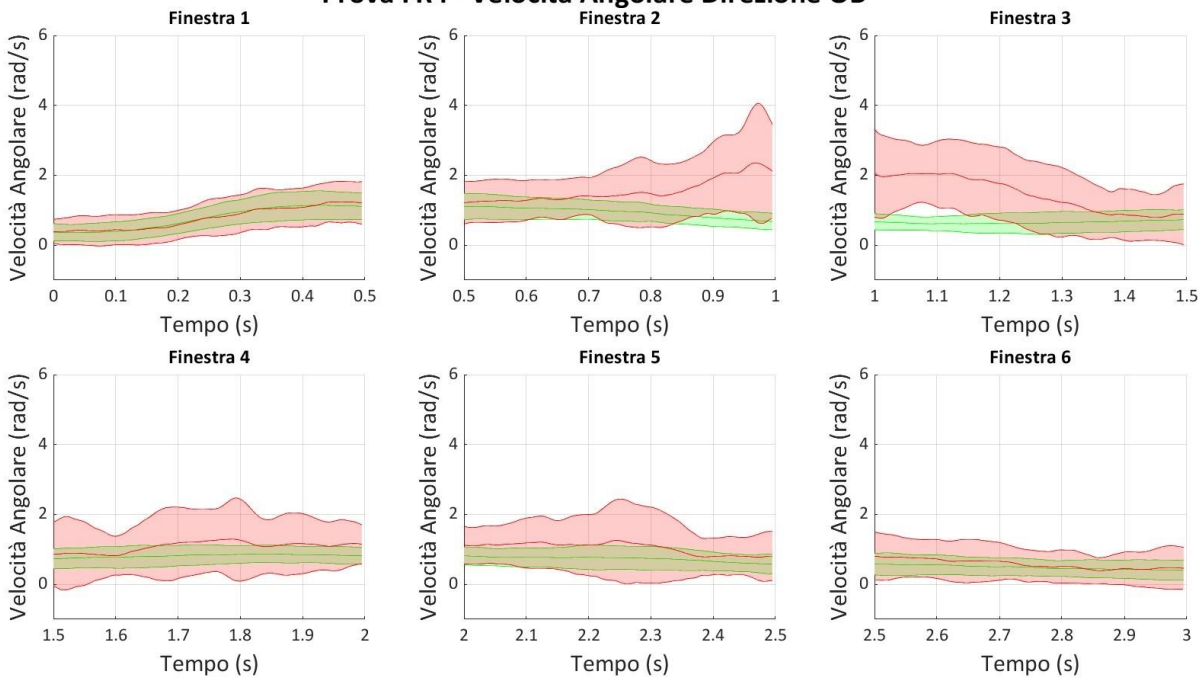

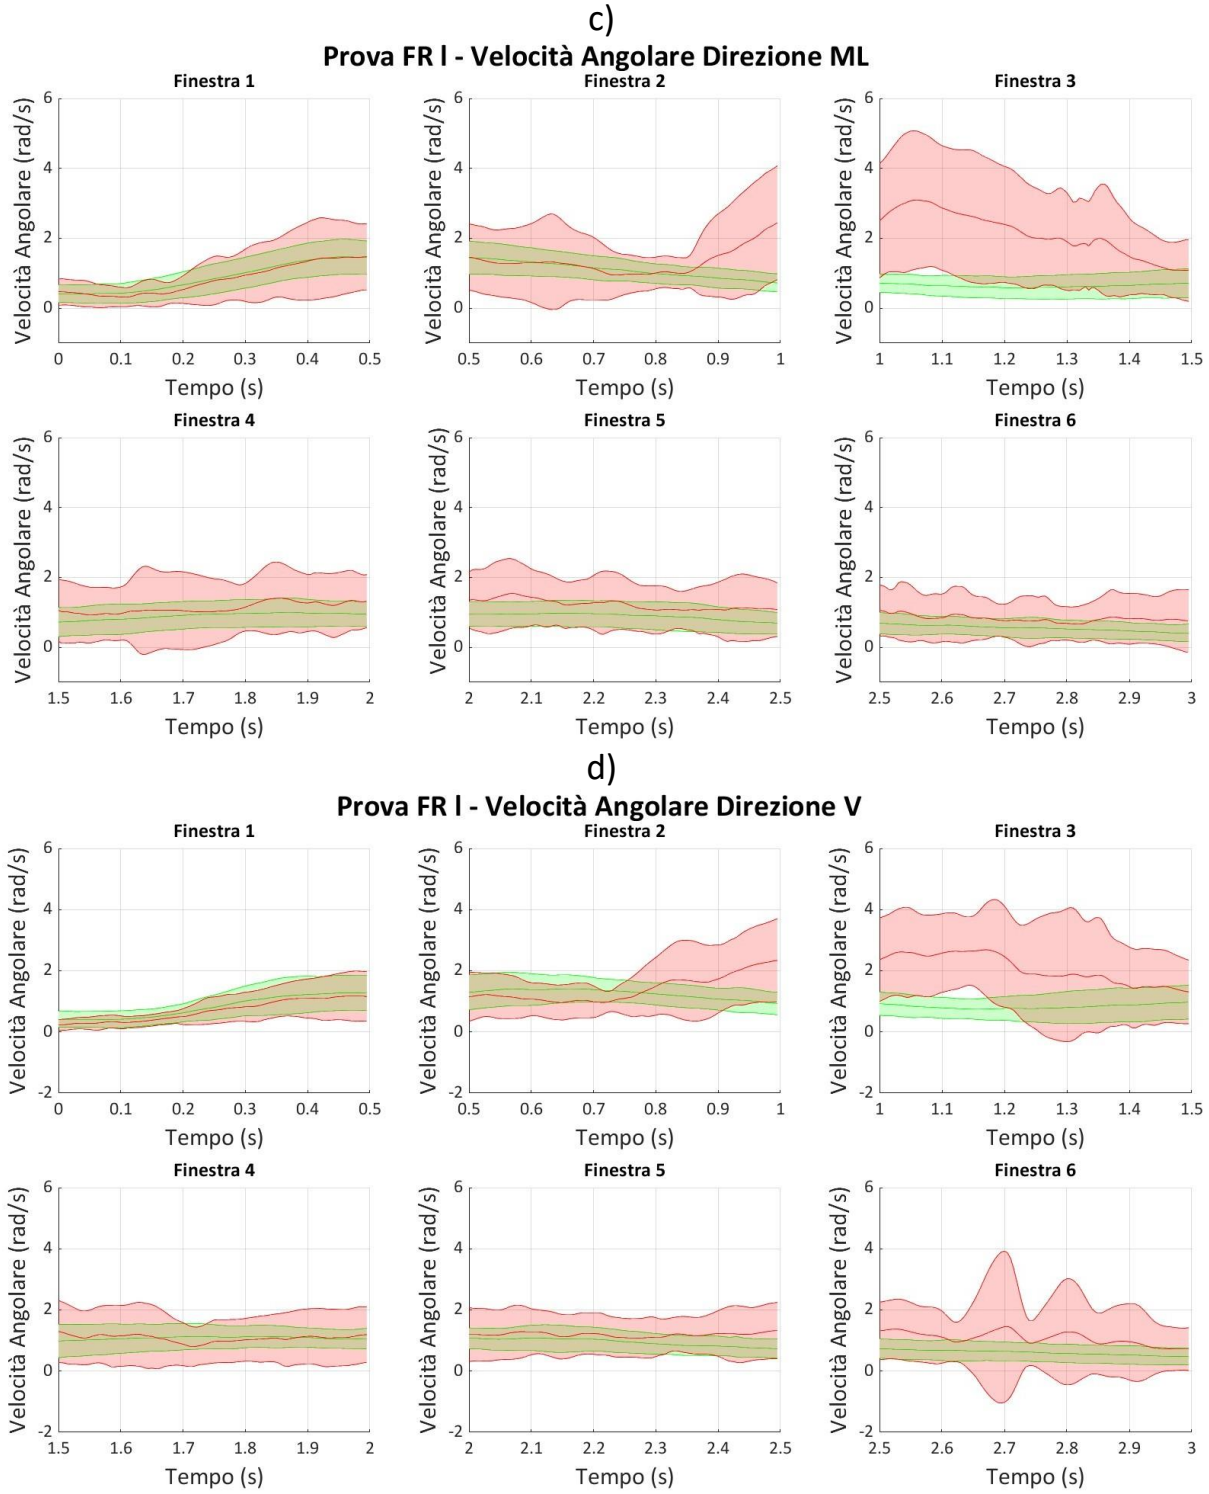

Figura A.5: boundlines per il segnale velocità angolare della prova FR_I con movimenti non impulsivi (in verde) e movimenti impulsivi (in rosso) sovrapposti per le differenti direzioni dei movimenti. a) Direzione AP, b) Direzione OB, c) Direzione ML, d) Direzione V.

I grafici relativi all'accelerazione per la prova LA_I sono riportati in *Figura A.6*:

a)

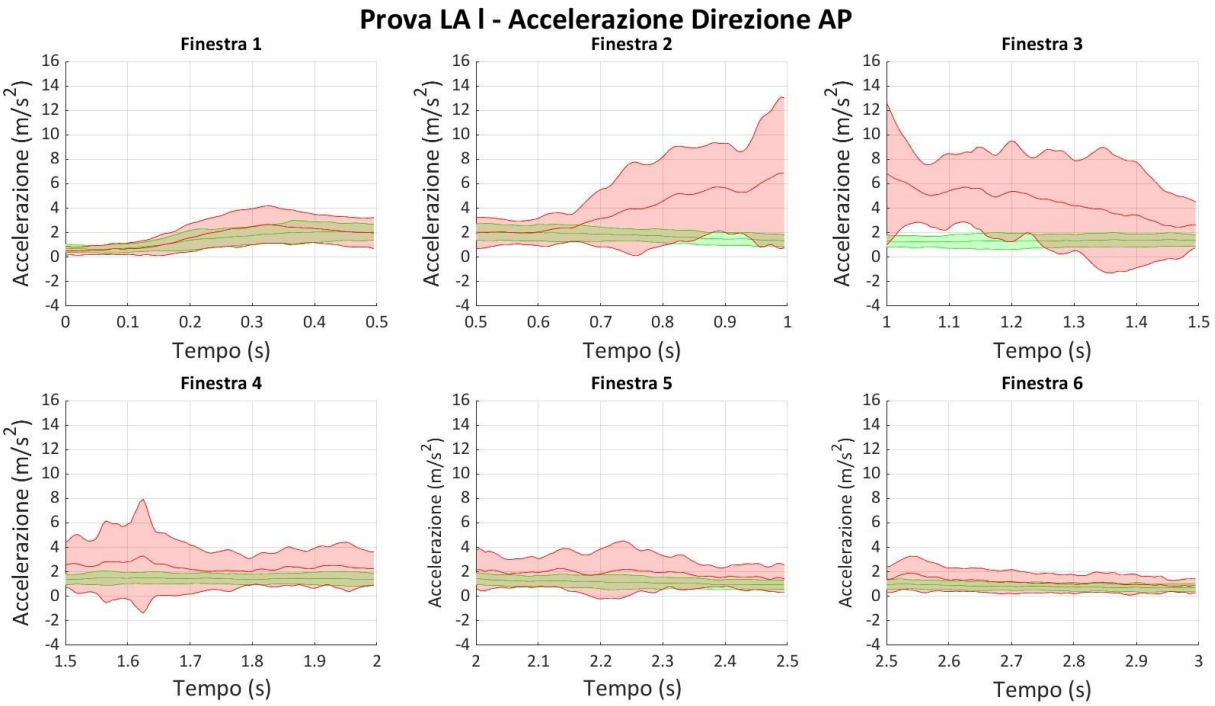

b)

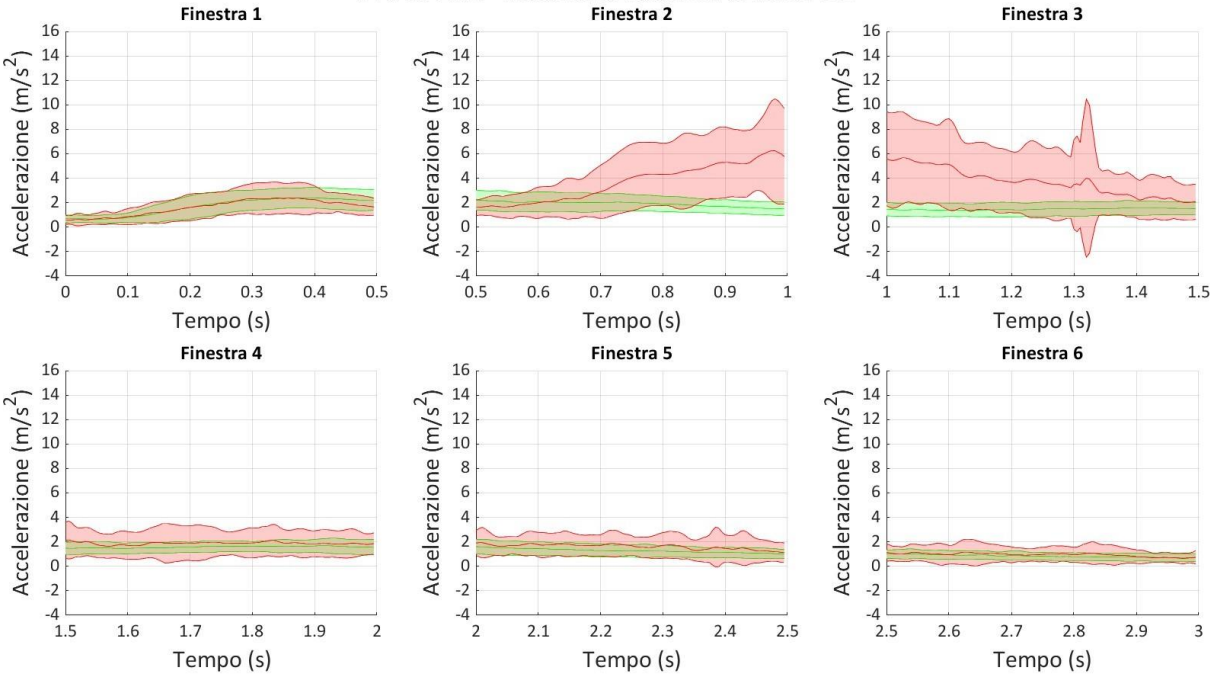

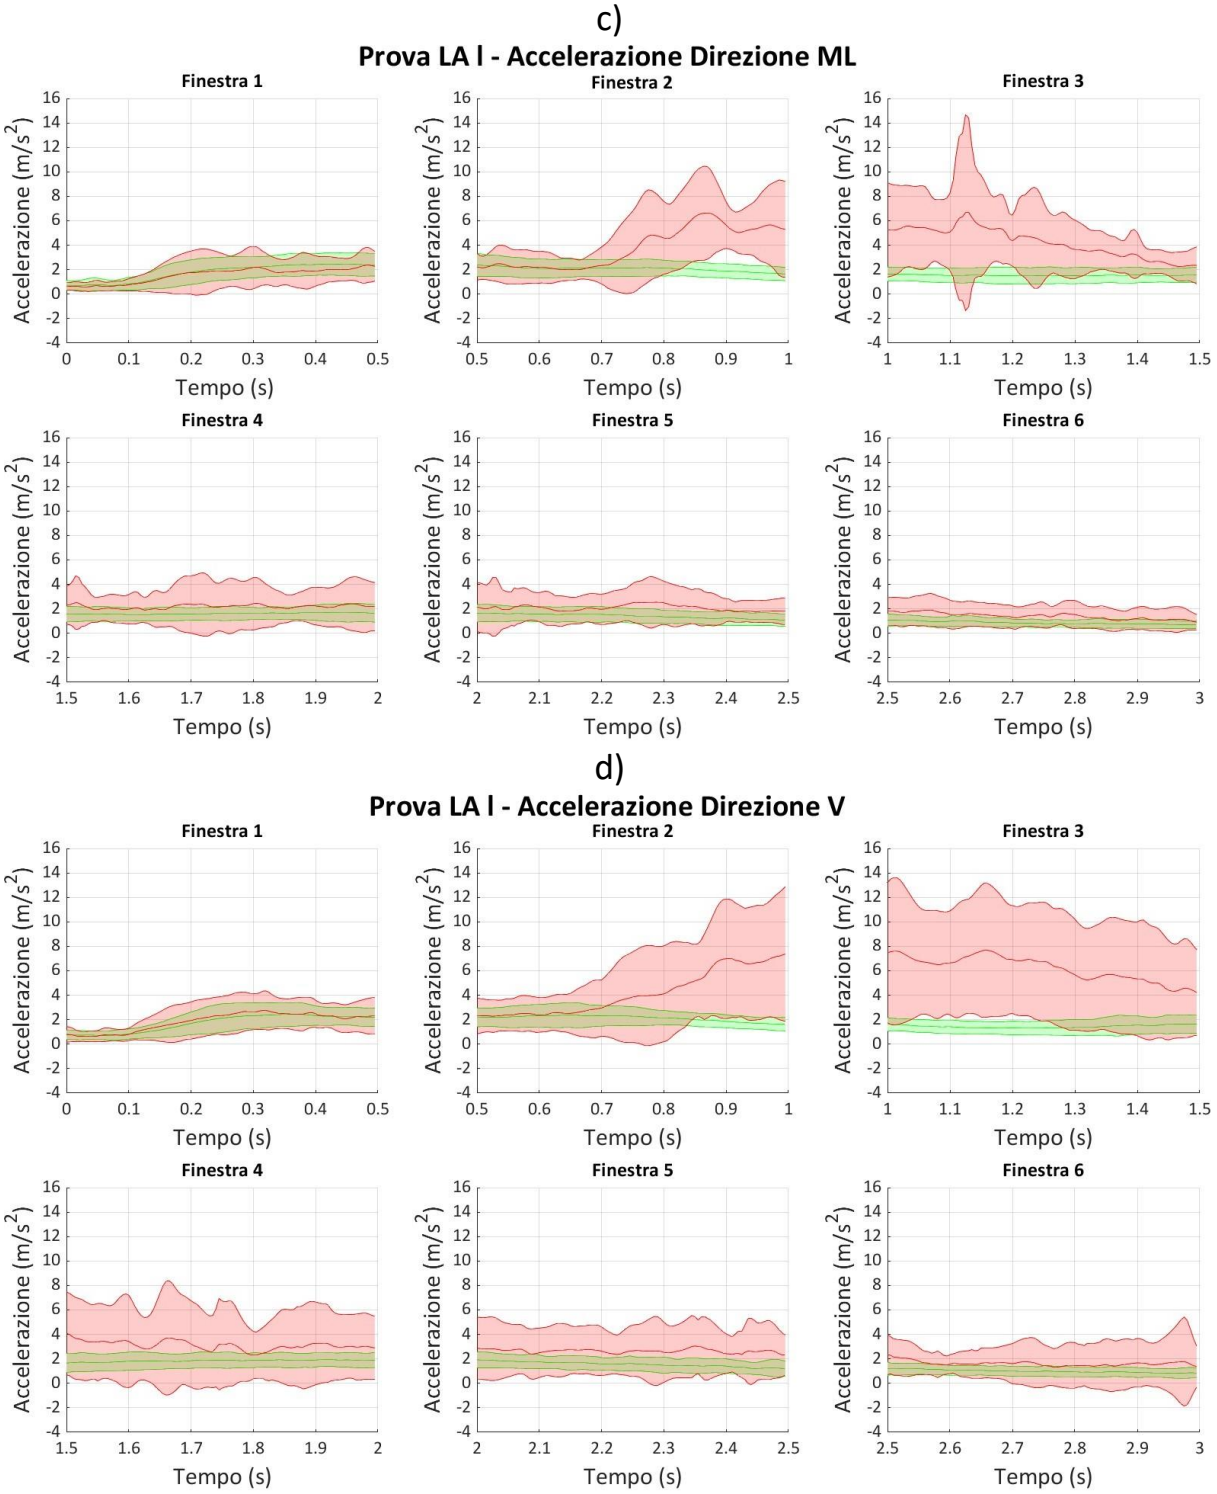

Figura A.6: boundlines per il segnale accelerazione della prova LA_l con movimenti non impulsivi (in verde) e movimenti impulsivi (in rosso) sovrapposti per le differenti direzioni dei movimenti. a) Direzione AP, b) Direzione OB, c) Direzione ML, d) Direzione V.

I grafici relativi alla velocità angolare per la prova LA_I sono riportati in *Figura A.7*:

a)

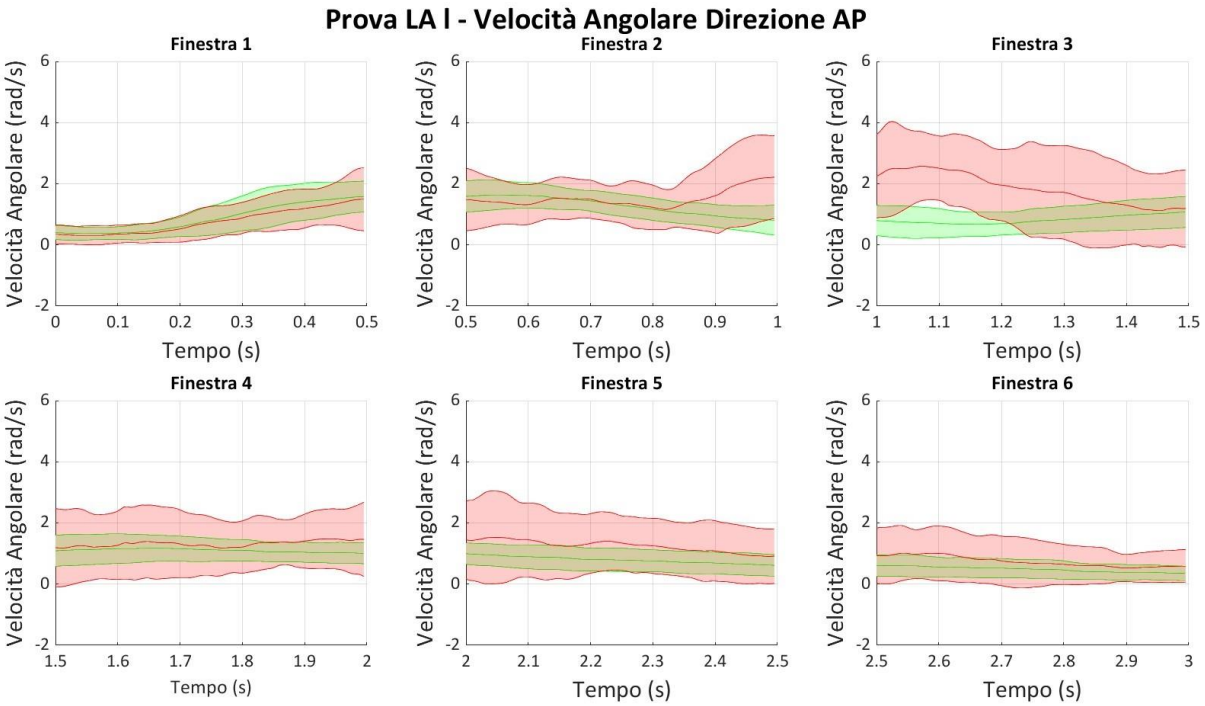

b)

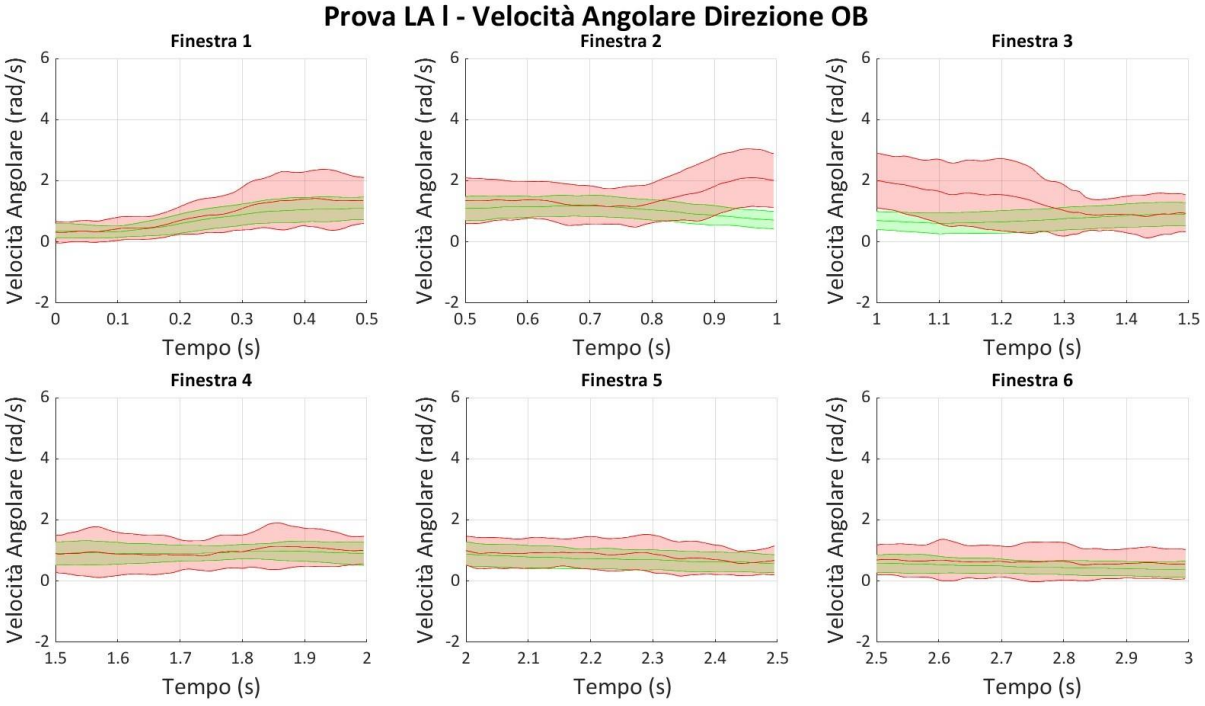

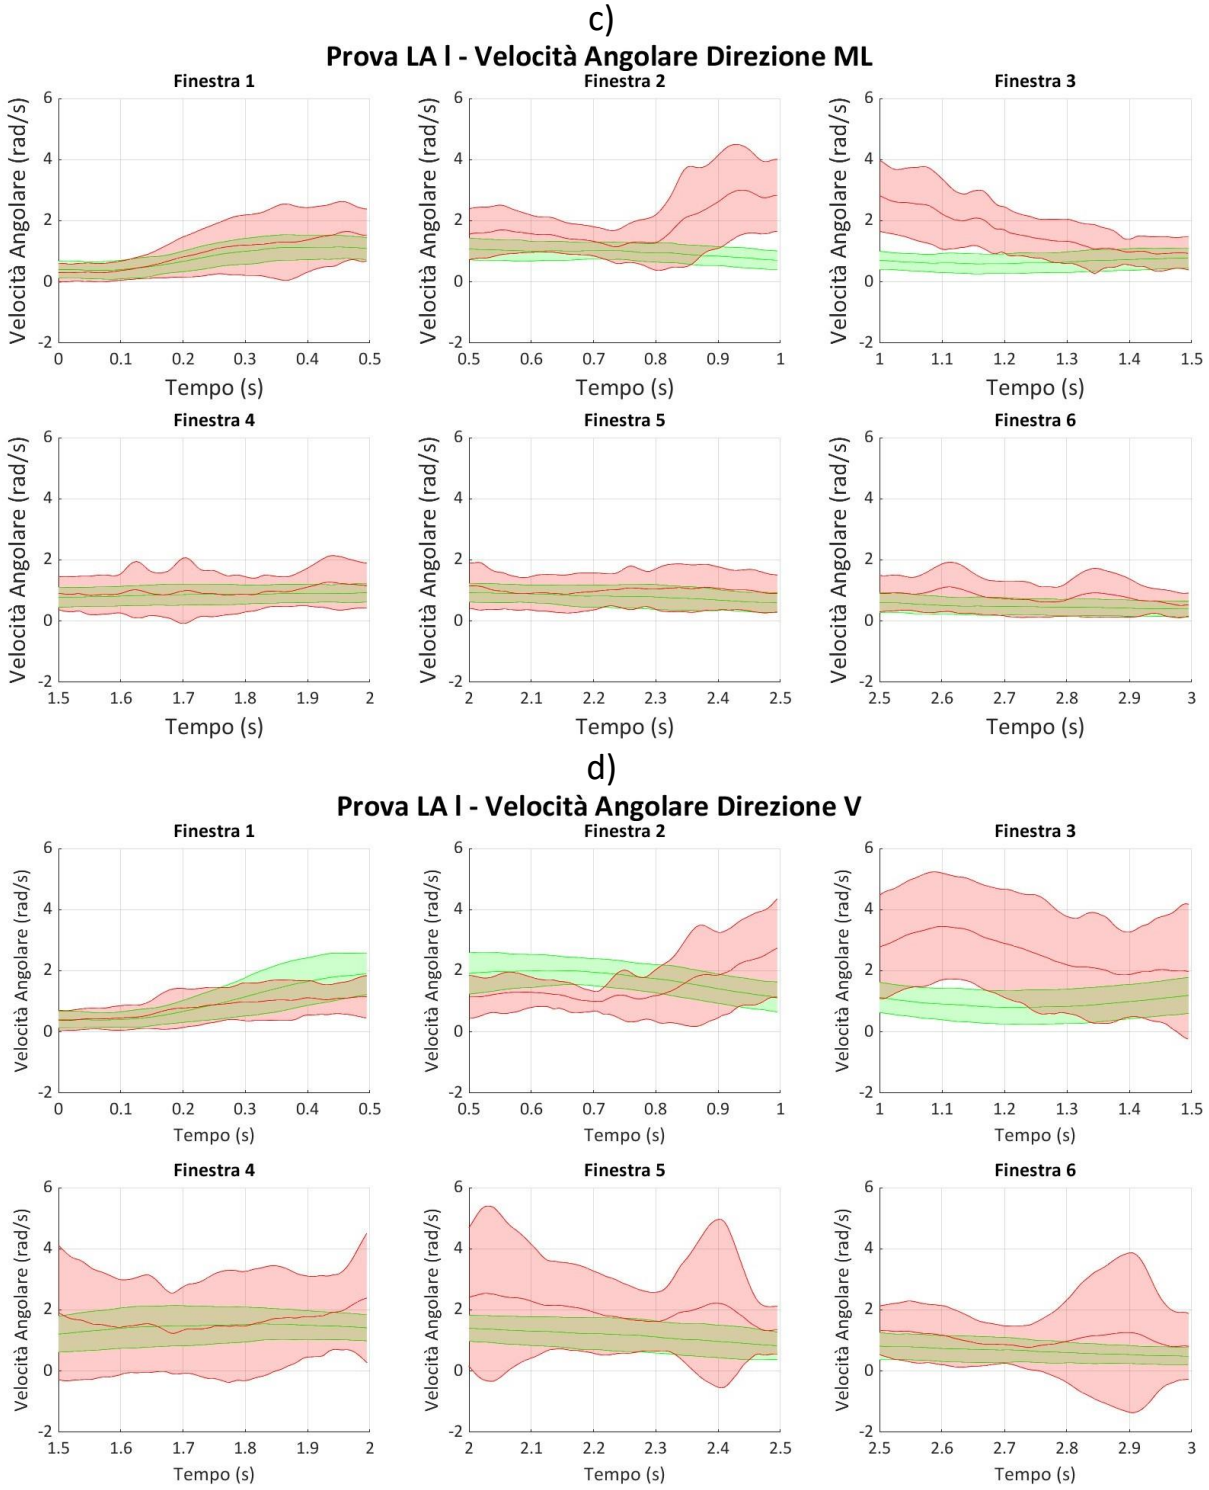

Figura A.7: boundlines per il segnale velocità angolare della prova LA_I con movimenti non impulsivi (in verde) e movimenti impulsivi (in rosso) sovrapposti per le differenti direzioni dei movimenti. a) Direzione AP, b) Direzione OB, c) Direzione ML, d) Direzione V.

I grafici relativi ai movimenti impulsivi dovuti all'attivazione del *buzzer* per l'accelerazione e la velocità angolare per la prova FR_I sono riportati in *Figura A.8*:

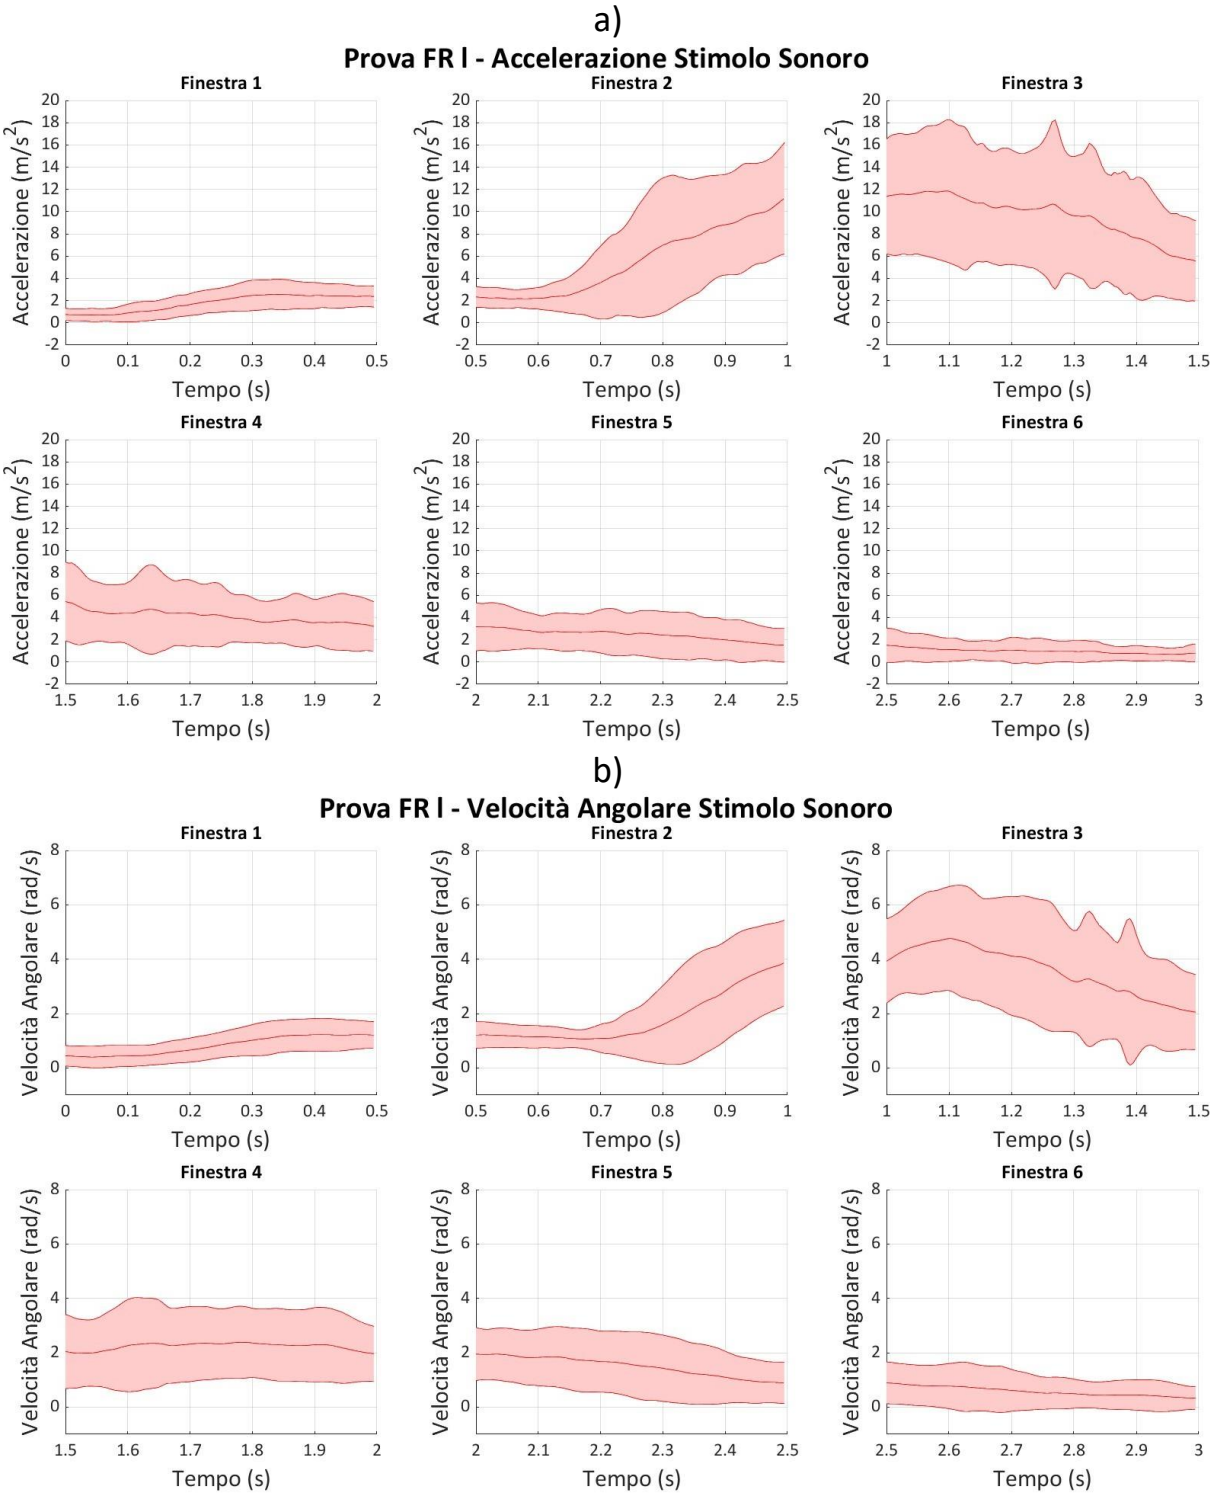

Figura A.8: *boundlines della prova FR_I con movimenti impulsivi dovuti all'attivazione del buzzer. a) Segnale accelerazione; b) Segnale velocità angolare.*

I grafici relativi ai movimenti impulsivi dovuti all'attivazione del *buzzer* per l'accelerazione e la velocità angolare per la prova LA_I sono riportati in *Figura A.9*:

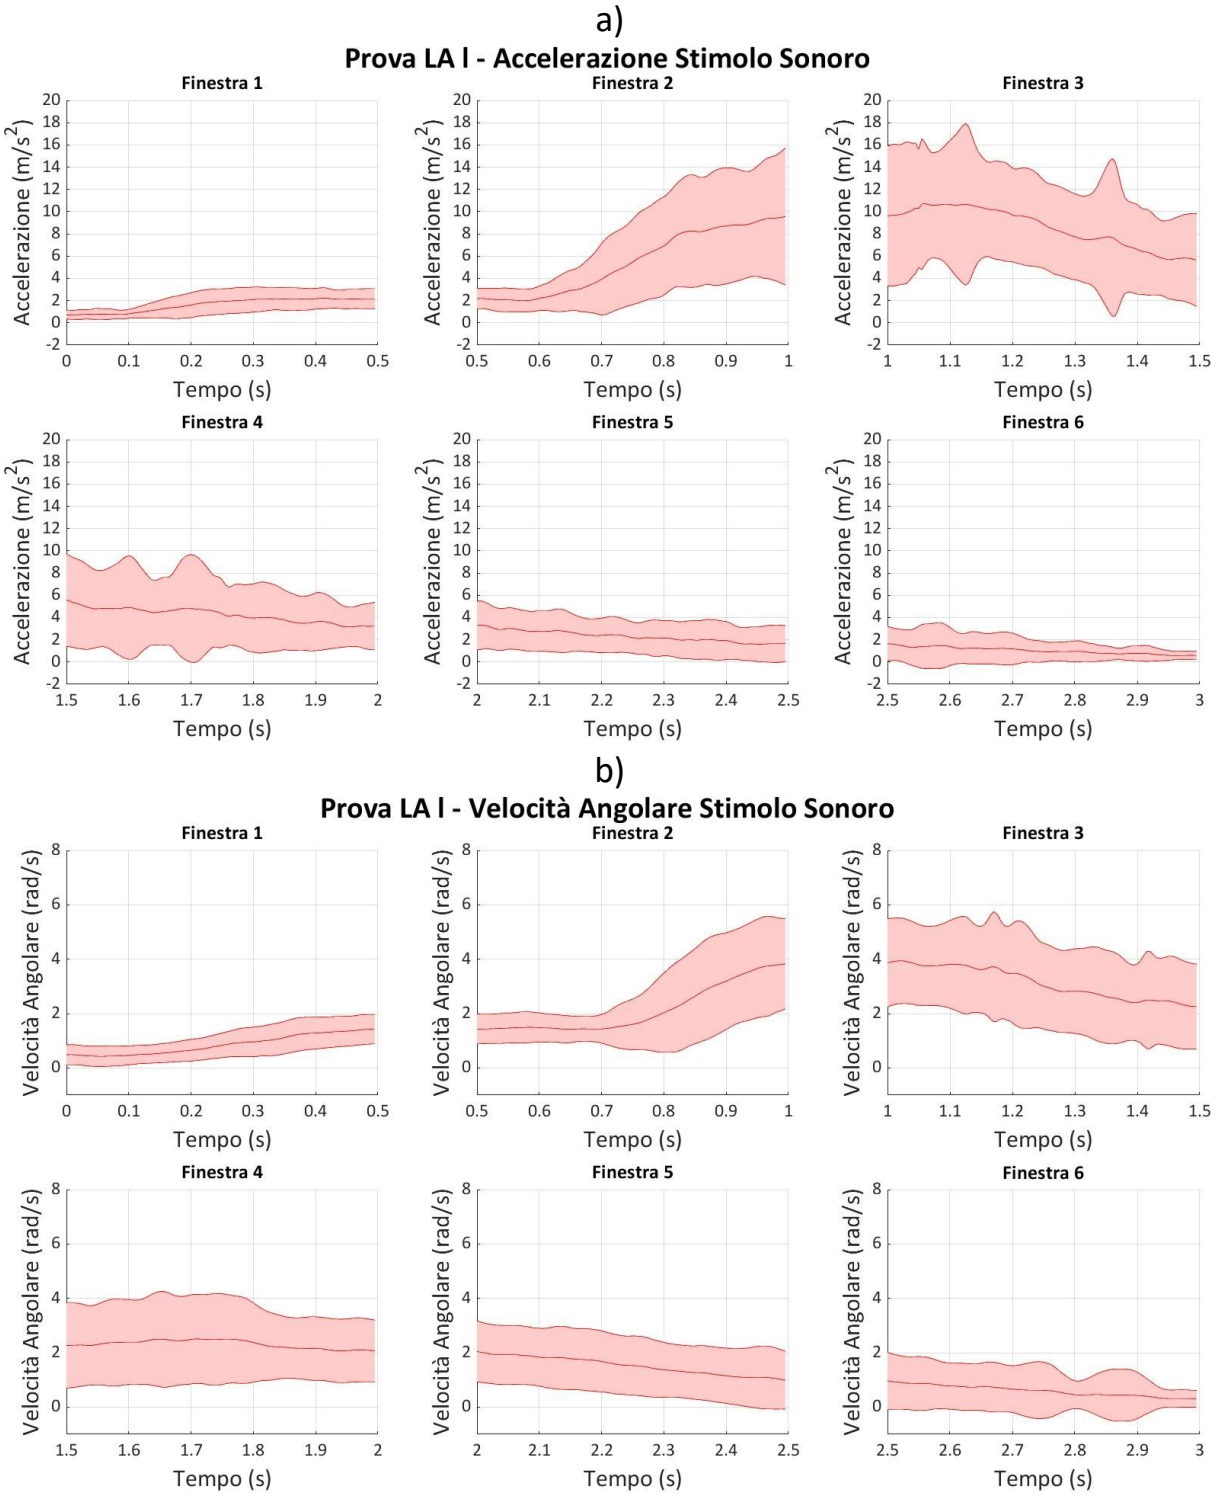

Figura A.9: boundlines della prova LA_I con movimenti impulsivi dovuti all'attivazione del buzzer. a) Segnale accelerazione; b) Segnale velocità angolare.

Scelta finestre impulsive per fase Deep Learning

In *Figura A.10* si riportano, per la prova FR_I, i valori medi di accelerazione (sull'asse y) e i valori medi della velocità angolare (asse x) distinguendo le sei finestre in cui è divisibile ogni movimento da 3 s.

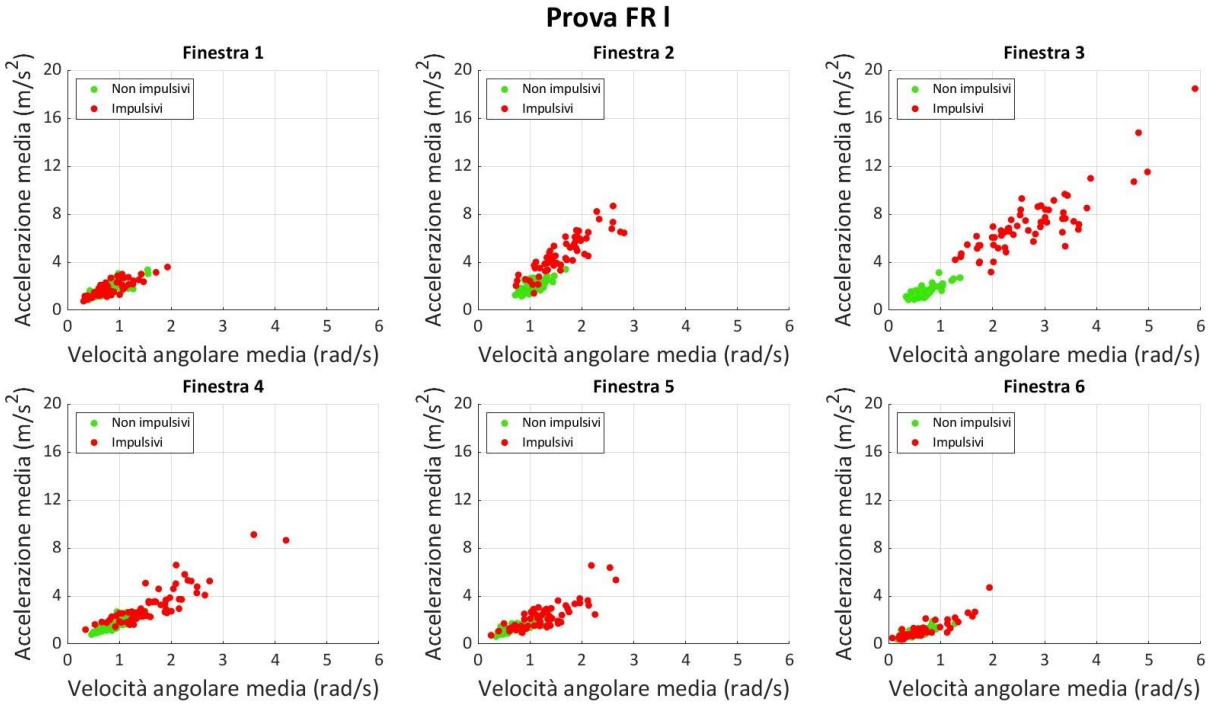

Figura A.10: distribuzione dei valori medi di accelerazione e velocità angolare, per la prova FR_I, a seconda della finestra da 0.5 s inclusa all'interno di un movimento da 3 s.

I risultati, per la prova FR_I, dell'analisi statistica (*Tabella A.1*) e dei *box plot* (*Figura A.11*), ottenuti utilizzando gli stessi dati diagrammati in *Figura A.10*, per scegliere quali finestre considerare impulsive per l'addestramento delle reti sono riportati di seguito.

	Accelerazione media	**Velocità angolare media**
	p-value	*p-value*
FINESTRA 1	0,8417	0,9551
FINESTRA 2	7,81E-18	2,71E-11
FINESTRA 3	1,67E-21	1,84E-21
FINESTRA 4	5,61E-13	2,57E-12
FINESTRA 5	2,12E-08	4,69E-09
FINESTRA 6	0,1882	0,4039

Tabella A.1: p-value ottenuti con il test di Wilcoxon, confrontando i valori di accelerazione media e velocità angolare media dei movimenti non impulsivi e dei movimenti impulsivi per la prova FR_I

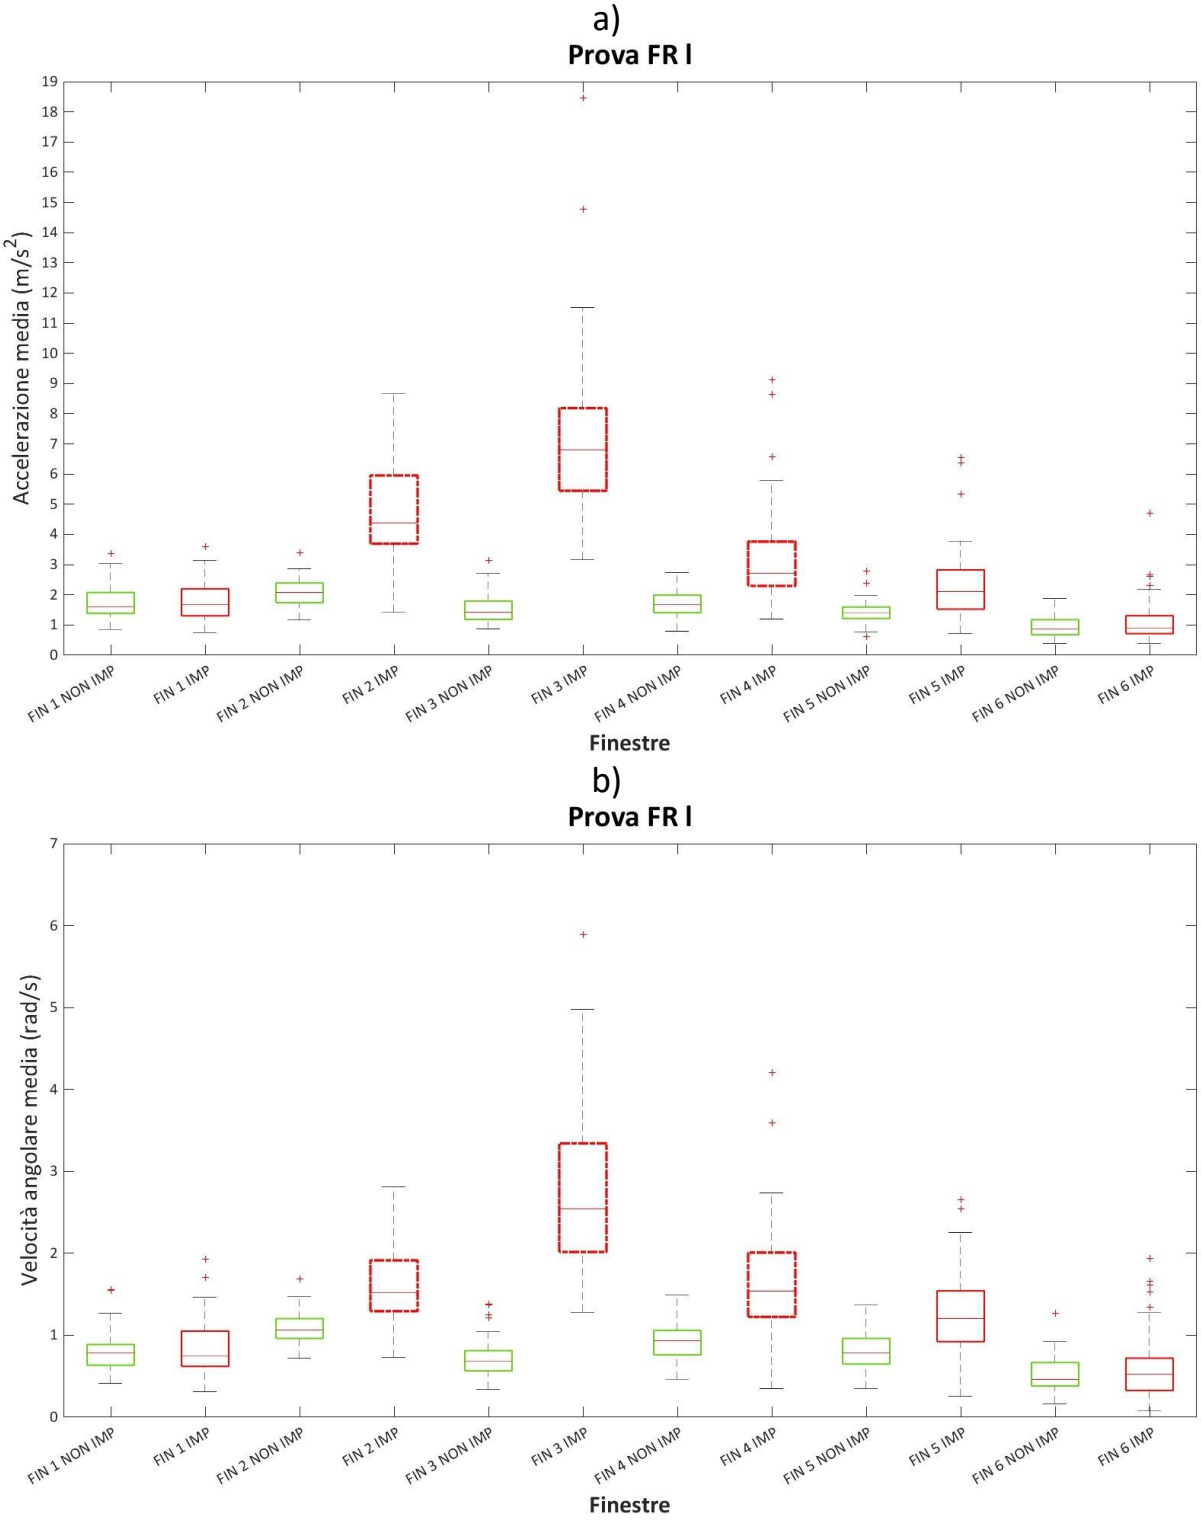

Figura A.11: box plot dei valori medi a) dell'accelerazione e b) della velocità angolare, entrambi per la prova FR_I.

In *Figura A.12* si riportano, per la prova LA_I, i valori medi di accelerazione (sull'asse y) e i valori medi della velocità angolare (asse x) distinguendo le sei finestre in cui è divisibile ogni movimento da 3 s.

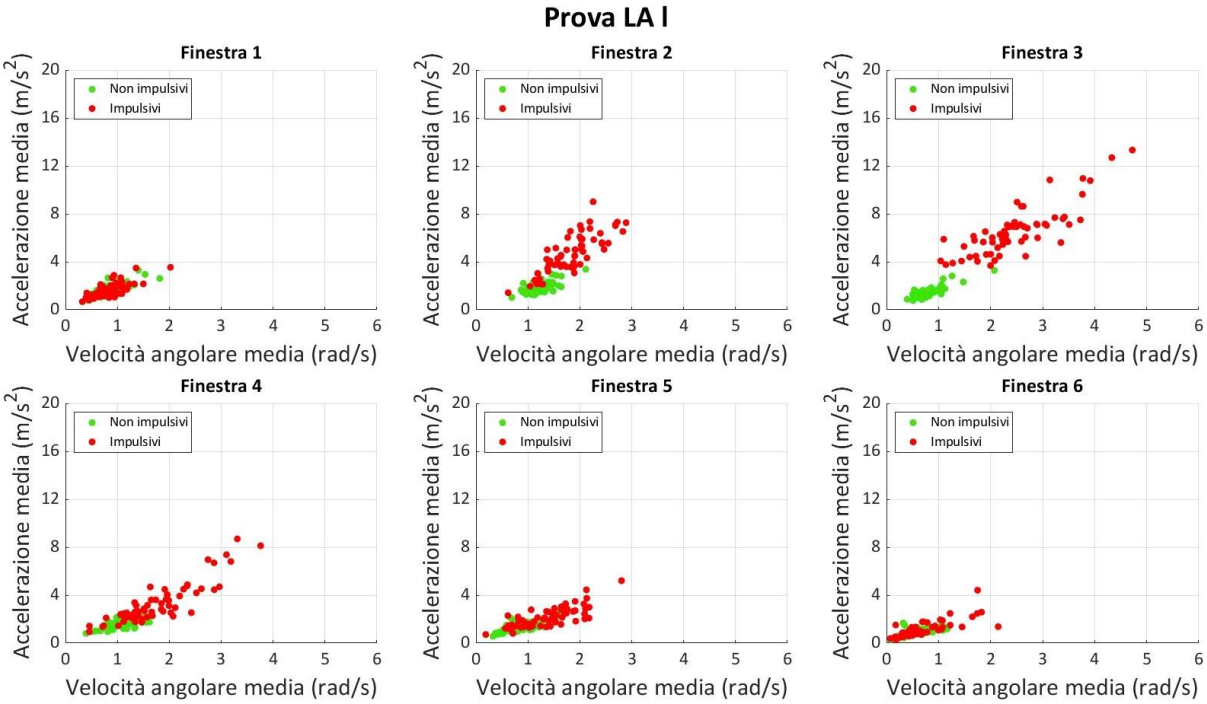

Figura A.12: distribuzione dei valori medi di accelerazione e velocità angolare, per la prova LA_I, a seconda della finestra da 0.5 s inclusa all'interno di un movimento da 3 s.

I risultati, per la prova LA_I, dell'analisi statistica (*Tabella A.2*) e dei *box plot* (*Figura A.13*), ottenuti utilizzando gli stessi dati diagrammati in *Figura A.12*, per scegliere quali finestre considerare impulsive per l'addestramento delle reti sono riportati di seguito.

	Accelerazione media	**Velocità angolare media**
	p-value	*p-value*
FINESTRA 1	0,6972	0,9837
FINESTRA 2	5,46E-18	1,78E-12
FINESTRA 3	1,67E-21	8,77E-21
FINESTRA 4	6,53E-15	5,62E-10
FINESTRA 5	1,89E-10	2,00E-08
FINESTRA 6	0,0367	0,1035

Tabella A.2: p-value ottenuti con il test di Wilcoxon, confrontando i valori di accelerazione media e velocità angolare media dei movimenti non impulsivi e dei movimenti impulsivi, per la prova LA_I.

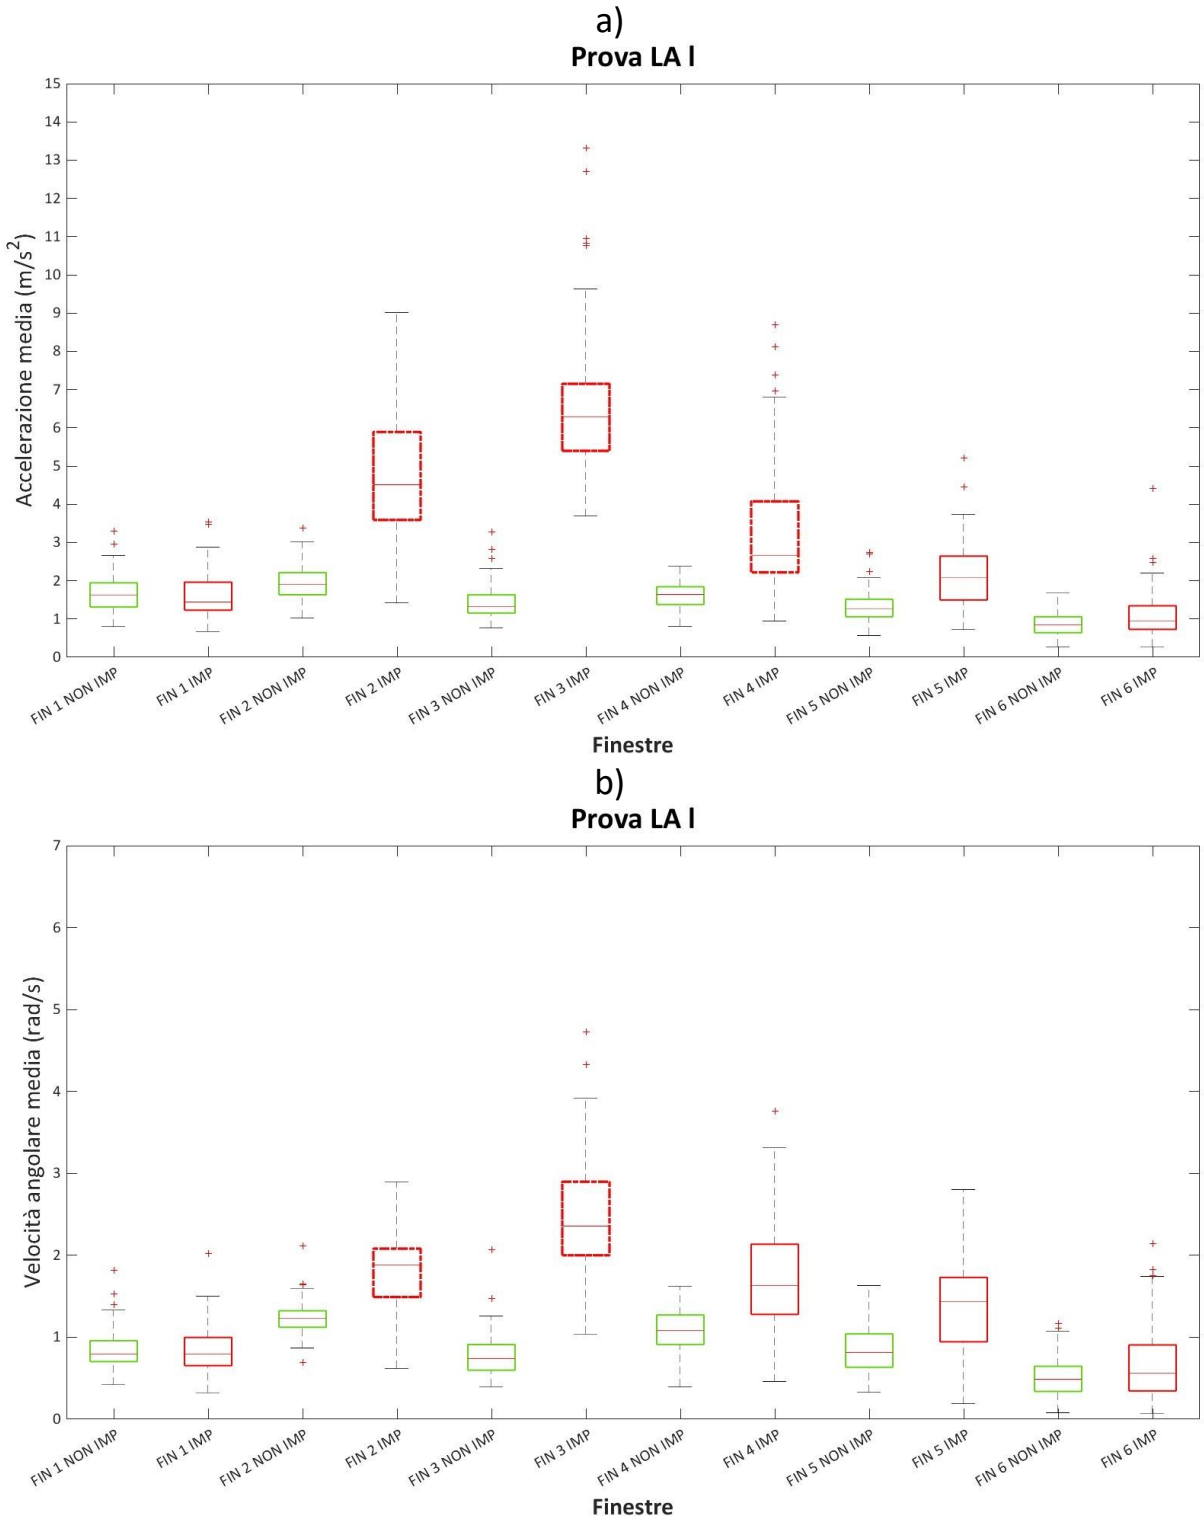

Figura A.13: box plot dei valori medi a) dell'accelerazione e b) della velocità angolare, entrambi per la prova LA_l.

BIBLIOGRAFIA

Angleraud, A., Ekrekli, A., Samarawickrama, K., Sharma, G., & Pieters, R. (2024). Sensor-based human–robot collaboration for industrial tasks. *Robotics and Computer-Integrated Manufacturing*, *86*. https://doi.org/10.1016/j.rcim.2023.102663

Anguita, D., Ghio, A., Oneto, L., Parra, X., & Reyes-Ortiz, J. L. (2013). A public domain dataset for human activity recognition using smartphones. *ESANN 2013 Proceedings, 21st European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*.

APDM - wearable technologies. (n.d.). APDM, Inc. USA. Retrieved December 2, 2023, from https://apdm.com/wearable-sensors/

Baratta, A., Cimino, A., Gnoni, M. G., & Longo, F. (2022). Human Robot Collaboration in Industry 4.0: a literature review. *Procedia Computer Science*, *217*, 1887–1895. https://doi.org/10.1016/j.procs.2022.12.389

Bdiwi, M., Pfeifer, M., & Sterzing, A. (2017). A new strategy for ensuring human safety during various levels of interaction with industrial robots. *CIRP Annals - Manufacturing Technology*, *66*(1), 453–456. https://doi.org/10.1016/j.cirp.2017.04.009

Chelli, A., & Patzold, M. (2019). A Machine Learning Approach for Fall Detection and Daily Living Activity Recognition. *IEEE Access*, *7*, 38670–38687. https://doi.org/10.1109/ACCESS.2019.2906693

Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., & Peter Campbell, J. (2020). Introduction to machine learning, neural networks, and deep learning. *Translational Vision Science and Technology*, *9*(2). https://doi.org/10.1167/tvst.9.2.14

Come funziona e come è possibile migliorare l'addestramento delle reti neurali. (2020, March 20). https://www.zerounoweb.it/resource-center/data-science-machine-learning/come-funziona-e-come-e-possibile-migliorare-laddestramento-delle-reti-neurali/

Create Simple Sequence Classification Network Using Deep Network Designer. (n.d.). Retrieved November 23, 2023, from https://it.mathworks.com/help/deeplearning/gs/create-simple-sequence-classification-network.html?lang=en

Cross-validation: evaluating estimator performance. (n.d.). Retrieved November 22, 2023, from https://scikit-learn.org/stable/modules/cross_validation.html

Digo, E., Caselli, E., Polito, M., Antonelli, M., Gastaldi, L., & Pastorelli, S. (2023). Test–Retest Repeatability of Human Gestures in Manipulation Tasks. *Applied Sciences (Switzerland)*, *13*(13). https://doi.org/10.3390/app13137808

Görür, O. C., Rosman, B., Sivrikaya, F., & Albayrak, S. (2018, March). Social Cobots: Anticipatory Decision-Making for Collaborative Robots Incorporating Unexpected Human Behaviors. *HRI'18:2018 ACM/IEEE International Conference on Human Robot Interaction, March 5-8,2018*.

Haddadin, S., & Croft, E. (2016). *Erratum to: Physical Human–Robot Interaction* (pp. 1835–1874). https://doi.org/10.1007/978-3-319-32552-1_81

Hentout, A., Aouache, M., Maoudj, A., & Akli, I. (2019). Human–robot interaction in industrial collaborative robotics: a literature review of the decade 2008–2017. *Advanced Robotics*, *33*(15–16), 764–799. https://doi.org/10.1080/01691864.2019.1636714

Heo, Y. J., Kim, D., Lee, W., Kim, H., Park, J., & Chung, W. K. (2019). Collision detection for industrial collaborative robots: A deep learning approach. *IEEE Robotics*

and Automation Letters, *4*(2), 740–746. https://doi.org/10.1109/LRA.2019.2893400

Hussain, A., Zafar, K., Baig, A. R., Almakki, R., Alsuwaidan, L., & Khan, S. (2022). Sensor-Based Gym Physical Exercise Recognition: Data Acquisition and Experiments. *Sensors*, *22*(7). https://doi.org/10.3390/s22072489

Intelligenza artificiale. (2008). Treccani - Enciclopedia Della Scienza e Della Tecnica. https://www.treccani.it/enciclopedia/intelligenza-artificiale_%28Enciclopedia-della-Scienza-e-della-Tecnica%29/

Janiesch, C., Zschech, P., & Heinrich, K. (2021). *Machine learning and deep learning*. https://doi.org/10.1007/s12525-021-00475-2/Published

Koskimäki, H., Huikari, V., Siirtola, P., Laurinen, P., & Röning, J. (2009). Activity recognition using a wrist-worn inertial measurement unit: A case study for industrial assembly lines. *2009 17th Mediterranean Conference on Control and Automation, MED 2009*, *2009-January*. https://doi.org/10.1109/MED.2009.5164574

Lasota, P. A., & Shah, J. A. (2015). Analyzing the effects of human-aware motion planning on close-proximity human-robot collaboration. *Human Factors*, *57*(1). https://doi.org/10.1177/0018720814565188

lillietest - Lilliefors test. (n.d.). Retrieved November 24, 2023, from https://it.mathworks.com/help/stats/lillietest.html

Muñoz-Organero, M., Powell, L., Heller, B., Harpin, V., & Parker, J. (2019). Using recurrent neural networks to compare movement patterns in ADHD and normally developing children based on acceleration signals from the wrist and ankle. *Sensors (Switzerland)*, *19*(13). https://doi.org/10.3390/s19132935

Ojetola, O., Gaura, E., & Brusey, J. (2015). Data set for fall events and daily activities from inertial sensors. *Proceedings of the 6th ACM Multimedia Systems Conference, MMSys 2015*. https://doi.org/10.1145/2713168.2713198

Özdemir, A. T., & Barshan, B. (2014). Detecting falls with wearable sensors using machine learning techniques. *Sensors (Switzerland)*, *14*(6), 10691–10708. https://doi.org/10.3390/s140610691

Pesenti, M., Invernizzi, G., Mazzella, J., Bocciolone, M., Pedrocchi, A., & Gandolla, M. (2023). IMU-based human activity recognition and payload classification for low-back exoskeletons. *Scientific Reports*, *13*(1). https://doi.org/10.1038/s41598-023-28195-x

Polito, M., Digo, E., Pastorelli, S., & Gastaldi, L. (2023). Deep Learning Technique to Identify Abrupt Movements in Human-Robot Collaboration. *Mechanisms and Machine Science*, *134 MMS*. https://doi.org/10.1007/978-3-031-32439-0_9

Sánchez-Fernández, L. P., Sánchez-Pérez, L. A., Concha-Gómez, P. D., & Shaout, A. (2023). Kinetic tremor analysis using wearable sensors and fuzzy inference systems in Parkinson's disease. *Biomedical Signal Processing and Control*, *84*. https://doi.org/10.1016/j.bspc.2023.104748

Schmidtler, J., Knott, V., Hölzel, C., & Bengler, K. (2015). Human Centered Assistance Applications for the working environment of the future. *Occupational Ergonomics*, *12*(3), 83–95. https://doi.org/10.3233/OER-150226

Sulkes, S. B. (2022). *Disturbo da deficit di attenzione/iperattività*. Manuale MSD - Versione per i Professionisti. https://www.msdmanuals.com/it-it/professionale/pediatria/disturbi-dell-apprendimento-e-dello-sviluppo/disturbo-da-deficit-di-attenzione-iperattivit%C3%A0

Vanmechelen, I., Bekteshi, S., Konings, M., Feys, H., Desloovere, K., Aerts, J. M., & Monbaliu, E. (2020). Upper limb movement characteristics of children and youth with dyskinetic cerebral palsy – A sensor approach. *Gait & Posture*, *81*, 377–378. https://doi.org/10.1016/j.gaitpost.2020.08.088

Villani, V., Pini, F., Leali, F., & Secchi, C. (2018). Survey on human–robot collaboration in industrial settings: Safety, intuitive interfaces and applications. *Mechatronics*, *55*, 248–266. https://doi.org/10.1016/j.mechatronics.2018.02.009

Wang, L., Gao, R., Váncza, J., Krüger, J., Wang, X. V., Makris, S., & Chryssolouris, G. (2019). Symbiotic human-robot collaborative assembly. *CIRP Annals*, *68*(2), 701–726. https://doi.org/10.1016/j.cirp.2019.05.002

Watanabe, Y., & Kimura, M. (2020). Gait identification and authentication using LSTM based on 3-axis accelerations of smartphone. *Procedia Computer Science*, *176*, 3873–3880. https://doi.org/10.1016/j.procs.2020.09.001

What Is a Recurrent Neural Network? (n.d.). Retrieved November 10, 2023, from https://it.mathworks.com/discovery/rnn.html

Xu, X., Lu, Y., Vogel-Heuser, B., & Wang, L. (2021). Industry 4.0 and Industry 5.0—Inception, conception and perception. *Journal of Manufacturing Systems*, *61*. https://doi.org/10.1016/j.jmsy.2021.10.006

Zhao, Y., Dong, F., Sun, T., Ju, Z., Yang, L., Shan, P., Li, L., Lv, X., & Lian, C. (2024). Image expression of time series data of wearable IMU sensor and fusion classification of gymnastics action. *Expert Systems with Applications*, *238*. https://doi.org/10.1016/j.eswa.2023.121978