UNIVERSITÀ POLITECNICA DELLE MARCHE

FACOLTÀ DI INGEGNERIA DELL'INFORMAZIONE

Corso di Laurea in ingegneria biomedica

Riconoscimento di attività di vita quotidiana da segnali mioelettrici e inerziali

Recognition of activities of daily living from myoelectric and inertial signals

Relatore:

Prof.ssa Federica Verdini

Primo correlatore:

Prof. Alessandro Mengarelli

Secondo correlatore:

Ing. Andrea Tigrini

Tesi di Laurea di:

Filippo Principi

Anno Accademico **2022**/ **2023**

Abstract

L'hand gesture recognition(HGR) è un campo dell'ingegneria biomedica che ha avuto un enorme sviluppo negli ultimi decenni e si occupa di fornire strumenti e dati per la progettazione di protesi e robot, per l'elaborazione dei segnali biologici e per la medicina riabilitativa.
L'analisi del gesto può essere svolta a partire da misure cinematiche ottenute da sistemi optoelettronici o di motion capture, da segnali dinamici registrati da sensori inerziali posizionati sui segmenti anatomici di cui si vuole registrare il movimento.
Informazione determinante per la caratterizzazione del gesto è ottenibile anche tramite l'analisi dell'attività elettrica dei muscoli coinvolti.
Questo studio verte sull'utilizzo di un dispositivo semplice ed economico rispetto ad altri per l'acqiusizione di segnali inerziali ed elettromiografici e sulla valutazione della sua efficienza nella corretta classificazione di gesti della vita quotidiana.
L'ulteriore obiettivo che ci si è posti è stato quello di verificare l'accuratezza del riconoscimento del gesto sulla base di alcune features estratte dai segnali EMG ed accelerometrici, per verificare se la fusione delle informazioni provenienti dalle due tipologie di segnale è necessaria per ottenere accuratezze nella classificazione o se le sole features estratte da una tipologia di segnale possono essere sufficienti.

Indice

1 Introduzione **1**

1.1 Introduzione 1

1.2 Obiettivo 2

2 Elettromiografia e unità inerziale **3**

2.1 Letteratura 3

2.2 Segnale elettromiografico 6

2.2.1 Elettromiografia 6

2.2.2 Elettrodi 7

2.2.3 Problematiche di acquisizione del segnale 9

2.3 Inertial Measurement Unit (IMU) 11

3 Device e procedure utilizzati **15**

3.1 Strumentazione 15

3.2 Protocollo di misura 18

3.3 Metodi di classificazione 19

3.3.1 Confusion matrix 19

3.3.2 Algoritmi di classificazione 20

4 Studio del segnale **25**

4.1 Acquisizione dati 25

4.2 Preprocessing 30

4.3 Estrazione features 32

4.3.1 Scelta delle features 33

5 Classificazione e risultati **43**

5.1 Creazione delle labels 43

5.1.1 Prove con diversi modelli di classificazione 45

5.2 Risultati e discussione 47

5.2.1 Risultati di matrice con dati EMG, accelerometrici e EMG e accelerometrici insieme 47

5.2.2 Robustezza del modello 54

5.2.3 Confronto con dati bilanciati 55

6 Conclusioni **57**

Elenco delle figure

2.1 EMG del gesto bere da bicchiere canale 1 6
2.2 Elettrodi EMG intramuscolare 7
2.3 Elettrodi EMG di superficie[1] 8
2.4 Elettrodi EMG di superficie monouso 8
2.5 Rumore di rete[2] 10
2.6 Artefatti da movimento[3] 11
2.7 Inertial measurement unit[4] 12
2.8 Direzioni assi x, y e z dell'IMU nel Myo armband[5] 12
2.9 Segnale accelerometrico del gesto bere da bicchire assi x, y, z 13
2.10 segnale giroscopico del gesto bere da bicchire assi x, y, z 13

3.1 Dispositivo MYO armband[6] 15
3.2 Dispositivo MYO armband su avambraccio[7] 16
3.3 Algoritmo KNN[8] 21
3.4 Algoritmo Decision tree[9] 21
3.5 Algoritmo LDA[10] 22
3.6 Algoritmo SVM[11] 23

4.1 Segnale elettromigrafico 8 canali nel caso del gesto di avvitamento sul piano orizzontale 28
4.2 Segnale accelerometrico, componenti x,y,z nel caso del gesto di avvitamento sul piano orizzontale 28
4.3 Segnale giroscopico, componenti x,y,z nel caso del gesto di avvitamento sul piano orizzontale 29
4.4 Istanti di start segnale giroscopico del gesto bere da bicchiere 30
4.5 Istanti di stop segnale giroscopico del gesto bere da bicchiere 31
4.6 MAV segnale EMG del gesto martellare su piano verticale 33

4.7 MAV segnale accelerometrico del gesto martellare su piano verticale 34
4.8 RMS segnale EMG del gesto martellare su piano verticale 35
4.9 RMS segnale accelerometrico del gesto martellare su piano verticale 35
4.10 IAV segnale EMG del gesto martellare su piano verticale 36
4.11 IAV segnale accelerometrico del gesto martellare su piano verticale 37
4.12 WL segnale EMG del gesto martellare su piano verticale 38
4.13 WL segnale accelerometrico del gesto martellare su piano verticale 38
4.14 ZC segnale EMG del gesto martellare su piano verticale 39
4.15 ZC segnale accelerometrico del gesto martellare su piano verticale 40
4.16 ZC segnale EMG del gesto martellare su piano verticale 41
4.17 SSC segnale accelerometrico del gesto martellare su piano verticale 41

5.1 MAV gesto bere da bicchiere con label 45
5.2 Risultati test utlilizzando Decision Tree 45
5.3 Risultati test utlilizzando LDA 46
5.4 Risultati test utlilizzando SVM 46
5.5 Risultati train e test dati elettromiografici 47
5.6 Confusion matrix test dati elettromiografici KNN 48
5.7 Scatter plot test dati elettromiografici KNN 48
5.8 Risultati train e test dati accelerometrici 49
5.9 Confusion matrix test dati accelerometrici KNN 50
5.10 Scatter plot test dati accelerometrici KNN 50
5.11 Risultati train e test dati accelerometrici e accelerometrici 51
5.12 Confusion matrix test dati elettromiografici e accelerometrici KNN 52
5.13 Scatter plot test dati elettromiografici e accelerometrici KNN 52
5.14 Risultati con 50% dei dati 54
5.15 Confusion matrix con 50%di dati 55
5.16 Risultati train e test matrice solo contrazioni 56
5.17 Confusion matrix matrice solo contrazioni 56

Elenco delle tabelle

5.1 Label gesti. 44
5.2 Accuratezza train e test. 53

Capitolo 1

Introduzione

1.1 Introduzione

Negli ultimi decenni l'Hand gesture recognition (HGR) è stato uno dei campi di maggior sviluppo in ambito biomedicale. Esso prevede l'interazione di nozioni provenienti dall'ingegneria biomedica, elettronica, informatica e dalla medicina per fornire informazioni utili allo sviluppo di tecnologie avanzate che possano essere utilizzate in diversi ambiti della medicina e dell'assistenza sanitaria come ad esempio: nella diagnostica, nella riabilitazione in caso di lesioni muscolari e neurologiche, nella progettazione di protesi per soggetti amputati, nella chirurgia assistita da robot per controllare il movimento degli stessi o nell'assistenza di persone con disabilità motorie.
I sistemi HGR, utilizzando ad esempio segnali dell'elettromiografia di superficie (sEMG), possono essere considerati una delle tecnologie più importanti per realizzare sistemi efficienti di interfaccia uomo-macchina (HMI). I sistemi HMI, che sfruttano algoritmi di intelligenza artificiale per il riconoscimento dei gesti della mano sulla base di segnali fisiologici, sono applicabili a un'ampia gamma di applicazioni tra cui protesi, neurorobotica, esoscheletri e ambienti di realtà mista (aumentata/virtuale), alcuni dei quali rivolti a individui normodotati.
In particolare, l'HGR basato sul sEMG è stato un argomento di crescente interesse per lo sviluppo di sistemi di assistenza per aiutare le persone con arti amputati. In generale, i dispositivi protesici mioelettrici funzionano classificando i modelli esistenti sulla base dell'informazione presente sui segnali sEMG raccolti e sintetizzando i gesti previsti. Più specificamente, per migliorare l'efficienza e le prestazioni dei sistemi protesici della mano, sono stati progettati diversi algoritmi di intelligenza artificiale (AI) che vanno dai modelli convenzionali di Machine Learning (ML) alle architetture Deep Neural Network (DNN) per il riconoscimento del gesto della mano basato su dispositivi protesici mioelettrici. I modelli basati su ML comprendono approcci tradizionali come Support Vector

Machines (SVM), Linear Discriminant Analysis (LDA) e k -Nearest Neighbours (kNN) mentre i modelli basati su DNN sono costituiti da framework come Reti neurali convoluzionali (CNN), reti neurali ricorrenti (RNN) e architetture basate su trasformatori.[12]

1.2 Obiettivo

L'obiettivo dello studio è quello di acquisire il segnale inerziale ed elettromiografico da un dispositivo meno complesso e che permette una più facile vestizione rispetto ad altri come il Myo armband per verificare la capacità di riconoscere gesti della vita quotidiana sulla base di features estratte da segnali accelerometrici, da segnali elettromiografici e dalla fusione delle features ottenute da entrambe le tipologie di segnale.

Capitolo 2

Elettromiografia e unità inerziale

2.1 Letteratura

I gesti della mano umana sono generati dall'attività coordinata dei muscoli del braccio. Essi sono attivati da comandi neurali affinchè si verifichi il gesto della mano. La contrazione e il rilassamento di questi muscoli producono segnali bioelettrici che possono essere misurati sulla superficie del braccio e sono chiamati elettromiogramma di superficie (sEMG).
I sistemi di riconoscimento dei gesti delle mani (HGR) basati su segnali elettromiografici (EMG) e segnali inerziali sono stati studiati per diverse applicazioni negli ultimi anni come, ad esempio, per le interfacce uomo-macchina, sistemi di riabilitazione muscolare, progettazione di protesi, applicazioni robotiche e realtà aumentata[13, 14, 15].
Diversi tipi di sistemi di HGR utilizzano metodi basati sulla visione, ad esempio Kinect e Leap Motion Sensor. Tuttavia, le prestazioni di questi metodi possono essere influenzate da problemi di occlusione e limitata illuminazione, nonché dalla distanza tra il sensore e la mano[16].
A causa dei limiti delle telecamere e della qualità delle immagini acquisite, molti lavori precedenti[17, 18], che includevano principalmente approcci HGR tradizionali basati sulla visione che utilizzano telecamere o sensori ultrasonici o ottici, non possono soddisfare la situazione pratica a causa di alcune suddette limitazioni[19]. Per questo, i sistemi HGR basati su segnali EMG o IMU sono preferiti per diverse applicazioni.
I gesti delle mani, in base al tipo di movimento, sono classificati come statici e dinamici. Quando il gesto è statico i muscoli scheletrici sono in contrazione costante (non c'è movimento durante il gesto), quando invece è dinamico, i muscoli scheletrici sono in contrazione, ma essa non è costante, il che indica che c'è movimento durante il gesto[20].
È importante sottolineare che i segnali EMG sono spesso selezionati quando vengono svolti gesti

statici poiché le informazioni provenienti dalla sola attività muscolare sono solitamente sufficienti per caratterizzare questo tipo di gesto. D'altra parte, i segnali IMU sono selezionati per caratterizzare i gesti dinamici poiché questo tipo di gesto dipende principalmente dai movimenti della mano e del braccio.

Pertanto, una combinazione di segnali EMG e IMU per riconoscere i gesti delle mani potrebbe aumentare le prestazioni dei sistemi HGR poiché vengono analizzate più informazioni per ogni gesto. Tuttavia, questo è ancora un problema di ricerca aperto.[16]

Infatti, l'elettromiografia di superficie nella maggior parte dei sistemi di interfaccia uomo-macchina, riabilitazione assistita, ecc. è utilizzata come fonte primaria di informazioni dato che il segnale EMG riflette l'intenzione motoria del soggetto. D'altra parte, il segnale EMG presenta alcune sfide perché esso può essere rumoroso, difficile da modellare a causa della natura stocastica, ritardato e suscettibile alle variazioni delle condizioni di utilizzo. Ciò potrebbe rendere limitate le strategie di controllo basate sull'EMG e con maggiori probabilità di presentare fallimenti.

Per mitigare alcuni di questi problemi, sono state utilizzate strategie come addestrare un sistema a riconoscere e ridurre questo effetto.

Diversi studi sono stati sostenuti in merito al campo dell'hand gesture recognition e la maggior parte di essi utilizza come fonte principale di dati l'elettromiografia [21, 5, 22]a cui è spesso affiancato uno studio dei segnali inerziali provenienti dall' unità IMU, ma anche altri tipi di tecniche che permettono di ottenere più informazioni e di conseguenza risultati migliori.

Uno studio di particolare importanza è quello di Zhang et al.[19], in questo articolo è descritto un sistema indossabile in grado di raccogliere facilmente i dati provenienti dai sensori come quelli inerziale, elettromiografico e del sensore di pressione. Questo sistema è composto da due dispositivi indossabili, uno è il Myo armband, e l'altro è un guanto autoprogettato dagli autori personalizzabile costituito da un array di sensori di pressione piezoelettrici per analizzare i modelli di movimento delle dita.

Lo studio ha dimostrato che l'utilizzo simultaneo di questi due devices ha ottenuto risultati soddisfacenti per quanto riguarda l'accuratezza nella classificazione di gesti dinamici e gesti aerei.

Un altro esempio degno di nota è quello di Cengiz Tepe e Muhammed Erdim [23]; in questo studio, è stata ottenuta una classificazione affidabile per i dati delle dita sEMG acquisiti da armband Myo posizionata sull'avambraccio inferiore. Al fine di migliorare la classificazione, sono stati utilizzati i segnali giroscopici ottenuti dai sensori posizionati sulle dita, non precedentemente utilizzati in altri studi.

Per permettere i movimenti delle dita, infatti, i muscoli dell'avambraccio producono dei movimenti sulla cute sovrastante durante la loro contrazione. Il movimento di questi muscoli sull'avambraccio è principalmente sull'asse z, ortogonale alla superficie della cute e al piano del sensore. Pertanto, i dati provenienti dalla suddetta componente del segnale del giroscopio(canale z) hanno fornito i migliori risultati ai fini della classificazione.

Dati gli obiettivi che ci siamo posti di raggiungere in questo studio, è adeguato citare due articoli in cui si utilizzano dispositivi semplici per l'HGR e in cui vengono considerati segnali elettromiografici e inerziali per la classificazione.

Il primo articolo, di Juan Pablo Vásconez et al.[16] verte sul confronto tra due dispositivi, in particolare il Myo armband e il sensore G-force.

È stato utilizzato un dataset composto da 85 soggetti e sono state utilizzate informazioni di segnali EMG e IMU di 11 gesti eseguiti (5 statici e 6 dinamici) acqisiti con entrambi i devices.

Guardando ai risultati, il Myo armband ha ottenuto un'accuratezza superiore del 6.5% per i gesti dinamici e del 4.3% nei gesti statici rispetto al dispositivo G-force ottenendo anche risultati migliori dal punto di vista dell'efficienza della classificazione con una standard deviation solo del 1.37%.

Il secondo articolo, di Nadja Arantes et al.[24] si concentra sul valutare i risultati della classificazione delle features estratte dall'EMG e dal sensore inerziale ottenute da individui con arti sani e soggetti con arto amputato.

I risultati ottenuti in questa ricerca hanno evidenziato, confrontando visivamente il segnale EMG di entrambi i gruppi, che nel caso dei soggetti con arti amputati, l'ampiezza del segnale è inferiore rispetto a quella del segnale negli individui con arti sani. Inoltre, è possibile osservare una maggiore attività di co-contrazione nel segnale EMG dei soggetti con arti amputati.

In questo articolo, si considera che nei soggetti con arti amputati tutti i segnali rilevati dai sensori EMG sono il risultato di co-contrazioni.

Il dato di interesse è che la combinazione di EMG e segnale di movimento inerziale ha migliorato i tassi di successo per entrambi gli avambracci, con incrementi maggiori nell'arto interessato (dal 2% al 10%).

2.2 Segnale elettromiografico

2.2.1 Elettromiografia

Il segnale elettromiografico fa parte dei segnali bioelettrici, i quali si generano negli organismi viventi a causa dello scambio di ioni elettrici.
Il segnale elettromiografico è quel segnale bioelettrico generato dalle fibre muscolari che rileva l'attivazione delle stesse.
Il segnale EMG è stocastico, aleatorio, e quindi non possiede una precisa descrizione matematica che lo caratterizza e può essere analizzato solo attraverso una caratterizzazione statistica, in termini di probabilità.
La casualità di tale segnale è dovuta alle caratteristiche intrinseche della contrazione muscolare; infatti, ciascun muscolo è formato da numerose unità motorie (MU) e perciò il segnale rilevato è la combinazione di tutti i singoli potenziali d'azione delle membrane muscolari sollecitate e presenti nell'area sottostante gli elettrodi.
Inoltre, l'impulso elettrico, proveniente dal sistema nervoso centrale (SNC), non segue mai perfettamente lo stesso percorso e ciò causa, anche in task motorie identiche, segnali differenti.
Per questi motivi il segnale elettromiografico presenta alcune sfide per il controllo delle interfacce uomo-macchina perché rende limitate le strategie dei sistemi basati sull'EMG e si deve spesso ricorrere a sistemi di addestramento mirati per mitigare il problema[24].
Osservando un segnale elettromiografico è possible distinguere delle fasi di attivazione, durante la contrazione del muscolo con un'ampiezza maggiore e le fasi di riposo (rest) in cui le fibre muscolari sono rilassate come è possibile osservare in (Figura 2.1)

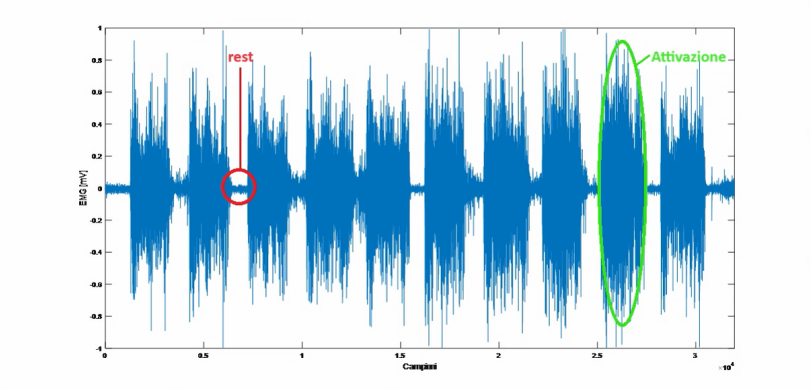


Figura 2.1: EMG del gesto bere da bicchiere canale 1

2.2.2 Elettrodi

Gli elettrodi svolgono la funzione di trasduzione tra la corrente ionica generata nel corpo umano e la corrente elettronica trasferita alla strumentazione di misura.
Esistono due metodi di acquisizione che permettono di ottenere risultati diversi e sono utilizzati per fini differenti:
1. SEGNALE EMG INTRAMUSCOLARE
Il segnale viene prelevato inserendo un ago all'interno del muscolo. Questa procedura permette di studiare l'attività dei muscoli posti in profondità. Si tratta di un metodo piuttosto invasivo, poiché l'ago è a contatto diretto con il gruppo muscolare di interesse, ma d'altra parte consente di captare il segnale in modo molto più preciso, riducendo gli effetti del cross talk fisiologico (Figura 2.2).
Gli elettrodi possono avere due diverse configurazioni:

1. Bipolari, quando sono presenti 2 elettrodi all'interno dell'ago ipodermico;

2. Monopolari, quando è presente un unico elettrodo sulla punta dell'ago.



Figura 2.2: Elettrodi EMG intramuscolare

2. SEGNALE EMG DI SUPERFICIE
Il segnale viene rilevato attraverso degli elettrodi accuratamente posizionati sulla cute.
Oggigiorno sono maggiormente diffusi gli elettrodi monouso(Figura 2.3), formati da un disco esterno, che costituisce la parte adesiva, e da un disco interno di dimensioni variabili (solitamente coperto di gel o da una pasta conduttiva per agevolare la conduzione del segnale) , che ne rappresenta invece la parte sensibile.

L'utilizzo di elettrodi di dimensioni inferiori aumenta la selettività delle misure, ma incrementa il valore dell'impedenza.
Per facilitare l'acquisizione è inoltre necessario preparare accuratamente la cute, ovvero rimuovere tutto ciò che può disturbare il segnale o che può interferire con l'aderenza dell'elettrodo stesso, come peli e sebo.
È il metodo più utilizzato nella ricerca, dato che il prelievo del segnale non risulta invasivo e può essere effettuato in laboratorio, senza la necessità di recarsi in una clinica ed è infatti quello che è stato utilizzato in questo studio.
Poiché gli elettrodi sono posti superficialmente, non sarà possibile isolare l'attività della singola unità motoria, ma del muscolo nel suo complesso e la misura dell'attività elettrica risulterà la somma dei potenziali d'azione dell'intera area sottostante(Figura 2.4).
Per favorire il confronto dei dati acquisiti intra-soggetto ed inter-soggetto è ormai standardizzato il posizionamento degli elettrodi.
Il segnale può essere acquisito tramite elettrodi:

1. Monopolari, utilizzando due elettrodi, di cui uno è posizionato in una zona in cui si suppone non vi sia attività muscolare, mentre l'altro sulla cute sopra il muscolo.

2. Bipolari, utilizzando due elettrodi entrambi posti sulla cute che captano il segnale elettrico, successivamente un amplificatore differenziale ne calcolerà la differenza. Questo metodo permette di avere una maggiore visibilità.



Figura 2.3: Elettrodi EMG di superficie[1]



Figura 2.4: Elettrodi EMG di superficie monouso

2.2.3 Problematiche di acquisizione del segnale

Sono riscontrabili alcuni disturbi nell'acquisizione del segnale, principalmente quando viene rilevato da elettrodi di superficie.

1. Tipologia di tessuto: la conducibilità elettrica del corpo umano cambia a seconda del tipo di tessuto che si interpone tra elettrodi e sorgente. La presenza di tessuto adiposo, lo spessore, determinate condizioni di temperatura possono attenuare il segnale, riducendone l'ampiezza. Tali condizioni sono fortemente differenti da un soggetto all'altro e sono profondamente influenzate anche dal posizionamento degli elettrodi.

2. Impedenza della pelle: per ridurre l'impedenza della pelle occorre pulire accuratamente la cute con una soluzione alcolica, oppure utilizzare una pasta elettrolitica per ridurre l'impedenza dell'interfaccia cute-elettrodo. In parte questo problema viene risolto con l'utilizzo di elettrodi pre-gellati.

3. Cross talk fisiologico: dato che l'elettromiogramma è captato in superficie, il segnale prodotto è la somma di tutte le unità motorie dei muscoli coinvolti nel movimento che viene analizzato. Pertanto può capitare che i sensori elettromiografici di superficie possano captare l'attività elettrica delle fibre muscolare di muscoli attivi contigui e non di un solo muscolo.

4. Rumore di rete: rumore dovuto all'accoppiamento con sorgenti elettromagnetiche esterne e con la frequenza di rete. Per ridurlo può essere utilizzato un filtro notch che solitamente è a 50Hz. Il rumore di rete dipende da molti fattori, specialmente dalla qualità dell'amplificatore dell'EMG, dal rumore ambientale e dalla qualità delle condizioni in cui viene effettuata l'acquisizione(Figura 2.5).

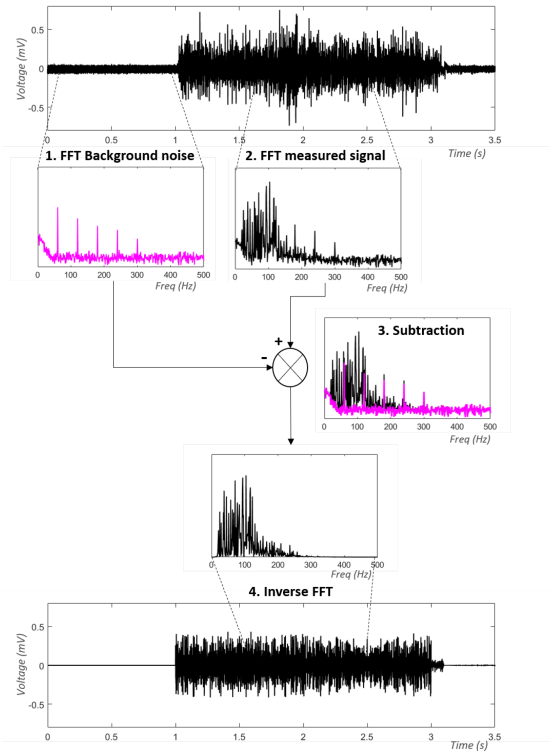


Figura 2.5: Rumore di rete[2]

5. Artefatti da movimento: sono causati da piccoli movimenti degli elettrodi; in passato gli elettrodi con supporti metallici davano maggiori complicazioni. Oggi si utilizzano elettrodi monouso, che aderiscono meglio alla cute ed essendo più morbidi, minimizzano gli spostamenti(Figura 2.6).

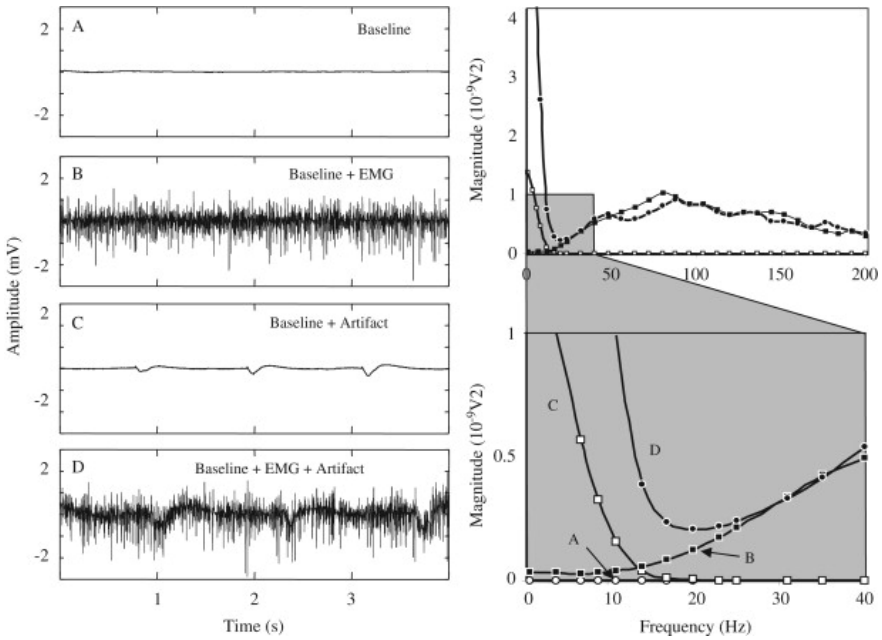


Figura 2.6: Artefatti da movimento[3]

2.3 Inertial Measurement Unit (IMU)

Un'unità di misurazione inerziale (IMU) è un dispositivo in grado di misurare le 3 componenti dell'accelerazione e le tre componenti della velocità angolare. L'IMU è tipicamente composta da:

- Giroscopi: forniscono una misura della velocità angolare.
- Accelerometri: forniscono una misura di forza/accelerazione specifica.
- Magnetometri (opzionali): misura del campo magnetico circostante il sistema.

L'accelerometro è il sensore principale responsabile della misurazione dell'accelerazione e può essere trovato in una varietà di tipi diversi, inclusi accelerometri meccanici, accelerometri al quarzo e accelerometri MEMS.
Il giroscopio è un sensore inerziale che misura la velocità angolare di un oggetto rispetto a un sistema di riferimento inerziale. Sul mercato sono disponibili molti tipi diversi di giroscopi, che spaziano su vari livelli di prestazioni e includono giroscopi meccanici, giroscopi a fibra ottica (FOG), giroscopi laser ad anello (RLG) e giroscopi al quarzo/MEMS.
Il magnetometro invece, misura l'orientazione del sensore rispetto al campo magnetico terrestre.
Per le misurazioni in campo biomedico le unità IMU sono degli oggetti di piccole dimensioni all'interno delle quali sono presenti acceleromentro, giroscopio e magnetometro(Figura 2.7).

Sono presenti 9 canali di acquisizione che corrispondo ai tre assi x, y, e z, che sono disposti come mostrato in (Figura 2.8), per tutti e tre i componenti(Figura 2.9),(Figura 2.10).

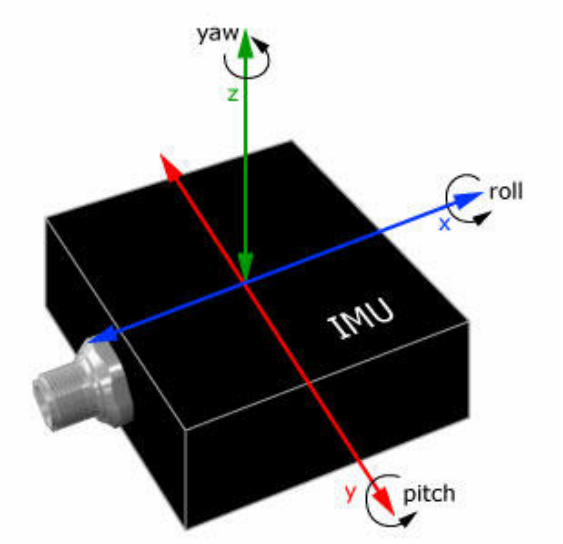


Figura 2.7: Inertial measurement unit[4]

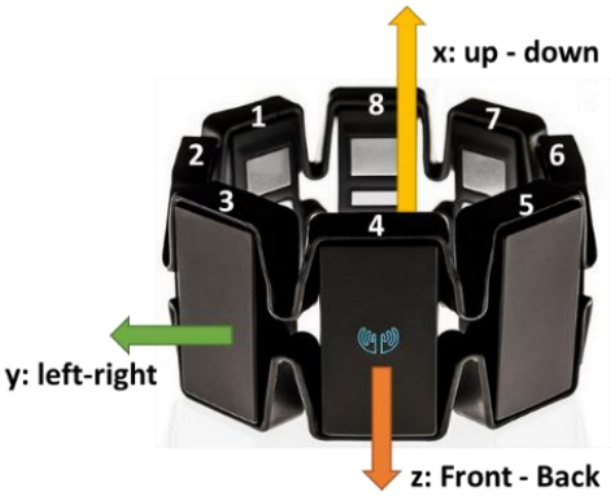


Figura 2.8: Direzioni assi x, y e z dell'IMU nel Myo armband[5]

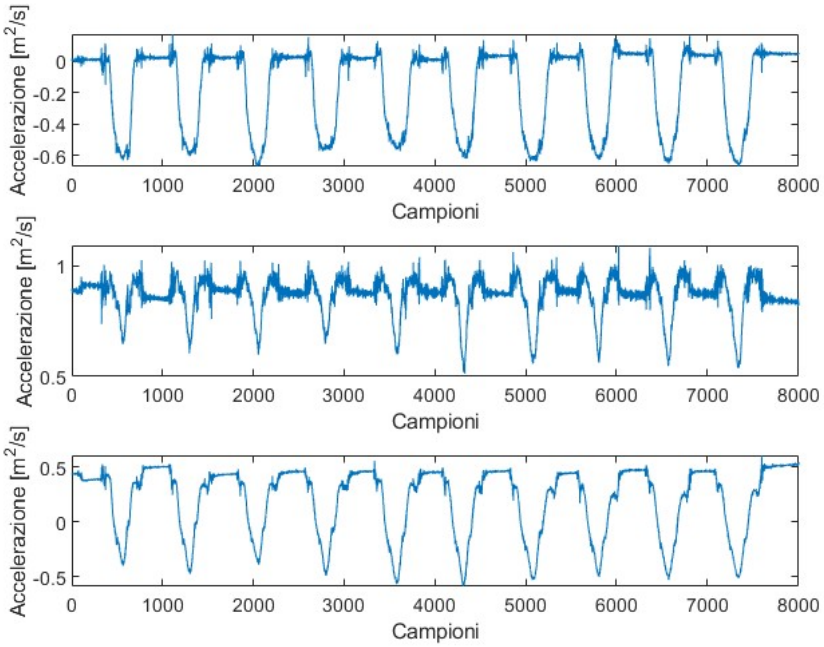


Figura 2.9: Segnale accelerometrico del gesto bere da bicchire assi x, y, z

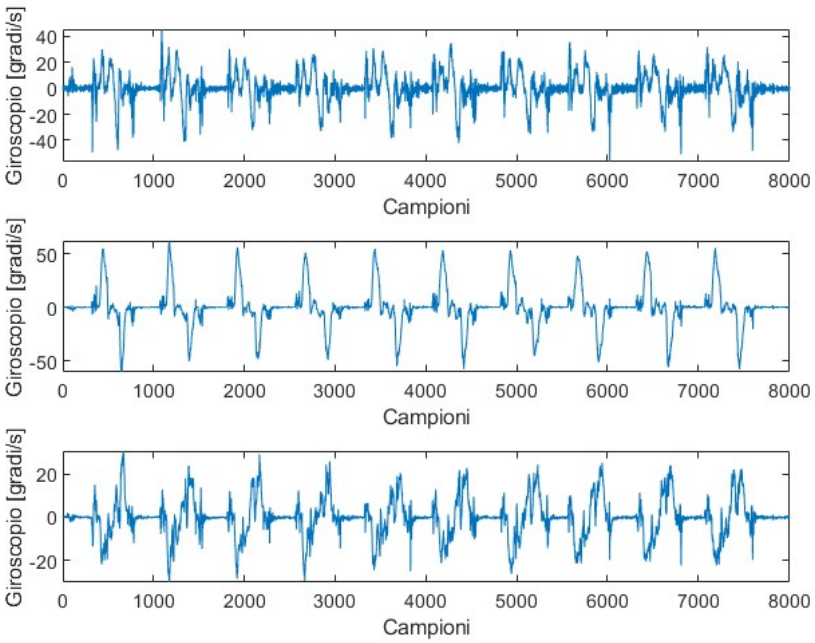


Figura 2.10: segnale giroscopico del gesto bere da bicchire assi x, y, z

Capitolo 3

Device e procedure utilizzati

3.1 Strumentazione

Il device utilizzato per lo studio è un dispositivo wereable Myo armband che va indossato al livello dell'avambraccio e che permette l'acquisizione del segnale elettromiografico e inerziale[25].
Esso è costituito da otto elettrodi che permettono l'acquisizione del segnale elettromiografico generato dalla contrazione delle fibre muscolari dell'avambraccio e da un unità inerziale(IMU) che invece, permette di acquisire il segnale accelerometrico, giroscopico e del magnetometro(Figura 3.1).



Figura 3.1: Dispositivo MYO armband[6]

Come sovracitato i canali del segnale elettromiografico sono otto e sono distribuiti su tutta la circonferenza del bracciale in modo da captare il segnale proveniente da tutte le zone dell'avambraccio. Come è facilmente intuibile il segnale registrato da questi elettrodi è un EMG di superficie e dunque i dati acquisiti si riferiscono a tutti i muscoli che stanno agendo in un determinato intervallo di

tempo sotto la superficie su cui poggia l'elettrodo.
L'IMU, invece, fornisce i dati di, accelerometro, giroscopio e magnetometro riferiti rispetto ai tre assi nello spazio x,y,z presentando quindi 9 canali di acquisizione.
In questo studio, come si vedrà in seguito, sono stati utilizzati i segnali giroscopici perché permettono di osservare in modo chiaro l'inizio e la fine del movimento e successivamente, per quanto riguarda la classificazione dei gesti, sono stati utilizzati il segnale elettromiografico, quello accelerometrico e poi entrambi.
Considerando che i canali di acquisizione dell'EMG sono 8 e le componenti del segnale accelerometrico sono 3, una per ogni asse nello spazio, nella parte finale dello studio sono stati utilizzati in totale 11 canali di acquisizione.
Il tratto peculiare del device è la sua semplicità di utilizzo, che non necessita vestizione o preparazione del soggetto, il quale deve solo indossare il bracciale che si può facilmente allargare o restringere.
Un' altra particolarità di questo strumento è che non necessita di particolari accorgimenti riguardanti il corretto posizionamento per un eventuale standardizzazione dato che i segnali acquisiti rappresentano la contrazione di tutti i muscoli dell'avambraccio simultaneamente e non sono selettivi.
Per questo motivo non è necessario porre troppa attenzione per quanto riguarda il posizionamento degli elettrodi che invece può risultare complesso e necessita tempo.
Un metodo che è spesso utilizzato in letteratura per cercare di confrontare le misure, è quello di utilizzare uno degli elettrodi, che è sempre indicato con una scritta blu come elettrodo di riferimento, ciò permette una sorta di standardizzazione del posizionamento dell'armband nel caso di prove con soggetti differenti (Figura 3.2).



Figura 3.2: Dispositivo MYO armband su avambraccio[7]

Ciò che si intende valutare è dunque se un dispositivo così semplice da utilizzare e relativamente economico, se comparato ad altre attrezzature biomedicali più complesse, possa comunque ottenere risultati di accuratezza elevati.
Inoltre il Myo armband è connesso tramite bluetooth a un computer, sul quale è presente un software, di facile gestione, che permette l'avvio dell'acquisizione e il salvataggio dei dati.

3.2 Protocollo di misura

Per quanto riguarda il protocollo di misura, poiché lo studio è preliminare e ha come fine la valutazione del protocollo sperimentale, è stato eseguito su un unico soggetto sano destrimano.
Dopo alcune prove per esercitarsi nell'esecuzione delle sequenze di movimento si è deciso di fissare a 10 secondi il tempo riguardante l'esecuzione del gesto e a 5 secondi il tempo per il riposo. Un software di temporizzazione è stato utilizzato per scandire le sequenze tra l'esecuzione e il rest.
Complessimente il tempo totale di ogni acquisizione è di due minuti e trentacinque secondi.
Ogni task è stato ripetuto per 10 volte consecutive.
La standardizzazione è fondamentale nelle sperimentazioni, nelle ricerche e negli studi scientifici perché permette dei creare delle linee guida sulle procedure da seguire, sugli strumenti da utilizzare, sui tempi da rispettare ecc. in modo da confrontare i dati acquisiti dallo stesso soggetto in tempi diversi (intrapersonale) oppure da diversi soggetti (interpersonale). Generalmente ogni task partiva da una posizione di riposo, che consisteva nel tenere il braccio rilassato appoggiato sul tavolo, successivamente si procedeva con il movimento, per poi tornare nella posizione di riposo. Questa procedura veniva eseguita per i gesti nei quali il soggetto era seduto davanti al piano, mentre per i task che richiedevano una posizione eretta è stata scelta come posizione di riposo lo stare in piedi con le braccia distese e rilassate.

3.3 Metodi di classificazione

Attraverso l'acquisizione e la successiva elaborazione dei dati si procede con il processo di classificazione che darà come risultato l'accuratezza nell'identificazione dei singoli gesti. la classificazione è il processo di riconoscimento di differenti categorie sulla base di una serie più o meno complessa di dati.
La classificazione si divide in due fasi:

1. Fase di training: il classificatore utilizza una percentuale di dati per l'addestramento.
2. Fase di testing: Il classificatore utilizza il resto dei dati non impiegati per l'addestramento del modello, per verificarne la capacità di classificare.

Per quanto riguarda l'addestramento si è deciso di utilizzare il 70% dei dati e quindi il 30% dei dati rimanenti sono stati conservati per il test.

3.3.1 Confusion matrix

Nel Machine Learning, per misurare le prestazioni del modello di classificazione viene utilizzata la matrice di confusione.
Molte misure di errore calcolano l'errore totale nel modello senza trovare le singole istanze di errore. Il modello potrebbe classificare erroneamente alcune categorie più di altre, ma ciò non è visibile usando le misure di accuratezza standard.
Inoltre, supponendo ci sia uno squilibrio significativo tra le classi nei dati forniti, una classe di dati avrebbe più istanze di dati rispetto alle altre e un modello potrebbe prevedere la classe maggioritaria per tutti i casi e avere un punteggio di accuratezza elevato.
In questo caso vengono in aiuto le confusion matrixs.
Una matrice di confusione presenta una tabella dei diversi risultati della previsione e dei risultati di un problema di classificazione e aiuta a visualizzarne i risultati.
Genera una tabella di tutti i valori previsti e reali di un classificatore e sono possibili quattro combinazioni di essi.

1. True positive: il numero di volte in cui i valori positivi effettivi sono uguali al positivo previsto. È stato previsto un valore positivo ed è corretto.

2. False positive: il numero di volte in cui il modello prevede erroneamente valori negativi come positivi. È stato previsto un valore positivo e in realtà è negativo.

3. True negative: il numero di volte in cui i valori negativi effettivi sono uguali ai valori negativi previsti. È stato previsto un valore negativo e in realtà è negativo.

4. False negative: il numero di volte in cui il modello prevede erroneamente valori positivi come negativi. È stato previsto un valore negativo e in realtà è positivo.

3.3.2 Algoritmi di classificazione

Per svolgere la classificazione il classificatore può utilizzare diversi modelli e algoritmi che poi portano a risultati diversi in base al tipo di dato fornito alla macchina.

1. K-nearest neighbors(KNN): un classificatore di apprendimento supervisionato non parametrico, che utilizza la prossimità per effettuare classificazioni o previsioni sul raggruppamento di un singolo punto dati. Sebbene possa essere utilizzato per problemi di regressione o classificazione, viene generalmente utilizzato come algoritmo di classificazione, basandosi sul presupposto che punti simili possono essere trovati l'uno vicino all'altro.
   Esso classifica in base alla distanza, considera la classe dei k dati più vicini per classificare un dato(Figura 3.3).
   Successivamente, il campione viene incluso in quella classe. È preferito nei problemi di classificazione a causa della sua semplicità ed efficienza. Se le proprietà di una distribuzione di dati sono sconosciute, questo metodo di classificazione può essere preferito come approccio iniziale[26].

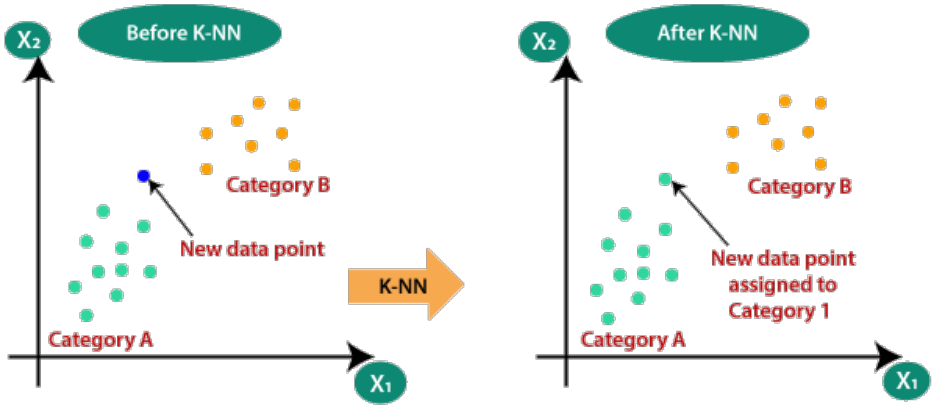


Figura 3.3: Algoritmo KNN[8]

2. Tree (Alberi decisionali) : la struttura di un albero decisionale è simile a un albero che contiene un nodo radice, diversi nodi interni e diversi nodi foglia(Figura 3.4).
   I nodi foglia corrispondono ai risultati della classificazione , mentre gli altri nodi rappresentano i risultati test su alcuni attributi. Secondo i test, i campioni di prova saranno suddivisi in diversi nodi figli. Pertanto, il nodo radice contiene tutti i campioni e il percorso dal nodo radice a un nodo interno, o nodo figlio, rappresenta una sequenza determinante. Attualmente esistono diverse varianti di Decision Tree[27].

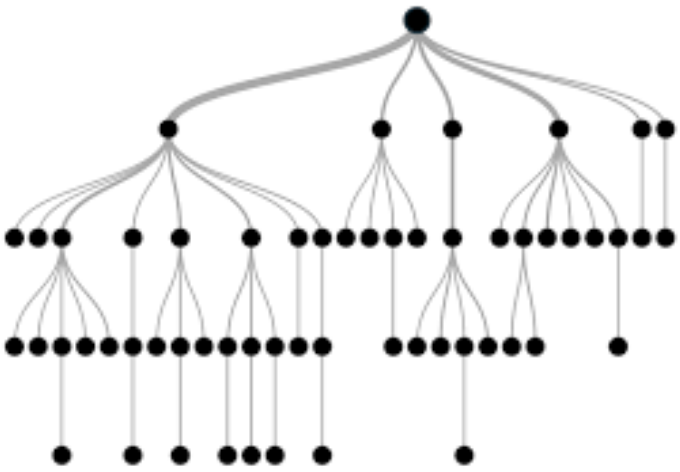


Figura 3.4: Algoritmo Decision tree[9]

3. Analisi Discriminante: questo tipo di algoritmo di classificazione si basa sul presupposto che i dati di classi diverse obbediscano a diverse distribuzioni gaussiane.

   Il processo principale consiste innanzitutto nell'addestrare un classificatore per adattare una funzione che può stimare i parametri della distribuzione di ciascuna classe, e quindi utilizzando il classificatore per prevedere nuovi campioni.

   L'analisi discriminante più utilizzata è l'analisi Discriminante Lineare(LDA)(Figura 3.5).

   In LDA, il passo fondamentale è trovare un iperpiano di proiezione in uno spazio k -dimensionale, poi proiettando in modo diverso classi di campioni sull'iperpiano, massimizzando le distanze tra le classi e minimizzando le distanze all'interno della classe[27].

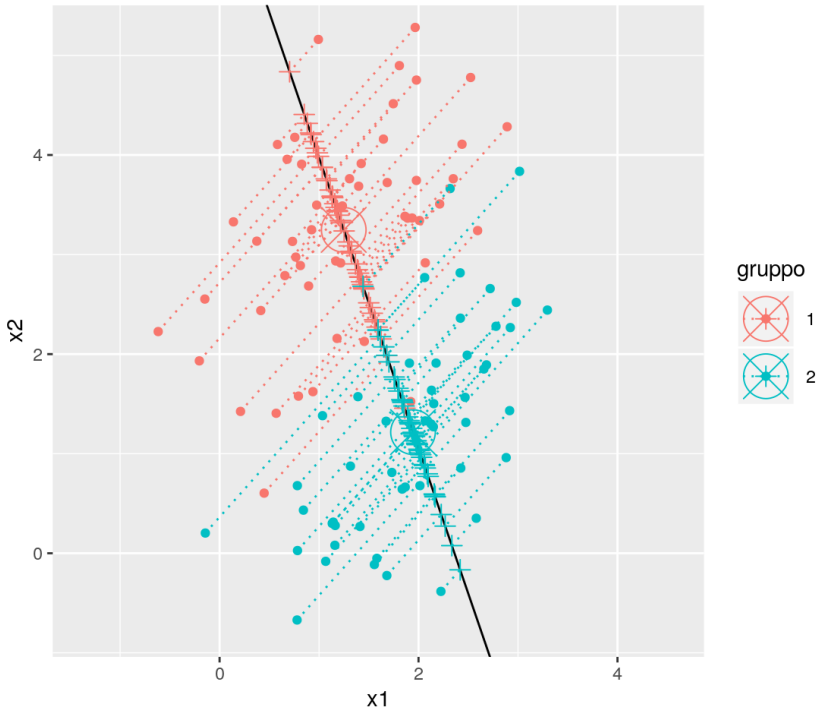


Figura 3.5: Algoritmo LDA[10]

4. Support Vector Machines (SVM) : questo tipo di algoritmi si basano sulla teoria della dimensione VC e del principio di minimizzazione del rischio strutturale(Figura 3.6).

   Il compito principale della SVM è trovare un iperpiano nello spazio dei campioni per massimizzare la distanza tra classi diverse. La chiave di SVM è progettare una funzione kernel efficace[27].

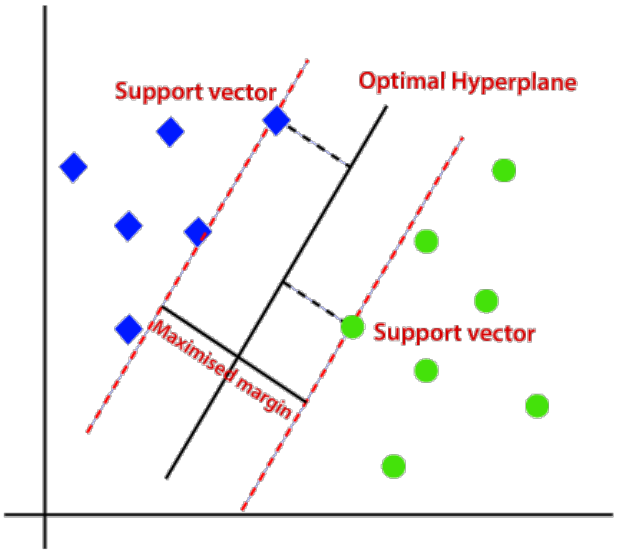


Figura 3.6: Algoritmo SVM[11]

Capitolo 4

Studio del segnale

4.1 Acquisizione dati

Il soggetto ha indossato il device sull'avambraccio destro, il dispositivo è stato acceso e collegato tramite Bluethoot al computer nel quale sono stati registrati e salvati i dati.
Non è stata effettuata una randomizzazione dei gesti, infatti come sopra citato lo stesso gesto veniva ripetuto più volte sequenzialmente, d'altra parte si è cercato di non eseguire movimenti simili uno dopo l'altro e quindi generalmente un task era molto differente da quello successivo.
I gesti eseguiti sono 17 e sono tutti movimenti riconducibili a azioni svolte comunemente nella vita quotidiana o a semplici lavori manuali.
I gesti in esame sono:

- Mangiare: il soggetto è seduto su una sedia, partenza in posizione di riposo, prendere una forchetta che si trova sul piano di fronte, infilzare e successivamente portare la forchetta alla bocca per poi tornare in posizione di riposo. Ripetere la sequenza per 10 volte.

- Bere dal bicchiere: il soggetto è seduto su una sedia, partenza in posizione di riposo, afferrare il bicchiere che è riempito a metà con del liquido, bere e tornare in posizione di riposo. Ripetere la sequenza per 10 volte.

- Bere da una tazzina: il soggetto è seduto su una sedia, partenza in posizione di riposo, afferrare la tazzina che è riempita a metà con del liquido dal manico, bere e tornare in posizione di riposo. Ripetere la sequenza per 10 volte.

- Versare in un bicchiere: il soggetto è seduto su una sedia, la bottiglia con la quale versare il liquido in un bicchiere è da 1,5L.
  Partenza in posizione di riposo, il soggetto afferra la bottiglia, versa l'acqua nel bicchiere e torna nella posizione di riposo. Ripetere la sequenza per 10 volte.

- Scrivere: il soggetto è seduto su una sedia, partenza in posizione di riposo, scrivere con una penna su un foglio e tornare in posizione di riposo. Ripetere la sequenza per 10 volte.

- Fumare: il soggetto è seduto su una sedia, già munito di sigaretta alla bocca. Il movimento consiste nel prendere la sigaretta dalla bocca, allontanarla da quest'ultima (per l'intervallo di tempo di espirazione) e riportare la sigaretta alla bocca. Ripetere la sequenza per 10 volte.

- Avvitare orizzontale: partenza in posizione di riposo, effettuare prese cacciavite in orizzontale per 5 volte appoggiare cacciavite e tornare in posizione di riposo. Ripetere la sequenza per 10 volte.

- Pulire mani (palmo e dorso): partenza in posizione di riposo, strofinare i palmi e i dorsi delle mani cercando di ripetere lo stesso movimento ogni volta e tornare in posizione di riposo. Ripetere la sequenza per 10 volte.

- Presa della maniglia: partenza in piedi con braccia rilassate, afferrare la maniglia e aprire la porta, tornare in posizione rilassata. Ripetere la sequenza per 10 volte.

- Avvitare verticale: partenza in posizione di riposo, effettuare prese cacciavite in verticale (movimento per 5 volte), appoggiare il cacciavite e tornare in posizione di riposo. Ripetere la sequenza per 10 volte.

- Martello orizzontale: partenza in posizione di riposo, prendere martello, colpire una volta sul piano orizzontale, appoggiare il martello e tornare in posizione di riposo. Ripetere la sequenza

per 10 volte.

- Martello verticale: partenza in posizione di riposo, prendere martello, colpire una volta sul piano verticale, appoggiare il martello e tornare in posizione di riposo. Ripetere la sequenza per 10 volte.

- Chiave orizzontale: partenza in posizione di riposo, prendere la chiave inglese, avvitare per 5 volte sul piano orizzontale, appoggiare la chiave e tornare in posizione riposo. Ripetere la sequenza per 10 volte.

- Chiave verticale: partenza in posizione di riposo, prendere la chiave inglese, avvitare per 5 volte sul piano verticale, appoggiare la chiave e tornare in posizione di riposo. Ripetere la sequenza per 10 volte.

- Movimenti del Joystick: il soggetto è seduto su una sedia, partenza in posizione di riposo presa del joystick, movimento antero-posteriore ripetuto 3 volte movimento destra-sinistra ripetuto 3 volte, rilasciare il joystick e tornare in posizione di riposo. Ripetere la sequenza per 10 volte.

- Sollevamento di una scatola da terra: partenza in piedi con braccia rilassate, piegare le ginocchia per la presa, sollevare la scatola mantenerla alcuni secondi e appoggiarla a terra, ritornare in posizione eretta e riposare. Ripetere la sequenza per 10 volte.

- Spingere la scatola sul piano: partenza in posizione di riposo, afferrare la scatola con entrambe le mani, spingere fino alla completa estensione dei gomiti, fermarsi, ritornare in posizione di riposo. Ripetere la sequenza per 10 volte.

Tutti i dati di ogni task acquisiti sono stati immagazzinati in una struttura che comprende i dati elettromigrafici (Figura 4.1), dati accelerometrici(Figura 4.2), dati giroscopici(Figura 4.3).

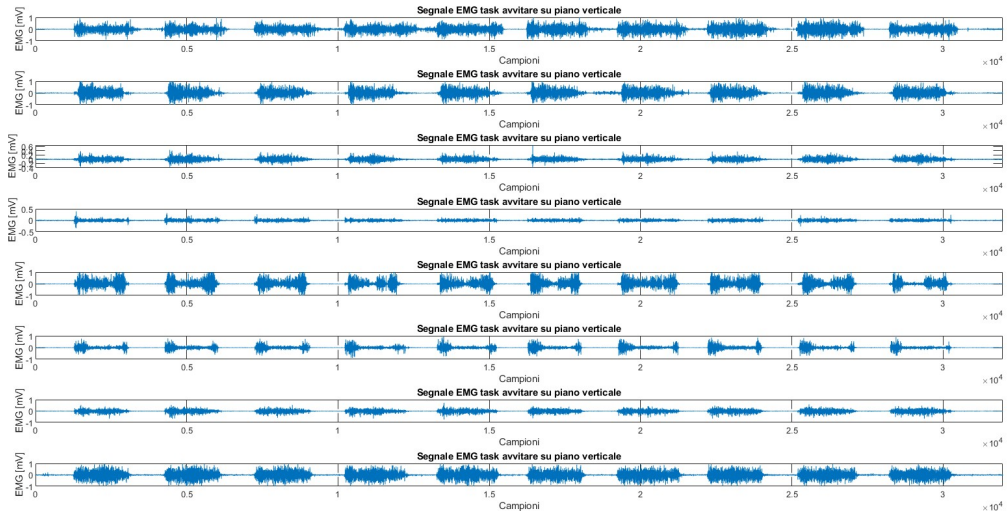


Figura 4.1: Segnale elettromigrafico 8 canali nel caso del gesto di avvitamento sul piano orizzontale

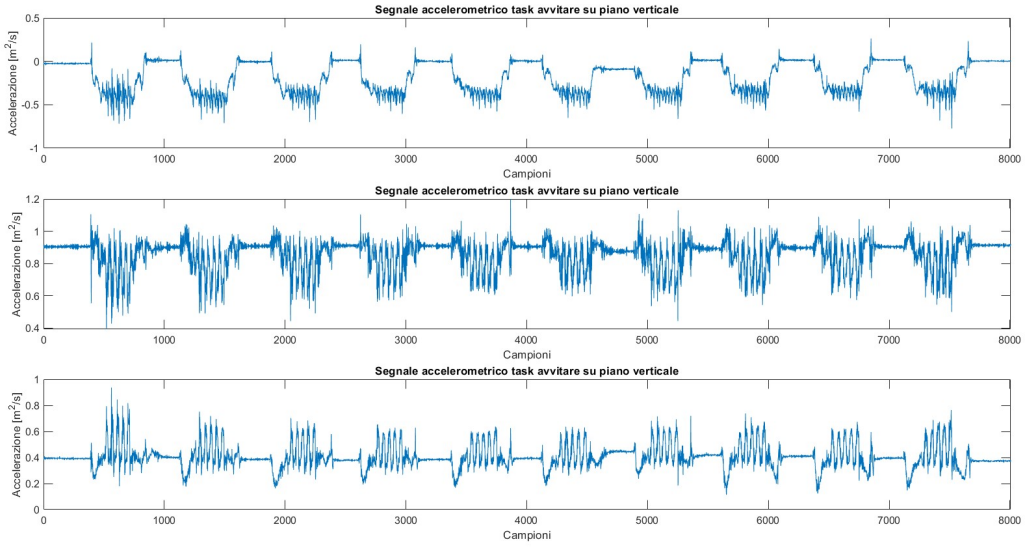


Figura 4.2: Segnale accelerometrico, componenti x,y,z nel caso del gesto di avvitamento sul piano orizzontale

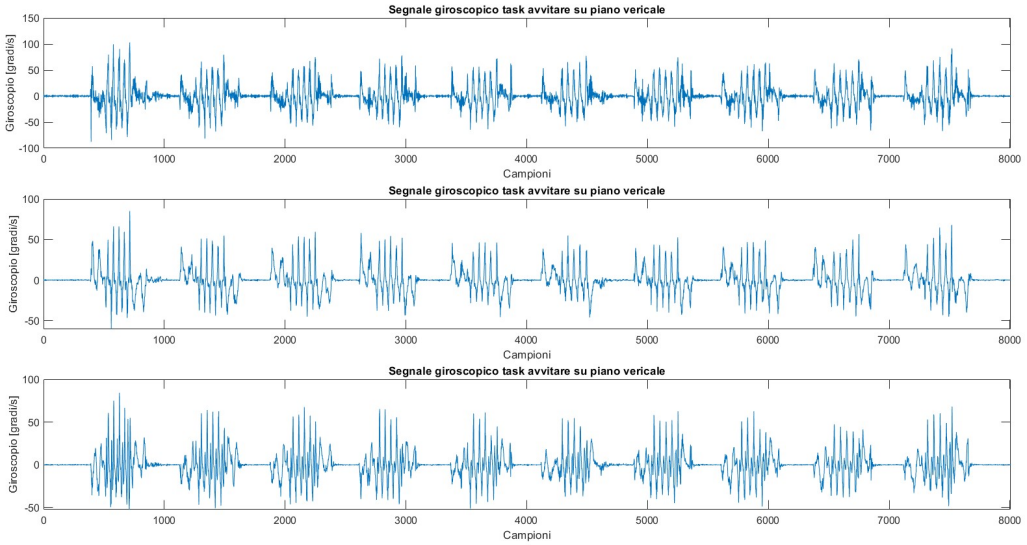


Figura 4.3: Segnale giroscopico, componenti x,y,z nel caso del gesto di avvitamento sul piano orizzontale

Per quanto riguarda l'EMG, essendo la banda di 500 Hz, la frequenza di campionamento dovrebbe essere almeno di 1.000 Hz; tuttavia, poiché l'attività è maggiormente concentrata entro i 250 Hz, può essere sufficiente una frequenza di Nyquist di 500 Hz.
In questo caso il segnale elettromiografico è stato acquisito con una frequenza di campionamento di 200 Hz per un limite tecnologico del device, mentre i segnali inerziali sono stati acquisiti con una frequenza di campionamento di 50 Hz.

4.2 Preprocessing

Gli obiettivi della preelaborazione sono ridurre al minimo il rumore proveniente da cause interne ed esterne nel segnale mioelettrico raccolto e rendere l'estrazione delle features più semplice[28]. Detto ciò è importante dire che il Myo armband è un dispositivo con dei filtri di riduzione del rumore integrati, e quindi non è stato necessario applicare nessun filtro[29].
Come esplicitato nel paragrafo 2.2 in cui si descrive il protocollo di misura, ogni gesto è stato ripetuto più volte e ogni ripetizione era intervallata da una fase di riposo.
La fase di contrazione e di movimento dell'avambraccio è ben identificabile in tutti i segnali di interesse. Per iniziare sono stati salvati tutti gli istanti di start, che identificano l'inizio della contrazione dei muscoli e, al contempo, del relativo movimento dell'avambraccio e gli istanti di stop, che identificano invece il termine della contrazione e il relativo rilassamento dell'avambraccio per ogni gesto. Questi istanti sono stati salvati in vettori e poi in matrici nelle quali ogni riga conteneva il campione che identificava l'istante di start e il campione che identificava l'istante di stop.
Il segnale selezionato per questa procedura è il segnale giroscopico che permette di individuare più facilmente l'inizio del movimento dato che indica tutte le variazioni angolari e dunque ogni minima rotazione del segmento in esame. Per ogni gesto è stata scelta, per la cattura degli istanti, la componente x, y, o z in base a quale di esse marcasse in modo più evidente l'inizio del movimento. Nelle (Figura 4.4) e(Figura 4.5), ad esempio, è stata utilizzata la componente y del segnale giroscopico.

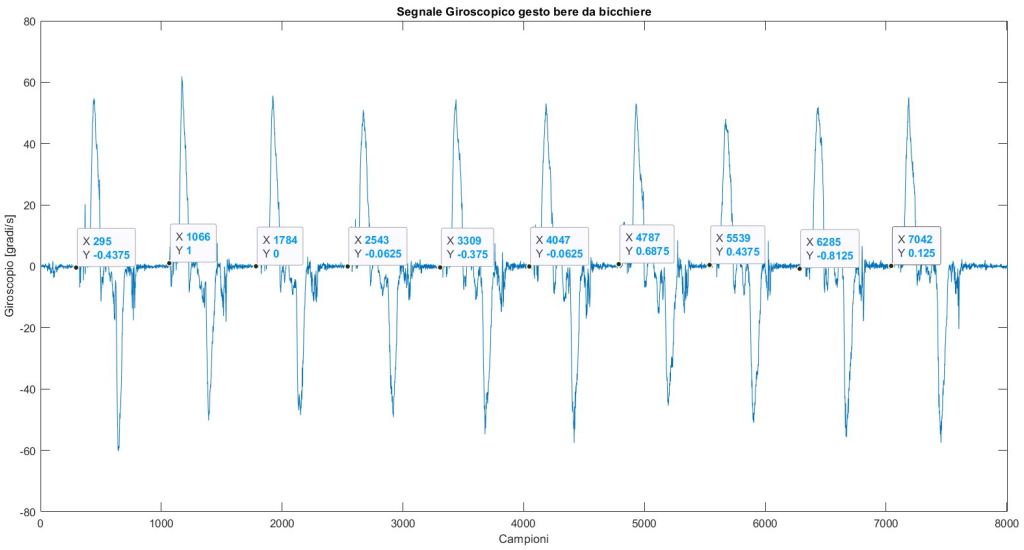


Figura 4.4: Istanti di start segnale giroscopico del gesto bere da bicchiere

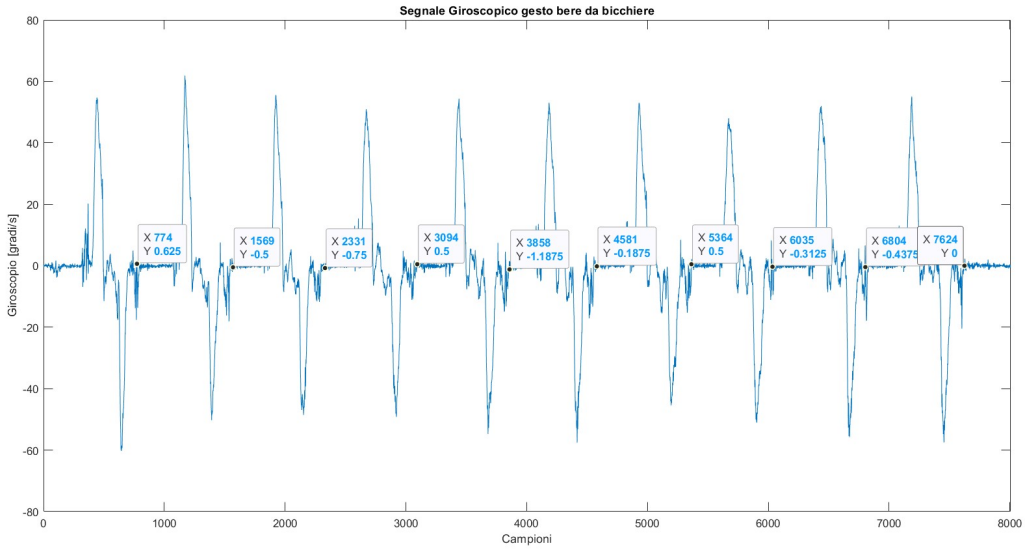


Figura 4.5: Istanti di stop segnale giroscopico del gesto bere da bicchiere

4.3 Estrazione features

Il controllo del riconoscimento del pattern mioelettrico si basa sull'estrazione di informazioni dai sensori dell'EMG per riconoscere il movimento.
Un classificatore discrimina i pattern di segnale e li classifica nelle loro categorie e per questo la scelta delle features è una delle chiavi per aumentare l'accuratezza della classificazione[30].
L' estrazione delle features è un metodo che estrae informazioni utili non immediatamente evidenti nel segnale EMG di superficie e rimuove le componenti indesiderate.
Le features sono divise in tre domini in cui sono rappresentate: nel dominio del tempo, nel dominio della frequenza e nel dominio tempo-frequenza.
Le features nel dominio del tempo sono solitamente implementate in modo semplice e rapido, poiché non necessitano di alcuna trasformazione e sono calcolate direttamente sul segnale EMG grezzo.
Esse sono state ampiamente utilizzate in ambiti di ricerca e per applicazioni in real time. Uno dei principali svantaggi delle caratteristiche di questo gruppo deriva dalla non stazionarietà del segnale EMG. Quindi si possono avere grandi variazioni delle features quando si acquisiscono dati di un gesto dinamico.
Inoltre, a causa dei loro calcoli basati sui valori di ampiezza del segnale EMG, si verificano molte interferenze che vengono acquisite insieme al segnale, che possono rappresentare un grave svantaggio soprattutto per le features relative all'energia.
Tuttavia, per la loro minore complessità computazionale sono utilizzate spesso, soprattutto in ambienti con basso rumore[31].
Per questi motivi in questo studio sono state utilizzate solamente features del dominio del tempo, in particolare le features prese in esame sono state Mean absolute value(MAV), Integrated absolute value(IAV), Root mean square(RMS), lo Zero crossing(ZC), la Waveform lenght(WL) e la Slope sign change(SSC).
Per calcolare le features di interesse sono state utilizzate delle funzioni fornite dal professore, ricercatore dell'università di Ottawa Adrian DC Chan.
Esse sono state applicate sia sul segnale elettromiografico che sul segnale accelerometrico.
Le funzioni inoltre adoperano un finestraggio del segnale, calcolando la feature in una finestra di default rettangolare.
Per quanto riguarda la dimensione si è deciso di selezionare finestre di 40 campioni con sovrapposizione di 8 per segnale EMG e di 10 campioni con sovrapposizione di 2 per segnale accelerometrico con l'obiettivo di conservare la maggior parte dei dati e non perdere informazione.

In questo modo inoltre, avendo frequenze di campionamento diverse (200 Hz per EMG e 50 Hz per segnale accelerometrico), i vettori di features calcolati avranno approssimativamente la stessa lunghezza.

4.3.1 Scelta delle features

Le features scelte sono, come precedentemente detto, nel dominio del tempo e ognuna di esse permette di osservare diverse caratteristiche o proprietà del segnale.

1. Mean absolute value(MAV)

   La funzione MAV è una media del valore assoluto dell'ampiezza del segnale EMG in un segmento, che può essere definita come (Eq. 4.1):

$$MAV = 1/N \sum_{i=1}^{N} |x_i| \tag{4.1}$$

   In poche parole la Mean absolute value calcola la media sul modulo dell'ampiezza in una certa finestra di campioni. Essa è stata calcolata con la funzione presente nel file Matlab "getmavfeat.m".

   In seguito i grafici della MAV dell'EMG(Figura 4.6) e del segnale accelerometrico(Figura 4.7).

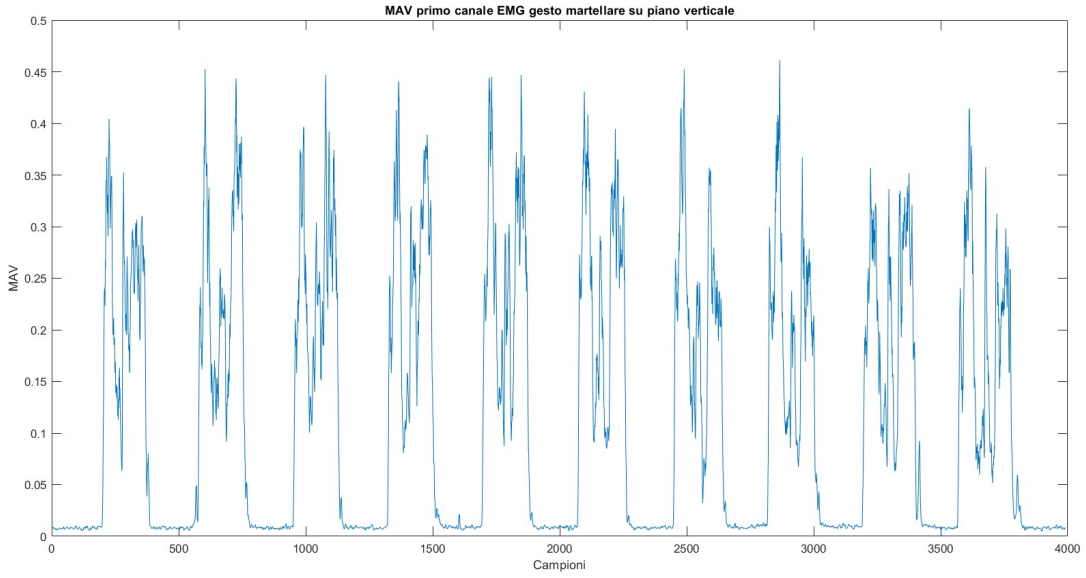


Figura 4.6: MAV segnale EMG del gesto martellare su piano verticale

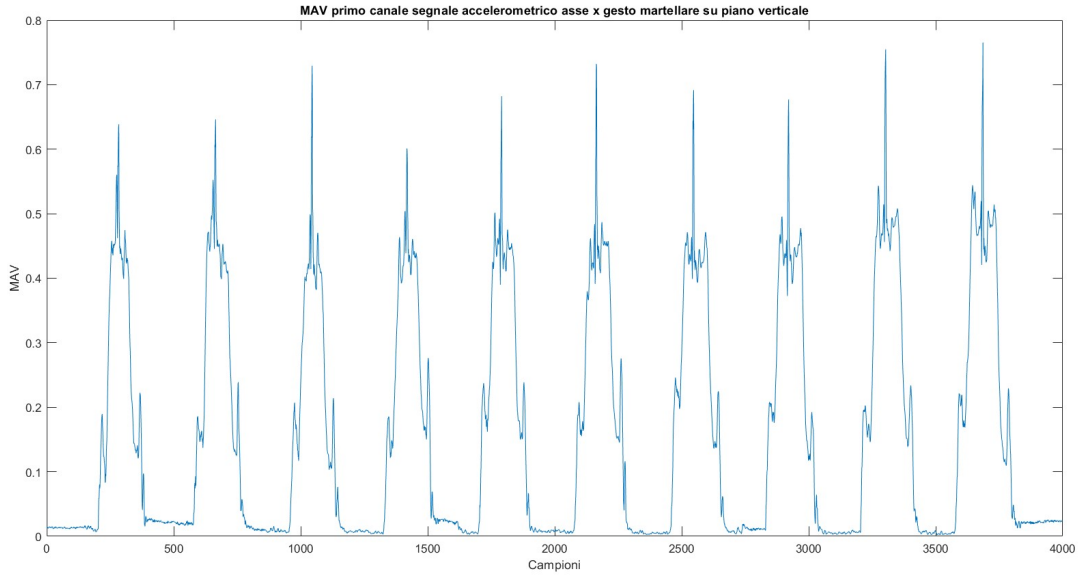


Figura 4.7: MAV segnale accelerometrico del gesto martellare su piano verticale

2. Root mean square(RMS)

   Il valore quadratico medio (RMS) è un'altra feature popolare nell'analisi del segnale EMG. È modellata come un processo casuale gaussiano modulato in ampiezza definito come forza costante e contrazione non affaticante. La definizione matematica della RMS può essere scritta come (Eq. 4.2):

$$RMS = \sqrt{1/N \sum_{i=1}^{N} x_i^2} \tag{4.2}$$

   La root mean square è stata calcolata con la funzione presente nel file Matlab "getrmsfeat.m". In seguito i grafici della RMS dell'EMG(Figura 4.8) e del segnale accelerometrico(Figura 4.9).

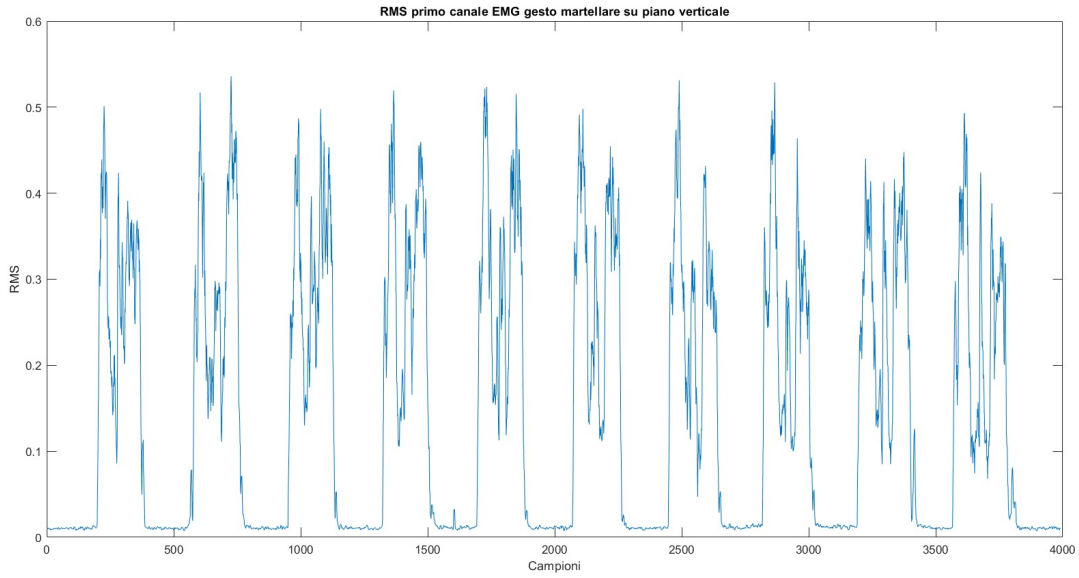


Figura 4.8: RMS segnale EMG del gesto martellare su piano verticale

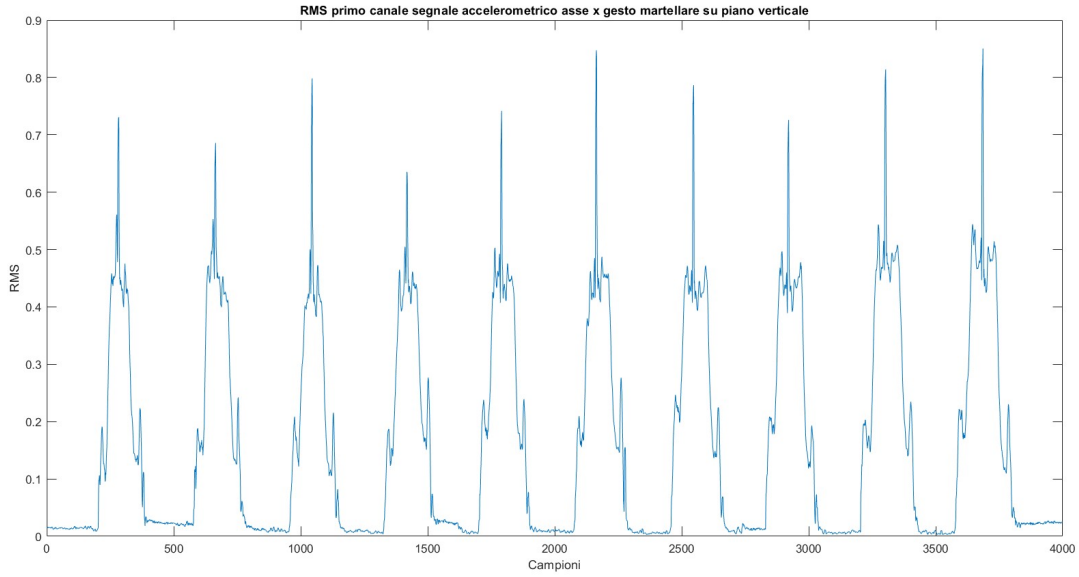


Figura 4.9: RMS segnale accelerometrico del gesto martellare su piano verticale

3. Integrated absolute value(IAV)

   Il valore assoluto integrale (IAV) può essere descritto come i valori assoluti dell'ampiezza del segnale EMG.

   La Integrate absolute value è stata calcolata con la funzione presente nel file Matlab "getiavfeat.m".

   In seguito sono presenti i grafici della IAV dell'EMG(Figura 4.10) e del segnale accelerometrico(Figura 4.11).

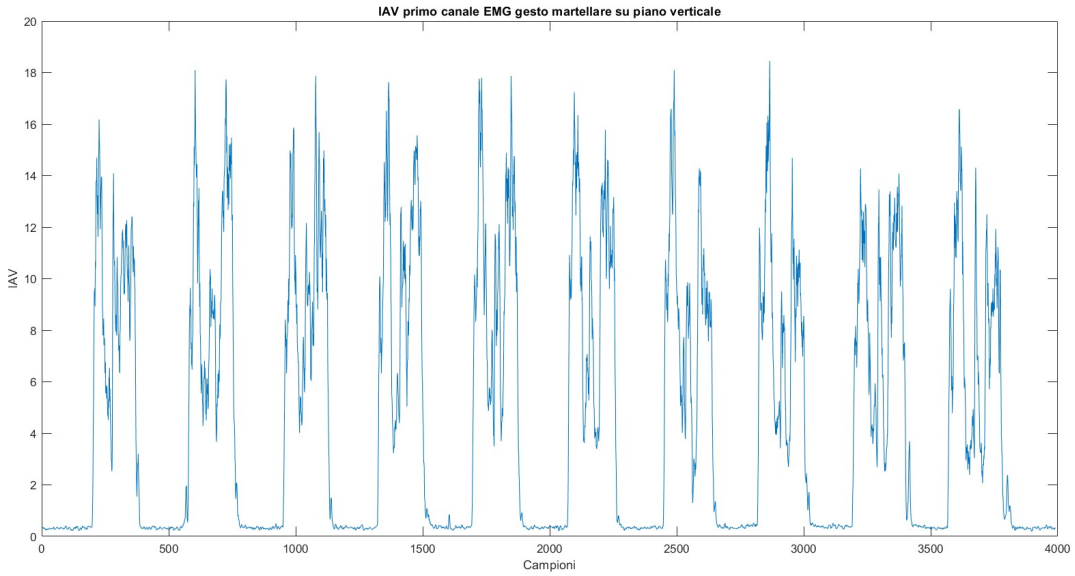


Figura 4.10: IAV segnale EMG del gesto martellare su piano verticale

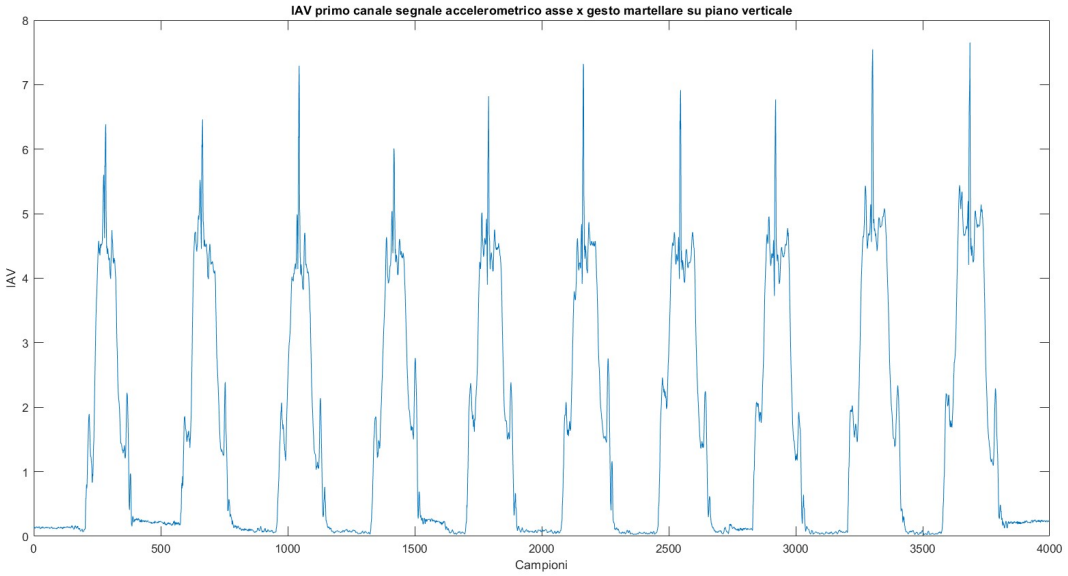


Figura 4.11: IAV segnale accelerometrico del gesto martellare su piano verticale

4. Waveform length(WL)

   La waveform length è una misura della complessità del segnale. È definita come lunghezza cumulativa della forma d'onda EMG sul segmento di tempo. Può essere calcolata come (Eq. 4.3):

$$WL = \sum_{i=1}^{N-1} |x_{i+1} - x_i| \tag{4.3}$$

   La waveform length è stata calcolata con la funzione presente nel file Matlab "getwlfeat.m". In seguito i grafici della WL dell'EMG(Figura 4.12) e del segnale accelerometrico(Figura 4.13).

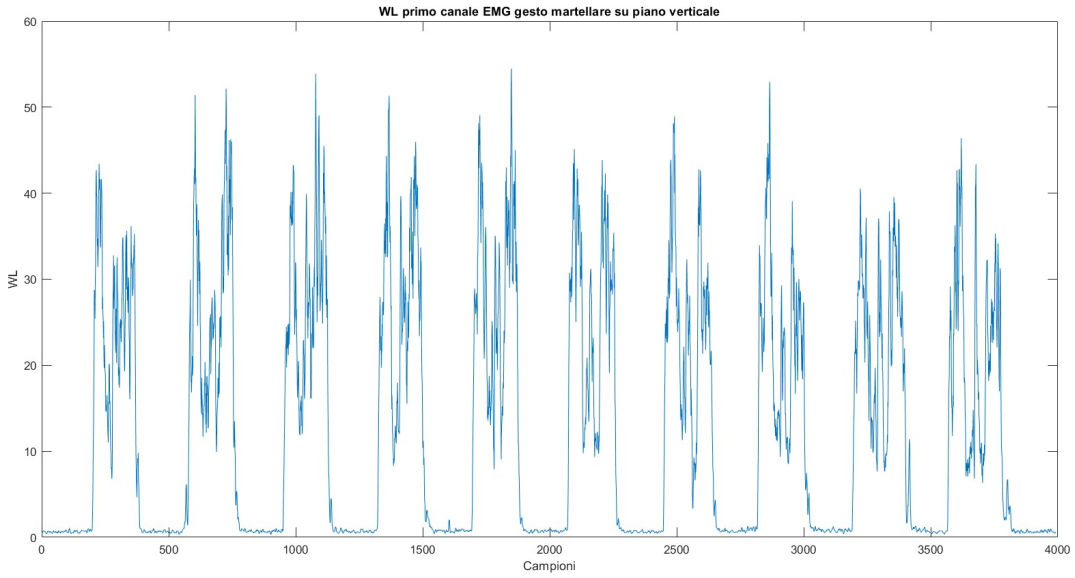


Figura 4.12: WL segnale EMG del gesto martellare su piano verticale

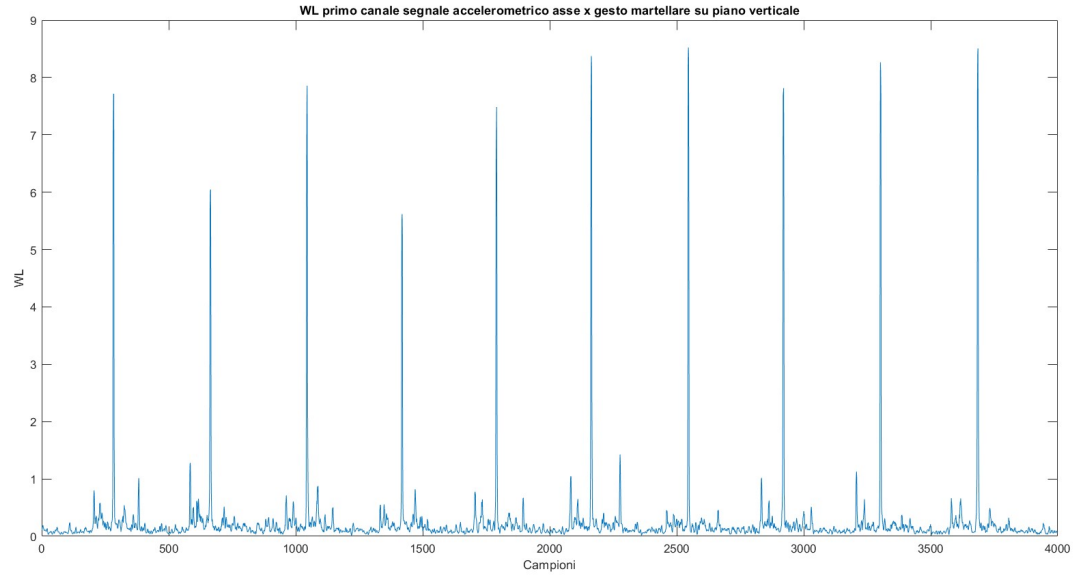


Figura 4.13: WL segnale accelerometrico del gesto martellare su piano verticale

5. Zero crossing(ZC)

   Lo zero crossing (ZC) è una misura dell'informazione in frequenza del segnale EMG definita nel dominio del tempo. È il numero di volte in cui i valori di ampiezza del segnale EMG attraversano il livello di ampiezza zero.

   Lo zero crossing è stato calcolato con la funzione presente nel file Matlab "getzcfeat.m" e in seguito sono presenti i grafici della feature calcolata su EMG(Figura 4.14) e su segnale accelerometrico(Figura 4.15).

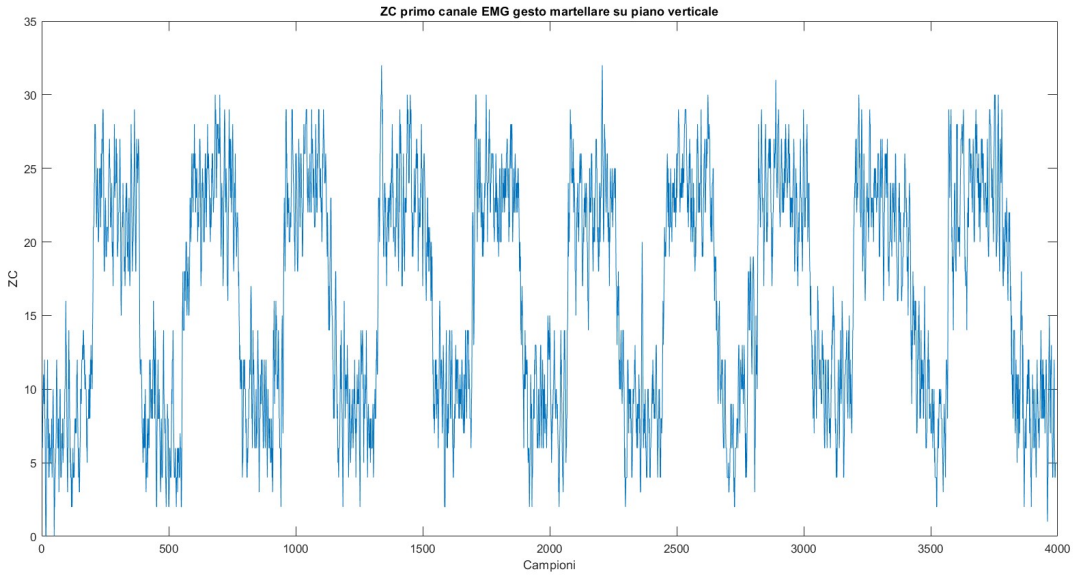


Figura 4.14: ZC segnale EMG del gesto martellare su piano verticale

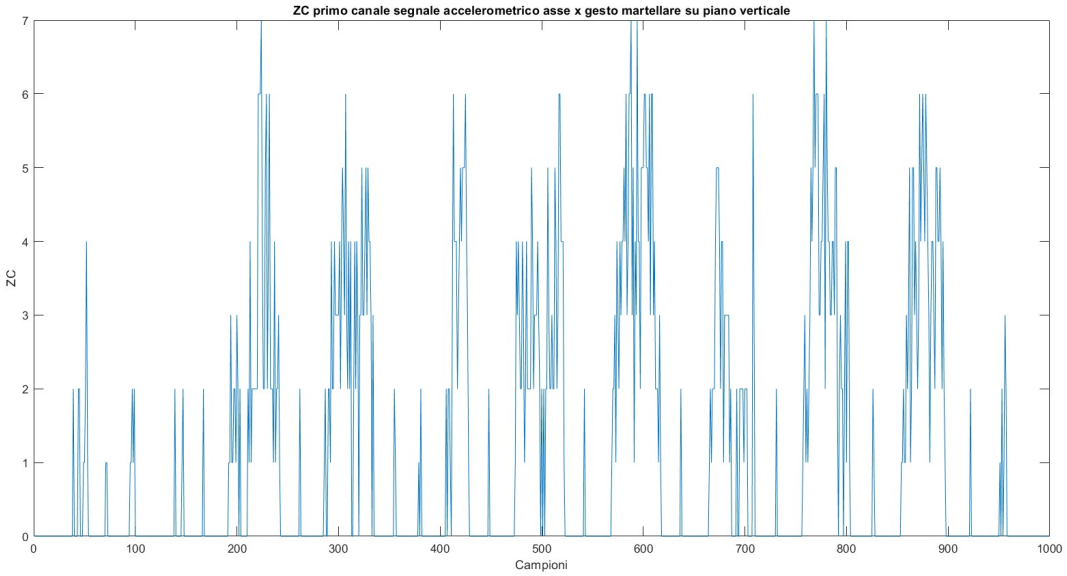


Figura 4.15: ZC segnale accelerometrico del gesto martellare su piano verticale

6. Slope sign change(SSC)

   La slope sign change(SSC) è un altro metodo per rappresentare le informazioni di frequenza del segnale EMG. È il numero di volte in cui la pendenza del segnale EMG cambia segno. La SSC è stata calcolata con la funzione presente nel file Matlab "getsscfeat.m". In seguito sono presenti i grafici della feature calcolata su EMG(Figura 4.16) e su segnale accelerometrico(Figura 4.17).

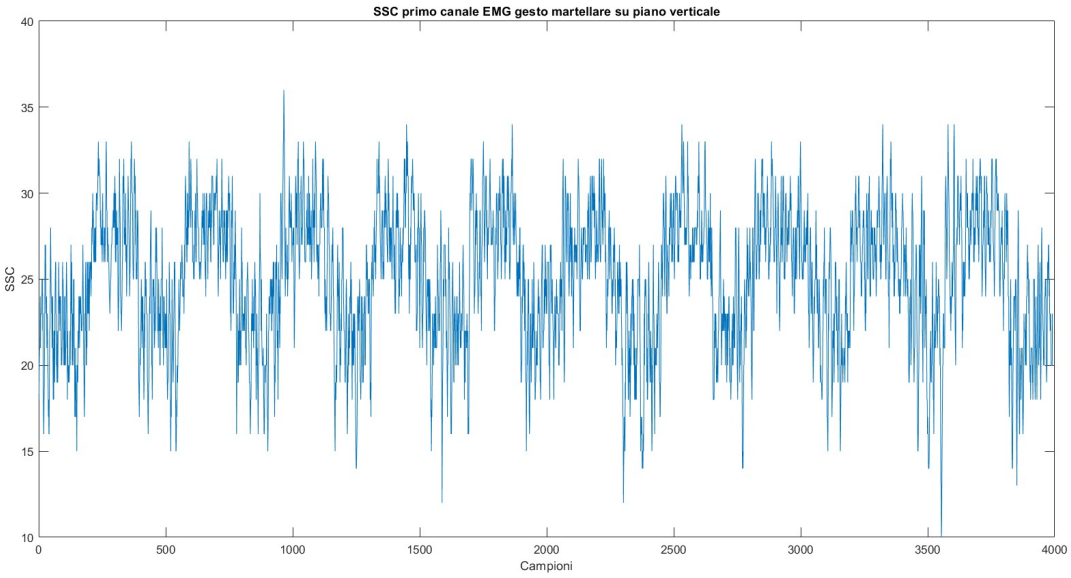


Figura 4.16: ZC segnale EMG del gesto martellare su piano verticale

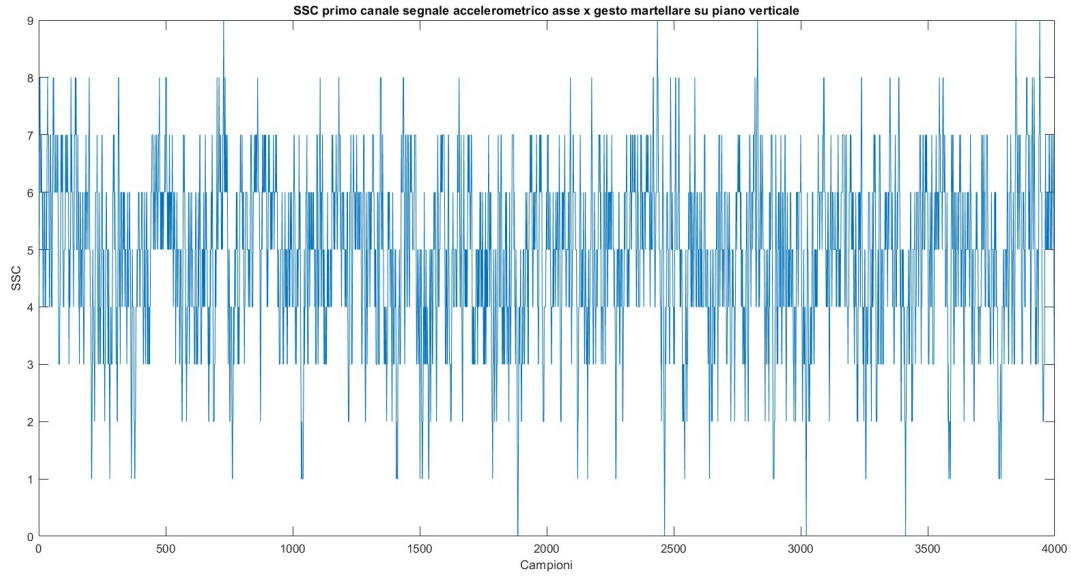


Figura 4.17: SSC segnale accelerometrico del gesto martellare su piano verticale

Per quanto riguarda la classificazione è stato utilizzato il classificatore ClassificationLearner di Matlab, uno strumento che consente agli utenti di operare un'analisi interattiva dei dati, addestrando i classificatori con diversi tipi di algoritmi di apprendimento.
Attraverso questa applicazione, gli utenti possono selezionare diversi algoritmi, diverse caratteristiche dei campioni e diversi parametri per ottenere un classificatore ottimale e osservare la corrispondente accuratezza di validazione.

Capitolo 5

Classificazione e risultati

5.1 Creazione delle labels

Dopo aver calcolato tutte le features sugli otto canali del segnale elettremiografico e i tre del segnale accelerometrico sono state costruite le matrici che poi sono state utilizzate per la classificazione dei gesti.

Delle features descritte nel capitolo precedente ne sono state utilizzate cinque, ovvero la WL,la MAV, la IAV, la RMS, lo ZC lasciando da parte la SSC poichè ritenuta di poco interesse per lo studio in esame.

I dati elaborati sono stati organizzati in matrici: una contenente le features estratte dai segnali accelerometrici, una contenente quelle ottenute dai dati elettromiografici. Infine è stata definita una matrice che contenesse le features estratte da entrambi i sistemi.

Prima di ottenere le matrici finali è stato necessario il passaggio della costruzione delle labels, ovvero dei vettori che presentano un valore numerico fisso se la feature si riferisce alla fase di movimento, identificando univocamente un gesto dall'altro, e lo zero nell'intervallo di campioni in cui il soggetto è in posizione di riposo(rest).

Queste ultime sono state definite grazie ai vettori di start e stop che sono stati definiti nel paragrafo 3.2, sono state implementate per ogni gesto e il valore numerico cambiava di gesto in gesto. Di seguito sono elencati i gesti con il loro rispettivo valore della label durante la contrazione (Tabella 5.1) e un esempio di una MAV calcolata su un segnale EMG (Figura 5.1).

A questo punto sono state create le matrici, quella relativa ai dati accelerometrici è stata costruita attraverso la concatenazione orizzontale delle matrici delle 5 features ottenute dai dati accelerometrici e poi con la concatenazione verticale delle matrici di tutti i gesti, ottenendo dunque una matrice con 15 colonne di dati più una sedicesima contenente le label.

La matrice dei dati elettromiografici è stata ottenuta con lo stesso processo, ma con i dati EMG. In questo caso naturalmente le colonne erano 40 più la quarantunesima per le label.
Le due matrici sono state normalizzate grazie alla funzione "normalize" di Matlab, mentre l'ultima colonna delle label è stata mantenuta invariata.
A questo punto, concatenando orizzontalmente le due matrici sovracitate e mantenendo solo l'ultima colonna delle lable è stata costruita la matrice contenente sia i dati inerziali che quelli elettromiografici.

Tabella 5.1: Label gesti.

Gesto	Classe
Rest	0
Bere da un bicchire	1
Lavarsi le mani	2
Mangiare	3
Abbassare una maniglia	4
Sollevare una scatola	5
Spostare una scatola orizzontalmente	6
Martellare su piano orizzontale	7
Martellare su piano verticale	8
Girare chiave inglese sul piano vertcale	9
Girare chiave inglese sul piano orizzontale	10
Scrivere	11
Versare liquido in un bicchiere	12
Bere da una tazzina	13
Fumare	14
Joystick	15
Avvitare con cacciavite su piano orizzontale	16
Avvitare con cacciavite su piano verticale	17

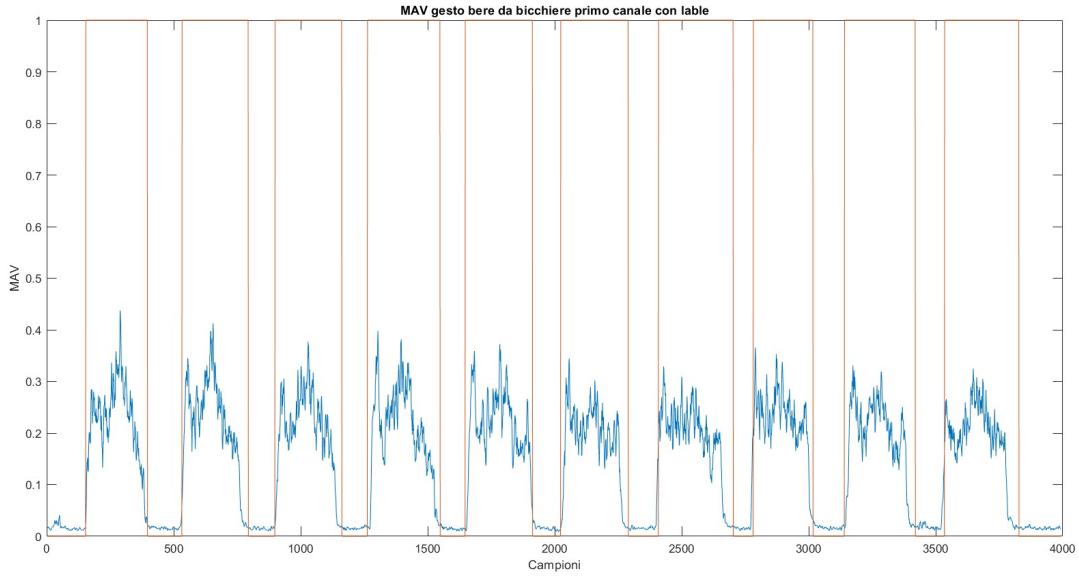


Figura 5.1: MAV gesto bere da bicchiere con label

5.1.1 Prove con diversi modelli di classificazione

Prima di arrivare a risultati soddisfacenti sono state eseguite diverse prove mediante l'utilizzo di vari tipi di modelli di classificazione.
Tra questi, quelli che non hanno fornito risultati adeguati sono stati i modelli Tree, LDA e SVM. Infatti, l'accuratezza ottenuta con la matrice di features contenente sia i dati accelerometrici che quelli elettromiografici utilizzando il Decision Tree, come riportato in(Figura 5.2), è solo del 63.2%.

Model 1: Tree
Status: Trained

Training Results

Accuracy (Validation)	63.5%
Total cost (Validation)	17353
Prediction speed	~160000 obs/sec
Training time	11.517 sec

Test Results

Accuracy (Test)	63.2%
Total cost (Test)	7485

Figura 5.2: Risultati test utlilizzando Decision Tree

I risultati ottenuti con il modello di classificatore Linear Discriminant con la matrice di features contenente sia i dati accelerometrici che quelli elettromiografici, riportati in (Figura 5.3) sono

altrettanto inadatti con un'accuratezza del 60.0%.

Model 4: Linear Discriminant
Status: Trained

Training Results

Accuracy (Validation)	59.9%
Total cost (Validation)	19039
Prediction speed	~55000 obs/sec
Training time	11.056 sec

Test Results

Accuracy (Test)	60.0%
Total cost (Test)	8140

Figura 5.3: Risultati test utlilizzando LDA

Risultati leggermente migliori sono stati ottenuti con la Support Vector Machines(SVM) e infatti, utilizzando la stessa matrice degli altri due modelli, come riportato in(Figura 5.4), l'accuratezza è del 74.0%.

Model 2: SVM
Status: Trained

Training Results

Accuracy (Validation)	73.9%
Total cost (Validation)	12375
Prediction speed	~9400 obs/sec
Training time	256.93 sec

Test Results

Accuracy (Test)	74.0%
Total cost (Test)	5286

Figura 5.4: Risultati test utlilizzando SVM

Come è possibile vedere dalle tre figure(Figura 5.2),(Figura 5.3),(Figura 5.4), nonostante sia stata utilizzata la matrice contenente entrambe le tipologie di dati, i risultati di accuratezza ottenuti non permettono una corretta classificazione dei gesti.
L'algoritmo che ha invece ottenuto i risultati più opportuni è stato il modello KNN del quale i risultati saranno discussi in seguito nel dettaglio.

5.2 Risultati e discussione

5.2.1 Risultati di matrice con dati EMG, accelerometrici e EMG e accelerometrici insieme

La prima matrice fornita al classificatore è stata quella dei dati elettromiografici. Il modello di classificatore addestrato è il KNN.

Come risultato si ottiene, con i dati forniti, un'accuratezza della classificazione abbastanza soddisfacente, infatti, dalla (Figura 5.5), dalla matrice di confusione(Figura 5.6) e dallo scatter plot(Figura 5.7) della fase di test si evince che i dati elettromiografici da soli già permettono di ottenere dei risultati di accuratezza di riconoscimento dei gesti abbastanza elevati ottenendo un'accuratezza del 82.4%.

Nel complesso la maggior parte dei gesti viene ben distinta dal classificatore, la classe che fornisce il massimo valore di accuratezza è la numero 14 (95.4% di accuratezza), che corrisponde al gesto fumare che evidentemente si distingue bene da tutti gli altri gesti data la differenza nel tipo di movimento e nella modalità di contrazione dei muscoli dell'avambraccio.

Le classi che invece presentano i valori di accuratezza minori sono quelle corrispondenti ai gesti 3 e 4, che corrispondono rispettivamente alle azioni di mangiare e di abbassare una maniglia (Tabella 5.1), che invece non vengono riconosciuti completamente e visti dal classificatore come gesti simili.

Un'ipotesi potrebbe essere che ciò sia dovuto al fatto che il movimento di afferrare la forchetta e abbassarla per infilzare risulti simile a quello di afferrare e abbassare una maniglia.

Model 2: KNN
Status: Trained

Training Results

Accuracy (Validation)	81.4%
Total cost (Validation)	8852
Prediction speed	~3100 obs/sec
Training time	69.082 sec

Test Results

Accuracy (Test)	82.4%
Total cost (Test)	3577

Figura 5.5: Risultati train e test dati elettromiografici

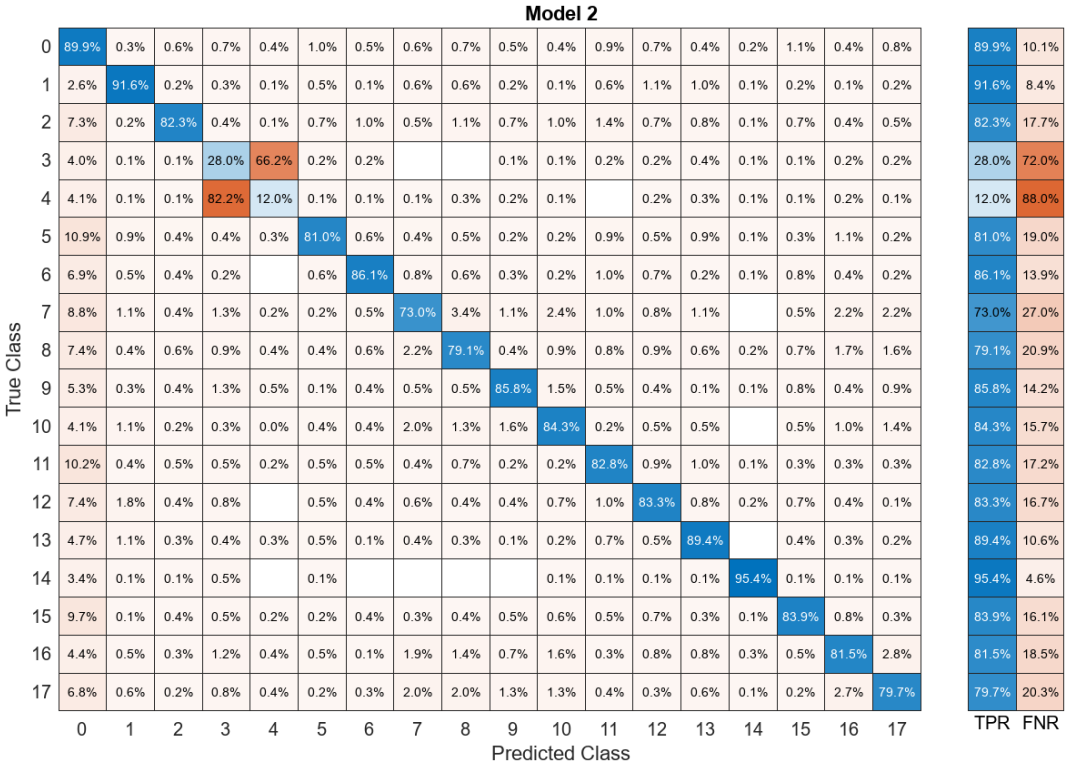


Figura 5.6: Confusion matrix test dati elettromiografici KNN

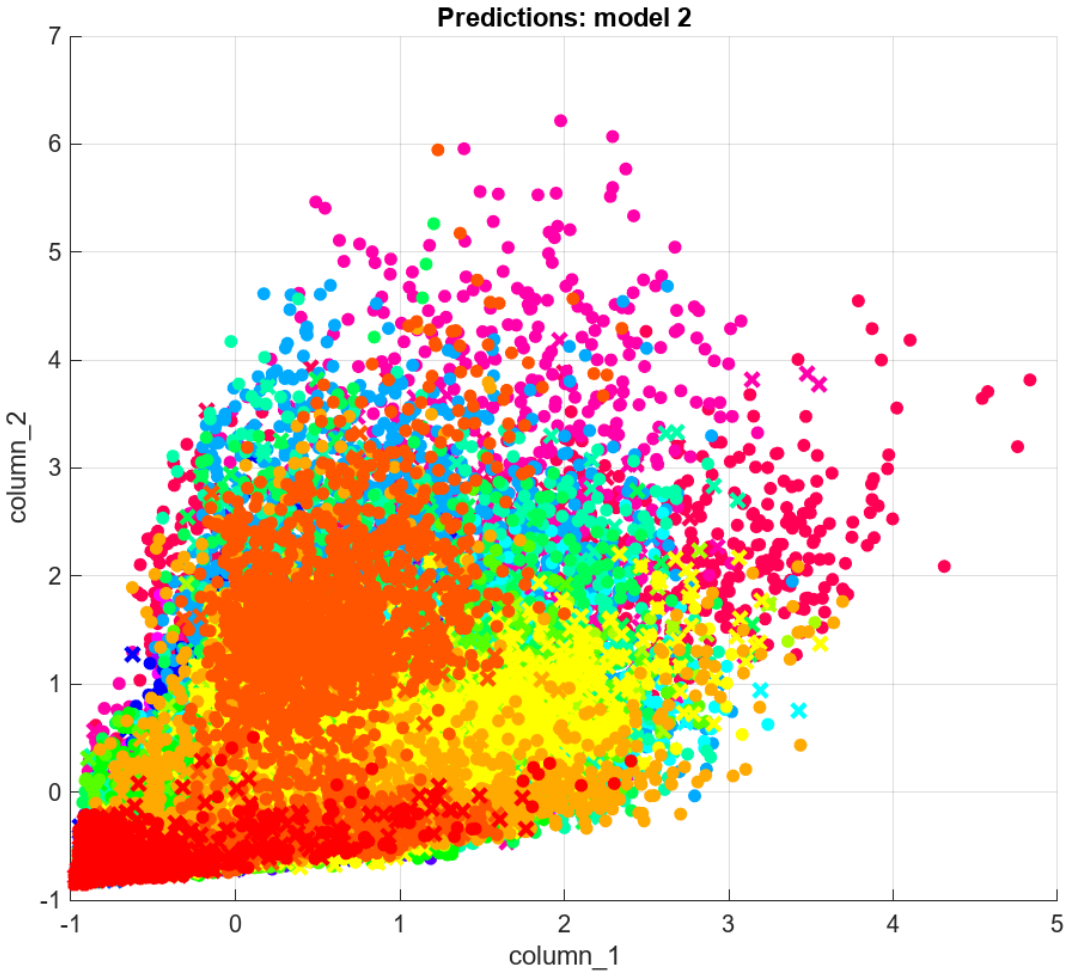


Figura 5.7: Scatter plot test dati elettromiografici KNN

La seconda matrice fornita al classificatore è stata quella dei dati inerziali accelerometrici.
A differenza dei primi, questi dati da soli non riescono a fornire al classificatore KNN abbastanza informazioni per ottenere una classificazione dei gesti accuarata e infatti i risultati, come è possibile vedere in (Figura 5.8), nella matrice di confusione(Figura 5.9) e nello scatter plot(Figura 5.10) della fase di test, sono ben lontani dall' essere adeguati per una corretta validità della classificazione con un'accuratezza del solo 65.2%.
In questo caso i gesti non sono ben riconosciuti dal classificatore e presentano valori di accuratezza decisamente più bassi rispetto alla classificazione precedente, la classe con valore massimo di accuratezza è quella corrispondente alla fase di rest (classe 0 con 90.1% di accuratezza) che rimane comunque ben distinguibile, essendo la fase di riposo ridondante nei dati.
Le classi con minore accuratezza di classificazione, invece, sono le stesse del caso precedente.

Model 2: KNN
Status: Trained

Training Results

Accuracy (Validation)	64.9%
Total cost (Validation)	16661
Prediction speed	~12000 obs/sec
Training time	17.274 sec

Test Results

Accuracy (Test)	65.2%
Total cost (Test)	7086

Figura 5.8: Risultati train e test dati accelerometrici

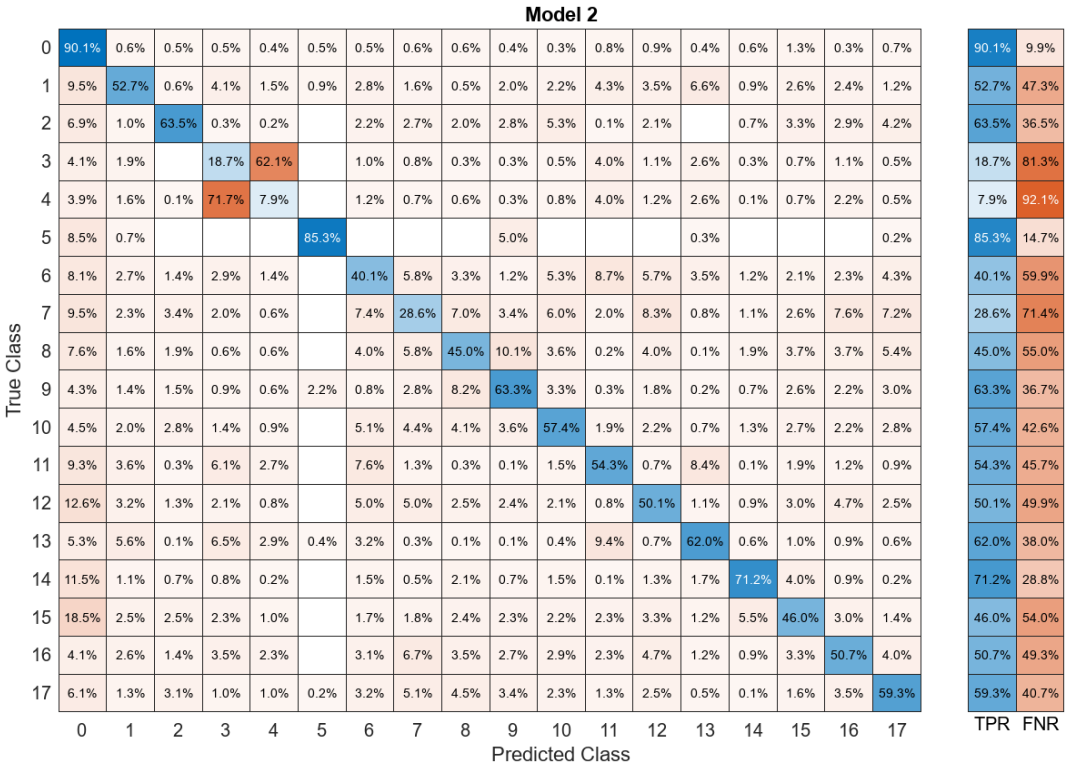


Figura 5.9: Confusion matrix test dati accelerometrici KNN

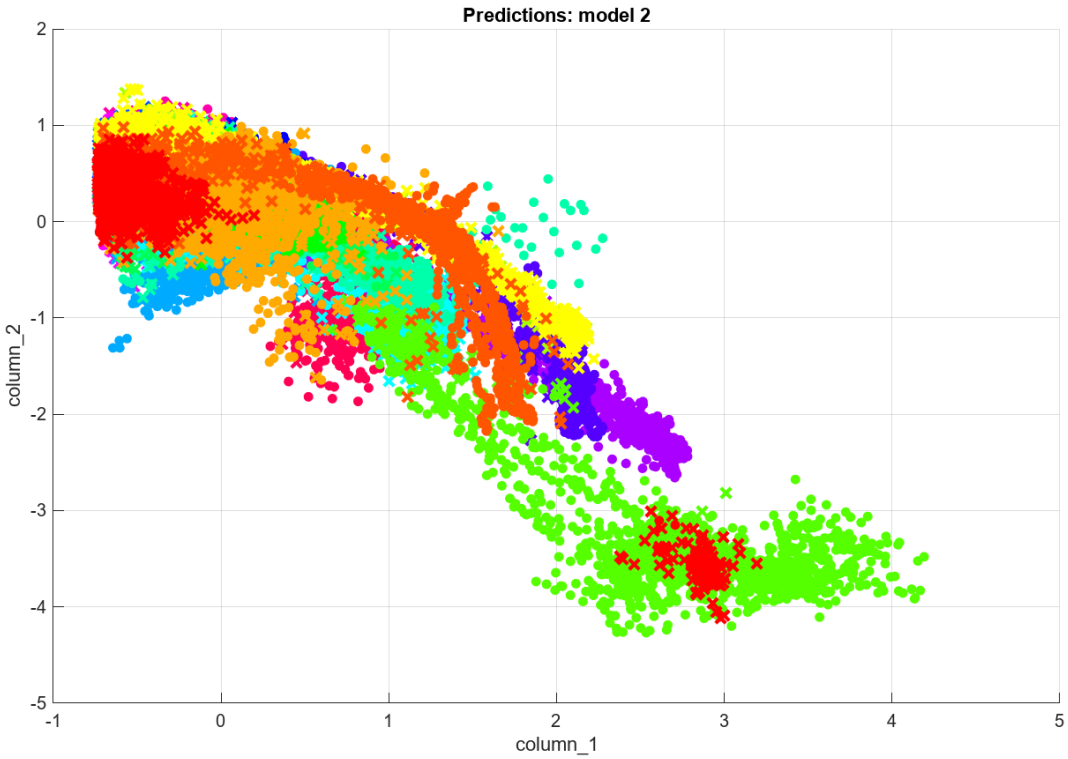


Figura 5.10: Scatter plot test dati accelerometrici KNN

Infine, la terza matrice inserita nel classificatore è stata quella dei dati totali contenente sia i dati EMG sia quelli accelerometrici.

Come detto precedentemente, infatti, uno degli obiettivi del tirocinio era confermare e verificare che, come indicato da molti recenti studi[24, 23, 29], l'associazione dei due tipi di dati, il primo relativo alla contrazione dei muscoli e il secondo relativo al movimento dell'avambraccio, potesse in qualche modo aumentare l'accuratezza della classificazione di gesti, soprattutto, come in questo caso, di gesti dinamici.

I risultati sono stati più che soddisfacenti, infatti l'accuratezza della classificazione è aumentata del circa 10% rispetto a quella fornita dai soli dati elettromiografici come è possibile evincere dalla (Figura 5.11), dalla matrice di confusione(Figura 5.12) e dallo scatter plot(Figura 5.13).

Infatti, tutti i gesti sono ben identificati e quasi tutti i task sono identificati con un valore superiore o che si avvicina al 90% di accuratezza.

Gli unici due gesti che non sono ben riconosciuti dal classificatore rimangono il gesto mangiare e il gesto abbassare la maniglia che però, avendo usato i due tipi di dati insieme, hanno un risultato di accuratezza più alto rispetto a quello ottenuto dai soli dati EMG.

Model 3: KNN
Status: Trained

Training Results

Accuracy (Validation)	90.5%
Total cost (Validation)	4507
Prediction speed	~2000 obs/sec
Training time	106.27 sec

Test Results

Accuracy (Test)	92.0%
Total cost (Test)	1637

Figura 5.11: Risultati train e test dati accelerometrici e accelerometrici

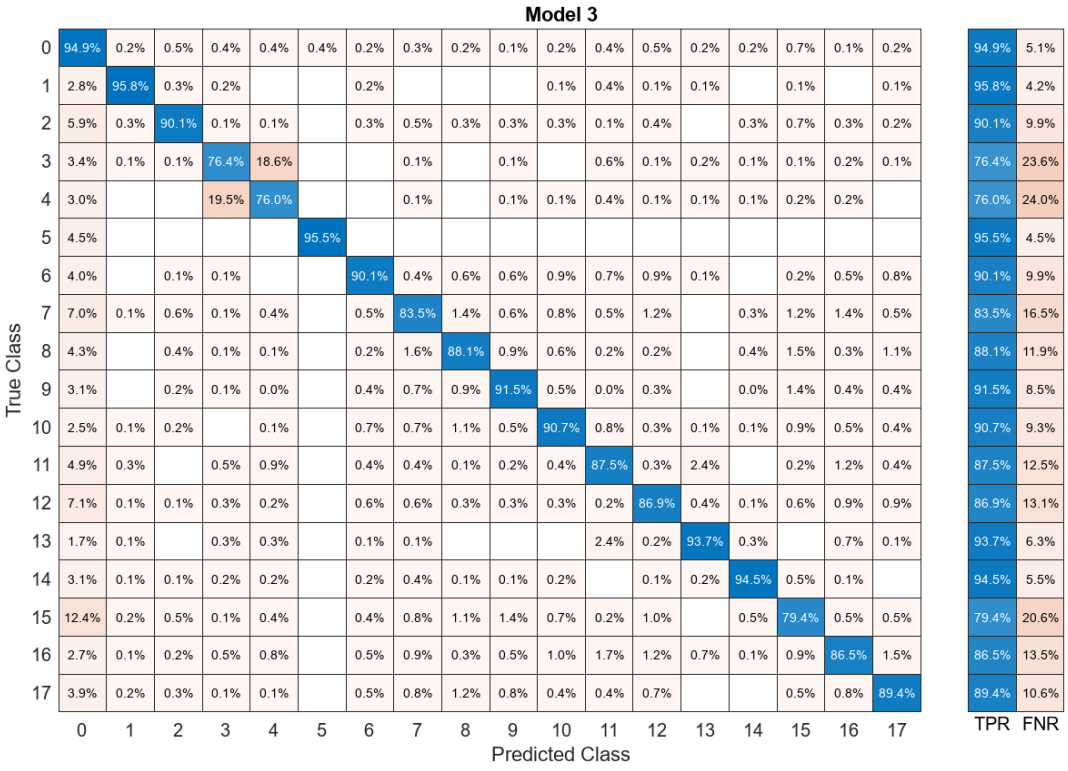


Figura 5.12: Confusion matrix test dati elettromiografici e accelerometrici KNN

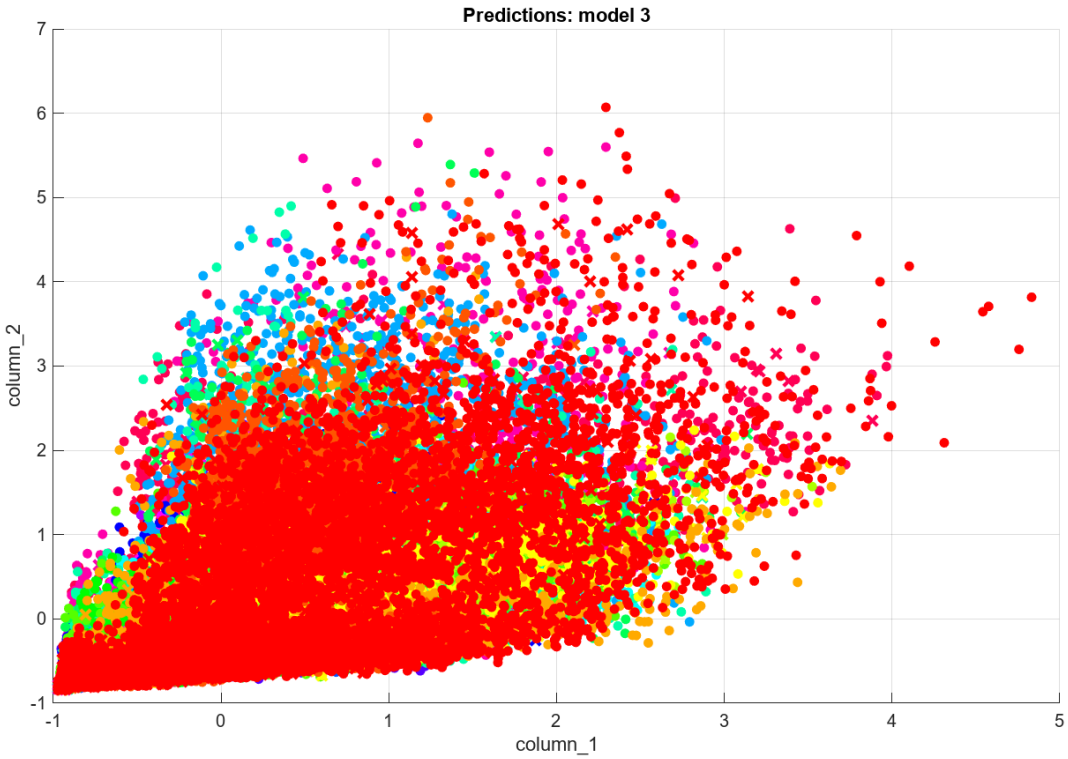


Figura 5.13: Scatter plot test dati elettromiografici e accelerometrici KNN

Confrontando i risultati provenienti da tutte e tre le matrici oltre alle osservazioni già discusse è possibile notare nella Tabella 5.2 che il risultato di accuratezza nella fase di test è sempre maggiore, anche se di poco, di quello nella fase di addestramento e ciò conferma che il modello utilizzato è corretto e che non ci sono errori nella distribuzione dei dati.

Tabella 5.2: Accuratezza train e test.

Tipo di dati	Accuratezza fase train	Accuratezza fase test
EMG	81.4%	82.4%
Dati accelerometrici	64.9%	65.2%
EMG e dati accelerometrici	90.5%	92.0%

5.2.2 Robustezza del modello

È stata inoltre verificata la robustezza del modello fornendo nuovamente al classificatore la matrice con dati accelerometrici e elettromiografici completa, inserendo però una percentuale di dati per l'addestramento del 50% e quindi del 50% per il test.
In questo caso ci si aspetta che l'accuratezza di classificazione dei gesti si abbassi perchè sono forniti troppi pochi dati affinchè il classificatore sia addestrato in modo efficiente.
Effettuando la prova i risultati ottenuti con l'algoritmo KNN sono promettenti (Figura 5.14) e (Figura 5.15) e con un'accuratezza del 89.7% il modello risulta robusto anche con quantità inferiori di dati forniti.

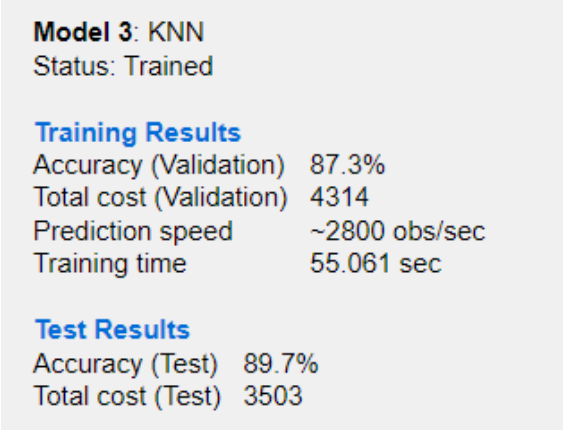


Figura 5.14: Risultati con 50% dei dati

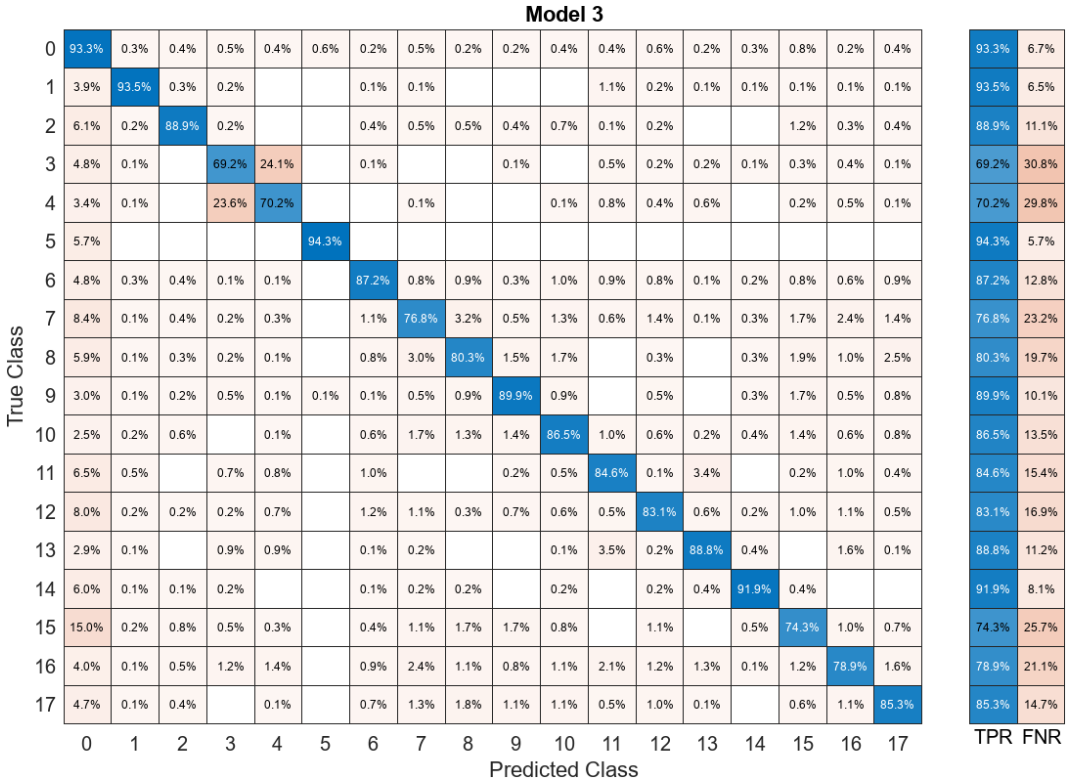


Figura 5.15: Confusion matrix con 50%di dati

5.2.3 Confronto con dati bilanciati

Arrivati a questo punto risulta necessario fare una precisazione, infatti le matrici fornite al classificatore, per come sono costruite, sono di per se sbilanciate perchè gran parte del vettore delle label è costituita da zeri.

Questo perchè in primo luogo, come detto nel protocollo di misura, ogni sequenza di gesti iniziava e terminava con una fase di riposo e per questo si avranno, per ogni ripetizione dello stesso gesto 11 intervalli di rest e 10 di contrazione e inoltre la classe zero era sempre la stessa per ogni gesto; quindi nel vettore label, mentre nella contrazione il numero variava di gesto in gesto, nella fase di riposo era sempre 0.

Questo porta a uno sbilanciamento dei dati e come conseguenza a un'accuratezza maggiore perchè la classe zero sarà riconosciuta più facilmente essendo preponderante.

Per confermare che il modello sia comunque corretto e fornisca una classificazione valida è stata eliminata la classe zero, inserendo una matrice che presenti solo fasi di contrazione nel classificatore (sempre utilizzando l'algoritmo KNN).

Come è possibile osservare in (Figura 5.16) e (Figura 5.17) la classificazione dei gesti con questo

nuovo approccio fornisce dei risultati di accuratezza più bassi come ci si aspettava, ma che comunque risultano soddisfacenti ottenendo un'accuratezza dell'87.0%.

Model 2: KNN
Status: Trained

Training Results

Accuracy (Validation)	86.1%
Total cost (Validation)	4242
Prediction speed	~3300 obs/sec
Training time	41.088 sec

Test Results

Accuracy (Test)	87.0%
Total cost (Test)	1691

Figura 5.16: Risultati train e test matrice solo contrazioni

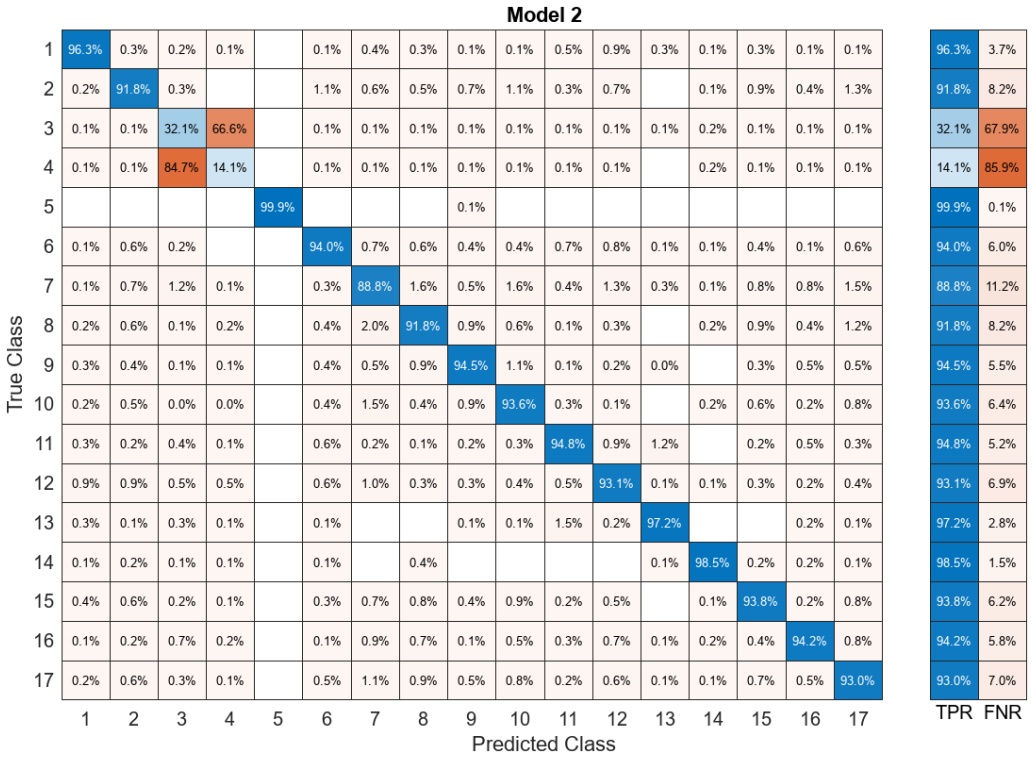


Figura 5.17: Confusion matrix matrice solo contrazioni

Capitolo 6

Conclusioni

La tesi tratta l'argomento del riconoscimento dei gesti della vita quotidiana tramite l'utilizzo di dati acquisiti con un dispositivo più facile da utilizzare e più economico rispetto ad altri per poi valutare la validità di essi grazie a un classificatore che utilizza algoritmi e fornisce l'accuratezza della categorizzazione dei gesti.
I risultati ottenuti sono promettenti, l'accuratezza nella classificazione dei gesti è abbastanza elevata da considerare lo strumento valido ed efficiente.
Infatti si è ottenuta un'accuratezza dell' 82.4% utilizzando unicamente il segnale EMG.
Non è questo però il risultato più rilevante, dato che, l'utilizzo di segnali elettormigrafici e inerziali ha prodotto un risultato di accuratezza del 92.0% , portando a compimento tutti e due gli obiettivi che ci eravamo posti.
Difatti, da un lato conferma la validità del dispositivo, dall'altro prova che i due segnali, se utilizzati entrambi, forniscono migliori risultati.
Il modello ottenuto risulta robusto e valido al di là dello sbilanciamento dei dati con grandi prestazioni anche per dati contenenti solamente gli intervalli di contrazione.
Infine dunque, possiamo affermare che il dispositivo Myo armband può essere, in determinati contesti, una valida sostituzione di altri dispositivi che necessiterebbero la presenza di professionisti specializzati, in quanto fornisce risultati confrontabili con quelli degli stessi.

Bibliografia

[1] https://www.physiofitlatina.it/elettromiografia-latina/.

[2] Marianne Boyer; Laurent Bouyer; Jean-Sébastien Roy and Alexandre Campeau-Lecours. Reducing noise, artifacts and interference in single-channel emg signals: A review. *Sensors*, 23(6), March 2023.

[3] Carlo J. De Luca; L. Donald Gilmore; Mikhail Kuznetsov; Serge H. Roy. Filtering the surface emg signal: Movement artifact and baseline noise contamination. *Sensors*, 43(8):1573–9, May 2010.

[4] https://www.usgs.gov/centers/pcmsc/science/inertial-measurement-unit-imu.

[5] Srikanth Sagar Bangaru; Chao Wang and Fereydoun Aghazadeh. Data quality and reliability assessment of wearable emg and imu sensor for construction activity recognition). *Sensors*, 20, 2020.

[6] https://wearables.com/products/myo.

[7] https://time.com/4173507/myo-armband-review/.

[8] https://ai.plainenglish.io/k-nearest-neighbors-knn-769bd39514c6.

[9] https://vitolavecchia.altervista.org/caratteristiche-degli-alberi-di-decisione-decision-tree-in-informatica/.

[10] http://www.r-project.it/book/analisi-discriminante-lineare-e-quadratica-lda-e-qda.html.

[11] https://www.analyticsvidhya.com/blog/2021/10/support-vector-machinessvm-a-complete-guide-for-beginners/.

[12] Mansooreh Montazerin; Elahe Rahimian ;Farnoosh Naderkhani; S. Farokh Atashzar; Svetlana Yanushkevich and Arash Mohammadi. Transformer-based hand gesture recognition from

instantaneous to fused neural decomposition of high-density emg signals. *Nature, scientific reports*, July 2023.

[13] Alejandro Peña; Alexandro López-González Alejandro Toro-Ossaba ; Juan Jaramillo-Tigreros; Juan C. Tejada and Rui Alexandre Castanho. Lstm recurrent neural network for hand gesture recognition using emg signals. *Applied sciences*, 12, 2022.

[14] Chico A.; Cruz P.J.; Vásconez J.P.; Benalcázar M.E.; Álvarez R.; Barona L.; Valdivieso Á.L. Hand. Gesture recognition and tracking control for a virtual ur5 robot manipulator. October 2021.

[15] Kim J.; Yang S.; Koo B.; Lee S.; Park S.; Kim S.; Cho K.H.; Kim Y. Based hand posture recognition and visual feedback training for the forearm amputee. *Sensors*, 22, 2022.

[16] Juan Pablo Vásconez ; Lorena Isabel Barona López; Ángel Leonardo Valdivieso Caraguay and Marco E. Benalcázar. Hand gesture recognition using emg-imu signals and deep q-networks. *Sensors*, 22(24), December 2022.

[17] Nuzzi Cristina; Pasinetti Simone; Lancini Matteo; Docchio Franco; Sansoni Giovanna. Deep learning based machine vision: First steps towards a hand gesture recognition set up for collaborative robots. *Workshop on Metrology for Industry 4.0 and IoT, MetroInd 4.0 and IoT - Proceedings*, August 2018.

[18] Linchu Yang ; Ji'an Chen and Weihang Zhu. Dynamic hand gesture recognition based on a leap motion controller and two-layer bidirectional recurrent neural network. *Sensor*, 20, 2020.

[19] Ziqi Yang; Taiyu Chen; Diliang Chen; Xiaoliang Zhang and Ming-Chun Huang. Cooperative sensing and wearable computing for sequential hand gesture. *IEEE SENSORS JOURNAL*, 19, July 2019.

[20] Andrés Jaramillo-Yánez; Marco E. Benalcázar and Elisa Mena-Maldonado. Real-time hand gesture recognition using surface electromyography and machine learning: A systematic literature review. *Sensor*, 20, 2020.

[21] Xinyu Jiang; Long Meng; Xiangyu Liu; Jiahao Fan; Xinming Ye; Chenyun Dai and Wei Chen. Optimizing the cross-day performance of electromyogram biometric decoder. *IEEE INTERNET OF THINGS JOURNAL*, 10, March 2023.

[22] Ruochen Hu; Graduate Student Member; Xiang Chen; Haotian Zhang; Xu Zhang and Xun Chen. A novel myoelectric control scheme supporting synchronous gesture recognition and muscle force estimation). *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING*, 30, 2022.

[23] Cengiz Tepe; Muhammed Erdim. Classification of surface electromyography and gyroscopic signals of finger gestures acquired by myo armband using machine learning methods. *Biomedical Signal Processing and Control*, 75, May 2022.

[24] Arantes; Ana Paula Bittar Britto PhD; Bressan; Nadja PhD. Classification of muscle inertial motion and electromyographic activity integration to improve accuracy in pattern recognition. *Journal of Prosthetics and Orthotics*, 35(2):83–91, April 2023.

[25] Sofija Spasojević ;Tihomir V.Ilić ;Ivan Stojković; Veljko Potkonjak; Aleksandar Rodić ;José Santos-Victor. Quantitative assessment of the arm/hand movements in parkinson's disease using a wireless armband device. *Movement Disorders*, 8, August 2017.

[26] Mohammed Z. Al-Faiz; Abduladhem A.Ali Abbas H.Miry. A k-nearest neighbor based algorithm for human arm movements recognition using emg signals(conference paper). *2010 1st International Conference on Energy, Power and Control (EPC-IQ), College of Engineering, University of Basrah, Basrah, Iraq*, 2010.

[27] Shuai Han; Mingchao Li and Qiubing Ren. Discriminating among tectonic settings of spinel based on multiple machine learning algorithms). *Big Earth Data*, 3, 2019.

[28] Dhirgaam A. Kadhim; Mithaq N. Raheema; Jabbar S. Hussein. Comparative analysis of machine learning algorithms on myoelectric signal from intact and transradial amputated limbs. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 12:1735–1743, December 2023.

[29] Ekaterina Kutafina; David Laukamp; Ralf Bettermann; Ulrik Schroeder and Stephan M. Jonas. Wearable sensors for elearning of manual tasks: Using forearm emg in hand hygiene training. *Sensors*, 16, August 2016.

[30] Raghad Radi Esaa; Hanadi A. Jaber; Abbas A. Jasim. Short-term hand gestures recognition based on electromyography signals. *IAES International Journal of Artificial Intelligence (IJ-AI,4)*, 12:1765–1773, December 2023.

[31] Angkoon Phinyomark; Pornchai Phukpattaranont; Chusak Limsakul. Feature reduction and selection for emg signal classification. *Expert Systems wit Applications Contents lists available at SciVerse ScienceDirect Expert Systems with Applications*, 39:7420–7431, 2012.

Ringraziamenti

Vorrei dedicare questo spazio della tesi a tutte le persone che mi hanno supportato nel mio percorso di crescita universitaria e professionale.
Per prima cosa, vorrei ringraziare il mio relatore, la professoressa Federica Verdini per la disponibilità durante tutto il percorso di attività di tirocinio e di stesura della tesi e per avermi spiegato in modo esaustivo tutti i passaggi di un protocollo sperimentale per lo studio dei segnali .
Ringrazio inoltre i miei due correlatori, i professori Alessandro Mengarelli e Andrea Tigrini per aver accresciuto le mie conoscenze e le mie competenze nel settore.
Vorrei ringraziare i miei genitori e tutta la mia famiglia per il sostegno nella mia realizzazione personale, dalle prime scelte fino ad ora e per spingermi sempre ad impegnarmi e a dare il meglio di me.
Un ringraziamento speciale va ai miei amici e colleghi di corso, con i quali ho condiviso esperienze e che sono stati sempre presenti sia nei momenti felici che in quelli difficili.

Ancona, Ottobre 2023

Filippo Principi