



*Scuola Dottorale di Ingegneria  
Sezione di Ingegneria dell'Elettronica Biomedica,  
dell'Elettromagnetismo e delle Telecomunicazioni*

# **“TECNICHE DI CLASSIFICAZIONE E PREDIZIONE DELLE ATTIVITÀ MOTORIE PER TELEMONITORAGGIO E TELERIABILITAZIONE”**

*Rossana Muscillo*

*Docente-guida*

*Prof. Tommaso D'Alessio  
Università degli Studi di Roma TRE*

*Coordinatore:*

*Prof. Lucio Vegni  
Università degli Studi di Firenze*

Tesi sottomessa

all'Università degli Studi Roma Tre  
Dipartimento di Elettronica Applicata

per il conseguimento del titolo di

**DOTTORE DI RICERCA**

Roma, 8 Marzo 2010

*A suor Teresa  
per il suo insegnamento*

# Indice

<b>Introduzione.....</b>	<b>Pag. 5</b>
<b>Capitolo 1 Il tele monitoraggio e la tele riabilitazione.....</b>	<b>Pag. 8</b>
1.1 La classificazione come problema teorico di fondo.....	Pag. 8
1.2 La sensoristica utilizzata.....	Pag. 14
<b>Capitolo 2 Il problema della classificazione.....</b>	<b>Pag. 17</b>
2.1 Il template matching e le tecniche di clustering.....	Pag. 22
2.1.1 Il Dynamic Time Warping (DTW).....	Pag. 25
2.1.2 Il Derivative Dynamic Time Warping (DDTW).....	Pag. 30
2.1.3 Le tecniche di clustering.....	Pag. 31
2.2 La classificazione bayesiana.....	Pag. 33
2.2.1 Stima della densità di probabilità condizionata: metodi parametrici e non parametrici	Pag. 38
2.3 Le SVM.....	Pag. 43
2.4 Gli alberi di decisione e la classificazione precoce.....	Pag. 45
<b>Capitolo 3 Le tecniche di classificazione proposte.....</b>	<b>Pag. 49</b>
3.1 La classificazione gerarchica.....	Pag. 49
3.2 La classificazione cooperativa.....	Pag. 52
3.2.1 Il classificatore bayesiano e il DTW.....	Pag. 52
3.2.2 Un classificatore bayesiano a n dimensioni: la riduzione dello spazio delle features.....	Pag. 56
3.2.3 Una classificazione adattiva: Bayes e il filtro di Kalman.....	Pag. 60
3.3 La classificazione precoce.....	Pag. 63
3.3.1 Il real-time DTW.....	Pag. 64
<b>Capitolo 4: L'attività progettuale e realizzativa.....</b>	<b>Pag. 69</b>
4.1 Realizzazione sistema di acquisizione dati per Pc e Pocket Pc.....	Pag. 69
4.2 Interfaccia LAbView per acquisizione ed elaborazione dati in real time da sensori della MicroStrain.....	Pag. 74
4.3 Sistema di acquisizione di dati in tempo reale con Matlab.....	Pag. 77
<b>Capitolo 5: L'estrazione di caratteristiche.....</b>	<b>Pag. 79</b>
5.1 Il cammino e le variabili di interesse.....	Pag. 79
5.1.1 Valutazione dei parametri della camminata tramite sensori accelerometrici.....	Pag. 83
5.1.2 Applicazione su soggetti anziani.....	Pag. 87
5.1.3 Applicazione su soggetti giovani.....	Pag. 91
5.1.3 Un nuovo metodo per il calcolo della step length.....	Pag. 96
5.2 Algoritmi di separazione del tremore dal movimento volontario su segnali accelerometrici.....	Pag. 98
5.3 Possibilità di ricostruzione della posa da dati provenienti da sensori inerziali.....	Pag.100
5.4 Estrazione di caratteristiche per la riabilitazione della pelvi.....	Pag.101

<b>Capitolo 6: Le applicazioni per il monitoraggio e la riabilitazione domiciliare.</b>	<b>Pag.106</b>
6.1 Il template matching applicato su segnali accelerometrici.....	Pag.107
6.1.1 Il DTW per il riconoscimento di task motori effettuati con gli arti superiori.....	Pag.107
6.1.1.1 I diversi metodi per la fase di calibrazione.....	Pag.110
6.1.2 Il DTW e il DDTW per il riconoscimento di attività motorie quotidiane.....	Pag.111
6.2 La classificazione gerarchica: applicazione alle ADL.....	Pag.113
6.3 La classificazione cooperativa: applicazione su attività relative agli arti inferiori.....	Pag.117
6.4 La classificazione cooperativa: riconoscimento di attività su giovani e anziani tramite bayesiano a n dimensioni.....	Pag.120
6.4.1 Confronto con le SVM.....	Pag.123
6.5 La classificazione adattiva: riconoscimento di attività su giovani e anziani.....	Pag.125
6.6 La classificazione precoce: riconoscimento di gesti dell'arto superiore..	Pag.130
6.6.1 Applicazione per il riconoscimento di attività in tempo reale tramite alberi di decisione.....	Pag.137
<b>Conclusioni.....</b>	<b>Pag.139</b>
<b>Bibliografia.....</b>	<b>Pag.142</b>

## INTRODUZIONE

A seguito dell'aumento dell'età media della popolazione e della possibilità delle tecnologie attuali di fornire servizi innovativi, nel mondo della ricerca si stanno esplorando soluzioni che consentano all'utente di poter usufruire di servizi sanitari direttamente stando a casa propria, limitando così le spese del servizio sanitario nazionale e riducendo il disagio per il paziente che altrimenti dovrebbe spostarsi per ottenere assistenza .

Il presente lavoro di ricerca si inserisce infatti tra i concetti di tele riabilitazione e di tele monitoraggio, approfondendone degli aspetti a nostro avviso cruciali, tra la vastità delle implicazioni che i due concetti inevitabilmente portano con sé.

Per tele monitoraggio si intende la possibilità di trasmettere a distanza parametri di interesse per la valutazione clinica di pazienti che necessitano di un controllo continuo della loro condizione di salute. La tele riabilitazione invece consente ad un

paziente, a seguito di un evento traumatico, di ricevere a domicilio terapie, indicazioni e ausilio durante la fase di riabilitazione.

Ambedue gli aspetti richiedono innanzitutto uno studio a monte delle problematiche da affrontare, relativo alla sensoristica da utilizzare e alla combinazione più opportuna di soluzioni versatili e innovative, che consentano al paziente facilità di utilizzo e naturalità nei movimenti.

La nostra analisi a questo proposito si è concentrata sui sensori inerziali dato che tramite essi è possibile acquisire informazioni riguardanti la velocità, l'accelerazione e la posizione dei segmenti corporei a cui il sensore viene rigidamente collegato. L'accelerometria, in particolare, è infatti una tecnica a basso costo, minimamente invasiva, che permette l'estrazione di parametri significativi dell'attività motoria. La rilevanza di tale tecnica va dalla classificazione delle attività, all'individuazione di parametri predittivi di cadute, alla stima del consumo metabolico e alla valutazione di parametri indicativi della funzionalità del movimento. Subito a valle della problematica suddetta un aspetto fondamentale, e cuore della nostra analisi, riguarda l'integrazione dei dati a disposizione e la possibilità di interpretare in modo consono le informazioni che da essi ne derivino. E' infatti necessario classificare le situazioni di interesse e scartare quelle che non producono alcun tipo di conseguenza così come è necessario classificare un tipo di movimento rispetto ad un altro quando la problematica richiede un monitoraggio delle attività motorie quotidiane, che vengono analizzate in tutti i contesti medico/riabilitativi considerando l'impatto che esse hanno sulla qualità della vita. Un tale approccio risulta particolarmente interessante per monitorare le azioni di persone anziane autosufficienti o con disabilità motorie lievi/moderate, in modo da individuare se l'azione svolta ad un dato istante di tempo rientra nella normalità delle azioni quotidiane, oppure se se ne discosta in modo significativo, rappresentando quindi una situazione di potenziale o effettivo pericolo. Ciò implica la necessità di creare un modello di interpretazione delle azioni del soggetto nell'ambiente in cui vive.

La classificazione diviene poi il cuore dell'analisi anche se stiamo parlando di tele riabilitazione, in quanto l'esecuzione della terapia riabilitativa, richiede il riconoscimento del task effettuato prima di poterne valutare la bontà di esecuzione. La teoria della classificazione è un aspetto enorme della conoscenza scientifica e il presente lavoro non ha la pretesa di affrontare il tema a tutto tondo ma di approfondirne criticamente gli aspetti ritenuti più opportuni rispetto ai problemi da noi posti inizialmente.

Tra le innumerevoli tecniche, in una prima fase, ci si è concentrati sulle tecniche di Template Matching, tecniche che consentono il confronto tra il segnale da classificare e un segnale di riferimento, detto *template*, tipico della classe da riconoscere. Il confronto avviene tramite misure di distanze ed è stato applicato su serie temporali accelerometriche. In una seconda fase sono stati approfonditi gli aspetti relativi alla classificazione bayesiana, concentrandosi sia sulla scelta delle features caratteristiche che sul tipo di densità di probabilità condizionata, fattori che condizionano la forma del classificatore. Inoltre si è esplorato un approccio innovativo che, tramite l'utilizzo delle catene di Markov e del filtro di Kalman, implementi un classificatore bayesiano di tipo adattativo, variando la probabilità a priori al passo  $k$  in funzione dell'attività riconosciuta al passo  $k-1$ .

Diversi approcci di classificazione sono stati implementati cercando la cooperazione di tecniche differenti, valutando i maggiori benefici che eventualmente ne derivino. Un ulteriore contributo alla classificazione è stato dato esplorando l'idea di classificare il gesto compiuto in maniera precoce, ovvero prima del termine del gesto stesso. A questo proposito è stata implementata una versione real-time dell'algoritmo del Dynamic Time Warping. Tutte le tecniche menzionate sono state applicate per il riconoscimento di attività motorie quotidiane, sia riferite agli arti inferiori che a quelli superiori e le diverse campagne sperimentali condotte hanno interessato sia popolazione giovane che anziana, in molteplicità di protocolli applicati e di set-up sperimentali.

# Capitolo 1

## Il Telemonitoraggio e la Teleriabilitazione

### 1.1 La classificazione come problema teorico di fondo

Per tele monitoraggio si intende la possibilità di trasmettere a distanza parametri di interesse per la valutazione clinica di pazienti che necessitano di un controllo continuo della loro condizione di salute. Queste soluzioni consentono al paziente di continuare a svolgere, nella maggior parte dei casi, le loro occupazioni quotidiane ma offrono loro la possibilità di controllare attivamente parametri vitali quali il battito cardiaco, la pressione arteriosa, la temperatura corporea, la glicemia, ecc..

Indubbi sono i vantaggi di questi progetti che consentono:

- Di far viaggiare i dati e non i pazienti
- Di poter fronteggiare tempestivamente situazioni di allarme
- Di migliorare la qualità di vita dei pazienti
- Di sfoltire il lavoro dei presidi sanitari
- Effettuare un'azione sanitaria capillare sul territorio
- Fornire assistenza continua anche 24h/24h

Agli indubbi benefici si associa un grande lavoro di background tecnologico e teorico, che deve indagare, tra le innumerevoli possibilità, le soluzioni ottimali rispetto ai requisiti e adattare al problema in questione.

Una prima questione da affrontare riguarda la sensoristica da utilizzare, soprattutto tenendo in considerazione non solo la finalità del progetto quanto i requisiti di basso costo, versatilità e facilità di utilizzo.

L'impianto teorico di fondo invece deve considerare il progetto nel suo complesso, le finalità, la gestione delle informazioni, la varietà dei dati a disposizione, l'integrazione di essi e l'estrazione delle informazioni utili tra le innumerevoli informazioni grezze che si hanno a disposizione.

Monitorare una patologia, monitorare un parametro clinico o semplicemente un paziente durante una giornata vuol dire classificare e distinguere le situazioni normali da quelle patologiche lievi/gravi, e vuol dire anche saper distinguere quali tipologie di attività il soggetto sta svolgendo, eventualmente rilevando situazioni di rischio, come una caduta. I sistemi di tele monitoraggio consentono quindi di classificare le informazioni di cui disponiamo in forma grezza o più spesso sotto forma di features estratte da questi dati, sia in loco, consentendo rapidità nell'azione da svolgere e gestione in tempo reale delle situazioni di rischio, sia in remoto, dove una unità di controllo può decidere autonomamente strategie di intervento differite.

I sistemi di tele monitoraggio classico hanno l'obiettivo di monitorare parametri fisiologici e trasmettere a distanza le informazioni relativi all'intero segnale, che possa essere così analizzato da personale competente, oppure di trasmettere il segnale

già classificato in base a diversi parametri. E' il caso ad esempio dell'invio del segnale ECG, che raramente viene trasmesso per intero, ma di cui vengono inviate le informazioni di interesse, quali la frequenza cardiaca, oppure le situazioni ritenute di anomalia.

Tra le applicazioni di tele monitoraggio più recenti, il riconoscimento delle attività quotidiane in questi anni ha visto un fiorire di tecniche e applicazioni tra le più svariate, applicate principalmente a tecniche video e a sensori indossabili. Per distinguere tra attività statiche e dinamiche le tecniche hanno fatto spesso uso degli alberi di decisione [1,2,3] in cui la decisione viene presa muovendosi lungo un albero di possibilità e riducendo ad ogni passo lo spazio di decisione, partendo appunto dalla decisione iniziale di distinguere tra attività statiche e dinamiche.

Altri studi hanno classificato le attività motorie usando tecniche di clustering (k-NN) esplorando la possibilità di una classificazione non supervisionata e confrontandola con la maggior parte delle tecniche supervisionate [4,5]. Molti di questi lavori hanno analizzato anche la bontà delle diverse features, ricavate per lo più, in queste applicazioni citate, da segnali accelerometrici, e anche la possibilità di differenziarle a seconda della tecnica usata e in base alla possibilità di combinarle con tecniche diverse [5,6]. Il riconoscimento dell'atto motorio può essere poi effettuato con i classificatori Bayesiani, in cui, in una preliminare fase di training, viene stimata la densità di probabilità condizionata e anche ipotizzata una probabilità a priori [1,2,7,8]. A questo proposito anche nel corso del nostro lavoro sono state effettuate diverse valutazioni in base alle diverse probabilità a priori [9,10]. Le probabilità di compiere una determinata azione prima/dopo di un'altra sono state sfruttate nel riconoscimento di attività qualora si riconosca la sequenza della attività come un processo markoviano e si sfruttino le probabilità di transizione e la teoria dei modelli markoviani [11,12,13,10]. Altre tecniche di classificazione che hanno dati risultati soddisfacenti utilizzano le reti neurali, dove lo strato di uscita classifica l'attività, avendo a disposizione come strato di ingresso tutte le features ritenute utili [14].

Il monitoraggio dei dati fisiologici umani e il riconoscimento delle attività compiute, sia in situazioni normali che anormali di attività, diviene interessante anche ai fini della rilevazione di eventi di emergenza, soprattutto nel caso di persone anziane che vivono da sole. Diverse tecniche sono state proposte per l'identificazione di situazioni di pericolo, ad esempio utilizzando il movimento, l'audio o i video relativi ai dati del soggetto oppure analizzandone l'ambiente circostante.

Per classificare situazioni di pericolo gli impianti teorici che sono stati proposti analizzano il segnale in tempo reale e, tramite features caratteristiche, estratte sulle diverse tipologie di dati a disposizione, identificano immediatamente la situazione di anomalia. Numerosi sistemi di gestione della situazione di rischio usano classificazione tramite sistemi video, ad esempio analizzando con algoritmi di tracking i contorni delle figure analizzate e classificando le diverse situazioni tramite analisi delle componenti principali o algoritmi di clustering come i k-nearest neighbors [15]. Altri sistemi utilizzano entrambe le tecniche menzionate, usando gli accelerometri per rilevare immediatamente la variazione di situazione che viene poi confermata dall'analisi video che consente l'identificazione della situazione di emergenza [16].

Tra le situazioni di rischio più diffuse e che meritano interesse nell'ambito del monitoraggio quotidiano delle attività motorie c'è il pericolo delle cadute. La caduta è un evento traumatico soprattutto per la popolazione anziana, non solo per le ovvie possibili conseguenze di ordine traumatico, ma anche per le ripercussioni di ordine psicologico, caratterizzate dall'insicurezza e quindi dalla tendenza ad un progressivo isolamento ed alla riduzione delle attività quotidiane e dei rapporti interpersonali.

Le cadute nei soggetti anziani infatti sono rovinose non solo per ragioni neurologiche, ma anche per le conseguenze sull'apparato muscolo-scheletrico. L'approccio più utilizzato per la rilevazione delle cadute prevede [17,18] che un cambiamento di orientazione dell'asse del corpo da eretto a steso che si verifichi subito dopo una grande, improvvisa accelerazione negativa, prodotta dall'impatto, sia indicativo di una caduta. Entrambe queste considerazioni possono essere determinate

usando un accelerometro che ha una risposta in continua, ovvero utilizzandolo cioè come inclinometro, e rilevate con diverse metodologie [19, 20, 21, 22, 23, 24]. Più specificamente per il rischio di cadute sono stati implementati molti sistemi di classificazione delle situazioni di rischio, che necessitano di una notevole fase di training per evitare situazioni di falsi positivi. Ad esempio, tramite l'utilizzo di reti neurali e features estratte da sensori inerziali quali accelerometri e giroscopi, sono stati addestrati classificatori con campioni di circa 30 soggetti anziani con diversi fattori di rischio di cadute, identificate tramite la scala di Tinetti, e testati su 100 soggetti altrettanto diversificati. La classificazione della situazione di rischio cadute fornita dalla rete ha fornito dati incoraggianti, addirittura superiori a sistemi addestrati grazie alle stime delle densità di probabilità a priori in un classificatore di Bayes classico [25]. Altri sistemi di classificazione del rischio di cadute prevedono l'utilizzo di un accelerometro triassiale posizionato sulla cintura che estrapoli, in una acquisizione a lungo termine, i parametri del cammino ritenuti utili in un'analisi di tipo quantitativo del cammino, e tramite essi produca in uscita una identificazione del rischio di caduta/non rischio di caduta. In questo caso sono stati utilizzati classificatori basati sugli alberi di decisione [26].

Metodi alternativi sono stati proposti grazie all'utilizzo del suono come una soluzione alternativa al video tele monitoraggio, grazie all'individuazione e la classificazione dei suoni allarmanti in un ambiente rumoroso. Il sistema di analisi audio è diviso in due fasi: individuazione del suono e classificazione. La prima fase di analisi (individuazione del suono) consiste nell'estrazione di suoni significativi da un flusso continuo del segnale audio proveniente dall'ambiente, di solito rumoroso, ed è costituito da un algoritmo di rilevazione basato sulla trasformata discreta wavelet. La seconda fase del sistema è la corretta classificazione, che utilizza un approccio statistico per individuare i suoni sconosciuti, tramite parametri ricavati dalle wavelet. Il sistema proposto presenta un 3% di tasso di mancato allarme e gli autori lo propongono come sistema che può essere fuso con altri sensori biomedici per

migliorare le prestazioni generali di un sistema di classificazione di parametri ambientali e di situazioni di anomalie [27].

Se parliamo invece di tele riabilitazione i metodi di classificazione assumono un ruolo leggermente diverso perché influenzano direttamente la terapia da seguire e consentono un ausilio in tempo reale per la realizzazione dell'esercizio riabilitativo. Infatti la tele-riabilitazione offre ad un paziente la possibilità di ricevere a domicilio sia la terapia che l'ausilio sulla fase di riabilitazione post-trauma, consentendogli di svolgere un programma riabilitativo personalizzato attraverso un computer, una webcam, sensori indossabili e interfacce ad hoc. In questo caso perciò l'approccio metodologico di fondo consente sia l'identificazione del task motorio eseguito o di una parte di esso, che la valutazione del task eseguito in termini di bontà del gesto eseguito. Tramite la tele riabilitazione esiste la possibilità di una interazione diretta e immediata tra il paziente e lo strumento che ha direttamente a disposizione per la terapia [28].

E' possibile ad esempio valutare se un determinato task motorio è stato eseguito in maniera corretta o meno confrontando i parametri estratti dal segnale a disposizione con gli stessi parametri estratti su una popolazione sana, oppure valutando la correlazione tra i dati a disposizione e le più comuni scale di valutazione funzionale. [29, 30, 31]. A questo proposito sono state utilizzate tecniche di classificazione basate sui Template Matching, che confrontano pattern di segnali in ingresso con andamenti dello stesso segnale in movimenti eseguiti da persone sane o, in fase di training dell'applicazione, dal soggetto stesso. Le stesse tecniche, da noi ampiamente trattate, sono state perfezionate per effettuare classificazioni dell'atto motorio in tempo reale [32], in modo da consentire un più rapido intervento dell'ausilio al movimento in tutte le tipologie di tecnologie assistive.

## 1.2 La sensoristica utilizzata

Come già ampiamente discusso, le problematiche di tele monitoraggio e tele riabilitazione sono state implementate in contesti applicativi tra i più svariati e anche con diversi apparati sperimentali. Molte applicazioni utilizzano i sistemi video per monitorare le attività quotidiane, estrapolare le situazioni di rischio e classificare le performance motorie [33, 34]. Tutti questi sistemi utilizzano telecamere, posizionate in diverse posizioni dell'abitazione, che consentono un videocontrollo quasi totale del paziente e dell'ambiente in cui normalmente vive. Soprattutto in ambito riabilitativo sono stati implementati sistemi più complessi di robotica o di realtà virtuale, ad esempio in cui, tramite ambiente virtuale, i pazienti eseguono gli esercizi proposti usando una workstation con sensori di forza che forniscono un feedback tattile in tempo reale. Al sistema viene anche fornita una webcam per il monitoraggio della seduta di riabilitazione [35]. Questi sistemi però hanno diverse problematiche, sono più costosi, esigono calibrazioni molto raffinate e non consentono di rilevare alcune situazioni in tempo reale.

Per questo nel corso degli anni si sono studiate situazioni alternative che superassero le difficoltà sopra poste e esplorassero settori più versatili, più economici e soprattutto indossabili, che sfruttassero le nuove tecnologie e consentissero facilità di utilizzo, libertà di movimento del paziente e nello stesso tempo garantissero rigorosità nei risultati.

Molto lavori hanno utilizzato, tra questi, i sensori inerziali sia per la classificazione delle attività motorie, identificando le situazioni di rischio, sia per la valutazione della bontà del gesto motorio in applicazioni più strettamente di riabilitazione. Nel corso dell'attività di ricerca svolta la nostra attenzione si è concentrata su questa tipologia di sensori per le caratteristiche che essi presentano e che da noi sono state ritenute rilevanti rispetto alle nostre priorità.

I sensori inerziali sono dispositivi a basso costo che consentono di rilevare la cinematica del segmento corporeo a cui sono rigidamente collegati. Gli accelerometri in particolare misurano l'accelerazione lungo l'asse corporeo a cui sono rigidamente collegati, e possono essere di diverse tipologie in base al principio di funzionamento e al numero di assi rispetto ai quali misurano l'accelerazione.

Il monitoraggio di attività quotidiane, tramite l'uso di sensori inerziali, ha diverse applicazioni sia in ambito riabilitativo che nella ricerca e nello sviluppo, e diviene fondamentale anche per ottenere importanti parametri, relativi sia alle attività funzionali sia indicativi di situazioni patologiche. Misurazioni, ad esempio, dell'andamento e della velocità del passo producono informazioni sul rischio di cadute [36, 37, 38, 39, 40, 41]. Movimenti come il sit-to-stand (alzarsi da una sedia) e il cammino risultano importanti per poter valutare l'autosufficienza [42, 43]. Gli accelerometri risultano essere anche appropriati nella determinazione di eventi come appunto le cadute, di cui abbiamo già ampiamente parlato nel paragrafo precedente, e metodi sempre più raffinati sono stati implementati per rivelare le cadute utilizzando solamente gli accelerometri. Negli ultimi anni vari autori hanno proposto l'uso di accelerometri per la misura dell'oscillazione posturale ad uso clinico [40, 44, 45]. L'accelerometro, tra la gamma dei sensori inerziali, offre un metodo indiretto anche per accertare e valutare attività fisiche in ambiente di vita quotidiana che funziona bene quando viene comparato con altri metodi indiretti come il self-report [46, 47] e le misurazioni del battito cardiaco [48, 49].

Un altro importante utilizzo degli accelerometri monoassiali e triassiali riguarda la possibilità di misurare i livelli dell'attività motoria quotidiana: essi si sono dimostrati affidabili e stabili quando vengono comparati con altri indicatori della capacità funzionale. Tali studi sono stati numerosi e hanno interessato soggetti giovani e sani [50, 51], soggetti anziani [52, 53], pazienti con sclerosi multipla [47], pazienti con malattie ostruttive polmonari croniche (COPD) [46] e bambini obesi [54, 55, 56].

Per la valutazione dei livelli di attività motoria un approccio molto studiato è quello relativo alla stima del livello di energia speso durante le attività compiute.

I sistemi accelerometrici si basano tipicamente sul modello secondo il quale l'area sottesa dalla curva che indica le tre accelerazioni del corpo lungo i tre assi principali, è direttamente proporzionale al consumo energetico metabolico (CEM). Tale ipotesi è stata verificata tramite l'utilizzo di accelerometri triassiali [57, 58, 46] e anche stimata mediante accelerometri monoassiali [59]. In uno studio con 11 soggetti sani che indossavano un accelerometro triassiale posizionato in vita, è stato dimostrato però che il miglior indicatore di CEM durante la camminata è rappresentato dall'integrale dell'ampiezza dell'accelerazione nella direzione antero-posteriore mentre il miglior stimatore per il dispendio energetico nelle totalità delle attività quotidiane risulta essere la somma degli integrali delle ampiezze di ognuna delle tre accelerazioni [60].

Alla luce dei risultati riguardanti il dispendio energetico, sono stati misurati anche alti livelli di correlazione (0,86) tra il livello di MET, che è un multiplo del metabolismo basale che identifica il dispendio energetico per una determinata attività, cioè un multiplo del consumo di ossigeno a riposo necessario per mantenere il metabolismo basale, e conteggio di attività motoria del (CSA) [56].

Molti studi hanno utilizzato accelerometri per classificare attività motorie e per stimare mediamente l'attività motoria compiuta, tramite stime di conteggi di attività per minuto (mediamente all'ora) su periodi che vanno da tre giorni a due settimane [61, 62, 63, 64, 46, 65]. A tutti questi impieghi, che sfruttano le molteplici potenzialità di questi sensori, si affianca il riconoscimento delle attività motorie di cui abbiamo ampiamente parlato nel paragrafo precedente che è la applicazione basilare fondamentale di un sistema di tele monitoraggio e di teleriabilitazione, affiancata alle diverse tecniche di classificazione applicabili. Molteplici studi hanno interessato questo settore e hanno esplorato le diverse possibilità di riconoscere il gesto motorio tramite queste tipologie di sensori, sfruttandone sia diverse tipologie di set up sperimentali sia diverse modalità di analisi dei dati a disposizione [ 66, 67, 68, 69, 70]

## Capitolo 2

# Il problema della classificazione

Lo studio affrontato sul problema della classificazione ha cercato di affrontarne il problema a tutto tondo, cercando di farne emergere delle linee di studio che fossero anche linee di pensiero, tali da poterci guidare nel corso degli anni di studio e che fossero tali da consentirci un approccio critico ai quesiti in questione . In particolare il contesto studiato ha fatto emergere alcune linee principali del problema della classificazione che possono essere così riassunte:

- Le tecniche di classificazione basate sul teorema di Bayes
  - I metodi parametrici

- I metodi non parametrici
  - Le tecniche di clustering
  - Le tecniche mutuuate dal soft computing
    - Il perceptrone e le reti neurali
    - La logica fuzzy e i sistemi neuro-fuzzy
    - Le euristiche
  - Le tecniche di template matching ( DTW – Dynamic Time Warping)

L'obiettivo generale della classificazione è quello di assegnare un campione, tramite un opportuno set di informazioni, ad una specifica classe in base a determinate regole di interpretazione. Nel caso del nostro lavoro le diverse classi sono i differenti movimenti che si vogliono monitorare/riconoscere/analizzare.

La classificazione si basa sulle seguenti ipotesi:

- per ogni campione si dispone di un insieme di misure detto vettore di caratteristiche (feature). Si suppone che le caratteristiche dei segnali a disposizione possano essere misurate tramite sensori che siano in grado di fornire dati in forma grezza, oppure caratteristiche ottenute dalle misure stesse mediante opportune elaborazioni;
- le classi di appartenenza del nostro campione sono in numero finito.

E, nella caso della classificazione supervisionata:

- si possiede una sufficiente conoscenza a priori sulle classi oppure si ha a disposizione un insieme di campioni di training di cui si conosce l'appartenenza alla classe.

In generale per classificare un insieme di dati si lavora su features caratteristiche estratte a partire dai dati. Una feature, come abbiamo detto, può essere il risultato di una misura (numero reale o intero) o una risposta binaria (sì/no) a date domande o un andamento del segnale opportunamente pre-elaborato.

Il problema della scelta del classificatore si articola secondo uno schema riassuntivo mostrato in Figura 1, in cui la prima domanda da porsi è se è possibile o meno porre il problema in forma probabilistica. A seguito di una risposta affermativa ci addentriamo nei classificatori bayesiani di cui parleremo diffusamente più avanti, con la prima problematica da affrontare che riguarda la conoscenza o meno della densità di probabilità della variabile in questione (metodi parametrici/non parametrici). Nell'altro caso ci troviamo di fronte alla possibilità di definire il nostro classificatore in base alla conoscenza a priori di cui disponiamo. Da questo punto in poi il problema diviene quello relativo ad una classificazione supervisionata/non supervisionata. La classificazione non supervisionata ha la particolarità che non richiede alcuna conoscenza a priori e sfrutta le similitudini naturali tra gruppi di dati, limitando però il controllo dell'operatore sul procedimento e sui risultati.

Nei classificatori non supervisionati:

- non viene utilizzato l'insieme dei dati di training (training set). Gli algoritmi devono pertanto essere in grado di raggruppare in classi naturali i diversi campioni a disposizione in base a delle caratteristiche di similitudini naturali tra gli oggetti stessi.
- la complessità è di solito maggiore rispetto classificatori supervisionati ed il risultato necessita di una ulteriore validazione.

Talora la classificazione non supervisionata non viene considerata classificazione vera e propria, essendo in realtà un processo di individuazione delle classi naturali. Tale processo si indica, in inglese, col termine “clustering”, dove “cluster” denota il raggruppamento di elementi con caratteristiche simili.

Le fasi di un processo di classificazione supervisionata invece sono diverse e richiedono ognuna la definizione di un differente insieme di dati su cui operare:

- addestramento (training): il sistema opera su un insieme di dati di addestramento (training set), cioè su un insieme di campioni di cui si conosce a priori l'appartenenza o meno ad una determinata classe, in base ai quali vengono ottimizzati sia la struttura che tutte le variabili di interesse del classificatore, fino a raggiungere una corretta classificazione. La scelta dei dati di training e di test è molto importante e

teoricamente essi dovrebbero rappresentare tutte le varie casistiche, ossia dovrebbero essere “statisticamente eterogenei”.

– test: tale fase è svolta operando su un test set composto da dati anch’essi preclassificati, ma che sono differenti da quelli utilizzati in fase di training; ottenute buone prestazioni sul test set, si può operare su dati incogniti.

In questo contesto noi ci siamo occupati rispettivamente delle tecniche di clustering, per quanto riguarda l’analisi non supervisionata, e di quelle Template Matching per quanto riguarda le tecniche supervisionate.

Queste diverse tecniche sono state analizzate per valutarne l’applicabilità alle tipologie di dati a nostra disposizione e per i requisiti di nostro interesse. Il nostro studio ha posto l’accento sulle peculiarità degli approcci, sulle possibilità di innovazione e soprattutto sulle possibilità di utilizzo in un contesto come il nostro, fatto di sensori indossabili e di requisiti differenti a seconda dell’applicazione.

In una prima fase del nostro lavoro ci siamo concentrati sulle tecniche di Template Matching e sull’ipotesi di fondere tecniche accreditate di clustering (ad esempio, algoritmo del k-means) con analisi di tipo DTW (Dynamic Time Warping) per una classificazione non supervisionata utilizzabile in ambito di telemonitoraggio con obiettivi adattativi e di apprendimento del contesto: tale tecnica può risultare valida, in quanto entrambi gli algoritmi fanno uso della nozione di distanza per stabilire l’appartenenza ad uno stesso cluster o ad una stessa classe. In una seconda fase del nostro lavoro ci siamo occupati di classificatori bayesiani, esplorati in diversi contesti teorici e di applicazione, anche volgendo uno sguardo approfondito all’analisi delle features, che è il primo passo nella costruzione di un classificatore di questo tipo. I classificatori bayesiani sono stati implementati supponendo di conoscere la forma della densità di probabilità condizionata delle features.

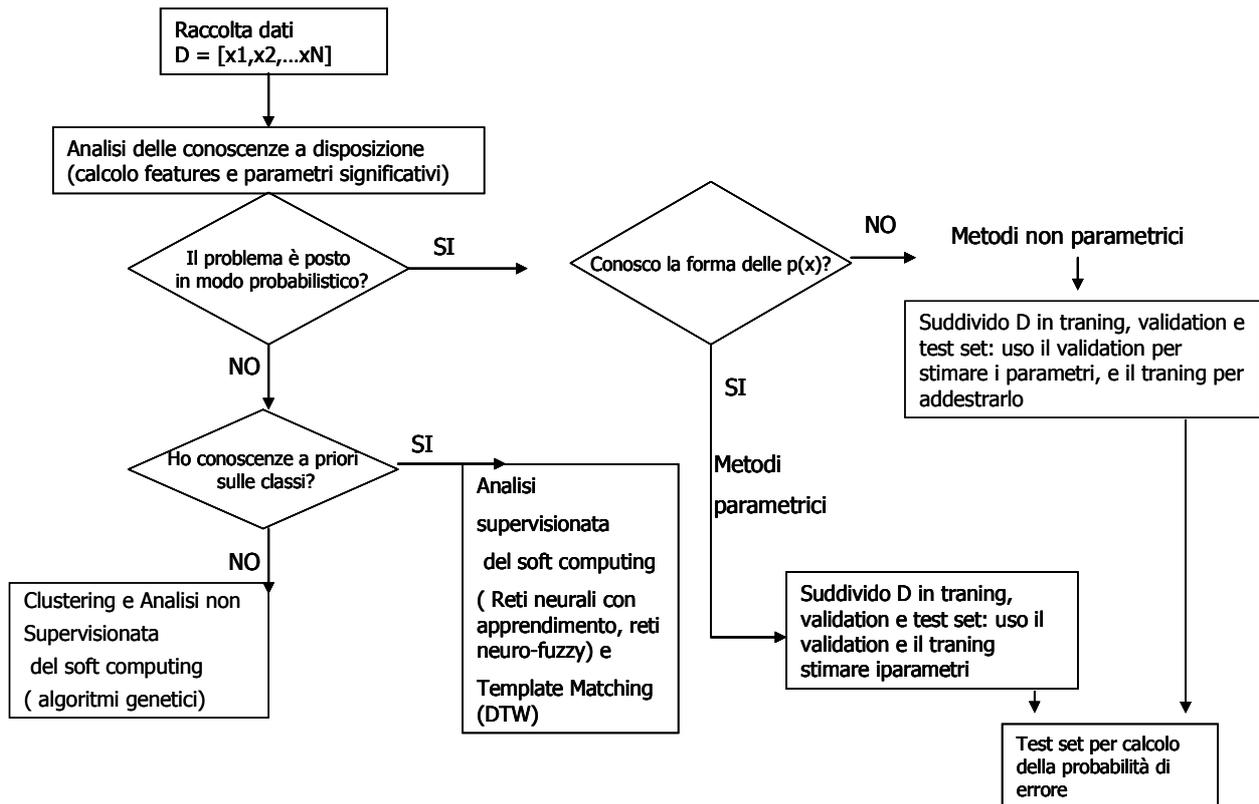


Figura 1 – Schema di massima del problema della classificazione

Sono state esplorate poi le possibilità di integrazione di tecniche differenti che hanno interessato i classificatori bayesiani, in differenti modalità, sia con le tecniche quali il Dynamic Time Warping che con strumenti teorici quali il filtro di Kalman e le catene di Markov. Inoltre abbiamo dato uno sguardo ai metodi decisionali basati sulle SVM e sugli alberi di decisione, con cui ci siamo confrontati sia in ottica di valutazione di performance che in ottica di integrazioni di sistemi. Un'ultima fase del lavoro sulla classificazione ha interessato le tecniche di classificazione precoce, sia con approcci innovativi per l'algoritmo del DTW in tempo reale, sia tramite l'utilizzo degli alberi di decisione.

## 2.1 Tecniche di Template Matching e di Clustering

Da una serie di considerazioni critiche sull'argomento, è parso utile concentrarsi dapprima su alcuni aspetti in particolare, legati all'approccio cosiddetto del template matching e degli algoritmi di clustering.

L'indecisione sull'uso di classificatori supervisionati e non supervisionati è stata superata in quanto disporre di segnali di training, la cui classe di appartenenza è nota, non è apparsa una criticità nei nostri tipi di applicazioni. La particolarità di questo approccio sta nel fatto che si lavora non su features caratteristiche ma su andamenti completi del segnale accelerometrico, opportunamente pre-elaborato, per cui è stato ritenuto più utile lavorare su funzioni di distanze tra pattern associati alle diverse attività motorie.

Le tecniche di classificazione che fanno uso di metriche di similarità/dissimilarità tra patterns sono quelle che vanno sotto il nome di template matching oppure tutte le varie forme di clustering. La caratteristica del primo approccio sta nella possibilità di confrontare il segnale in ingresso da classificare con un segnale caratteristico della classe da riconoscere. Questo segnale caratteristico viene definito Template e di solito viene stimato in una fase di training iniziale.

Esistono a questo proposito innumerevoli tecniche di Template Matching che sfruttano diverse definizioni di distanza: euclidea, di Minkowski, Mahalanobis ecc..

Una distanza o metrica nello spazio delle features è una funzione  $d(\cdot, \cdot)$  definita dalle seguenti proprietà:

- $d(x, x) = 0$ ;
- $d(x, y) = d(y, x) > 0$  per ogni  $x \neq y$ ;
- $d(x, z) \leq d(x, y) + d(y, z)$  (disuguaglianza triangolare)

- Distanza euclidea: è la distanza più conosciuta ed è espressa da:

$$d(x, y) = \left[ \sum_{i=1}^n (x_i - y_i)^2 \right]^{1/2}$$

- Distanza di Minkowsky: è una forma di distanza più generale che contiene come caso particolare la distanza euclidea, e utilizza un generico esponente  $\lambda \geq 1$ :

$$d(x, y) = \left[ \sum_{i=1}^n (x_i - y_i)^\lambda \right]^{1/\lambda}$$

- Distanza matrice quadrata: data una matrice quadrata ( $n \times n$ )  $Q$  simmetrica e definita positiva:

$$d(x, y) = \sqrt{(x - y)^T Q (x - y)}$$

- Distanza di Chebychev: corrisponde alla massima distanza delle componenti (feature) dei due campioni

$$d(x, y) = \max_{i=1,2,\dots,n} |x_i - y_i|$$

Tra le diverse tecniche di template matching presenti in letteratura, si inserisce la classificazione a distanza minima effettuata con l'algoritmo del DTW (Dynamic Time Warping) da noi implementato e adattato ai nostri requisiti.

Le tecniche di clustering consentono invece di suddividere un insieme di dati in una serie di gruppi o cluster che risultino avere delle similarità. Le tecniche di classificazione basate sugli algoritmi di clustering fanno dunque anch'esse uso di calcoli di distanze o similarità e sembrano collocarsi bene in un approccio non supervisionato. Naturalmente le modalità con cui vengono definite le distanze influiscono direttamente sull'appartenenza o meno di un elemento ad un determinato cluster e divengono l'elemento chiave degli algoritmi.

L'obiettivo di questa prima analisi è stato quello cercare di trovare una possibile integrazione tra queste due tecniche nell'ottica di sviluppare un algoritmo di clustering di tipo partitivo/gerarchico che utilizzi, tra gli altri, il metodo del DTW

come criterio di similarità, e approfondire le possibilità di utilizzo di queste tecniche non supervisionate per il riconoscimento dei gesti tramite i segnali accelerometrici.

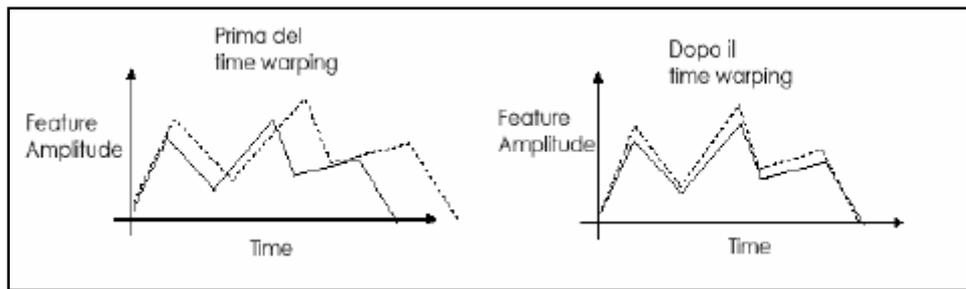
### 2.1.1 Dynamic Time Warping (DTW)

L'algoritmo del DTW si basa sul principio di ricercare similarità tra segnali relativi a due istanze della stessa attività.

Esso viene usato per riconoscere pattern in sequenze di dati anche non perfettamente allineate che si riferiscono sostanzialmente alla stessa "forma" di segnale; un tipico esempio è quello di uno stesso movimento o di una stessa parola effettuato/pronunciata a differente velocità.

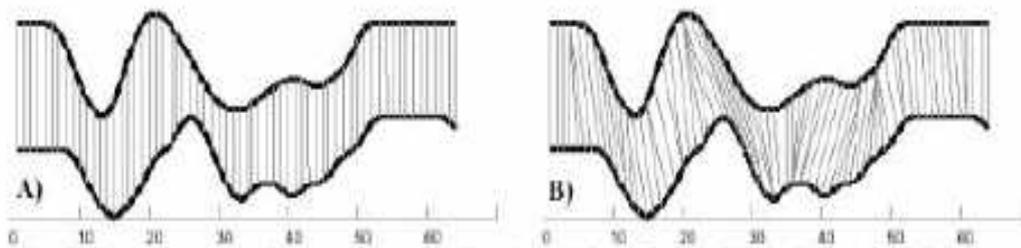
Il buon fine del riconoscimento è legato ai possibili criteri di "distanza" tra due sequenze e, più in particolare, a tutte le difficoltà derivanti da imperfetti allineamenti temporali tra le due sequenze e/o effetti di distorsione. In realtà, più che riferirsi a due generiche sequenze, occorre considerare il confronto di una sequenza di dati con una sequenza di riferimento genericamente ottenuta con una procedura di calibrazione. Con calibrazione si intende il procedimento che, in generale, prevede una serie di misurazioni iniziali e che nel nostro caso consente la determinazione del segnale di riferimento detto *template*.

L'algoritmo in questione si propone di risolvere il problema considerando le possibili distorsioni nel tempo del segnale d'ingresso e confrontandolo con il segnale di riferimento. Il confronto avviene considerando i due segnali come se fossero due vettori.



**Figura 2 – Il concetto di “warp”**

In Figura 2 viene illustrato il concetto appena esposto dove il segnale tratteggiato rappresenta l’ingresso, mentre quello a tratto continuo un campione di un ipotetico database contenente i segnali di riferimento.



**Figura 3-Confronto tra DTW e calcolo della distanza euclidea**

Consideriamo il segnale in ingresso come una sequenza di  $n$  campioni  $X(k)$   $k=1,2,\dots,N$  e il segnale di riferimento (*template*) come una sequenza di  $m$  campioni  $Y(k)$   $k=1,2,\dots,M$ . Il DTW “allinea” il segnale di ingresso con quello di riferimento mediante una variazione temporale non lineare. Tale variazione temporale avviene secondo quanto illustrato dal grafico B di Figura 3. Come si vede dalla figura, anche la distanza euclidea tra due serie temporali può essere considerata una tecnica di Template Matching, ma non consente di tenere conto delle differenze “temporali”

delle due serie numeriche limitandosi ad effettuare un calcolo di distanza tra punti corrispondenti.

Ogni punto del segnale di ingresso (traccia superiore),  $X(k)$ , non viene confrontato con il corrispondente omologo temporale del segnale di riferimento (traccia inferiore)  $Y(k)$ , come avverrebbe in un confronto classico e illustrato nel grafico (A) della Figura, ma con diversi punti del segnale di riferimento appartenenti ad un intorno temporale di dimensione  $2N+1$  del  $k$ -mo punto del segnale di riferimento. Il confronto uno a molti del DTW, permette di individuare un punto ottimo (secondo un criterio di distanza minima), chiamiamolo  $Y(k_{ott})$ , nel segnale di riferimento e quindi permette un “allineamento” di  $k$  con  $k_{ott}$ .

Il confronto di tutti i punti dà luogo alla costruzione di un percorso minimo, mediante la procedura che si articola nei seguenti passi:

1) Costruzione della matrice  $d$  ( $[N \times M]$ ) in cui ogni elemento di posizione  $(i,j)$  rappresenta la distanza tra l'elemento  $i$ -esimo della sequenza  $X(k)$  e l' $j$ -esimo elemento della  $Y(k)$ . La distanza scelta è quella euclidea. La matrice  $d$  ha la seguente forma:

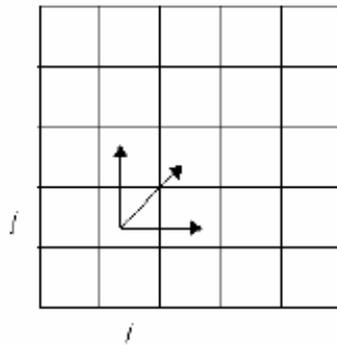
$$d(i, j) = \begin{bmatrix} d(x_1, y_1) & d(x_1, y_2) & \dots \\ \dots & \dots & d(x_2, y_M) \\ d(x_N, y_1) & \dots & d(x_N, y_M) \end{bmatrix}$$

2) Calcolo, secondo un approccio ricorsivo, di una nuova matrice  $D(i,j)$  (sempre di dimensione  $[N \times M]$ ), detta matrice delle distanze globali, definita nel seguente modo:

$$D(i, j) = d(i, j) + \min [D(i-1, j-1), D(i, j-1), D(i-1, j)]$$

Ogni elemento di questa nuova matrice è calcolato come la somma tra la distanza locale  $d(j,i)$  e il minimo delle distanze globali degli elementi immediatamente circostanti.

3) Calcolo, a partire dalla matrice  $D(i,j)$ , del percorso di minimizzazione (Warp-path) procedendo come in Figura 4 e cioè muovendosi dal punto (1,1) al punto (N,M) (o viceversa).



**Figura 4- Vincoli al percorso**

Il percorso è costituito da un insieme  $W$  di  $k$  coppie di punti che vengono presi nella matrice  $D(i,j)$  compiendo un percorso soggetto alle seguenti regole (figura5):

- non è possibile un'inversione di direzione nel tempo ;
- l'andamento nel tempo deve essere monotono non decrescente;
- il segnale d'ingresso deve essere continuo nel tempo;
- al fine di ottenere una distanza globale, ogni nuovo elemento del percorso deve essere frutto della somma di distanze locali.

La mancanza di una precisa delimitazione del segnale d'ingresso e il mancato allineamento del punto d'inizio dei segnali che formano il database fa sì che il percorso prenda una direzione parallela all'asse temporale relativo alla sequenza dove l'inizio del segnale è ritardato.

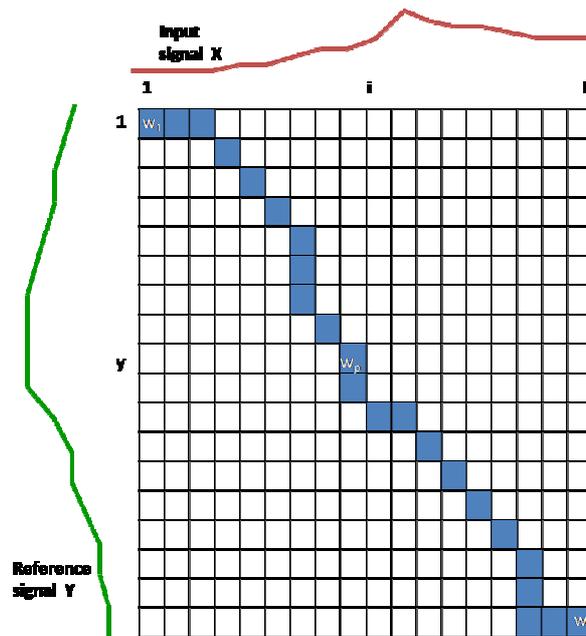


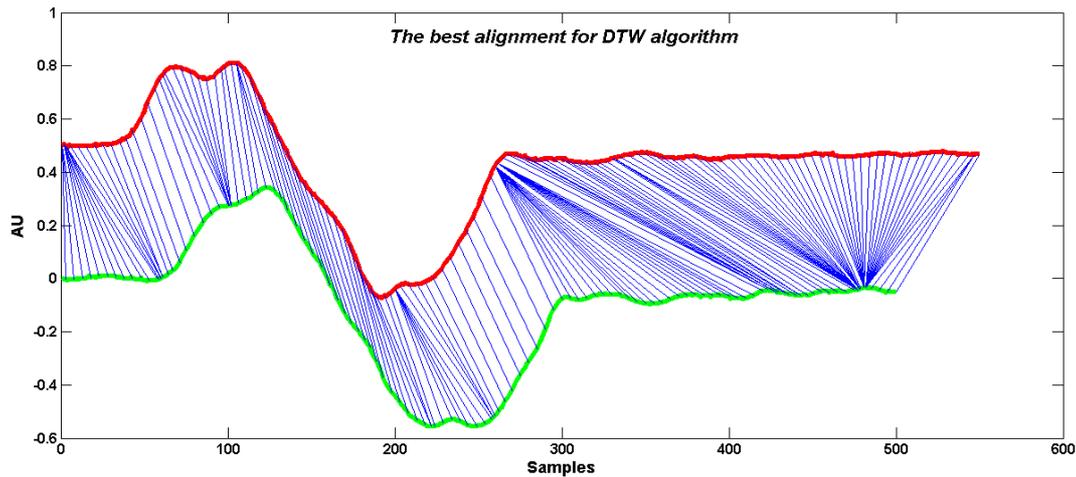
Figura 5 –Il warp path

Come ulteriore condizione, ogni percorso della matrice D parte da  $j=1, i=1$  e termina una volta calcolato l'  $(N,M)$ -esimo (o viceversa ).

Infine notiamo che per il calcolo di  $D(1,1)$  sono necessari valori di D corrispondenti ad indici negativi, e così anche per tutti gli elementi della prima riga e della prima colonna. Per risolvere il problema si pongono precise condizioni al contorno:

- $D(1,1) = d(1,1)$
- $D(1,i) = d(1,i) + D(1,i-1)$
- $D(j,1) = d(j,1) + D(j-1,1)$

Il percorso sarebbe la diagonale di una matrice di dimensione  $[N \times M]$  se i due segnali fossero perfettamente allineati. Tramite questo warp-path è possibile allora riallineare un segnale rispetto all'altro e consentire il calcolo ottimale della distanza tra di loro (figura6)



**Figura 6: Allineamento ottimale di due segnali tramite il DTW**

Il termine  $D(N,M)$  rappresenta il punteggio associato al percorso minimo tra l'elemento  $X(N)$  e l'elemento  $Y(M)$  e dunque la distanza tra le due forme d'onda:

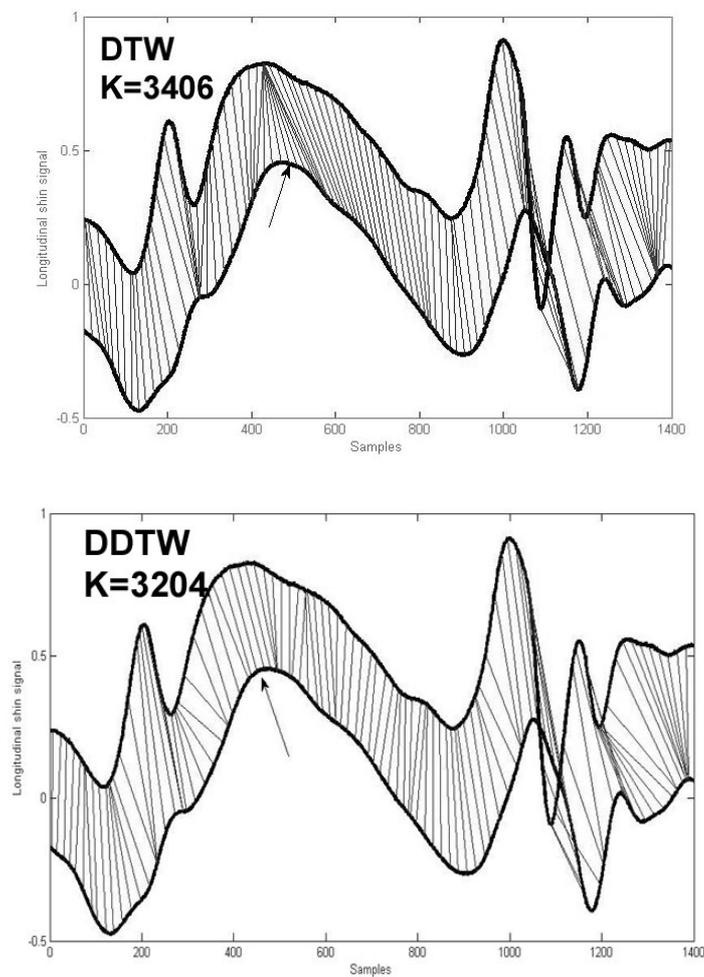
$$\text{Dist}_{DTW}(X,Y) = D(N,M).$$

### 2.1.2 Derivative Dynamic Time Warping (DDTW)

Il Derivative Dynamic Time Warping (DDTW) è una variante del DTW e considera, al posto della matrice  $d(i,j)$  delle distanze euclidee tra i campioni, una nuova matrice  $d$  che è la matrice data dalla differenza tra le stime della derivata:

$$D(X) = \frac{(X_i - X_{i-1}) + (X_{i+1} - X_{i-1}) / 2}{2}$$

Questo algoritmo risulta essere più robusto del precedente nell'allineamento dei due segnali sia rispetto a variazioni dei due segnali lungo l'asse delle ordinate (cioè variazioni in ampiezza), sia rispetto ad alcuni punti di singolarità come mostrato in Figura 7 :



**Figura 7 - Confronto tra DTW DDTW**

### 2.1.3 Le tecniche di clustering

Le tecniche di clustering nascono dalla necessità di partizionare un insieme di dati in gruppi (o clusters) omogenei, tali da rappresentare una classe rispetto ad un'altra o da isolare una particolare proprietà rispetto ad un'altra.

Essi infatti sono costituiti da algoritmi che hanno come obiettivo la ricerca di clusters omogenei minimizzando una particolare funzione di costo definita attraverso misure di distanza di tipo euclideo fra i punti del nostro spazio e le medie dei gruppi.

Le tecniche di clustering si dividono essenzialmente in due tipologie:

- Dal basso verso l'alto (Bottom-Up):

Questa filosofia prevede che inizialmente tutti gli elementi siano considerati come cluster e poi l'algoritmo continua ad agglomerare i dati unendo via via i cluster omogenei fino ad ottenere un numero prefissato di cluster, oppure fino a che la distanza minima tra i cluster non supera un certo valore.

- Dall'alto verso il basso (Top-Down):

All'inizio tutti gli elementi costituiscono un unico cluster e poi l'algoritmo inizia a dividere il cluster in tanti cluster di dimensioni inferiori. Il criterio che guida la divisione è sempre quello di cercare di ottenere elementi omogenei. L'algoritmo procede fino a che non ha raggiunto un numero prefissato di cluster.

Una tra i più noti e più usati algoritmi di clustering è l'algoritmo del k-means.

*L'algoritmo del k-mean* minimizza la varianza totale tra i cluster. Ogni cluster viene identificato mediante un centroide o punto medio. L'algoritmo segue una procedura iterativa che inizialmente crea K cluster ognuno con uno degli elementi da classificare. Per ogni cluster viene stimato anche il suo centroide ( $z_i$ ).

Al passaggio successivo associa ogni punto d'ingresso al cluster il cui centroide è più vicino ad esso ed identifica iterativamente i  $K$  cluster  $S_1, S_2, \dots, S_K$  che minimizzano il funzionale sum-of-squared error (SSE):

$$SSE = \sum_{i=1}^K \sum_{x \in S_i} \|x - z_i\|^2$$

Quindi vengono ricalcolati i centroidi per i nuovi cluster e così via, finché l'algoritmo non converge.

Si dimostra che l'algoritmo converge sempre in un numero finito di passi, ossia che, dopo un certo numero  $i$  di iterazioni, i centri-cluster non si spostano più (coincidono con quelli dell'iterazione precedente). Il numero  $i$  di iterazioni necessario a raggiungere la convergenza dipende dai dati e dalla scelta dei centri-cluster iniziali (schema dell'algoritmo in figura 8):

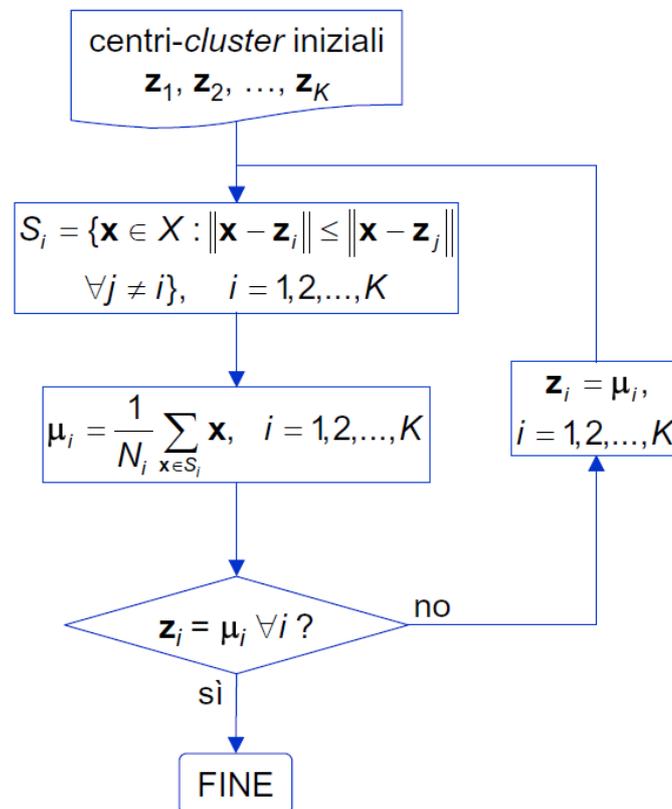


Figura 8 – Procedimento dell'algoritmo del "k-means"

## 2.2 La classificazione bayesiana

Per introdurre la classificazione bayesiana è necessario introdurre alcuni concetti di probabilità e il teorema di Bayes.

Sappiamo che con la notazione  $p(A | B)$  si denota la probabilità condizionata dell'evento A dato B, che in uno spazio degli eventi che non è quello originario, ma è ristretto a B, identifica la probabilità che A si verifichi negli stati del mondo nei quali B si verifica. Potremmo anche dire “la probabilità che l'enunciato A sia vero negli stati del mondo in cui l'enunciato B è vero”.

Un caso particolare è  $p(A | B) = 1$ : sapendo che B si è verificato, sappiamo che A è certo. Se invece  $p(A | B) = 0$ : sapendo che B si è verificato, sappiamo che A è impossibile. Se  $p(A | B) > p(A)$  allora il verificarsi di B facilita, rende più probabile il verificarsi di A. Se le due probabilità sono uguali, allora l'informazione su B è irrilevante per prevedere A, B non facilita né ostacola A: in tal caso si dice che i due eventi sono indipendenti.

Vale la seguente relazione (il cosiddetto teorema delle probabilità composte):

$$p(A \cup B) = p(A | B)p(B)$$

Il teorema delle probabilità composte, come si è visto, porta immediatamente alla seguente identità

$$p(A | B)p(B) = p(B | A)p(A)$$

poiché entrambi i membri uguagliano  $p(A \cup B)$ . Questa identità si trova in genere scritta in questo modo ( Teorema di Bayes):

$$p(B | A) = \frac{p(A | B)p(B)}{p(A)}$$

mettendo in evidenza una delle due probabilità condizionate. Si vuole così suggerire che, conoscendo le due probabilità a priori, non condizionate, e una delle due probabilità condizionate, si riesce a calcolare l'altra probabilità condizionata. Dato il teorema di Bayes sopra menzionato, possiamo introdurre la classificazione di Bayes. Supponiamo, per semplicità di esposizione, di avere due classi  $\omega_1$  e  $\omega_2$ , e ipotizziamo di conoscere le probabilità a priori delle classi ( $P(\omega_1)$  e  $P(\omega_2)$ ).

- La teoria della decisione assume nota la densità di probabilità (ddp)  $p(x|\omega_i)$  del vettore delle feature  $x$  condizionate all'appartenenza a ciascuna classe  $\omega_i$  ( $i = 1, 2, \dots, M$ ).
- Un campione incognito  $x_i$  è assegnato ad una delle classi  $\omega_1, \omega_2, \dots, \omega_M$  sfruttando l'informazione statistica contenuta nelle ddp condizionate alle classi  $p(x|\omega_i)$  ( $i = 1, 2, \dots, M$ ) e la conoscenza della probabilità a priori di tutte le classi  $\omega_i$ .

Criterio di decisione MAP (Massima Probabilità a Posteriori):

- un campione  $x$  è assegnato alla classe che presenta la massima probabilità a posteriori  $P(\omega_i | x)$ :
- Le probabilità a posteriori vengono stimate applicando il teorema di Bayes (la definizione di probabilità condizionata).

Ad esempio per la classe 1, detto  $x$  il vettore di dati a disposizione (features), si definisce la probabilità condizionata come la densità di probabilità di  $x$  appartenente alla data classe  $\omega_1$ ,  $p(x | \omega_1)$ . Si utilizza quindi il Teorema di Bayes:

$$P(\omega_1|x) = p(x | \omega_1)P(\omega_1)/P(x)$$

dove, per  $N$  condizioni mutuamente esclusive  $\omega_1 \dots \omega_N$ , la probabilità (totale) di una osservazione  $x$  si calcola come:

$$P(x) = \sum p(x | \omega_j)P(\omega_j) \quad \text{con } j=1,2,\dots,N$$

$P(\omega_1|x)$  è indicata come probabilità a posteriori. La probabilità a posteriori esprime dunque la probabilità che, dato un determinato vettore caratteristico in ingresso, esso appartenga ad una determinata classe. La teoria della decisione vuole che, se le densità di probabilità sono note, la regola di decisione più razionale è quella della massima probabilità a posteriori (MAP):

*Se  $P(w_1/x) > P(w_2/x)$  è più razionale scegliere  $w_1$   
Altrimenti  $w_2$*

Se le probabilità a priori sono uguali ( $P(\omega_1) = P(\omega_2)$ ) è possibile decidere in base alle sole verosimiglianze (ML maximum likelihood), ovvero solo in base alle densità di probabilità condizionata, in quanto il denominatore sarebbe lo stesso per le diverse espressioni e la formula verrebbe per le due classi identificata solo dalla densità di probabilità a priori.

Inoltre è possibile esprimere valutare la accuratezza dei nostri risultati valutando la probabilità di errore che si compie con questo tipo di classificazione. La probabilità di errore si esprime nel modo seguente:

$$P_e = P(err) = \sum_{i=1}^M P(err | w_i)P(w_i)$$

Si dimostra che il classificatore MAP minimizza la probabilità di errore, note le ddp condizionate alle classi e le probabilità a priori delle classi stesse.

Il criterio MAP non tiene conto degli eventuali costi associati ai diversi errori di classificazione. A questo proposito accenniamo brevemente alla teoria generale del minimo rischio, di cui il criterio della massima probabilità a posteriori diviene un caso particolare.

La teoria del minimo rischio è basata anch'essa sulla definizione e sulla massimizzazione di una misura di natura probabilistica e tiene conto dei costi associati alle azioni che si possono intraprendere in seguito alla decisione e ai rischi associati ad esse.

I costi delle azioni che è possibile intraprendere dipendono dalle classi e sono definiti da una matrice dei costi  $\Lambda$ :

$$\Delta = \begin{bmatrix} \lambda(\alpha_1 | w_1) & \lambda(\alpha_1 | w_2) & \dots & \lambda(\alpha_1 | w_M) \\ \lambda(\alpha_2 | w_1) & \lambda(\alpha_2 | w_2) & \dots & \lambda(\alpha_2 | w_M) \\ \dots & \dots & \dots & \dots \\ \lambda(\alpha_R | w_1) & \lambda(\alpha_R | w_2) & \dots & \lambda(\alpha_R | w_M) \end{bmatrix}$$

L'elemento  $\lambda_{ij} = \lambda(\alpha_i | \omega_j)$  è il costo dell'azione  $\alpha_i$  data la classe  $\omega_j$  ed è, in genere, un numero reale e positivo (qualora fosse negativo, denoterebbe un "guadagno").

Per ogni pattern  $x$ , introduciamo il rischio condizionato  $R(\alpha_i | x)$  di effettuare l'azione  $\alpha_i$  dato il pattern  $x$ :

$$R(\alpha_i | x) = \sum_{j=1}^M \lambda(\alpha_i | w_j) P(w_j | x) = E_{w \in \Omega} \{ \lambda(\alpha_i | w) | x \}$$

Il rischio condizionato può essere visto come un costo medio (rispetto alla distribuzione di probabilità a posteriori delle classi) che si ha se, osservato un campione  $x$ , si decide per un'azione  $\alpha_i$

Dato il pattern  $x$  viene scelta l'azione  $\alpha_j$  cui è associato il minimo rischio condizionato:

$$x \rightarrow \alpha_i \Leftrightarrow R(\alpha_i | x) \leq R(\alpha_j | x) \forall j = 1, 2..R$$

Anche mediante l'approccio globale, si può verificare che il classificatore MAP è un caso particolare del classificatore a minimo rischio.

Nel caso di matrice dei costi:

$$C = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \Rightarrow \eta = \frac{P_0}{P_1}$$

Pertanto il classificatore a minimo rischio basato su tale matrice dei costi è:

$$\Delta(x) = \frac{p(x | w1)}{p(x | w0)} > \frac{P_0}{P_1} \Rightarrow MAP$$

Inoltre, in questo caso particolare, il rischio coincide con la probabilità di errore. È pertanto confermato che il classificatore MAP minimizza la probabilità di errore anche in senso globale.

## 2.2.1 Stima della densità di probabilità condizionata: metodi parametrici e non parametrici

Il primo problema da affrontare nella costruzione di un classificatore bayesiano è quello di stimare la densità di probabilità condizionata della nostra variabile rispetto all'appartenenza ad una classe. Esistono metodi parametrici, che suppongono nota la forma della densità di probabilità e si riconducono ad una stima dei parametri, e metodi non parametrici, che non ipotizzano informazioni a priori sulle caratteristiche della densità di probabilità (Figura 9)

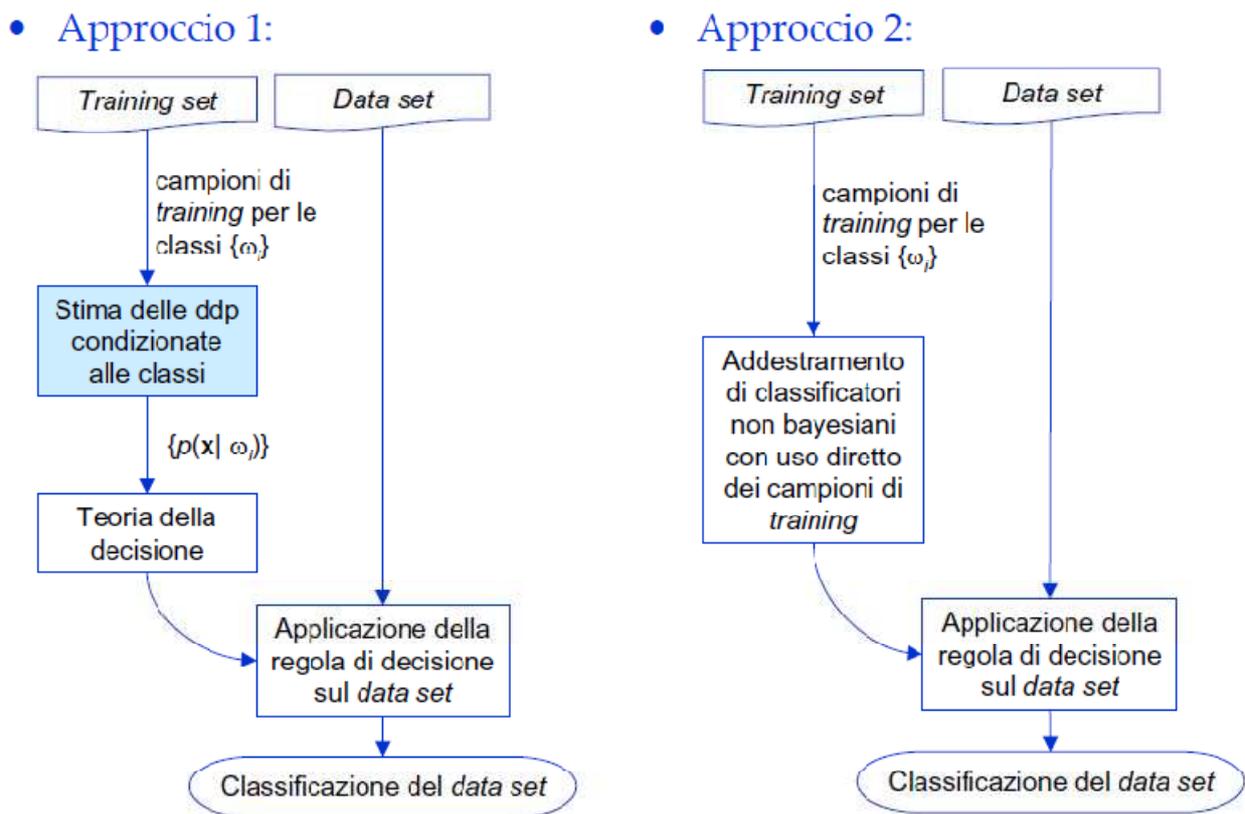


Figura 9 – Schema degli approcci parametrici e non parametrici

Tra i metodi parametrici quello classico, e anche da noi implementato, suppone nota la forma della densità di probabilità come una gaussiana ( n-dimensionale ) e la fase

di training prevede dunque la stima dei soli parametri che in questo caso sono la media e matrice di covarianza.

In generale, una giustificazione della grande diffusione dei modelli gaussiani è rappresentata dal teorema del limite centrale, secondo cui la somma di  $N$  variabili aleatorie indipendenti converge in distribuzione ad una gaussiana per  $N \rightarrow +\infty$ .

Da questo se ne deduce che un grande numero di fenomeni stocastici possono essere descritti con un modello di tipo gaussiano che può essere espresso nella seguente forma:

$$p(x) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp \left[ -\frac{1}{2} (x - m)^t \Sigma^{-1} (x - m) \right]$$

Una volta definita la forma della densità di probabilità, tramite i dati di training è possibile fare una stima dei parametri della forma d'onda. Nel caso in questione, tramite i nostri dati a disposizione, possiamo stimare la media e la matrice di covarianza, che risulteranno anch'essi delle variabili aleatorie. Date  $N$  osservazioni aleatorie indipendenti, si può dimostrare che le stime a massima verosimiglianza di media e matrice di covarianza sono:

$$\hat{m} = \frac{1}{N} \sum_{k=1}^N x_k$$

$$\hat{\Sigma} = \frac{1}{N} \sum_{k=1}^N (x_k - \hat{m})(x_k - \hat{m})^t$$

Invece in un contesto non parametrico non si suppone nessuna forma per la densità di probabilità condizionata e si stima direttamente dai dati di training. Supponiamo che  $x_i$  sia uno di questi campioni e che sia contenuto in una regione dello spazio delle features ( $S$ ). Possiamo definire:

$$\hat{P}_S = P\{x \in S\} = \int_S p(x) dx \approx p(x_i)V$$

dove  $V$  è il volume  $n$ -dimensionale (misura) di  $S$ .

Una stima consistente della probabilità  $P$  è data dalla frequenza relativa:

$$\hat{P}_S = \frac{K}{N}$$

Con  $K$  numero di campioni di training che cadono nella superficie  $S$ . Dalla stima della probabilità che un punto appartenga ad  $S$  ne deduco una stima della ddp per il punto  $x_i$

Osservazioni

- $S$  deve essere abbastanza “grossa” da contenere un numero di campioni di training che giustifichi l’applicazione delle legge dei grandi numeri;
- $S$  deve essere abbastanza “piccola” da giustificare l’ipotesi che  $p(x)$  non vari apprezzabilmente in  $S$ .

Come tutte le situazioni in cui sembrano esserci condizioni contrastanti è necessario un compromesso fra queste due esigenze, per fare in modo che la stima della ddp sia consistente. E’ necessario comunque che il numero totale  $N$  di campioni di training sia abbastanza numeroso.

A seconda delle grandezze  $K$  e  $V$ , ci sono diverse possibilità di approccio alla stima non parametrica, di cui noi accenniamo a due metodi in particolare :

- metodo dei “ $K$ -punti vicini”: si fissa  $K$  e si determina la regione  $R$  in base al training set, se ne calcola l’ipervolume  $V$  e se ne deduce la stima delle ddp;
- metodo di Parzen: fissata la regione  $S$  (e fissato quindi anche il suo ipervolume  $V$ ), si calcola  $K$  a partire dal training set se ne deduce la stima.

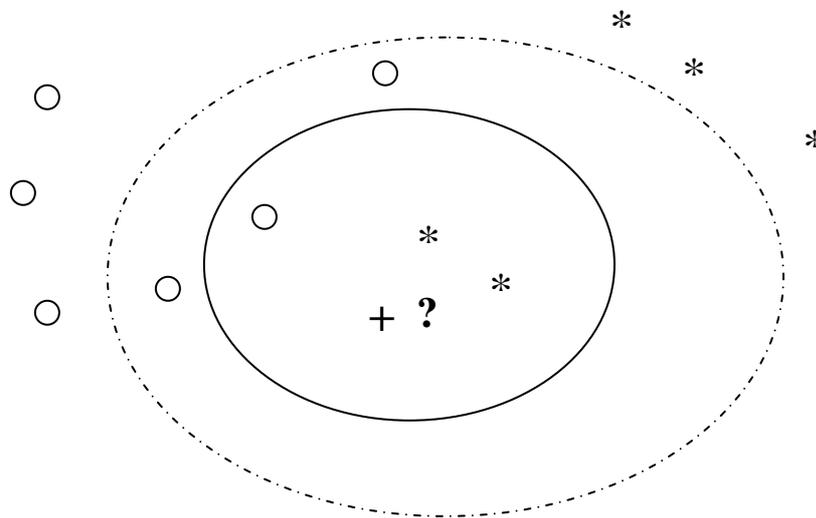
È possibile dimostrare che entrambi gli approcci conducono a stime consistenti.

- Il metodo dei “*K-punti vicini*” (K-nearest neighbors, K-NN) espande la cella finché essa non contenga esattamente K campioni di training: sia  $VK(x^*)$  il volume della cella risultante. La ddp nel punto  $x_i$  è stimata allora come segue:

$$\hat{p}(x_i) = \frac{K}{NV_k(x_i)}$$

Si può dimostrare che, scelto K in funzione di N ( $K = K_N$ ), condizione necessaria e sufficiente affinché la stima K-NN sia consistente in tutti i punti in cui  $p(x)$  è continua è che  $K_N \rightarrow +\infty$  per  $N \rightarrow +\infty$ , ma di ordine inferiore ad 1

In parole semplici il nuovo campione da classificare viene assegnato alla classe, se questa è la più frequente tra i k esempi più vicini al nuovo elemento. Il nuovo campione, una volta classificato, può far parte o meno della decisione certa e contribuire alla classificazione dell'elemento successivo. Il procedimento è illustrato in figura 10:



**Figura 10**

In figura 10 abbiamo cercato di esemplificare il procedimento dell'algorithm di KNN. Supponiamo di ricevere il campione rappresentato dal simbolo + . Abbiamo a disposizione due classi, quelli dei pallini e quella degli asterischi.

Supponiamo che  $k = 3$  (cioè vengono considerati i 3 oggetti più vicini), allora il nostro nuovo elemento sarà inserito nella classe degli asterischi perché dei tre elementi più vicini, due appartengono a quest'ultima classe. Se invece  $k$  fosse stato 5 allora il campione sarebbe stato inserito nell'altra classe perché ci sono 3 pallini e solo 2 asterischi.

- Metodo di **Parzen**: Supponiamo che  $S$  sia un ipercubo  $n$ -dimensionale di lato  $h$  (e quindi di volume  $V = h^n$ ), centrato nel punto  $x_i$ . Introduciamo la seguente funzione rettangolare:

$$\gamma(x) = \begin{cases} 1 & \text{Se } x \text{ appartiene all'ipercubo di lato } h \text{ e} \\ & \text{centro } x_i \\ 0 & \text{Altrove} \end{cases}$$

Se il campione di training  $x_k$  appartiene all'ipercubo  $S$  di centro  $x_i$  e lato  $h$  vuole dire che

$$\gamma[(x_k - x_i)/h] = 1.$$

In caso contrario,

$$\gamma[(x_k - x_i)/h] = 0.$$

Allora il numero di campioni di training che cadono in  $S$  è:

$$K = \sum_{k=1}^N \gamma\left(\frac{x_k - x_i}{h}\right)$$

Da cui è possibile ricavare anche la stima della densità di probabilità condizionata:

$$\hat{p}(x_i) = \frac{K}{NV} = \frac{1}{Nh^n} \sum_{k=1}^N \gamma\left(\frac{x_k - x_i}{h}\right) = \frac{1}{N} \sum_{k=1}^N \frac{1}{h^n} \gamma\left(\frac{x_i - x_k}{h}\right)$$

## 2.4 Le Support Vector Machines (SVM)

Trattando il dominio delle features a  $n$  dimensioni ci si è posto il problema della validità di altri metodi di classificazione che fossero in grado di partizionare in maniera corretta il mio spazio delle features, senza dover ricorrere per forza una densità di probabilità gaussiana a  $n$ -dimensioni e un classificatore bayesiano.

Per questo motivo si è esplorata la classificazione supervisionata lineare/non lineare delle Support Vector Machines (SVM). Tramite esse è possibile ricavare una funzione di decisione che sia in grado, dato un addestramento su un insieme di training, di suddividere il piano delle features in due o  $n$  regioni tramite un iperpiano, sfruttando le informazioni dei punti che si trovano alle interfacce. Un training set si dice linearmente separabile se esiste un iperpiano che separa correttamente tutti i vettori, in caso contrario il training set si dice non linearmente separabile. Nel primo caso siano date due classi  $\omega_1$  ed  $\omega_2$ ,  $N$  campioni di training  $x_1, x_2, \dots, x_N$ , e sia  $y_k$  l'etichetta di classe del campione  $x_k$ , definita come segue:

$$\begin{cases} y_k = 1 \Leftrightarrow x_k \in \omega_1 \\ y_k = -1 \Leftrightarrow x_k \in \omega_2 \end{cases}$$

Tra tutti i possibili iperpiani separatori bisogna cercare quello che massimizza il margine, cioè la distanza dal più vicino esempio dei dati del training set (figura 11a). Se, in particolare,  $H: w^T x + \theta = 0$  è un iperpiano separatore, considero l'iperpiano  $H_i$  ad esso parallelo e passante per il campione di  $\omega_i$  più vicino ad  $H$  ( $i = 1, 2$ ): il margine è la distanza fra gli iperpiani  $H_1$  ed  $H_2$ ; i campioni appartenenti ad  $H_1$  o ad  $H_2$  sono detti support vector.

Senza perdere generalità, posso assumere che  $H$  sia situato a metà fra  $H_1$  ed  $H_2$  e posso scegliere questo iperpiano in modo che  $\text{margine} = 2/\|w\|$

Nel caso più generale lo spazio delle features era non linearmente separabile nel qual caso le SVM usano delle funzioni di Kernel (Figura 11b) in grado di mappare lo spazio non linearmente separabile in uno a differente dimensione che sia separabile linearmente. Le funzioni di Kernel devono soddisfare una serie di requisiti e alcuni Kernel usati in letteratura sono:

$$K(\mathbf{x}, \mathbf{y}) = (\mathbf{x}^t \mathbf{y} + 1)^p \quad (p = 1, 2, \dots)$$

$$K(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{2\sigma^2}\right) \quad (\sigma > 0)$$

$$K(\mathbf{x}, \mathbf{y}) = \tanh(a\mathbf{x}^t \mathbf{y} + b) \quad (a > 0, b \in \mathbb{R})$$

Nelle nostre applicazioni abbiamo definito una formulazione nuova di kernel che ci ha permesso di mappare lo spazio delle features n-dimensionale in uno bidimensionale che, con un certo margine di errore, è risultato separabile in maniera lineare da una funzione di decisione.

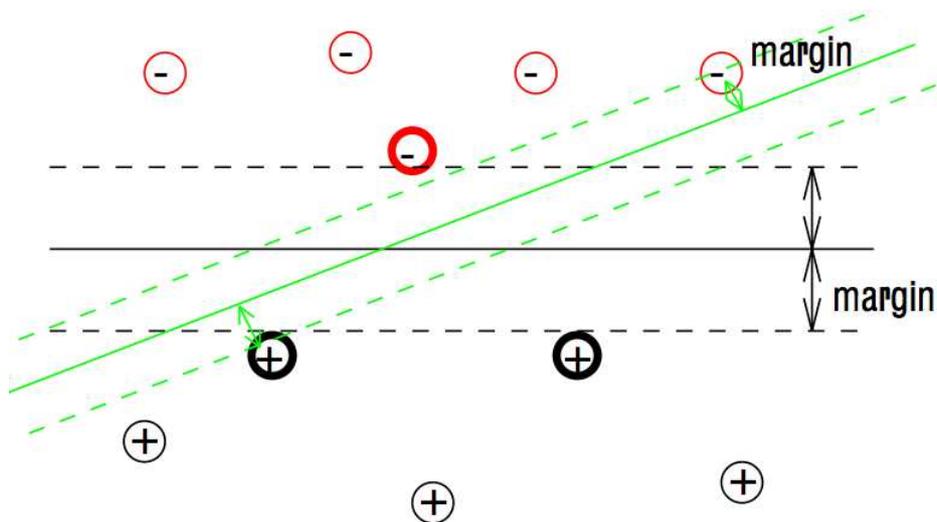


Figura 11a

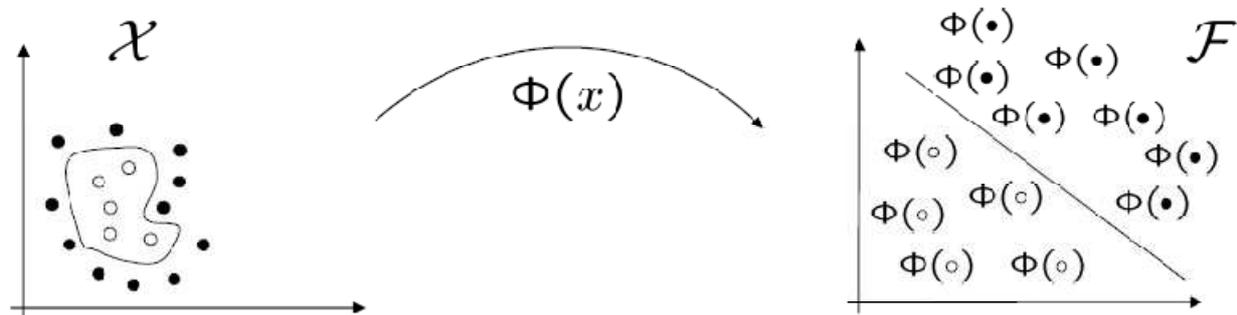


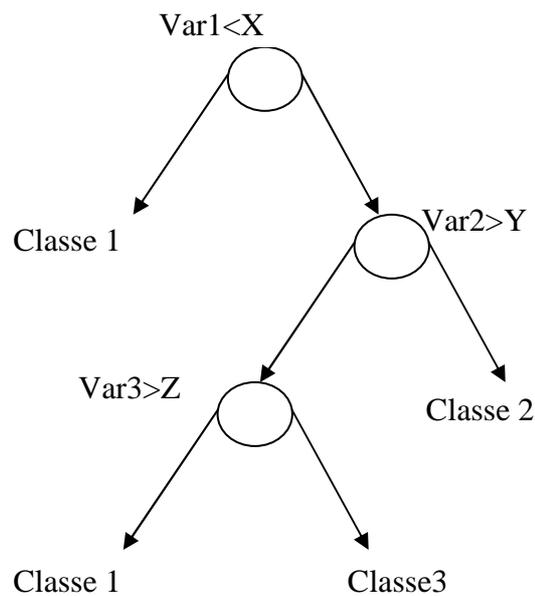
Figura 11b

## 2.5 Gli alberi di decisione e la classificazione precoce

Lo studio sugli alberi di decisione è stato affrontato per la rilevanza occupata nell'ambito degli algoritmi di classificazione e in particolare nel pattern recognition [71]. Essi vengono costruiti suddividendo ripetutamente i dati di training a disposizione in sottoinsiemi omogenei rispetto ad una determinata variabile.

La suddivisione produce una gerarchia ad albero, dove i sottoinsiemi vengono chiamati nodi e quelli finali foglie. I nodi corrispondono ad una particolare variabile e gli archi (i rami dell'albero) sono etichettati con i valori della variabile soprastante lungo quel ramo (Figura 8). In generale gli alberi di decisione sono di facile interpretazione ma la struttura di un albero di decisione può diventare molto complicata, soprattutto nei casi derivati da database contenenti centinaia di attributi ed una variabile risposta con differenti classi. E' auspicabile però che l'albero non si espanda a dismisura, diventando altrimenti sia di difficile gestione che

interpretazione. Esistono perciò dei criteri di controllo che limitano la crescita degli alberi, basati o sul massimo numero di regole applicabili alla classificazione o sulla massima “profondità” raggiungibile dall’albero o ancora sul numero minimo di records che devono essere presenti in ogni nodo per poter effettuare la divisione (splitting) in quel nodo.



**Figura 12: Albero di decisione creato con i dati di training a disposizione**

Esaminiamo ora alcuni concetti con i quali è possibile quantificare la accuratezza di un albero di decisione, ovvero le sua capacità di classificare.

Se indichiamo con  $n_i'$  il numero totale di records del training set che terminano nella foglia  $i$  e con  $n_i$  il numero di record classificati correttamente in  $i$ , è possibile associare ad ogni foglia  $i$  un errore  $\epsilon_i$  dato dalla frazione di records classificati correttamente nel training set:

$$\epsilon_i = \frac{n_i}{n_i'}$$

L'errore associato a tutto l'albero è dato dalla somma degli errori di tutte le foglie, pesati rispetto alla probabilità che un record finisca su ciascuna foglia. Se il numero totale di records del training set è  $N$ , la probabilità che un determinato record finisca nella foglia  $i$  è data da:

$$\frac{n_i}{N}$$

e dunque l'espressione dell'errore associato a tutto l'albero ( $E$ ) è la seguente:

$$E = \sum_i \frac{n_i}{N} \varepsilon_i$$

E' chiaro che la situazione di ottimo si ha quando  $E = 1$ ; in tal caso, infatti, l'albero classifica perfettamente tutti i records del training set, poiché  $\varepsilon_i = 1$  per ogni  $i$  ed  $E$  risulta uguale alla probabilità che un record cada in una qualsiasi foglia, e cioè pari ad uno.

Però questo modo di valutare l'accuratezza di un albero nel classificare non è esente da critiche per il fatto che gli errori di classificazione non sono tutti uguali. Per specificare queste differenze negli errori di classificazione potremmo definire delle matrici di costo, in cui in ogni campo della matrice viene indicato il costo di un determinato errore di classificazione. Si tratta di matrici che hanno la diagonale principale fatta tutta di zeri (casi in cui l'albero classifica perfettamente i records), mentre altrove i valori sono generalmente  $\neq 0$  e rappresentano i costi della errata classificazione dei records.

Queste matrici sono in generale non simmetriche, poiché il costo dell'aver classificato un record nella classe  $i$  piuttosto che nella vera classe  $j$  è, solitamente, diverso dal costo di errata classificazione opposto.

Gli alberi di decisione sono stati esplorati per le possibilità che essi offrono di una classificazione veloce, perché molto spesso si può, durante la discesa nella regole dell'albero, per i dati di test, assestarsi e dunque classificare, in maniera precoce, ovvero senza la necessità di esplorare tutto l'albero. Nel caso di applicazioni ad un riconoscimento precoce del gesto che usi tecniche di Template Matching essi possono essere usati per ridurre ad ogni passo i segnali di riferimento con cui il segnale in ingresso viene confrontato, riducendo così i tempi di decisione.

Naturalmente nel caso in esame, questa struttura decisionale risulta inefficiente per segnali che risultino simili nella parte finale.

# Capitolo 3

## Le tecniche innovative proposte

### 3.1 La classificazione gerarchica

La classificazione gerarchica ha un significato molto vasto e nel nostro caso è stata impiegata come gerarchica nell'utilizzo dei dati a disposizione. La gerarchia può svilupparsi nell'ambito della decisione, come fanno appunto gli alberi di decisione [1,2,3,72], o nell'utilizzo gerarchico di diversi sensori [73] o ancora nell'applicazione di diverse tecniche di riconoscimento [74]. La definizione generale prevede che il classificatore possa prendere una decisione, con un certo margine di errore, in diverse fasi della sua struttura. Qualora ritenga la sua probabilità di errore elevata può decidere di esplorare una fase successiva e rimandare la decisione.

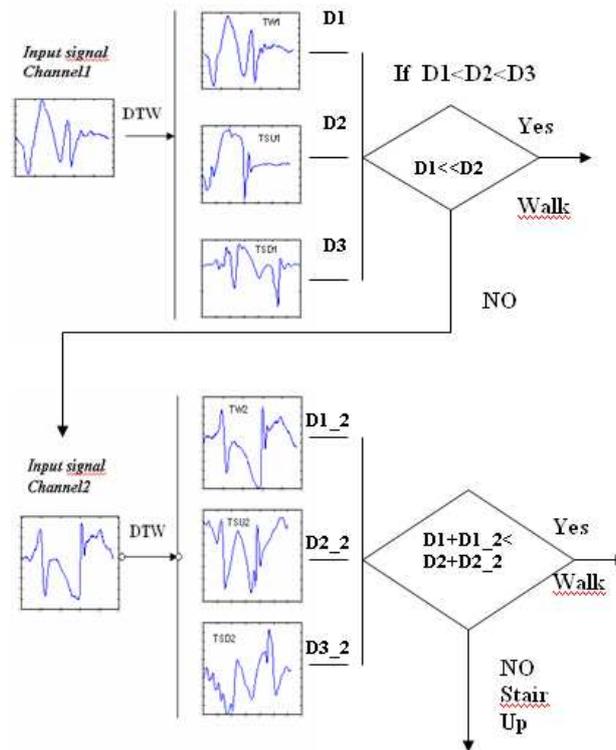
Nel nostro lavoro la scelta si è orientata verso la ricerca di un metodo per classificare le attività del soggetto che fosse il più versatile possibile, sia per rendere più veloce la classificazione sia per ottimizzarne le risorse in uso. Le considerazioni che seguono sono state applicate ad un sensore accelerometrico biassiale posto sullo stinco ed utilizzato per classificare attività della vita quotidiana compiute con gli arti inferiori.

Procedendo per via euristica e a seguito di una prima fase di risultati, si è analizzata la accuratezza della classificazione utilizzando i due canali dell'accelerometro

separatamente e con tecniche di tipo DTW. Dai risultati è emerso come il canale verticale (che per semplicità chiamerò canale1) ha dato migliori risultati in termini di classificazione, rispetto al canale lungo la direzione del cammino (canale2). Si è pensato allora di sfruttare i due canali in maniera indicata “gerarchica” nel senso di stabilire una gerarchia di intervento/utilizzazione dei dati dai sensori. In tal modo, la classificazione è stata affidata prima al solo canale1 e, qualora i risultati di questa prima fase non fossero soddisfacenti, si aggiungono all’algoritmo le informazioni derivanti dal secondo canale, che vanno ad integrare le prime.

Le motivazioni di questo approccio sono ovvie, nel senso di cercare di scegliere il set minimo di sensori che possa dare la migliore discriminazione delle varie attività compatibilmente con i requisiti di semplicità ed usabilità del dispositivo, minore tempo di calcolo per successivi impieghi in tempo reale, introducendo elementi di complicazione solo se necessario ed a ragion veduta.

Il primo canale viene acquisito e segmentato in epoche ( nel nostro caso singole attività motorie come il passo) ed ognuna viene poi confrontata tramite il DTW con tutti i Template delle attività da riconoscere (uno per ogni attività), ricavati nella fase di calibrazione, per ogni soggetto e per ogni canale.



**Figura 13 – Procedimento della gerarchia di decisione**

Le distanze calcolate vengono fornite ad un decisore con soglia che analizza i due valori più bassi di distanze e decide se è il caso o meno di chiamare in causa il secondo canale.

La soglia resta la criticità di questo lavoro dato, in quanto viene ricavata in modo empirico dall’osservazione dei dati.

Una volta che viene richiesto l’uso del canale2, l’algoritmo analizza anche l’epoca corrispondente per il secondo canale e calcola con il DTW le distanze con i Template disponibili per questo secondo canale. Le distanze calcolate vengono sommate con quelle ricavate con il confronto del canale1 e l’algoritmo classifica l’attività in base alla distanza cumulativa minima.

Il procedimento descritto è stato illustrato tramite il grafico di Figura 13.

## 3.2 La classificazione cooperativa

Per classificazione cooperativa intendiamo la possibilità, sperimentata, di poter unire diverse tecniche di classificazione e strumenti metodologici/matematici per migliorare le performance del classificatore. In tutti i casi mostrati i dati sono estratti da sensori accelerometrici e le features utilizzate sono state ricavate sia nel dominio del tempo che nel dominio della frequenza.

Nel nostro caso abbiamo, in una prima fase, cercato di ottimizzare il criterio di decisione della massima verosimiglianza (MAP) supportando il valore della probabilità a posteriori tramite un peso, ricavato da misure di tipo DTW. Nel secondo approccio abbiamo cercato di ottimizzare uno spazio delle features che fosse n-dimensionale, rispetto al caso semplice di due solo features nel dominio della frequenza, per ricondurlo ad uno bidimensionale senza perdita di informazione. Ci siamo serviti in questo caso della cooperazione con i concetti di mappe di Sammon e delle reti neurali. Come ultimo caso, abbiamo esplorato la possibilità di una classificazione bayesiana che fosse adattiva rispetto alle attività compiute dal soggetto in tempo reale. In questo caso abbiamo utilizzato la struttura del filtro di Kalman per far variare dinamicamente la probabilità a priori delle attività da riconoscere.

### 3.2.1 Il classificatore bayesiano e il DTW

L'idea di base di questo lavoro è stata quella di mettere a confronto un'analisi di tipo bayesiano basata su *features* estratte nel dominio della frequenza, con tecniche di template matching, che usano segnali caratteristici nel dominio del tempo. Le considerazioni che seguono sono state applicate a segnali accelerometrici e al riconoscimento di attività motorie della vita quotidiana, realizzate con gli arti inferiori. In questo caso supponiamo che siano 3 le classi da riconoscere.

Il 30% dei segnali acquisiti è stato usato per la fase di calibrazione e la parte restante per il test dell'algoritmo.

Dopo aver rivelato le singole attività, la fase di calibrazione prevede l'estrazione del *template* o segnale caratteristico, per ogni tipologia di attività, nel dominio del tempo, e per ogni canale dell'accelerometro.

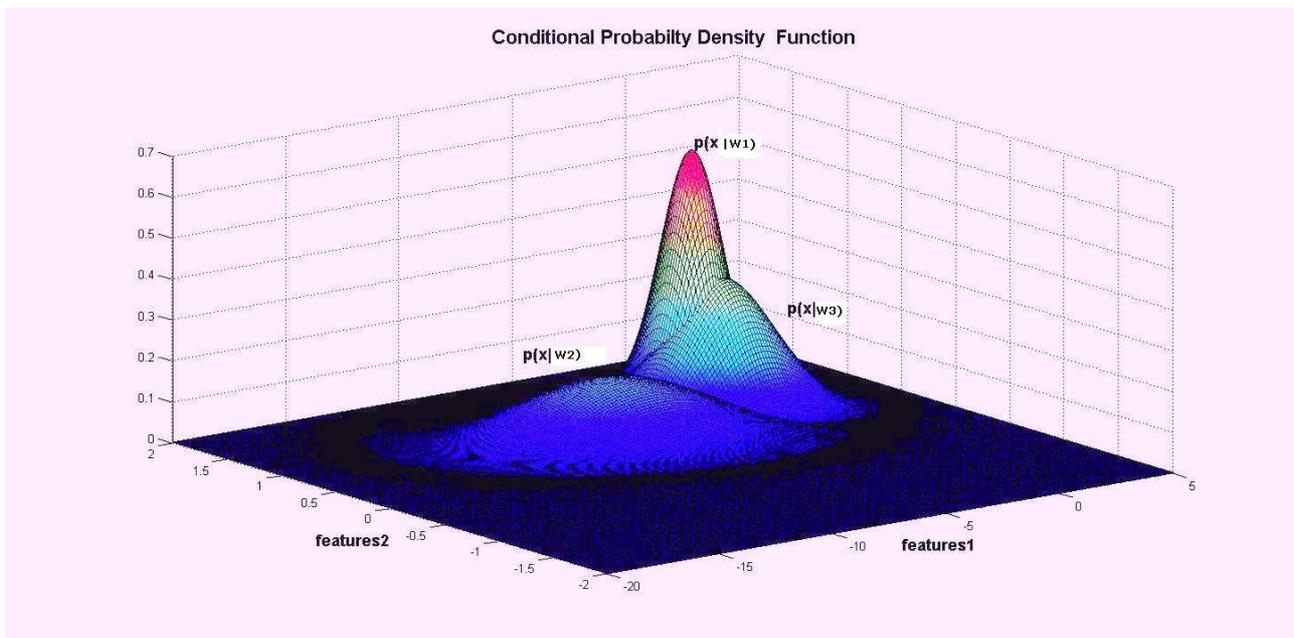
Le *features* estratte nel dominio della frequenza sono invece, per ogni attività, la coppia di valori data dal valore massimo e il valore minimo della frequenza media istantanea. Con queste coppie di valori estratti dai dati a disposizione per la calibrazione, sono state stimate media e varianza di una distribuzione gaussiana bivariata. Le tre attività hanno dimostrato di avere distribuzioni gaussiane non sovrapposte e dunque adeguate per un approccio probabilistico del problema (Figura. 14).

Per ogni attività è stata stimata dunque una densità di probabilità condizionata date dalle seguenti espressioni

$$p(x | W_1) = \frac{1}{2\pi\sigma_{x1W}\sigma_{x2W}} \exp \left[ -\frac{1}{2} \left( \frac{(x_1 - \mu_{x1W})^2}{\sigma_{x1W}} + \frac{(x_2 - \mu_{x2W})^2}{\sigma_{x2W}} \right) \right]$$

$$p(x | W_2) = \frac{1}{2\pi\sigma_{x1SU}\sigma_{x2SU}} \exp \left[ -\frac{1}{2} \left( \frac{(x_1 - \mu_{x1SU})^2}{\sigma_{x1SU}} + \frac{(x_2 - \mu_{x2SU})^2}{\sigma_{x2SU}} \right) \right]$$

$$p(x | W_3) = \frac{1}{2\pi\sigma_{x1SD}\sigma_{x2SD}} \exp \left[ -\frac{1}{2} \left( \frac{(x_1 - \mu_{x1SD})^2}{\sigma_{x1SD}} + \frac{(x_2 - \mu_{x2SD})^2}{\sigma_{x2SD}} \right) \right]$$



**Figura 14 – Densità di probabilità condizionate**

Si è supposto che tutte e tre le attività avessero la stessa probabilità a priori ( $P(W_1) = P(W_2) = P(W_3) = 1/3$ ). Da queste informazioni, tramite il teorema di Bayes è possibile stimare la probabilità a posteriori. Ma per classificare l'attività in questo caso è sufficiente l'informazione contenuta nella densità di probabilità a priori e dunque utilizzare un semplice classificatore ML (maximum likelihood).

All'informazione di classificazione ottenuta nel dominio della frequenza si è pensato di aggiungere le informazioni ottenute con un altro criterio di classificazione ottenuto tramite il Template matching, sia per unire informazioni derivanti dal dominio del tempo, sia per rafforzare la classificazione bayesiana.

Nella fase di calibrazione si è stimato un segnale caratteristico nel dominio del tempo, che rappresenta il *template* per ogni specifica attività, e che viene utilizzato tramite l'algoritmo del DTW (Dynamic Time Warping) per stimare misure di distanza tra essi e i segnali in ingresso.

Come abbiamo già spiegato l'algoritmo del DTW è un algoritmo che tramite deformazione non lineare di uno degli assi del segnale consente di calcolare un percorso minimo tra il segnale in ingresso e il segnale di riferimento e consente di calcolare una misura di distanza tra i due segnali temporali. Il *template*, per ogni

attività, è stato scelto, tra le diverse prove a disposizione, come quell'attività elementare (passo, salita/discesa del gradino) che ha la distanza minore, calcolata con il DTW, da tutte le altre prove effettuate. I metodi per la scelta del *template* possono essere molteplici. La regola di classificazione per le tecniche di questo tipo vuole che si scelga come classe quella il cui *template* rappresentativo produce misure di distanza minori.

Nel nostro caso il criterio generale proposto in questo metodo di classificazione, applicato ai segnali di test, è stato quello di scegliere come classe, e dunque attività, più probabile quella che rende massima questa relazione:

$$\frac{1}{DTW(x, T_i)} p(x | W_i) > \frac{1}{DTW(x, T_j)} p(x | W_j), \forall i \neq j, i := 1 to 3$$

in cui è massimo il prodotto tra la probabilità di appartenere ad una determinata classe ( Numeratore) e l'inverso della distanza (DTW) dal segnale di riferimento di quella classe ( Denominatore) . Schema in figura 15.

L'idea proposta di questa nuova regola di classificazione nasce dall'esigenza di voler rafforzare la regola di classificazione bayesiana classica, tenendo conto anche delle caratteristiche che il segnale mantiene nel dominio del tempo. Infatti la distanza calcolata con l'algoritmo del Dynamic Time Warping consente di calcolare un parametro di similarità tra serie temporali che tiene conto anche delle diverse velocità con cui viene compiuto il gesto.

Dai risultati emerge come il classificatore proposto produca risultati migliori rispetto ad un semplice classificatore bayesiano, a riprova del fatto di quanto gli andamenti nel tempo del segnale accelerometrico siano caratteristici della effettività attività svolta.

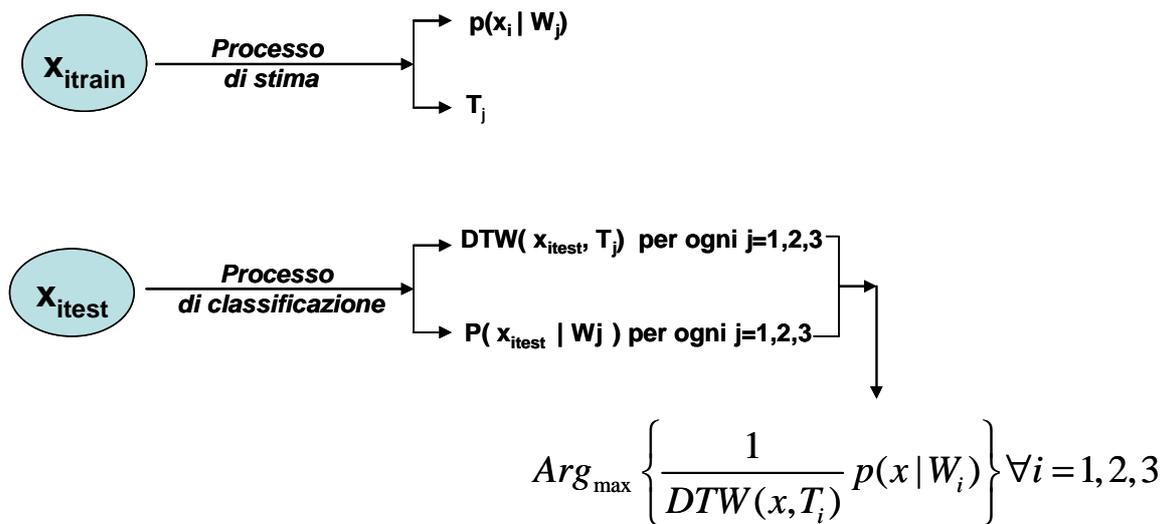


Figura 15 – Schema classificazione cooperativa Bayes + DTW

### 3.2.2 Un classificatore bayesiano a n dimensioni: la riduzione dello spazio delle features

Un ulteriore approccio sperimentato, per migliorare le performance del classificatore Bayesiano, è stato quello di agire sulla scelta delle features, cercando di rendere più consistente la probabilità di rilevare l'attività. Anche in questo caso i dati sono stati forniti da sensori accelerometrici e le attività da riconoscere sono attività della vita quotidiana relative agli arti inferiori

Si è cercato di intervenire sulla definizione e sulla dimensionalità delle features, nel tempo e nella frequenza, che fossero indicative della classe da riconoscere.

Studi precedenti hanno dimostrato delle variabilità nella distribuzione delle features tra i diversi soggetti, indice delle differenti modalità di effettuare i diversi movimenti. Per questo in una prima fase del lavoro si è preferito effettuare una ricerca di features tipica di ogni soggetto, preferendo i migliori risultati di classificazione ad un aumento

di generalizzazione. Le features considerate in ingresso sono 16 per ogni canale degli accelerometri a disposizione e si è cercato di mapparle in uno spazio bidimensionale tramite l' utilizzo delle mappe di Sammon, dopo che per ogni soggetto ne è stata valutata anche la effettiva separabilità nel nuovo spazio bidimensionale.

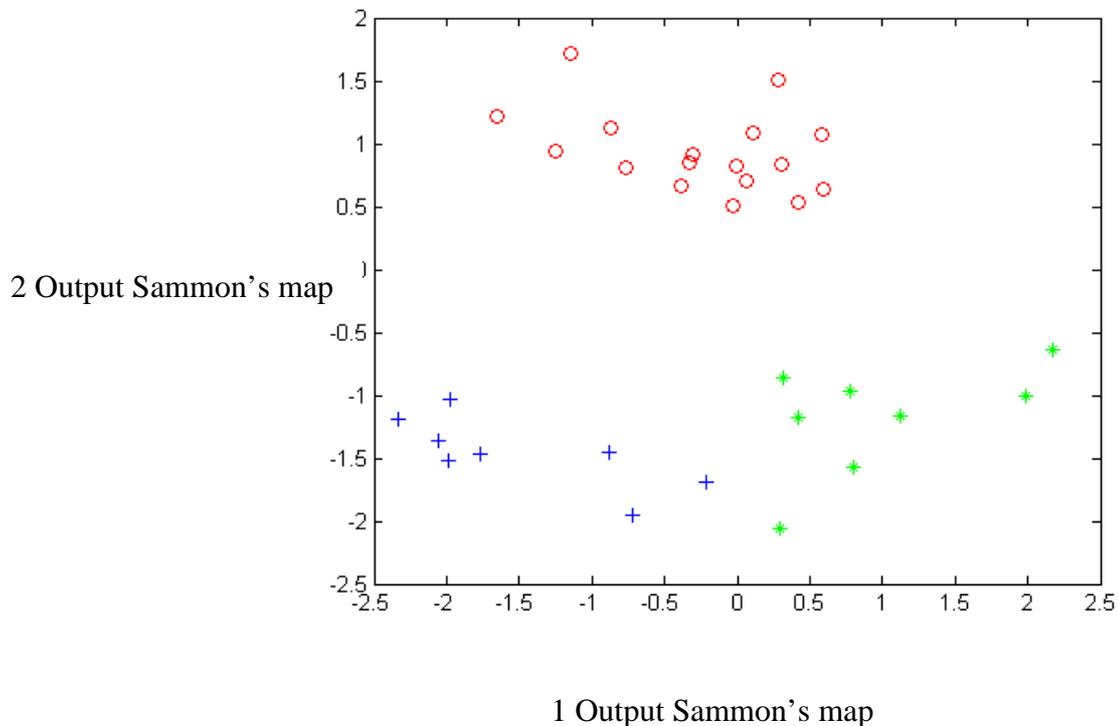
Le mappe di Sammon usano un algoritmo non lineare di mapping (NLM). L'algoritmo mappa N vettori di uno spazio L-dimensionale in N vettori di uno spazio a dimensione più bassa in modo che gli N vettori nel nuovo spazio mantengono le stesse distanze reciproche dello spazio di partenza. L'algoritmo in questione attua questa riduzione di dimensionalità tramite procedure di minimizzazione di una funzione di errore, come sotto indicata. Tramite questa riduzione di spazio, ad esempio in un dominio bidimensionale è stato possibile valutarne la effettiva separabilità delle features e la possibilità di lavorare in un dominio a più bassa dimensione.

$$E = \frac{1}{\sum_{i<j} d_{ij}^*} \sum \sum_{i<j} \frac{(d_{ij}^* - d_{ij})^2}{d_{ij}^*}$$

Le 16 features, per ogni canale, considerate indicative delle attività in esame, sono state scelte sia nel dominio della frequenza che nel dominio del tempo e sono : max, min, posizione relativa del max, posizione relativa del min, distanza tra il max e il min, numeri di zero crossing, distanza tra i minimi relativi, distanza tra i massimi relativi, freq max, freq min, mass e min del log dell'andamento frequenza media [75], massimo della derivata, min della derivata, massimo dell'integrale, min dell'integrale.

Tramite le mappe di Sammon queste features sono state mappate nello spazio 2D e in questo spazio sono state stimate le gaussiane bidimensionali, densità di probabilità condizionate per ogni attività, per poi potervi applicare un semplice classificatore bayesiano. Essendo una stima parametrica sono stata stimate le medie e le matrici di covarianza di ogni insieme di punti, per ogni attività. Era possibile anche una

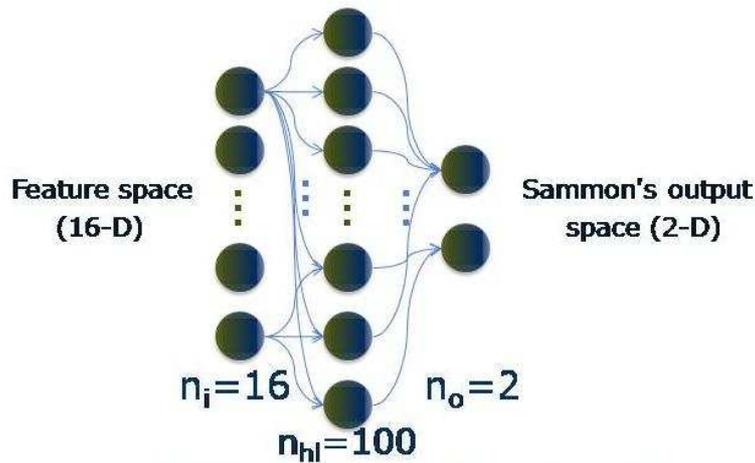
mappatura nello spazio 3d ma osservando i dati si è preferito il risparmio computazionale derivante dalla riduzione di una dimensione (figura 16).



**Figure 16 – Separabilità delle features nello spazio bidimensionale**

Essendo la mappatura di Sammon una funzione non lineare, che dipende dalle distanze reciproche tra punti e sfrutta algoritmi di minimizzazione, non ha una uscita univoca. Per la necessità di una relazione univoca tra ingresso e uscita è stata stimata la funzione di mapping, implementando una rete neurale a 16 ingressi e 2 uscite, avente in ingresso la matrice delle 16 features di training (Dim Matrice\_Input: numfeatures\_trainingx16) e in uscita la matrice degli output desiderati forniti dall'uscita della mappatura di Sammon (Dim\_matrice\_Output: numfeatures\_trainingx2).

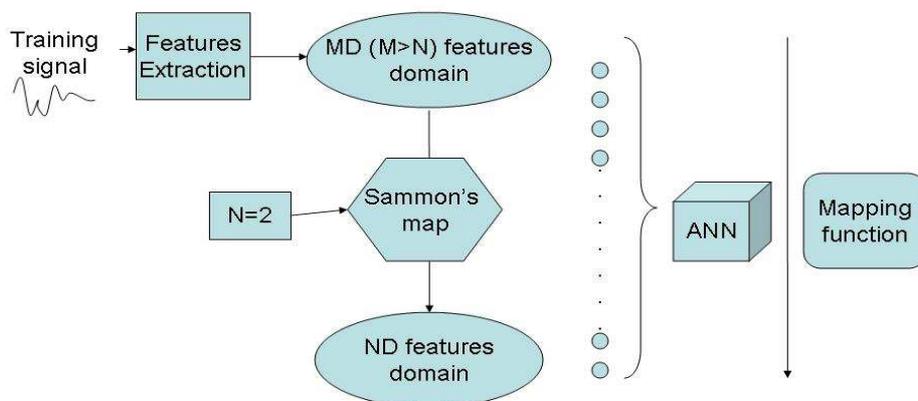
La rete è del tipo feed-forward con uno strato intermedio di 40 neuroni. L'algoritmo di training è il Levenberg-Marquardt algorithm e l'obiettivo è stato impostato a 0.001.



**Figura 17 – Rete per la stima della funzione di mapping**

La rete converge velocemente. Una volta stimata la funzione di mapping tramite questa rete, per ogni soggetto sarà utile proiettare le features del segnale di test nello spazio a due dimensioni in cui il teorema di Bayes a due dimensione opera semplicemente (Figura 18).

Anche in questo caso la densità di probabilità condizionata è stata supposta una gaussiana bidimensionale e nella fase di training, per ogni attività, sono state stimate media e matrice di covarianza.



**Figura 18**

### 3.2.3 Una classificazione adattiva: Bayes e il filtro di Kalman

Nello studio dei classificatori bayesiani e dei metodi di applicazione proposti si è supposto che le probabilità a priori per le diverse attività fossero uguali ( $1/n$  con  $n$  numero di attività da classificare). È stata sviluppata a questo proposito una tecnica adattativa basata su classificazione bayesiana, in grado di modificare, durante lo svolgimento dell'attività stessa, le probabilità a priori, che tenesse conto, passo per passo, delle attività effettivamente eseguite dal soggetto in esame.

L'idea parte dal presupposto che si possa modellizzare un insieme di attività motorie, compiute da un soggetto sano/no in un contesto di vita quotidiana, come un processo stocastico markoviano o processo di Markov nel quale la probabilità di transizione che determina il passaggio ad uno stato all'altro dipende unicamente dallo stato di sistema immediatamente precedente e non dal come si è giunti a tale stato.

Per questo proposito nel nostro lavoro sono stati utilizzati i concetti delle catene di Markov unite allo strumento matematico noto come Filtro di Kalman.

Il filtro di Kalman si applica a sistemi nella forma:

$$\left\{ \begin{array}{l} x(k+1) = A(k)x(k) + B(k)u(k) + w(k) \\ y(k) = C(k)x(k) + D(k)u(k) + v(k) \end{array} \right\}$$

Dove  $x(k)$ , vettore di stato all'istante  $k$ , nel nostro caso è rappresentato dal vettore composto dalle tre probabilità a priori nell'istante  $k$  ( $Pw_1(k)$ ,  $Pw_2(k)$ ,  $Pw_3(k)$ ), supponendo le tre classi  $w_1, w_2$  e  $w_3$ ),  $w(k)$  e  $v(k)$  sono rumori bianchi gaussiani rispettivamente dell'aggiornamento dello stato e della misura. Questi ultimi si possono esprimere come una matrice  $V$  :

$$V = \begin{bmatrix} \tilde{Q} & Z \\ Z & \tilde{R} \end{bmatrix}$$

dove

$$Z = Cov(v(k), w(k))$$

$$\tilde{Q} = \text{var}(w(k))$$

$$\tilde{R} = \text{var}(v(k))$$

$U(k)$  è l'eventuale ingresso del sistema,  $y(k)$  l'uscita o la misura del sistema e  $x(k+1)$  è l'aggiornamento dello stato.

Il problema tipicamente associato all'utilizzo di tali tecniche deriva dal fatto che la stima di tali dati diviene sufficientemente accurata solo dopo una ampia fase sperimentale di calibrazione.

Nei casi sperimentali studiati,  $A(k)$  è la matrice di transizione dello stato e nel nostro caso può essere espressa in questo modo:

$$A(k) = \begin{bmatrix} p_{w1w1} & p_{w1w2} & p_{w1w3} \\ p_{w2w1} & p_{w2w2} & p_{w2w3} \\ p_{w3w1} & p_{w3w2} & p_{w3w3} \end{bmatrix}$$

dove  $p_{ww}$  è la probabilità di rimanere nello stato  $w1$ . Nel nostro caso la classe  $w1$  rappresenta l'attività del camminare e dunque questa probabilità di transizione esprime la probabilità che ad un passo segua un altro passo. Analogamente vanno interpretate tutte le altre  $p$ : ad esempio  $p_{w1w2}$  è la probabilità di transizione tra lo stato  $w1$  e lo stato  $w2$ , ovvero se con  $w1$  indico l'attività del camminare e con  $w2$  l'attività

della salita delle scale, che ad un passo segua la salita di un gradino, e così via. In questo modo è possibile definire, in base ad una stima della matrice di transizione, l'evoluzione teorica dello stato:

$$\left\{ \begin{array}{l} Pw1(k+1) = Pw1(k) \cdot p_{w1w1} + Pw2(k) \cdot p_{w2w1} + Pw3(k) \cdot p_{w3w1} \\ Pw2(k+1) = Pw1(k) \cdot p_{w1w2} + Pw2(k) \cdot p_{w2w2} + Pw3(k) \cdot p_{w3w2} \\ Pw3(k+1) = Pw1(k) \cdot p_{w1w3} + Pw2(k) \cdot p_{w2w3} + Pw3(k) \cdot p_{w3w3} \end{array} \right\} = A'(k) \cdot x(k) = x(k+1)$$

In questo lavoro si propone che l'uscita all'istante k (y(k)), considerata come la stima dell'attività effettivamente svolta, possa essere misurata, in base al teorema di Bayes, tramite le features in ingresso, definendo quindi la matrice C in questo modo:

$$\left\{ \begin{array}{l} P(w1 | x) = \frac{p(x | w1)}{\sum_1^3 Pi \cdot p(x | Ci)} \cdot Pw1(k) \\ P(w2 | x) = \frac{p(x | w2)}{\sum_1^3 Pi \cdot p(x | Ci)} \cdot Pw2(k) \\ P(w3 | x) = \frac{p(x | w3)}{\sum_1^3 Pi \cdot p(x | Ci)} \cdot Pw3(k) \end{array} \right\}$$

Indicato con Cost il coefficiente costante a denominatore, si può definire la matrice C:

$$C = \begin{bmatrix} \frac{p(x|w1)}{Cost} & 0 & 0 \\ 0 & \frac{p(x|w2)}{Cost} & 0 \\ 0 & 0 & \frac{p(x|w3)}{Cost} \end{bmatrix} \rightarrow y(k) = C(k) \cdot x(k)$$

Con questa struttura il filtro di Kalman stima uno stato, utilizzando quello previsto dal sistema e quello misurato grazie alle *features* di ingresso. Lo stato così stimato all'istante  $k$  (probabilità a posteriori) diventerà input per lo stadio successivo come probabilità a priori. In questo modo, quindi, ad ogni passo la probabilità a priori cambia in funzione della storia del sistema. Il sistema così proposto risulta essere adattivo rispetto alle attività che vengono compiute dal soggetto e si presta in modo del tutto generale come metodo innovativo per la classificazione di attività motorie, in cui si possa supporre un processo markoviano tra le attività da riconoscere.

### 3.3 La classificazione precoce

La possibilità di riconoscere il gesto, prima che il gesto finisca o immediatamente dopo la sua fine, riveste una importanza notevole in tutte le applicazioni di telemedicina: dal telemonitoraggio alla teleriabilitazione.

Ciò consentirebbe di controllare in tempo reale il movimento e gli eventuali dispositivi di ausilio del movimento.

Da uno studio dello stato dell'arte risulta che è un settore ancora in espansione e sembra essere relegato alle tecniche video [71,76].

### 3.3.1 Il real-time DTW

L'algoritmo del DTW classico necessita di tutte e due le serie temporali in ingresso di cui si vuole calcolare la distanza. Questo per consentire il calcolo delle due matrici  $d$  e  $D$  utilizzando tutti i punti delle due serie.

E' stata apportata una modifica all'algoritmo base per consentire una stima di distanza campione per campione. Naturalmente l'algoritmo risulta non utile quando la classificazione dovesse distinguere tra attività le quali, a fronte di una supervisione iniziale, risultino costituite da segnali simili soprattutto nell'ultima parte.

L'algoritmo proposto si basa sulla condizione iniziale di non conoscenza delle dimensioni della serie temporale in input,  $X$ , e con la sola conoscenza a priori del segnale di riferimento, o *template*,  $Y$ .

Nella nostra formulazione, le matrici  $d(x_i, y_i)$  e  $D(x_i, y_i)$  sono costruite campione per campione, così come il corrispondente warping path e di conseguenza anche la distanza parziale tra le due serie temporali.

Questa implementazione può dunque essere sviluppate istante per istante, campione per campione e dunque in applicazione in tempo reale: chiameremo questa implementazione infatti real-time DTW (RT\_DTW).

Il primo passo è la costruzione della matrice  $d$  2x2 con le distanze corrispondenti tra punti dei due vettori e la matrice  $D$ , sempre 2x2, come sotto:

$$d(x, y) = \begin{bmatrix} (x_1 - y_1)^2 & (x_1 - y_2)^2 \\ (x_2 - y_1)^2 & (x_2 - y_2)^2 \end{bmatrix}$$

$$D(x, y) = \begin{bmatrix} d(1,1) & D(1,1) + d(1,2) \\ D(1,1) + d(2,1) & \min(D(1,1), D(1,2), D(2,1)) + d(2,2) \end{bmatrix}$$

Ad ogni step, la dimensione delle matrici  $d$  e  $D$  si incrementano, ad ogni nuovo campione, inserendovi una riga ed una colonna aggiuntive: (vedi figura 19).

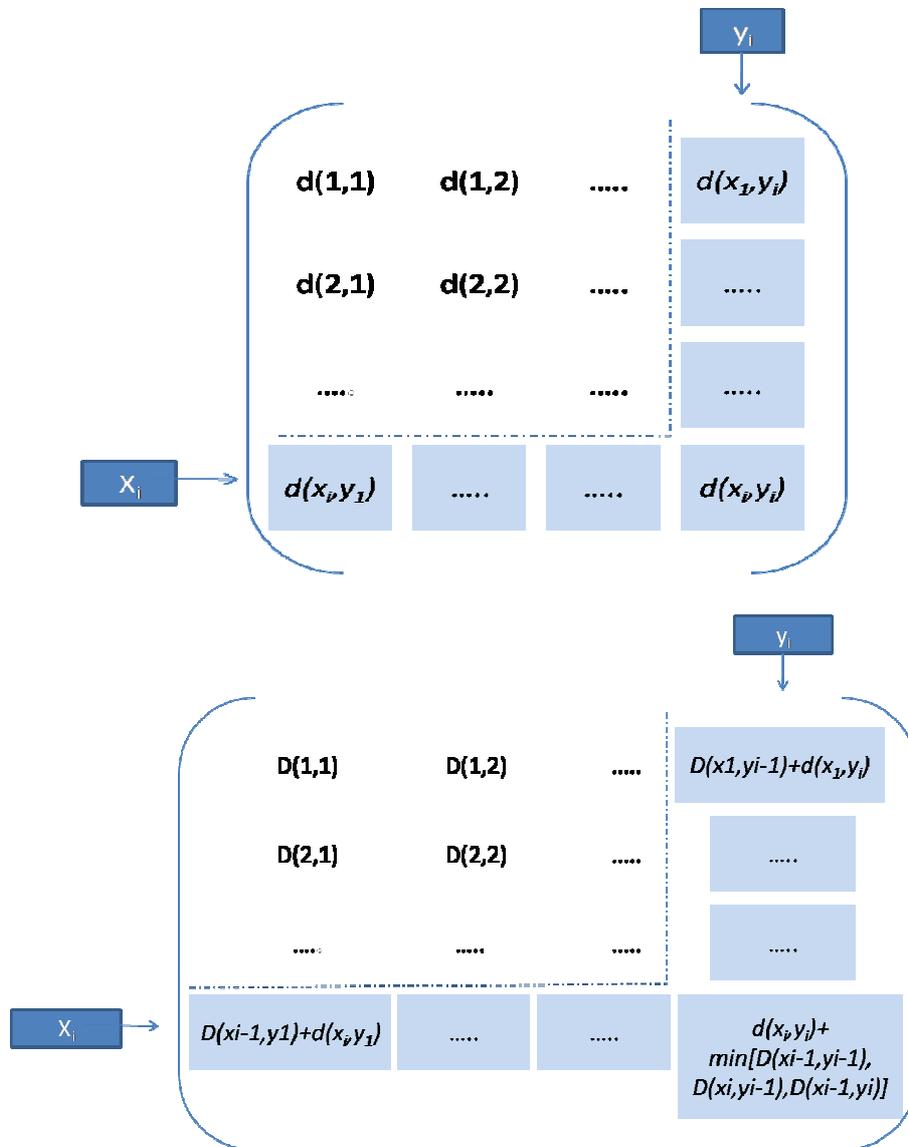


Figura 19 - Costruzione delle matrici  $d$  e  $D$

Ad ogni step possiamo anche identificare tramite gli indici  $(i,j)$  il warping path  $w(i,j)$ , cercando il minimo valore secondo la regola:

$$w(i,j) = \min [D(i+1, j), D(i+1, j+1), D(i, j+1)]$$

e possiamo anche dare una stima di misura di distanza tra serie aggiungendo volta per volta il valore di distanza, sommando questo minimo valore lungo il warping path e creando il vettore  $L$ . Quando una delle due serie finisce, le matrici  $d$  e  $D$  si costruiscono aggiungendo una singola riga o colonna fino alla fine dell'algoritmo.

$$L_w = \Sigma D_w(i,j)$$

La principale differenza con il classico algoritmo del DTW è che, nella nostra formulazione, la distanza al tempo  $i$ -esimo non è l'ultimo elemento della matrice  $D(N_i, M_i)$ , come per il DTW, ma è un valore cumulativo di distanza sull'elemento  $D$ -esimo calcolato lungo il percorso di minimizzazione all'istante  $i$ .

La dimensione del vettore  $L$  è spesso più lungo di  $i$  o  $j$  allo step corrente  $(i,j)$  e più lungo di  $N$  e  $M$  allo step finale, perché la sua dimensione eguaglia la dimensione del warping path.

Un possibile problema che può sopraggiungere durante l'esecuzione dell'algoritmo è la possibilità che durante la minimizzazione il percorso raggiunga il bordo della matrice troppo presto, e continui così in maniera non corretta la definizione del minimo percorso. Questo può essere superato inserendo alcune condizioni sulla pendenza del percorso, come proposto da Sakoe and Chiba [77]: se l'elemento  $w(i,j)$  procede in avanti nella direzione dell'asse  $i$  (o asse  $j$ ) per  $p$  passi consecutivi, deve andare avanti almeno  $t$  passi in diagonale (o lungo l'altro asse) (vedi figura 20). Nel nostro caso noi abbiamo imposto  $t/p = 1$ .

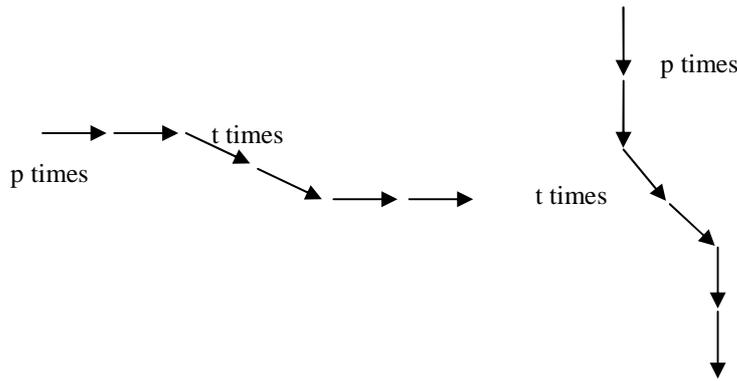


Figura 20 – Imposizioni al warping path

Uno degli svantaggi del DTW è che non si occupa di occupazione di memoria, dato che una volta note le lunghezze delle due serie temporali ( $N$  e  $M$ ), non ha bisogno di altro ma solo di allocare due matrici  $N \times M$ . Nella nostra formulazione si propone di ottimizzare l'algoritmo in termini di occupazione di memoria, distruggendo allo step  $k$ , caratterizzato dalla locazione  $(i, j)$ , la  $(i-1)$ -esima riga e la  $(i-1)$ -esima colonna, secondo la definizione di  $D$ . Per esempio, guardando la figura 21, allo step  $k$  la matrice  $D$  è ancora quadrata e il the warp path è  $w_k(i, j)$  e la distanza parziale è calcolata come  $D(w_1) + D(w_2) + \dots + D(w_k)$ .

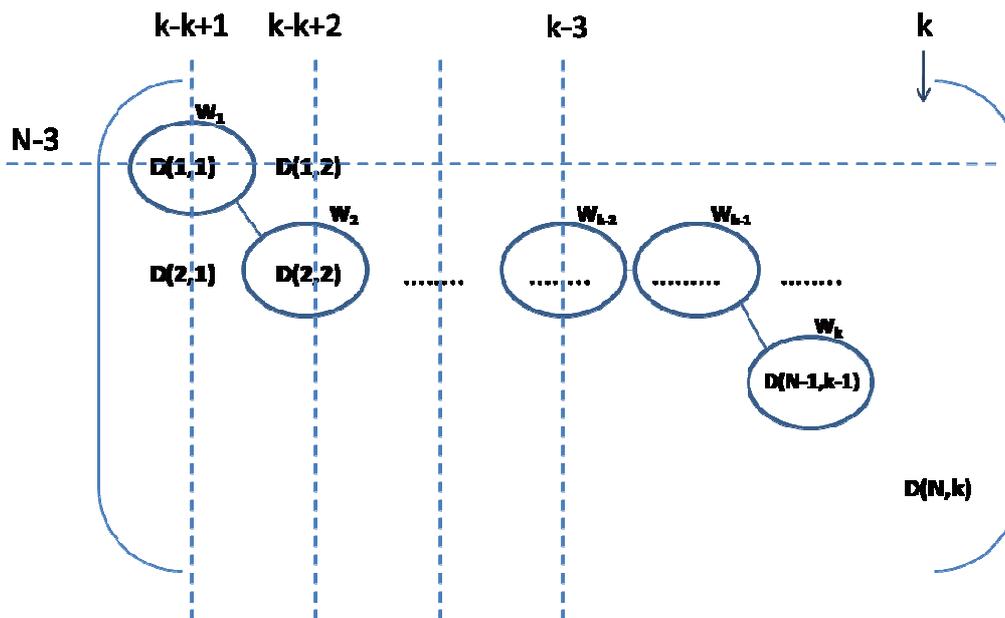


Figura 21 Procedura dell'algoritmo al k-step

L'algoritmo è stato implementato in C con Visual Studio 2008, mentre la interfaccia grafica (GUI) è stata implementata con il real-time toolbox in Matlab R2007a. Nella versione finale dell'algoritmo, presentata qui, l'allocazione dinamica della memoria delle matrici 2-D si basa sulla informazione iniziale nota delle dimensioni dei segnali di riferimento, e a ogni step sia righe che colonne vengono aggiunte, mentre quelle che ad ogni passo non servono più, vengono distrutte. Questa versione è risultata preferibile rispetto alla dinamica allocazione e riallocazione di matrici 2-D di dimensioni via via crescenti (matrici  $2 \times 2$ ,  $3 \times 3$ , ...,  $k \times k$ ).

Il tempo di esecuzione è perfettamente compatibile con una implementazione real-time.

## **Capitolo 4**

# **L'attività progettuale e realizzativa**

Per consentire le misure necessarie e le validazioni ai metodi proposti, e descritti nei capitoli precedenti, sono stati realizzati diversi sistemi di acquisizione e gestione del segnale accelerometrico. Nel seguito, vengono descritti questi progetti di ricerca sviluppati come naturali prodotti dell'attività di ricerca stessa e che hanno portato alla realizzazione di prototipi HW/SW per implementare le funzioni descritte nelle varie attività di ricerca elencate.

### **4.1 Realizzazione sistema di acquisizione dati per Pc e Pocket PC**

Per consentire l'acquisizione del segnale accelerometrico, fuori dal contesto di laboratorio, è stato realizzato un nuovo sistema per l'acquisizione dei segnali

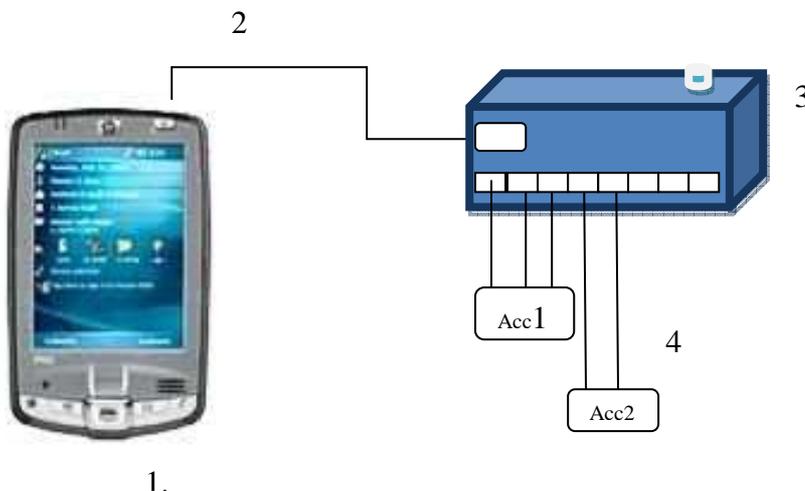
provenienti dagli accelerometri che fosse portatile, indossabile e il meno invasivo possibile.

Questo per consentire sia la facilità che la libertà di movimento del soggetto interessato alle diverse prove.

Il software è stato implementato e gestito nel laboratorio nel Biolab3, e quindi controllabili anche ai fini di successivi ampliamenti/modifiche.

La catena di acquisizione prevede tutti gli elementi di Figura 22:

- 1) Palmare
- 2) Pc Card/USB
- 3) Dispositivo acquisizione
- 4) Accelerometri



**Figura 22**

I sensori accelerometrici prodotti dalla Demitalia srl sono biassiali. Per realizzare il sensore triassiale sono stati posti due biassiali in modo perpendicolare con un asse in comune. L'uscita dei sensori avviene con connettori tipo RJ45 (Figura 23), non

compatibili con il dispositivo di acquisizione della National Instruments ( NI USB 6009 – Figura.24).



**Figura 23 – Accelerometro  
biassiale**



**Figura24 – NI USB 6009**

Per far sì che i sensori e il DAQ (dispositivo di acquisizione) possano comunicare è stata realizzata in laboratorio una scheda comprendente l'alimentazione, 8 porte di ingresso del tipo RJ45 e 8 uscite collegate direttamente agli input del dispositivo di acquisizione NI USB 6009.

Il tutto è stato racchiuso in un contenitore plastico, che chiameremo recording box (RB), controllato da un interruttore, accessibile solo tramite le 8 porte in ingresso e il cavo di uscita dell'NI USB 6009, per garantire sia la sicurezza che la portabilità di tutto il dispositivo.

Il dispositivo della NI richiede una porta Usb Host che fornisca anche l'alimentazione. Per questo è stata usata una Polar Express Card, inserita nella porta PMCIA del palmare (Figura 25 e 26), che consente al palmare di poter avere una porta USB valida.



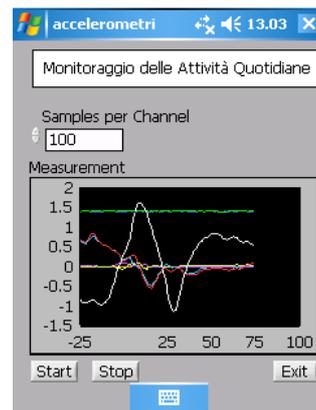
**Figura 25 – Card USB**



**Figura 26 – Connessione Card su palmare**

Il palmare è un HP iPAQ serie hx2700.

L'applicativo che consente l'acquisizione, la visualizzazione e il salvataggio dei dati è stato sviluppato in LabView 8.5, grazie al *PDA module* che consente di creare applicativi ad hoc per dispositivi PDA. Questo consente di creare programmi sul proprio computer, modificarli, e, sincronizzandosi con il palmare, effettuare il download del solo eseguibile. L'interfaccia realizzata è mostrata in figura 27



**Figura 27 – Interfaccia per palmare realizzata con LabView 8.5**

Tramite il programma e l'utilizzo di task per la gestione del dispositivo di acquisizione è possibile la lettura dei dati da 5 canali analogici, l'impostazione la frequenza di campionamento, la dimensione del buffer, la visualizzazione delle forme d'onda e il salvataggio dei dati in formato binario su file. I dati sono stati salvati in formato binario per consentire un risparmio di risorse sulla memoria del palmare e per consentire anche acquisizioni di segnali su lunghi intervalli temporali.

In Figura 28, a titolo di esempio, è mostrato il VI (Virtual Instrument), che è la forma basilare per la realizzazione di programmi in LabView, per la successiva conversione del file binario in un file di testo.

Tramite questo eseguibile infatti, una volta scaricati i file binari delle acquisizioni, sul proprio Pc, è possibile convertirli in una forma testuale semplicemente analizzabile in Matlab.

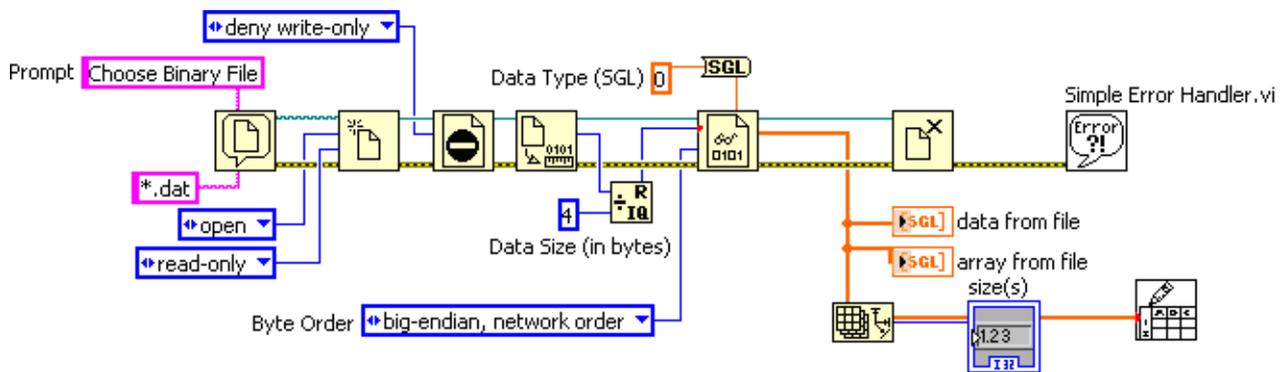


Figura 28 – VI per la conversione dei files da binario a file di testo

## 4.2 Interfaccia LabView per acquisizione ed elaborazione dati in real time da sensori della MicroStrain

E' stata realizzata in LabView 8.5 una applicazione che consente l'acquisizione e l'elaborazione in tempo reale dei dati proveniente da sensore IMU 3DM-GX2 sia in versione wireless che seriale (figura 29). L'applicazione, in base al tipo di sensore, gestisce il protocollo di comunicazione e la gestione dei pacchetti. Nel dettaglio descriveremo l'interfaccia e la sua applicazione specifica, ma i moduli sono completamente separabili per consentire la realizzazioni di applicazioni tra le più svariate, con la possibilità di visualizzare i dati di accelerometri, giroscopi e le inclinazioni in tempo reale e farne semplici elaborazioni.



**Figura 29**

L'applicazione specifica che descriveremo consente, tramite sensore inerziale posizionato rigidamente sulla pelvi, di acquisire in tempo reale le inclinazioni della stessa durante l'esecuzione di diversi task motori, rispetto ai tre piani di inclinazione. In base alle esecuzioni l'applicazione effettua un biofeedback acustico e visivo, guidando l'utente nell'esecuzione dell'esercizio scelto.

La difficoltà dell'applicativo è stata data dalla gestione del protocollo di comunicazione. Nel caso di sensore collegato alla porta seriale il software si è occupato della gestione della porta e della creazione dei pacchetti di dati, separando opportunamente le informazioni di interesse e gestendo la suddivisione dei dati tra i rispettivi canali. Nel caso di sensore wireless ci si è confrontati con una difficoltà in più, dovuta prima all'instaurazione della connessione tra il dispositivo trasmittente e quello ricevente, e in secondo luogo per la gestione dei pacchetti, che dispongono anche di codice di controllo, da analizzare e validare.

Nel seguente diagramma (figura 30) a blocchi la struttura generale dell'applicazione, che consente in generale le seguenti operazioni, ripetibili n volte grazie alla gestione dell'intera sessione di lavoro:

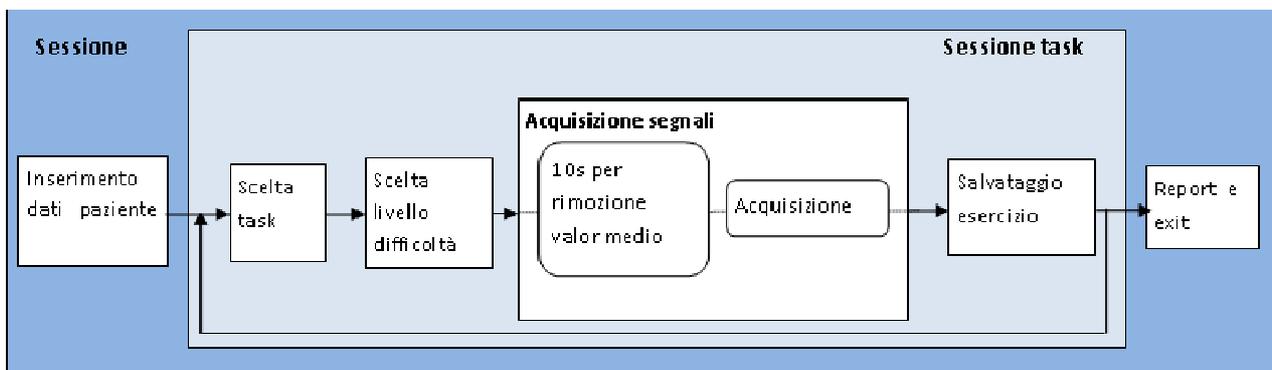
- 1) Inserimento dai paziente, in modo da consentire la creazione di un data base pazienti. Nel nostro caso si è gestita l'informazione del paziente tramite cartelle con il cognome del paziente e diverse sottocartelle a seconda della data

di esecuzione dei test. Questo per consentire anche una storia nelle sessioni di riabilitazione dell'utente.

- 2) Scelta del task motorio. I task motori sono descritti nel paragrafo relativo alla riabilitazione della pelvi ( par. 5.4). Essi vengono scelti da un menù a tendina e sono differenziati tra esercizi svolti con il lato destro e sinistro del corpo.
- 3) Scelta del livello di difficoltà. Abbiamo supposto tre livelli di difficoltà, che si ripercuotono in tre livelli relativi alle soglie da porre per la realizzazione ottimale dell'esercizio. Naturalmente le diverse soglie sono utili anche per monitorare un livello crescente di progressi in una eventuale terapia riabilitativa.
- 4) Acquisizione del segnale, comprensivo di 10 sec iniziali per rimozione del segnale medio e contemporanea visualizzazione. L'acquisizione avviene contemporaneamente sui tre piani di inclinazione e in tempo reale.
- 5) Biofeedback: grazie al confronto dei dati, in tempo reale, con curve di normalità, ricavate da un campione significativo di soggetti sani, è possibile valutare la bontà o meno dell'esercizio svolto. Questo consente, tramite le soglie che creano una fascia di tollerabilità rispetto alle curve di normalità, di poter acusticamente seguire il paziente nell'esecuzione del task. Il segnale acustico cambia poi una volta superate le fasce di normalità.
- 6) Finita la sessione di lavoro, comprensiva di più ripetizioni anche di diversi task, c'è il salvataggio dei dati e il calcolo in offline dei seguenti parametri:
  - a. Numero attraversamenti della soglia superiore
  - b. Massimo errore commesso sopra soglia
  - c. Posizione % del massimo errore
  - d. Numero attraversamenti della soglia inferiore

- e. Massimo errore commesso sotto soglia
- f. Posizione % del minimo errore
- g. Durata dell'esercizio
- h. RMSE tra la prova effettuata e la corrispondente curva di normalità

7) Creazione report in HTML con indicazioni relative ai dati del paziente, alla data, ai parametri calcolati, per ogni esercizio e per ogni ripetizione di esso, con i relativi grafici.



**Figura 30 - Diagramma a blocchi applicazione**

Un esempio dell'interfaccia realizzata è mostrato in figura 31.

### 4.3 Sistema di acquisizione di dati in tempo reale con Matlab

Tramite Matlab R2007a ed il tool *Data Acquisition toolbox* è stata creata una applicazione per interfacciare il dispositivo, recording box (RB par.4.1 – figura 22), realizzato presso questo laboratorio e sopra descritto. Tramite esso, equipaggiato di 8 diverse porte RJ45, è possibile acquisire e elaborare in tempo reale i segnali di 8 diversi sensori della DemItalia, quali accelerometri, elettrogoniometri e foot switches.

Il lavoro si è reso necessario per consentire l'elaborazione in tempo reale di segnali accelerometrici sfruttando le potenzialità di calcolo dell'ambiente Matlab.

Tale applicazione consente sia l'acquisizione direttamente in Matlab dei dati accelerometrici che la possibilità di testare le applicazioni sviluppate per applicazioni in tempo reale.

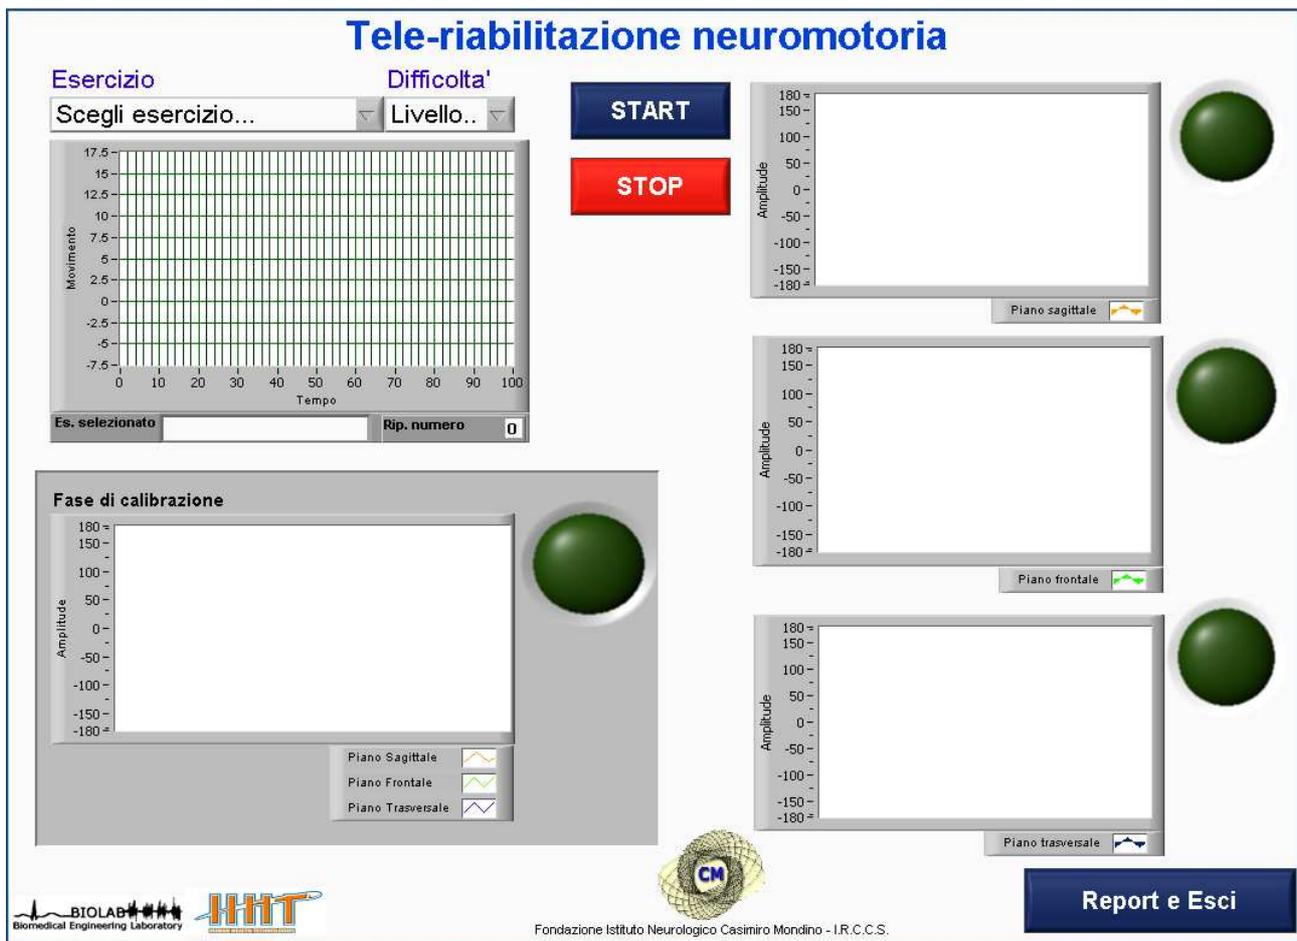


Figura 31 – Interfaccia applicazione

# Capitolo 5

## L'estrazione di caratteristiche

Le estrazione delle caratteristiche da segnali accelerometrici riguarda un aspetto fondamentale della classificazione, sia per il tele monitoraggio e la tele riabilitazione, che in generale per la valutazione clinica di un particolare atto motorio.

Estrarre una caratteristica significa estrarre una features per analizzare e riconoscere il movimento oppure significa estrarre una caratteristica di interesse dal segnale che ci consenta di estrapolare informazioni utili sul tipo di movimento svolto.

### 5.1 Il cammino e le variabili di interesse

Negli ultimi dieci anni si è avviato e si va sempre più consolidando l'impiego di sistemi basati su sensoristica indossabile, inerziale ma anche basografica, EMG, goniometrica, ecc per la valutazione della bontà dell'attività motoria. Attraverso l'integrazione di informazioni cinematiche e dinamiche (in taluni casi agevolata dall'impiego di modelli biomeccanici) provenienti dai sensori, il più delle volte indossati su entrambi gli arti inferiori e sul tronco, è ora possibile determinare con accettabile accuratezza i principali parametri spazio-temporali del cammino, ma

anche stimare la regolarità del pattern ciclico del cammino oppure la variabilità della sua dinamica temporale. Soluzioni basate su sensori multipli sono state ampiamente presentate in letteratura e validate [78,79], e stanno sempre più prendendo piede sistemi basati sull'impiego di una sola unità di elaborazione e acquisizione [80] Tali risultati sono ancora più rilevanti perché sembrano prefigurare una nuova generazione di sistemi per l'analisi del cammino completamente indossabili e anche slegati dalla acquisizione di laboratorio .

Infatti va comunque segnalato un problema rilevante per le applicazioni in Ambient Assisted Living (AAL ) che è tuttora irrisolto. Gli algoritmi sin qui proposti sono stati validati solo per il cammino rettilineo regolare e non per percorsi brevi, misti, comprensivi di svolte e cambi di direzione. Questo ovviamente limita, ad oggi, l'impiego di questi sistemi di analisi in condizioni non controllate quali quelle della vita quotidiana in ambiente domestico. La maggior parte delle applicazioni analizzate infatti sfrutta tapis roulant, o ambiente di laboratorio controllato per valutare parametri non altrimenti ricavabili con i soli sensori indossabili. Per questo la nostra analisi sembra porsi come preambolo in un uso di sensoristica indossabile, quella accelerometrica, che possa essere in grado prima di classificare l'attività, eventualmente scartare quelle di non interesse, e in seguito di stimare i parametri ritenuti significativi.

L'analisi del cammino a questo proposito diviene un tipo di analisi quantitativa e che è in grado di svolgersi al di fuori degli ambienti di laboratorio e dunque controllati, consentendo così una valutazione più naturale.

Il *cammino* è caratterizzato da un pattern di attività motoria ciclica degli arti inferiori e del tronco, che consente di trasferire il peso corporeo sull'arto di supporto e di avanzare l'arto controlaterale in avanti. Lo studio del cammino può essere utile nella diagnosi delle patologie a carico di uno dei sistemi coinvolti (sistema nervoso, muscolo-scheletrico), può fornire informazioni per conoscere il livello di limitazione funzionale conseguente alla patologia, consente la pianificazione di specifici trattamenti e fornisce importanti elementi di valutazione dell'efficacia di interventi

riabilitativi. La valutazione clinica del cammino, effettuata attraverso una *analisi osservazionale* del passo, consente di analizzare attentamente il comportamento dei diversi distretti articolari e/o segmenti (caviglia complesso piede-caviglia, ginocchio, anca, pelvi e tronco) durante le singole fasi del ciclo del passo; si ottengono in tal modo informazioni qualitative utili ad individuare le principali deviazioni del cammino. Il *ciclo del passo* rappresenta l'unità funzionale di riferimento nella analisi del cammino. Ogni ciclo è suddiviso in due fasi principali: la fase di appoggio (*Stance*) e la fase di oscillazione (*Swing*). La prima rappresenta l'intervallo di tempo durante il quale il piede rimane a contatto con il terreno. La seconda rappresenta l'intervallo di tempo durante il quale l'arto è sospeso, producendo la progressione in avanti e lo spostamento verticale del baricentro. E' nell'ambito del ciclo del passo che si definiscono i principali parametri spazio-temporali di riferimento:

- 1) Walking speed [m/s] – velocità della camminata;
- 2) (SF) Stride frequency [Hz] – frequenza del passo;
- 3) (SL) Step length [m] – lunghezza del passo;
- 4) (Sym) Stride symmetry – simmetria del passo;
- 5) (Reg) Stride regularity – regolarità del passo;
- 6) (CCA) Cranial-caudal acceleration – accelerazioni cranio-caudali;
- 7) Variabili armoniche come le cranial-caudal harmonics (CCHS) e le median-lateral harmonics (MHS);
- 8) Rapporto tra le armoniche pari e dispari dei segnali cranio-caudali (RH).

Nella maggior parte degli esami l'accelerometro utilizzato è un triassiale ed è comunemente posizionato sul tronco del soggetto, il più delle volte incorporato con una cinta semielastica attorno alla vita.

Il passo può essere considerato come uno dei maggiori determinanti per l'indipendenza motoria, ed il numero di camminate durante la giornata è indicativo del livello di attività fisica profusa.

Differenti patologie possono avere effetti sul passo e sull'equilibrio di una persona. Per questo motivo un'ampia gamma di discipline cliniche sono rivolte alla cura ed al trattamento dei disturbi del passo e dell'equilibrio. Su questo tema sono stati fatti molti test su uomini, donne, anziani, bambini ed anche su persone che hanno un passo non regolare, estrapolando dati e estrapolandone delle relazioni [81,82].

Da diversi studi è emerso che la velocità della camminata è maggiore negli uomini ( $1.51 \pm 0.16$  m/s) che nelle donne ( $1.44 \pm 0.17$  m/s). Tale velocità diminuisce con gli anni in entrambi i sessi; l'analisi in particolare mostra che la velocità inizia a diminuire durante il sesto decennio per gli uomini e durante il settimo per la donna. La stride frequency (SF) è più alta nelle donne ( $1.04 \pm 0.06$  Hz) che negli uomini ( $0.97 \pm 0.06$  Hz). La step length (SL) è più lunga negli uomini ( $1.55 \pm 0.13$  m) che nelle donne ( $1.40 \pm 0.13$  m). Tale variabile è strettamente correlata con la velocità della camminata. Infine, la simmetria (Sym) e regolarità (Reg) del passo sono piuttosto distribuite in entrambi i sessi, e non ci sono grandi squilibri andando avanti con l'età.

Altro studio di rilievo effettuato con gli accelerometri, rivolto in particolar modo all'ambiente medico, è quello di mettere in relazione le variabili del passo di persone con una camminata normale e fluida, con quelli che invece hanno un passo anormale. Tale studio è finalizzato alla misura delle variabili del passo in persone soprattutto anziane, che hanno un passo diverso dal consueto dovuto essenzialmente a cadute avute in passato. In media tali soggetti hanno tra le 3 e le 4 cadute subite negli anni precedenti. Il dato fondamentale venuto fuori da questa analisi, è che tali variabili del passo riferite a persone che hanno subito cadute, e che quindi non hanno un passo normale, sono significativamente più basse rispetto agli altri soggetti.

Per quanto riguarda la velocità abbiamo:  $0.73 \pm 0.22$  m/s contro  $1.24 \pm 0.19$  m/s. Questa bassa velocità è dovuta innanzitutto ad una lunghezza del passo più corta ( $0.86 \pm 0.26$  m vs  $1.28 \pm 0.17$  m), e ad una frequenza più bassa ( $0.86 \pm 0.07$  vs  $0.97 \pm 0.08$ ). Da rilevare anche una più bassa simmetria ( $173.4 \pm 45.5$  vs  $210.9 \pm 39.4$ ) e regolarità ( $191.3 \pm 56.0$  vs  $291.9 \pm 51.9$ ). Tutti questi studi consentono perciò sia di

poter analizzare il cammino in quanto tale, ma soprattutto permettono la correlazione tra variabili di interesse e tra il valore di queste variabili con situazioni patologiche.

### 5.1.1 Valutazione dei parametri della camminata tramite sensori accelerometrici

- *Step length* : distanza tra l'appoggio di un piede (generalmente il tallone) e l'appoggio della stessa parte del piede controlaterale. Si misura in metri [m]; differisce dalla *stride length* o lunghezza del passo intero, in cui invece la distanza è misurata tra due appoggi consecutivi dello stesso piede;

L'approccio più diffuso per il calcolo della *step length* fa uso di un modello a "pendolo invertito" [83] . (Figura 35)

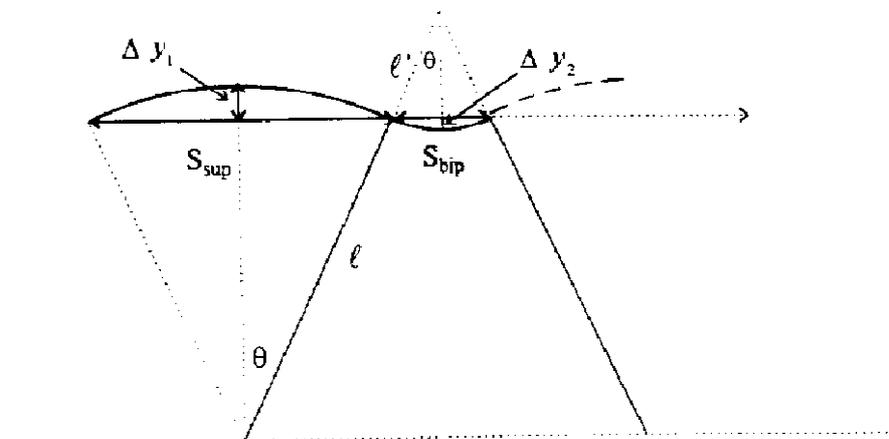


Figura 32 – Il modello del pendolo invertito

Osservando la figura abbiamo i seguenti parametri:

- $l$  - lunghezza della gamba;
- *heel strike* - momento in cui il tallone si stacca da terra (inizio del passo)
- *toe off* - momento in cui le dita del piede si appoggiano a terra (fase finale del passo);

- *mid-stance*: spostamento dovuto alla differenza tra toe off e heel strike
- $S_1$  - spostamento relativo alla fase di mid-stance
- $S_2$  - spostamento relativo alla fase di double-stance
- $h_1$  e  $h_2$  – spostamenti verticali relativi ad ogni rispettiva fase

Tramite questo modello si tiene in considerazione la relazione che intercorre fra gli spostamenti verticali del centro di massa ( COM ) e quelli in avanti, ed è possibile calcolare la step length tramite la seguente equazione:

$$S_1 = K 2\sqrt{2lh - h^2}$$

dove  $l$  sta per lunghezza della gamba, e  $h$  per spostamento verticale del centro di massa del corpo durante ogni step.  $K$  è una costante, calibrata per ogni soggetto. Lo spostamento verticale per ogni step,  $h$ , è calcolato tramite una doppia integrazione dell'accelerazione verticale del centro di massa del corpo.

Sono state proposte poi diverse varianti al metodo con aggiunte di costanti e diversi metodi di integrazione. Il primo consiste nell'aggiungere alla doppia integrazione dell'accelerazione verticale del centro di massa, una costante di offset al periodo dell'accelerazione che va da  $t_0$  a  $t_1$ :

$$\int_{t_0}^{t_1} \left( \int_{t_0}^{t_1} (a_y + c_1) dt \right) + c_2 dt = 0$$

dove  $c_1$  e  $c_2$  sono appunto le due costanti di offset. Questo metodo riduce gli effetti del movimento e fornisce un calcolo migliore degli spostamenti verticali del centro di massa del corpo.

Il terzo metodo per il calcolo, non tiene in considerazione il solo spostamento in avanti come conseguenza del passo stesso, ma somma a questo lo spostamento dovuto al baricentro (COM). La formula è la seguente:

$$S_3 = S_1 + S_2 = 2\sqrt{2lh_1 - h_1^2} + S_2$$

Tramite questa schematizzazione della camminata, la step length si può calcolare come la somma di due fattori: lo spostamento di mid-stance ( $S_1$ ) e lo spostamento di double-stance ( $S_2$ ), dove per double-stance si intende il momento in cui entrambi i piedi sono appoggiati a terra. La fase  $S_1$  inizia nel momento in cui il tallone si stacca da terra (*Heel strike*) e termina con l'appoggio delle dita del piede (*Toe off*). In pratica rappresenta la fase di oscillazione (*swing*).

Il quarto metodo fa riferimento ad una empirica relazione dell'accelerazione verticale con la lunghezza della camminata che dipende dal numero  $n$  dei passi:

$$S_4 = Kn^4\sqrt{a_M - a_m}$$

$a_M$  e  $a_m$  corrispondono ai valori di massimo e minimo della prima armonica dell'accelerazione verticale ad ogni passo, e  $K$  è una costante di calibrazione. La prima armonica dell'accelerazione verticale è elaborata tramite un filtro passa-basso alla frequenza di 3 Hz.

Un'altro metodo è basato su una relazione fra la cadenza e la lunghezza del passo. La stima di ogni passo è calcolata tramite la seguente equazione:

$$S_5 = \frac{K_1}{T_{step}} + K_2$$

L'evidente potenziale di tale strumento, usato nella valutazione delle funzioni motorie sotto determinate condizioni di vita reale, necessita ancora di determinati approcci metodologici, ed inoltre la strumentazione non deve, oppure solo minimamente, interferire con la regolare attività fisica.

- *Simmetria e regolarità*: per simmetria, dal punto di vista fisico, si intende un fenomeno che si ripete in modo identico a distanza di tempo e spazio, mentre per regolarità un fenomeno che si ripete in maniera costante nel tempo. Vengono stimati tramite due coefficienti di correlazione,  $C_1$  e  $C_2$ , ottenuti a loro volta attraverso il calcolo della funzione di autocorrelazione delle accelerazioni verticali. Tali coefficienti indicano rispettivamente il periodo di uno step e di uno stride.

Prima di applicare le formule della simmetria e regolarità [84], sui coefficienti di correlazione estrapolati, è stata eseguita la trasformata di Fisher, in modo tale da ottenere una funzione che sia caratterizzata da una distribuzione più uniforme e i nuovi coefficienti diventano  $Z_1$  e  $Z_2$

Le formule della simmetria e della regolarità sono le seguenti:

$$symmetry = \left( \frac{Z_1}{Z_2} \right) \cdot 100$$

$$regularity = (Z_1 + Z_2) \cdot 100$$

- *Stride frequency/cadence (frequenza o cadenza del passo)*: numero di step al minuto (steps/min);

$$\begin{aligned} \text{steps} : \text{temposegnale} &= \text{cadence} : 60 \\ \Rightarrow \text{cadence} &= \frac{\text{steps} \cdot 60}{\text{temposegnale}} \end{aligned}$$

Dove “temposegnale” rappresenta il numero di campioni relativi ad un passo/frequenza di campionamento

- *walking speed (velocità del cammino)*: rapporto fra step length e tempo impiegato per effettuare il passo. Unità di misura [m/s]

### 5.1.2 Applicazione su soggetti anziani

L’analisi dei parametri spazio temporali del cammino riveste molta importanza in letteratura ed è stata da noi esplorata come applicazione complementare al problema della classificazione dell’attività motoria. Le nostre applicazioni in merito riguardano i dati prelevati da un accelerometro biassiale posto sullo stinco di 12 soggetti anziani, di età compresa tra i 60-80 anni. Prima di effettuare le prove sono state lette e spiegate al soggetto le modalità della prova ed è stato firmato il modulo per il consenso informato .

Successivamente si è passati alla compilazione di un modulo indicativo dello stato generale del soggetto, nel quale vengono richiesti dati anagrafici, parametri, e la compilazione di un piccolo test sulla valutazione funzionale (Functional Independence Measurement - FIM).

Ogni soggetto è stato sottoposto ad una serie di domande, previste nelle scheda di valutazione funzionale, per avere una misura sul livello di attività funzionale (FIM).

Dalla valutazione delle schede di valutazione compilate dai soggetti si sono estrapolati i seguenti dati:

- in media i soggetti hanno una lunghezza del passo (m) che va da un minimo di 0,34 ad un massimo di 0,51.
- un livello di FIM in media di 80-85, considerando che la scala va da un minimo di 13 ad un massimo di 91.

Ogni soggetto doveva effettuare un percorso che consisteva principalmente in una camminata, in 4 salite e 4 discese di scale. Il percorso è stato effettuato a velocità normale e i soggetti sono stati accompagnati, in modo da poter compilare un diario delle prove. I soggetti sono stati invitati a fermarsi alla fine del percorso o alla fine della scalinata, prima di tornare indietro e iniziare di nuovo. L'intera parte sperimentale è durata circa 30 minuti, inclusa la parte di spiegazione e test. Circa il 30% del percorso è stato utilizzato per la parte di training del classificatore bayesiano, mentre il rimanente 70% è stato utilizzato per testare l'algoritmo di classificazione e per calcolare i parametri di interesse. Il percorso è riportato qui di seguito (tabella 1):

<b>Percorso</b>	<b>Soggetto1</b>	<b>Soggetto2</b>
<b>passo</b>	239	222
<b>1 gradino</b>		
<b>passo</b>	184	183
<b>Salita 14 gradini</b>		
<b>passo</b>	13	12
<b>Salita 16 gradini</b>		
<b>passo</b>	62	62
<b>Discesa 2 gradini</b>		
<b>passo</b>	4	5
<b>Discesa 10 gradini</b>		
<b>passo</b>	9	12
<b>Salita 10 gradini</b>		
<b>passo</b>	4	3
<b>Salita 2 gradini</b>		
<b>passo</b>	41	57
<b>Discesa 16 gradini</b>		
<b>passo</b>	12	12
<b>Discesa 14 gradini</b>		
<b>passo</b>	151	309
<b>1 gradino</b>		No gradino
<b>passo</b>	230 (stop) poi 29	no

**Tabella 1 - Esempi di percorsi effettuati da due soggetti**

Soltanto due persone hanno avuto difficoltà a portare a termine la prova a causa di affaticamento perciò è stato scelto un percorso più breve.

Il classificatore bayesiano è un semplice bayesiano bidimensionale, pesato con il DTW, già descritto precedentemente (par 3.2), che ci ha consentito di classificare, e quindi di isolare, la parte del percorso relativa al cammino e trattando separatamente le fasi relative alle salite e alle discese dei gradini.

Le fasi del percorso, sono state segmentate in epoche, che rappresentano dunque i singoli passi o le singole salite/discese di gradini. I dati raccolti sono stati utilizzati per il calcolo di parametri spazio temporali, elencati in tabella 2, come:

- l'indice di massa corporea
- il livello di indipendenza funzionale
- kcal spese durante il percorso e fabbisogno giornaliero
- lunghezza del passo e velocità media
- tempo medio del passo
- tempo medio di salita e discesa scale

In questa prima applicazione si sono stimati lunghezza media del passo grazie ad un test preliminare sul cammino, contenuto nella FMI, su un percorso di 2,44m.

- *IMC*: Indice di massa corporea

$$IMC = \text{peso}/\text{altezza}$$

- $IMC < 18,5$  sottopeso
- $25 < IMC < 29,9$  sovrappeso
- $IMC > 30$  obeso

Date le valutazioni del *IMC* come sopra, è stato possibile valutare che:

- Nessun soggetto sottopeso
- 3 soggetti normali
- 6 soggetti sovrappeso

- 3 soggetti obesi

	IMC	FIM	Percorso	Calorie tot. spese	% / di	Lunghez.media passo	Tempo medio passo	Tempo medio SU	Tempo medio SD
Soggetto1	38,7	80	881 p, 2 SU(21), 2 SD(21)	62,45	2357	0,4	0,9	1,2	0,7
Soggetto2	29,2	89	563 p, 4SU(33),4SD(33)	42,5	1979	0,51	0,7	1,25	1,15
Soggetto3	27,2	90	1236p, 4SU(33),4SD(33)	74,3	2330	0,44	0,84	0,7	0,9
Soggetto4	26,4	90	910p, 4SU(33),4SD(33)	70	1328	0,51	0,8	1	1,15
Soggetto5	26,0	88	916p, 4SU(33),4SD(33)	69,66	2290	0,48	0,76	0,7	0,7
Soggetto6	24,7	90	874p, 4SU(33),4SD(33)	67,3	2377,1	0,5	0,89	0,7	1,04
Soggetto7	26,2	89	1131p, 4SU(33),4SD(33)	97,5	1925	0,44	0,42	0,67	0,6
Soggetto8	38,2	75	1083p, 2 SU(21), 2 SD(21)	100,28	2181	0,34	0,43	1,09	0,8
Soggetto9	35,5	76	423p,1SU(14),1SD(14)	42	2100	0,43	0,7	1,6	1,4
Soggetto10	24,2	88	978p,4SU(33),4SD(33)	37,12	1857	0,35	0,48	1,1	1,2
Soggettoll	28,5	81	877p,4SU(33),4SD(33)	88	2019	0,4	0,7	0,75	1,25
Soggettoll2	24,9	86	955p,4SU(33),4SD(33)	94,41	1979	0,51	0,64	0,7	0,73

**Tabella 2- Parametri calcolati per ogni soggetto**

- *FIM* (Functional Independence Measurement): La misura di indipendenza funzionale è stata ottenuta da questionari fatti compilare ai soggetti prima dell'esecuzione delle prove. Per ogni attività viene dato un punteggio da 1 a 7 . La somma dei punteggi fornisce l'indice di indipendenza funzionale. Il minimo valore è 13 e il massimo è 91 sulla base dei quali è risultato che solo due soggetti sono al limite dell'autosufficienza.

- *Kcal spese e dispendio giornaliero*: Sono stati calcolati in base a tabella in letteratura e alla formula che lega il dispendio energetico a metabolismo basale x livello di attività fisica

- *Tempi medi passo/salita/discesa*: Sono stati ottenuti a seguito di rilevazione epoche e classificazione, con algoritmo a integrazione e soglia. Il numero dei campioni di ogni epoca è stato diviso per la frequenza di campionamento e poi è stata fatta la media su tutte le attività corrispondenti

### 5.1.3 Applicazione su soggetti giovani

La seconda applicazione a riguardo ha cercato di stimare i parametri di interesse e in particolare il calcolo della step length come proposto dalla letteratura, per valutare la stabilità dei risultati in un contesto che non fosse controllato e su dati misurati su percorsi della durata superiore a 10 minuti. I soggetti reclutati per la nostra applicazione sono 12 soggetti giovani con età media di 32 anni, tutti sani. Nell'ambito della sperimentazione svolta, tutti i soggetti erano consapevoli che lo studio effettuato non aveva alcun fine diagnostico in senso stretto, ma permetteva un'analisi di tipo quantitativo di alcuni parametri relativi allo svolgimento di attività motorie.

Ai 12 soggetti interessati è stata fatta indossare una cintura con una tasca contenente un palmare Hp 27xx collegato ad una scheda di acquisizione della NI (NI US 6900) anch'essa contenuta in una tasca. Alla scheda è connesso un accelerometro biassiale (ADXL202) posizionato sullo stinco della gamba dominante, con asse x nella direzione longitudinale (direzione del cammino) e l'asse y diretto lungo la verticale. Inoltre un accelerometro triassiale, formato da due biassiali sempre ADXL202, è stato posizionato sullo sterno con l'asse x rivolto lungo la direzione del cammino, il secondo lungo la direzione verticale e il terzo in direzione trasversale.

L'applicativo per l'acquisizione e l'elaborazione preliminare del segnale, sul Pocket PC, è stato implementato in LabView 8.5, modulo PDA. I segnali accelerometrici vengono campionati a 100 Hz e filtrati con un filtraggio passa basso a 40 Hz e la successiva parte di elaborazione è stata svolta in ambiente Matlab R2007a. Nella prima fase di pre-elaborazione del segnale, dato che il protocollo prevedeva un percorso misto, fatto anche di salite e discese, sono state eliminate le componenti che non fossero il cammino. Per fare ciò ci si basa un metodo [5] basato sulla Dynamic Time Warping (DTW), il quale, osservando i segnali che differiscono tra loro in

ampiezza, mantenendo però una forma d'onda simile, permette di classificare il tipo di attività motoria svolta, e quindi distinguere i passi, dalle salite e discese di gradini.

Il primo passo dell'analisi è quello di impostare un algoritmo a soglia sul segnale accelerometrico verticale posto sulla gamba in modo tale da selezionare i singoli passi, e segmentare quindi l'intera attività motoria in epoche. Determinato il numero totale di passi su tutto il segnale, si passa poi a calcolare tutti i parametri di interesse.

Tutte le implementazioni sono state fatte sia su tutto il percorso, che separatamente su parti veloci/lente.

Per prima cosa sono stati analizzati i dati in letteratura da cui è possibile riportare alcuni valori relativi ai parametri stimati per valutare la bontà dei risultati ottenuti. Attraverso uno studio dei parametri del cammino su soggetti sani, privi di problemi neurologici e fisici eseguito su 282 soggetti [84][85], di cui 144 donne, con età compresa tra i 20-98 anni e valutando i dati a disposizione è possibile riassumere i valori delle gait variables per gli uomini e le donne a seconda delle diverse fasce di età ( Tabella3):

### Uomini

Age	20-29	30-39	40-49	50-59	60-69	≥70	Mean
	Mean						
Step length (m)	0.83 ± 0.07	0.88 ± 0.06	0.82 ± 0.05	0.80 ± 0.07	0.77 ± 0.08	0.73 ± 0.09	0.80 ± 0.08
Speed (m/s)	1.55 ± 0.18	1.67 ± 0.13	1.55 ± 0.10	1.45 ± 0.18	1.42 ± 0.14	1.25 ± 0.21	1.49 ± 0.20
Stride Time (s)	1.03	1.02	1	1.04	1.04	1.05	1.03
Cadence	112.32 ± 5.79	114.06 ± 3.80	113.55 ± 3.99	107.94 ± 8.17	109.51 ± 3.39	105.66 ± 7.41	110.51 ± 6.30
Stride Symmetry	5.46 ± 0.19	5.41 ± 0.18	5.40 ± 0.15	5.39 ± 0.19	5.43 ± 0.17	5.35 ± 0.10	5.41 ± 0.17
Stride Regularity	346.6 ± 36.2	335.5 ± 40.8	333.7 ± 40.2	320.6 ± 43.9	331.2 ± 44.2	310.2 ± 24.5	331.2 ± 40.7

**Donne**

Age	20-29 Mean	30-39 Mean	40-49 Mean	50-59 Mean	60-69 Mean	≥70 Mean	Mean
Step length (m)	0.75 ± 0.06	0.75 ± 0.05	0.73 ± 0.03	0.72 ± 0.07	0.66 ± 0.07	0.66 ± 0.08	0.71 ± 0.07
Speed (m/s)	1.50 ± 0.15	1.47 ± 0.13	1.46 ± 0.13	1.44 ± 0.14	1.42 ± 0.14	1.29 ± 0.14	1.40 ± 0.17
Stride Time (s)	0.97	0.96	0.94	0.95	0.97	1	0.96
Cadence	120.24 ± 6.96	118.02 ± 5.83	119.52 ± 7.47	120.72 ± 6.04	116.53 ± 5.60	115.56 ± 9.24	118.43 ± 6.94
Stride Symmetry	5.45 ± 0.15	5.41 ± 0.13	5.40 ± 0.13	5.47 ± 0.12	5.47 ± 0.09	5.40 ± 0.21	5.43 ± 0.14
Stride Regularity	328.2 ± 38.0	325.2 ± 43.8	337.4 ± 28.0	336.6 ± 43.5	332.1 ± 32.0	302.1 ± 37.0	329.0 ± 38.0

**Tabella 3 – Gait parameters per soggetti sani**

Nell'osservare i dati è possibile dedurre che, in media, gli uomini camminano più velocemente ( $1.49 \pm 0.20$  m/s) delle donne ( $1.40 \pm 0.17$ ). La velocità decresce con l'età in entrambi i sessi. Per gli uomini la velocità inizia a diminuire durante la quinta decade di età, per le donne durante la quarta. La step length è più alta negli uomini ( $0.80 \pm 0.08$ ) che nelle donne ( $0.71 \pm 0.07$ ). Oltre alla naturale correlazione con l'altezza, si evidenzia che questa variabile è anche correlata con la velocità del passo, poiché la step length inizia a decrescere nella stessa fascia di età in cui diminuisce la velocità del passo. Questo accade sia per gli uomini che per le donne. La cadenza è invece più alta nelle donne ( $118.43 \pm 6.94$ ) che negli uomini ( $110.51 \pm 6.30$ ), poiché la frequenza del passo delle donne è più elevata. Tale variabile è quindi inversamente proporzionale con lo stride time. Per quanto riguarda simmetria e regolarità, esse sono piuttosto distribuite, non essendoci sostanziali differenze tra le varie fasce di età. Di seguito sono riportati i dati da noi ottenuti divisi su quattro tabelle. Una con i dati calcolati come media su tutto il percorso (Tabella 4), una con i dati relativi al solo percorso effettuato velocemente (Tabella 5), una con i dati relativi al percorso effettuato a velocità media (Tabella 6) e una con i dati su un tratto di percorso effettuato in maniera più lenta (Tabella 7).

<i>Parametri</i>	<i>20-29</i>	<i>20-29</i>	<i>30-39</i>	<i>30-39</i>
	<i>Men</i>	<i>Women</i>	<i>Men</i>	<i>Women</i>
<i>SL</i>	0.50 ± 0.06	0.44 ± 0.01	0.52 ± 0.06	0.46 ± 0.02
<i>ST</i>	1.15 ± 0.05	1.13 ± 0.01	1.27 ± 0.11	1.11 ± 0.03
<i>Cadence</i>	52 ± 2.8	53.5 ± 0.7	47.8 ± 4.4	53.5 ± 0.7
<i>Sym</i>	188.3 ± 23.4	194.2 ± 10.7	178.2 ± 21.9	171.8 ± 13.5
<i>Reg</i>	129.9 ± 11.4	116.8 ± 4.3	138.3 ± 26.6	118.6 ± 20.9

**Tabella 4 – Media (±sd) dei parametri del cammino stimati su tutto il percorso effettuato**

Si nota che ad una velocità della camminata in crescendo, risulta una step length maggiore, sia per gli uomini che per le donne in tutte le fasce di età, ad eccezione della fascia tra i 20-29 anni delle donne riferita al percorso veloce. Altra importante constatazione, sempre strettamente correlata con la velocità, è il fatto che i passi con lunghezza maggiore eseguiti durante il percorso veloce, hanno anche un tempo di esecuzione (stride time) minore. Questo accade sia per gli uomini che per le donne e questa volta su tutte le fasce di età. Oltre a questo c'è da aggiungere che la stride time, generalmente nel confronto risulta superiore negli uomini.

La cadenza avrà quindi un ordine dei valori crescente, partendo dal percorso lento fino a quello veloce. Per la simmetria e la regolarità, osservando i confronti tra uomini e donne, risulta una distribuzione piuttosto lineare. Andando nel dettaglio, la simmetria risulta superiore negli uomini nel tratto veloce e medio ma non in quello lento. Per la regolarità abbiamo una perfetta distribuzione, ovvero: nel tratto veloce, nella fascia tra 20-29 anni, la regolarità è maggiore negli uomini al contrario della decade di età tra i 30-39; nel tratto medio, nella decade 20-29, la regolarità è maggiore nelle donne, mentre nella decade 30-39 succede l'opposto; infine nel tratto di percorso lento, nella decade 20-29 la regolarità risulta maggiore negli uomini, mentre in quella tra i 30-39 anni anche questa volta succede l'esatto contrario.

<i>Parametri</i>	<i>20-29</i>	<i>20-29</i>	<i>30-39</i>	<i>30-39</i>
	<i>Men</i>	<i>Women</i>	<i>Men</i>	<i>Women</i>
<i>SL</i>	0.51 ± 0.07	0.42 ± 0.04	0.51 ± 0.07	0.49 ± 0.10
<i>ST</i>	1.05 ± 0.12	0.97 ± 0.09	1.10 ± 0.07	0.96 ± 0.13
<i>Cadence</i>	57.5 ± 6.4	55.5 ± 3.5	54.8 ± 4.0	62.5 ± 9.2
<i>Sym</i>	153.6 ± 40.0	115.6 ± 11.7	120.42 ± 11.1	120.5 ± 10.0
<i>Reg</i>	167.0 ± 60.0	223.7 ± 29.9	251.8 ± 20.5	211.8 ± 33.4

**Tabella 5- Media (±sd) dei parametri stimati sul percorso veloce**

<i>Parametri</i>	<i>20-29</i>	<i>20-29</i>	<i>30-39</i>	<i>30-39</i>
	<i>Men</i>	<i>Women</i>	<i>Men</i>	<i>Women</i>
<i>SL</i>	0.49 ± 0.08	0.44 ± 0.02	0.46 ± 0.03	0.47 ± 0.04
<i>ST</i>	1.13 ± 0.02	1.12 ± 0.09	1.23 ± 0.08	1.09 ± 0.04
<i>Cadence</i>	53.5 ± 0.7	54.0 ± 4.2	49.2 ± 3.4	55.5 ± 2.1
<i>Sym</i>	163.5 ± 49.1	116.4 ± 6.4	116.5 ± 16.2	116.4 ± 8.1
<i>Reg</i>	195.9 ± 76.4	256.8 ± 10.0	243.6 ± 22.9	200.9 ± 14.2

**Tabella 6 - Media (±sd) dei parametri stimati sul percorso medio**

<i>Parametri</i>	<i>20-29</i>	<i>20-29</i>	<i>30-39</i>	<i>30-39</i>
	<i>Men</i>	<i>Women</i>	<i>Men</i>	<i>Women</i>
<i>SL</i>	0.46 ± 0.03	0.43 ± 0.01	0.46 ± 0.04	0.47 ± 0.03
<i>ST</i>	1.22 ± 0.07	1.32 ± 0.04	1.57 ± 0.18	1.17 ± 0.13
<i>Cadence</i>	49.5 ± 3.5	45.0 ± 1.4	38.5 ± 5.2	52.0 ± 5.6
<i>Sym</i>	124.8 ± 8.9	147.6 ± 18.7	129.8 ± 7.1	134.9 ± 2.6
<i>Reg</i>	186.4 ± 11.1	126.0 ± 47.6	172.8 ± 20.6	190.5 ± 18.0

**Tabella 7 - Media (±sd) dei parametri stimati sul percorso lento**

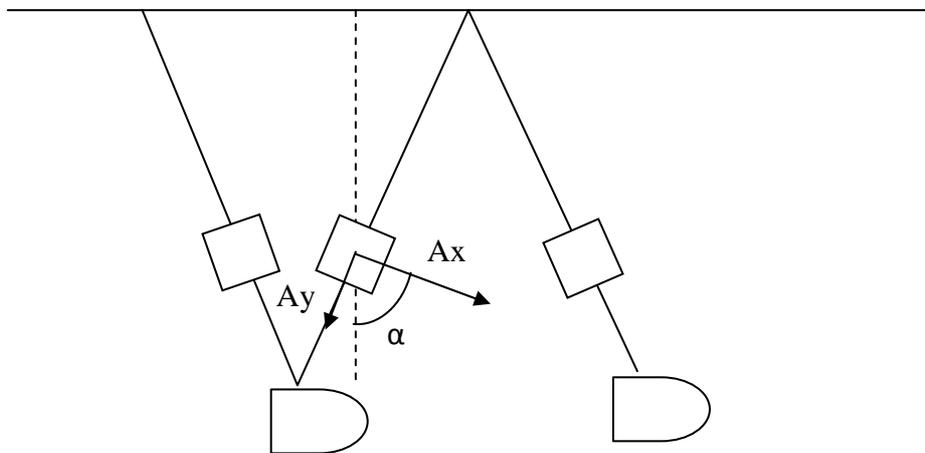
Inoltre dal seguente grafico (Grafico 1) è possibile notare come i valori di step length ottenuti lungo l'intero percorso siano stabili



**Grafico 1 – Andamento dei valori della step length**

### **5.1.4 Un nuovo metodo per il calcolo della step length**

Nella nostra ipotesi l'accelerometro è posto sulla gamba per questo le condizioni geometriche e spaziali sono differenti. Si è supposta una situazione come quella in figura 33 in cui l'accelerazione lungo la verticale possa essere proiettata sul piano longitudinale e verticale sfruttando considerazioni geometriche e sfruttando le informazioni dell'accelerometro usato come inclinometro:



**Figura 33 – Modello della gamba**

La proiezione sul piano longitudinale dell'accelerazione istantanea sarà:

$$A_{x\text{tot}} = A_x \cdot \text{sen}(\alpha) - A_y \cdot \text{cos}(\alpha)$$

Questa accelerazione verrà integrata due volte, per la durata del passo e da considerazioni geometriche relative al modello del pendolo invertito, questo spostamento orizzontale corrisponde alla definizione di step length. Il modello è ancora in fase di validazione.

## 5.2 Algoritmi di separazione del tremore dal movimento volontario su segnali accelerometrici

Al lavoro svolto nell'ambito del dottorato, orientato alla caratterizzazione del movimento dell'arto superiore, si collega naturalmente quanto si sta sviluppando nell'ambito del progetto europeo Tremor (ICT 2007), in cui sono stati approfonditi gli algoritmi, basati su segnali provenienti da sensori inerziali, che consentono la valutazione della componente tremorigena durante l'esecuzione di movimenti volontari dell'arto superiore.

E' stato studiato l'algoritmo di separazione del movimento volontario rispetto al tremore, a partire da segnali derivanti da giroscopi, e che prevede la possibilità, senza la conoscenza di alcuna informazione a priori, di decomporre il segnale di partenza.

Questo algoritmo, denominato EMD (Empirical Mode Decomposition), decompone il segnale di partenza in tante IMFs (Intrinsic Mode Functions) ognuna su una differente scala temporale.

L'algoritmo è inizializzato calcolando un segnale che è la media di due inviluppi del segnale di partenza, uno passante per i punti di massimo e uno passante per i punti di minimo.

La prima funzione candidata ad essere una IMF è la differenza tra il segnale di input e questo segnale medio. Affinché una funzione sia una IMF deve rispettare due condizioni:

- 1) Il numero degli estremi e il numero degli attraversamenti dello 0 devono essere uguali o differire al massimo di uno
- 2) In ogni punto il valor medio degli inviluppi definiti sui massimi e sui minimi locali deve approssimare il valore nullo

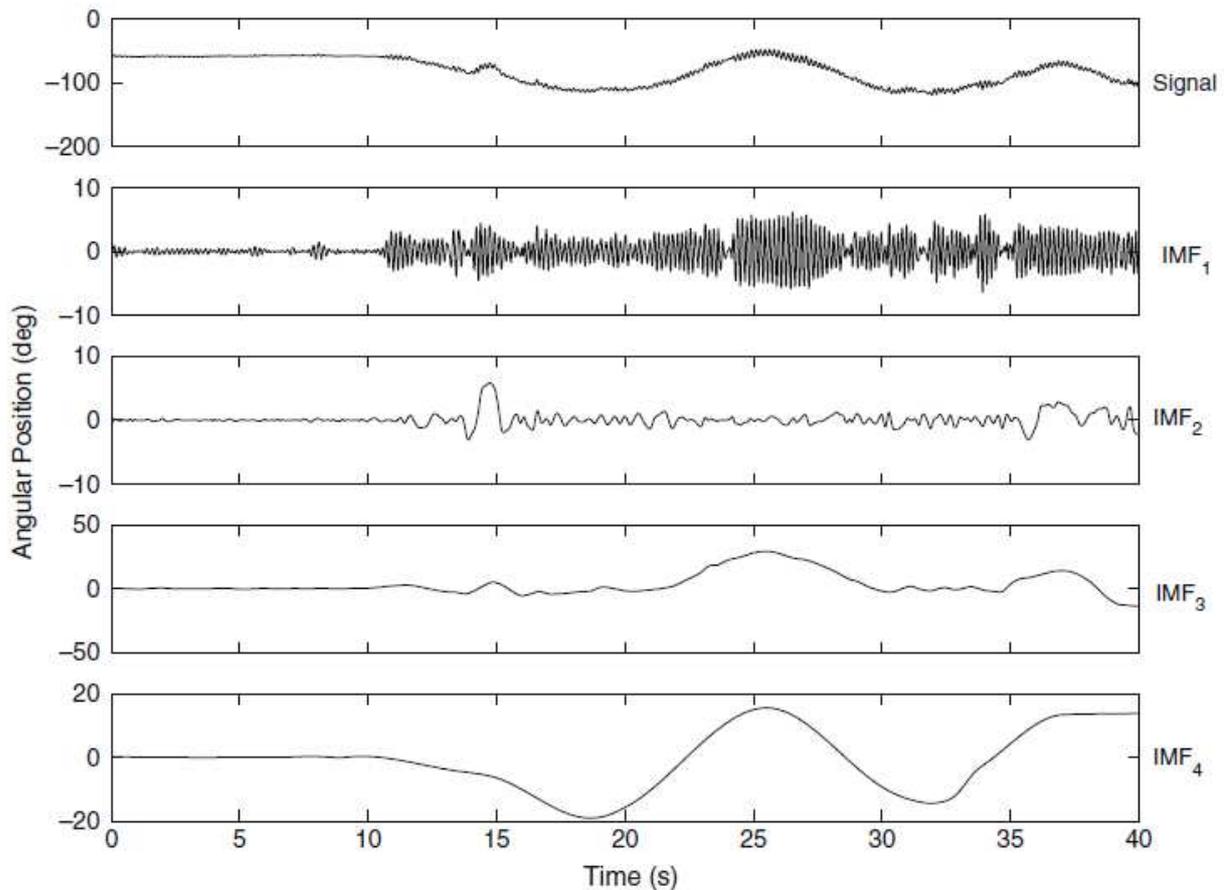
L'algoritmo continua iterativamente, usando come dato di input la differenza tra l'input dello stato precedente e la IMF appena trovata.

La condizione di stop è data dal confronto tra la differenza tra le ultime 2 IMF consecutive e un valore di soglia.

Un esempio è mostrato in Figura 34, dove un segnale di posizione angolare è stato decomposto in quattro funzioni. Da studi derivanti dall'analisi dei segnali provenienti da quattro giroscopi posti sul braccio di 31 pazienti, con disturbi di natura tremorosa, Rocon et al. [86] hanno dimostrato come la IMF1 sia assimilabile al solo tremore, mentre la somma di tutte le altre componenti rappresenta il movimento volontario.

Altri metodi sono stati usati per l'individuazione della componente tremorigena su segnali IMU (Inertial Measurement Unit) e per la sua separazione dal movimento volontario. I più semplici usano semplici filtri, dopo aver dimostrato che la componente relativa al tremore si trova in una banda di frequenze più alta rispetto al movimento volontario. In generale si usano filtri tra i 3 e gli 8 Hz a fronte di un movimento volontario del braccio stimato sempre al di sotto dei 2 Hz.

Altri metodi per rilevazione del movimento volontario sono stati implementati con il filtro di Benedict – Bordner, alla cui uscita il tremore è stato calcolato per differenza. Questo metodo è stato usato per applicazioni in tempo reale affiancato all'uso di un controllore [86].



**Figura 34**

Tali algoritmi sono stati valutati e confrontati con quelli messi a punto nel terzo anno di dottorato, ai fini di:

- effettiva separazione segnale tremorogeno da segnale volontario
- implementazione in tempo reale

I risultati sono in fase di completamento.

### **5.3 Possibilità di ricostruzione della posa da dati provenienti da sensori inerziali**

Un altro studio compiuto ha valutato l'obiettivo, a livello di scelta dei sensori, di studiare tecniche di integrazione di sensori di tipo giroscopico da associare ai sensori

accelerometrici già usati per ricostruire il movimento eseguito dal braccio. Anche i giroscopi sono sensori non invasivi e facilmente indossabili e dunque rispondono ai requisiti di portabilità e semplicità di utilizzo da rispettare in un progetto che si propone il monitoraggio delle attività quotidiane.

Uno degli obiettivi riguarda la possibilità di ricostruire in tre dimensioni il movimento del braccio tramite semplici sensori inerziali, quali accelerometri e giroscopi.

La prima parte di questo lavoro, che riguarda la ricostruzione di semplici movimenti individuati da tre rotazioni possibili di segmenti del braccio, è stata già affrontata e prevede l'uso di un semplice modello del braccio costituito da due segmenti rigidi (braccio e avambraccio) collegati da un giunto rotoidale (gomito).

L'input di questo modello è la posizione assunta dall'end-effector assimilato alla parte interna del polso. Le misure delle posizioni assunte istante per istante dal polso sono state ottenute dalla doppia integrazione dei segnali di accelerazione provenienti da un accelerometro lì posizionato. Durante questa prima fase è emersa la necessità di affiancare le misure dell'accelerometro con quelle di un altro sensore che potesse sia fornire nuovi dati sull'orientamento della mano, sia correggere gli errori derivanti dalle sole misure accelerometriche. A tale proposito l'uso del filtro di Kalman sembra un passaggio obbligato.

## **5.4 Estrazione di caratteristiche per la riabilitazione della pelvi**

In collaborazione con ISPESL (Istituto Superiore per la Prevenzione e la Sicurezza del Lavoro) e presso i loro laboratori di analisi del movimento, è stata svolta una campagna di misure volta alla validazione di un sistema inerziale per la valutazione della mobilità della pelvi.

Tramite il sistema inerziale e gli esercizi svolti l'obiettivo è valutare la mobilità della pelvi a riposo e durante l'esecuzione dei movimenti per consentire maggior comprensione delle strategie motorie messe in atto durante il lavoro e consentire così la prevenzione di disfunzioni come la lombalgia e la fatica meccanica.

Dieci soggetti giovani di età compresa tra 20 e 55 anni sono stati reclutati per effettuare il protocollo descritto.

Un sensore inerziale con trasmissione wireless, composto da un accelerometro triassiale e un giroscopio (MicroStrain 3DM-GX2, MicroStrain, Inc., Williston, USA), è stato posizionato a contatto con la pelle del soggetto all'altezza dell'osso sacro. Il sensore fornisce in uscita direttamente le inclinazioni del sensore rispetto ai tre piani sagittale, frontale e orizzontale.

Le curve in uscita dal sensore sono state confrontate con le stesse informazioni ricavate tramite un sistema optoelettronico (SMART-E System, BTS, Milan, Italy, Ferrigno and Pedotti 1985) costituito da 8 telecamere a infrarosso (120 fps), che lavorava in contemporanea con l'altro sistema. Tramite esso è stato possibile rilevare il movimento nello spazio tridimensionale grazie a tre marker riflettenti di 15 mm di diametro.

I soggetti hanno eseguito i seguenti task motori:

- Standing reaching and grasping: con le braccia lungo il corpo, dalla posizione eretta, il soggetto in modo naturale doveva raggiungere e afferrare un cilindro delle dimensioni di 6 cm di altezza, diametro di 3 cm e peso di 300g, piegandosi in avanti.
- Oblique and opposite reaching and grasping: l'esercizio è come il precedente ma con il cilindro posto a 45° rispetto alla direzione anteriore
- Anterior trunk flexion: flessione anteriore del tronco
- Sit to stand: per questo esercizio il soggetto si doveva alzare in modo naturale da una sedia confortevole

Per confrontare le curve è stato utilizzato il root mean squared error (RMSE) sui range of motion (ROM)

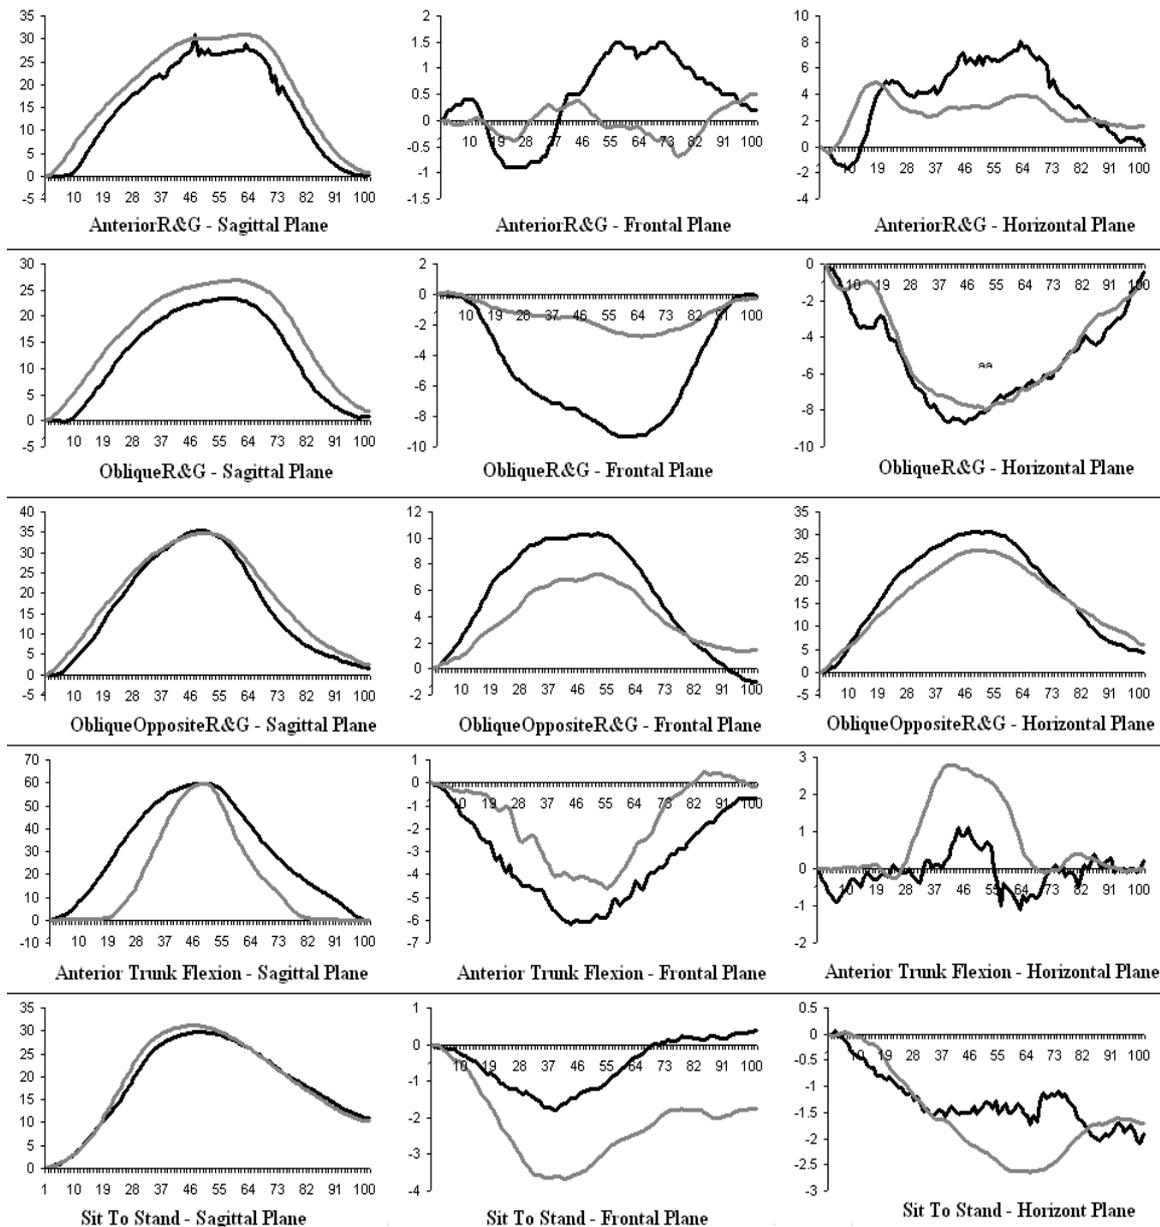
$$RMS = \sqrt{\frac{\sum_{i=1}^N (x_{o,i} - x_{d,i})^2}{N}}$$

e il CMC (Coefficient of Multiple Correlation) calcolato usando la seguente formula [87, 88]

$$R_{BT} = \sqrt{1 - \frac{\frac{1}{T(N-1)} \sum_{i=1}^N \sum_{t=1}^T (y_{it} - \bar{y}_t)^2}{\frac{1}{TN-1} \sum_{i=1}^N \sum_{t=1}^T (y_{it} - \bar{y})^2}}$$

Dove T = 100 ( numero dei punti in un ciclo), N=2 ( numero di curve) e  $y_{it}$  è il valore al tempo t nel ciclo i-esimo

L'analisi statistica è stata effettuata con SAS 8.2 . I risultati sono mostrati in tabella 13. Un t test è stato utilizzato per confrontare ROM calcolato usando le due tecniche. P valori inferiori a 0,01 sono stati considerati significativi. In figura 35 le curve medie ricavate con i due metodi, per ogni esercizio



**Figura 35**

La tabella 8 mostra il ROM ( range of motion ) calcolato con il sistema optoelettronico (Opt) e il sistema inerziale (I), il valore di P, il RMS e il CMC per ogni task motorio

I risultati mostrano maggiore somiglianza tra le curve dell'inclinazione rispetto al piano sagittale (CMC>0.88), poi di quelle di obliquità rispetto al piano frontale (CMC>0.7 ad eccezione dell'anterior reach and grasping ) e poi della rotazione intra-extra della pelvi sul piano orizzontale (CMC>0.61)

	Sagittal					Frontal					Horizontal				
	Opt	I	P	RM S	CM C	Opt	I	P	RM S	CM C	Opt	I	P	RM S	CM C
<b>Anterior R&amp;G</b>	27.7 ± 5.7	31.7 ± 8.1	0.5	4.0	0.96	0.3± 0.6	1.7 ± 0.3	0.02 3	1.4	0.50	8.2± 1.7	6.6± 0.8	0.2	2.0	0.61
<b>Oblique R&amp;G</b>	23.5 ± 1.5	26.9 ± 1.8	0.06 6	3.4	0.94	6.3± 4.6	3.3 ± 1.2	0.33 6	5.2	0.82	9.9± 2.0	9.7± 1.5	0.89 7	1.6	0.96
<b>ObliqueOppR&amp;G</b>	36.2 ± 3.2	36.0 ± 3.1	0.94 2	5.3	0.98	10.7 ± 1.0	7.7 ± 1.2	0.02 9	3.5	0.84	31.5 ± 0.7	28.0 ± 0.9	0.00 6	3.5	0.96
<b>Anterior Trunk Flexion</b>	59.9 ± 0.6	60.4 ± 2.1	0.71 2	1.6	0.88	6.3± 0.2	5.3 ± 1.7	0.36 9	1.8	0.77	1.9± 0.3	3.4± 0.4	0.00 7	1.5	0.31
<b>STS</b>	30.6 ± 2.0	31.6 ± 1.6	0.53 6	3.4	0.99	1.9± 0.4	4.0 ± 1.0	0.01 3	2.1	0.70	1.2± 0.9	3.0± 0.2	0.00 1	4.1	0.76

**Tabella 8**

## **Capitolo 6**

# **Le applicazioni per il monitoraggio e la riabilitazione domiciliare**

Viene qui descritto l'insieme delle attività sperimentali, e le corrispondenti tecniche utilizzate, nei contesti applicativi del monitoraggio domiciliare e della riabilitazione. Come sarà possibile riconoscere, il denominatore comune di tali attività sperimentali è legato all'utilizzo dei sensori accelerometrici, da una parte come strumenti per il riconoscimento di compiti motori effettuati sia con gli arti inferiori, sia con gli arti superiori, dall'altra come strumenti di predizione o riconoscimento precoce di attività. In molti casi, quindi, le tecniche sviluppate saranno principalmente basate su attività effettuate off-line rispetto alla registrazione dei dati, mentre in alcuni contesti si sfrutteranno metodologie che richiedono attività di elaborazione ed interpretazione in tempo reale.

## 6.1 Il template matching applicato su segnali accelerometrici

### 6.1.1 Il DTW per il riconoscimento di task motori effettuati con gli arti superiori

Le tecniche di classificazione studiate nel corso del primo anno sono state approfondite e valutate anche nel riconoscimento del gesto dell'arto superiore. L'algoritmo di riconoscimento utilizzato è il DTW (Dynamic Time Warping) relazioni già precedentemente descritto. Esso stima la distanza tra due vettori, il segnale di riferimento (Template) e il segnale in ingresso.

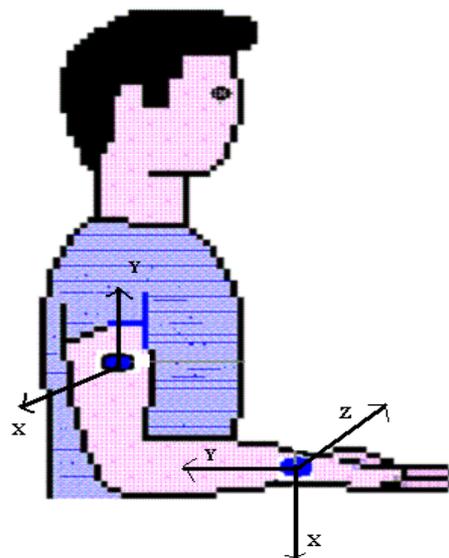
I movimenti da riconoscere sono 5 e sono stati scelti da una lista di esercizi proposti per la riabilitazione post-ictus, nella scala detta Wolf Motor Function Test (WMFT). Gli esercizi sono stati scelti tra quelli che sembrano più simili a gesti della vita quotidiana:

- *Esercizio 1: RD* – recover and draw up – l'esercizio di recupero di un oggetto a distanza di 20 cm posto su un tavolo di fronte a noi e di avvicinamento fino al bordo del tavolo
- *Esercizio 2: RJ* – raise jar – l'esercizio di sollevare una lattina e portarla alla bocca, nel gesto classico che si fa per bere.
- *Esercizio 3: RP* – raise pencil – raggiungere e sollevare una matita.
- *Esercizio 4: SUP* - stack up pawn – accatastare 3 pedine da gioco una sull'altra.
- *Esercizio 5: TK* – turn up keys - girare le chiavi nella serratura della porta.

I dati sono stati registrati su 5 volontari di età dai 28 ai 35 anni, due donne e tre uomini. Ogni soggetto ha ripetuto ogni esercizio 10 volte, 5 volte lentamente e 5 volte velocemente. I dati sono stati registrati tramite due accelerometri (ADXL202), uno triassiale posto nella parte interna del polso e uno biassiale posto nella parte interna del bicipite, con assi orientati come in Figura 22.

Per il riconoscimento tramite il DTW, tra tutte le prove effettuate, per ogni soggetto, per ogni prova e per ogni canale, si è scelto come *template* quella prova a distanza minore, calcolata sempre con il DTW, da tutte le altre.

In questo caso sono stati stimati differenti *template* per le prove lente e per quelle veloci. In totale sono stati stimati 250 *template* ( 5 soggetti X 5 prove X 5 canali X 2 velocità). Per riconoscere il gesto compiuto a differenti velocità è stato implementato un algoritmo che stima un *template* medio tra due prove uguali ma compiute a diverse velocità. Questo *template* è stato estrapolato dal percorso di minimizzazione che calcola il DTW per effettuare il confronto tra i due segnali, prendendone i punti medi e interpolandoli su un segmento lungo la metà dei due (Esempio in Figura 23).



**Figura 36 - Posizionamento accelerometri**

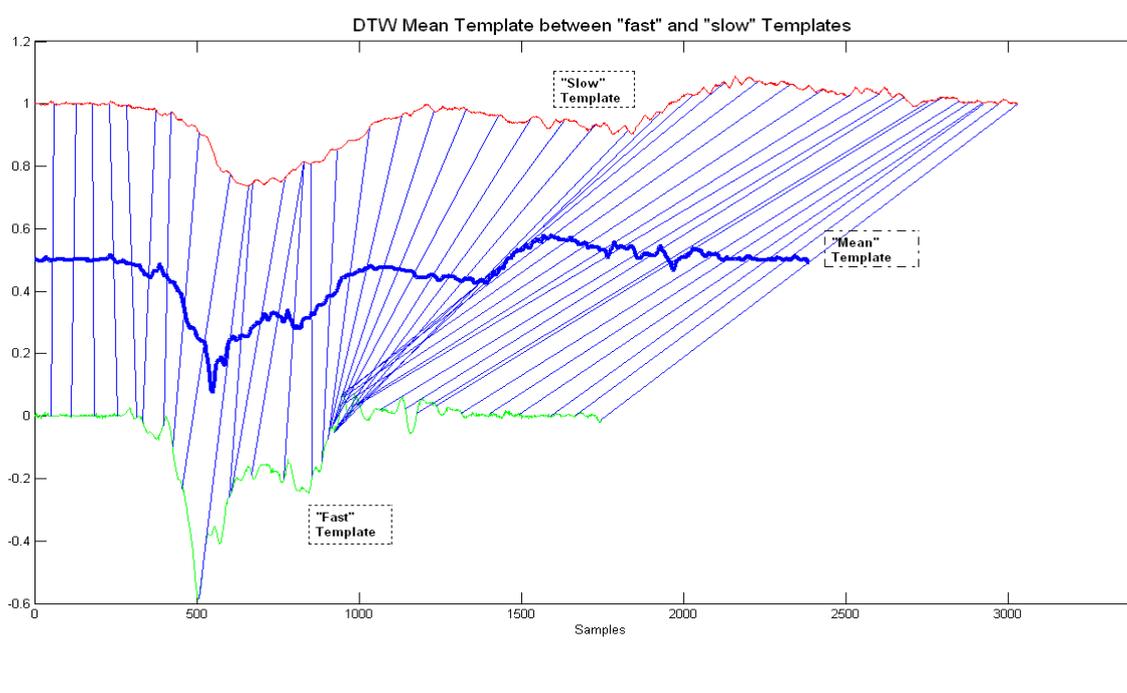
In questo modo il numero dei *template* è stato dimezzato ( 25 *template*/soggetto). Un ultimo passaggio di questa analisi, volto ad massimizzare la capacità di generalizzazione, si è ottenuto attraverso ispezione visiva delle forme d'onda dei segnali accelerometrici di differenti soggetti ma riferiti alle stesse prove.

Si è constatata una notevole similarità nella forma dell'andamento temporale anche in soggetti diversi. Da qui l'idea di provare ad usare un unico *template* caratteristico del

gesto e del canale. Il numero dei template stimati diventa allora 25 in totale ( 5 prove x 5 canali) ed è del tutto indipendente dal soggetto.

Questo template è stato scelto con il criterio della minima distanza, come illustrato precedentemente. Con questi segnali di riferimento il tentativo di riconoscere il gesto motorio ha dato i risultati presentati in tabella 2, divisi per prove, e ottenuti mettendo a confronto le tre tipologie di template utilizzate.

In tabella 9 i risultati del riconoscimento per gesto, distinti per tipologia di Template utilizzato, dal più legato al gesto del soggetto al più generale



**Figura 38**

<b>TASK</b>	<b>Template fast/slow</b>	<b>Mean Template</b>	<b>General Template</b>
<b>RD</b>	98	96	80
<b>RJ</b>	100	94	88
<b>RP</b>	98	90	86
<b>SUP</b>	95	88	88
<b>TK</b>	94	94	89

**Tabella 9: Confronto percentuali di riconoscimento**

I risultati mostrano valori molto soddisfacenti delle percentuali di riconoscimento anche con il *General Template*, che aprono possibilità di studio e analisi del tutto indipendenti dal soggetto e dunque su prodotti e software privi della fase di calibrazione.

Nell'ambito di queste applicazioni, relative al riconoscimento del gesto tramite gli algoritmi suddetti, sono in fase di realizzazione acquisizioni di dati presso il dipartimento di scienze neurologiche dell'Università "Sapienza". Tramite due accelerometri posti sull'arto superiore compromesso, di pazienti post-ictus, vengono registrati i dati durante l'esecuzione di esercizi presi dalla scala Fugl-Meyer. Si tratta di una scala specifica per la valutazione del recupero post-stroke nell'emiparetico e nell'emiplegico. È una scala con punteggio massimo di 225 punti divisa in cinque aree: funzione motoria, funzione sensoriale, equilibrio, range of motion articolare, dolore articolare. Nel nostro caso i pazienti effettuano soltanto la parte relativa alla funzione motoria.

Alla classificazione dovrebbe seguire una fase di valutazione della bontà di esecuzione del gesto, tramite l'estrazione di parametri il più possibile correlati al punteggio espresso dalla Fugl-Meyer.

### **6.1.1.1 I diversi metodi per la fase di calibrazione**

Nell'analisi riportata sopra, il template, e cioè la forma d'onda caratteristica per ogni soggetto, attività e canale, viene ricavato dal 30% dei segnali acquisiti mediante normalizzazione e media. Per superare le insite difficoltà dell'uso della media e per la necessità di mantenere il più possibile evidenti le caratteristiche del segnale (picchi e curvature) si è studiato un metodo alternativo per ricavare i segnali di riferimento  $Y(k)$ .

E' stata prevista una fase di calibrazione ulteriore in cui al soggetto viene chiesto di effettuare, una per volta, una delle tre attività da rilevare, per un periodo di tempo di circa 30 secondi. Il segnale acquisito viene così elaborato, suddiviso in epoche

caratteristiche (tramite algoritmi di rilevazione con integrazione e soglia) e ogni epoca (passo o salita/discesa di un gradino) viene confrontata con tutte le altre tramite l'algoritmo del DTW.

L'epoca che ha la distanza minore da tutte le altre viene quindi presa come segnale caratteristico per quell'attività, per quel soggetto e per quel canale (Template – Figura 39).

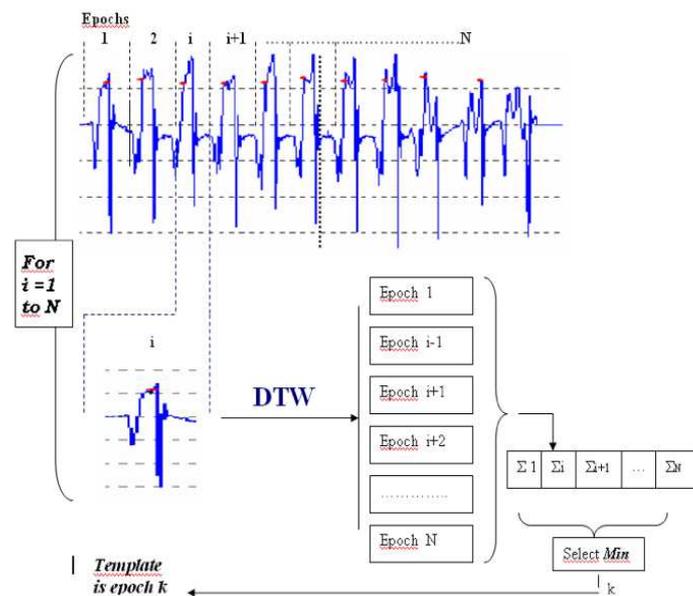


Figura 39- Diagramma di flusso di stima del Template

Così facendo il segnale caratteristico è effettivamente uno dei segnali direttamente derivante dall'attività del soggetto, e risulta in qualche modo "tipico". Questa fase di calibrazione è stata resa più veloce da una opportuna interfaccia grafica realizzata con Matlab GUI versione 7.0 (Figura 40).

### 6.1.2 Il DTW e il DDTW per il riconoscimento di attività motorie quotidiane

L'algoritmo DTW è stato scelto, tra le diverse tecniche di Template Matching, poiché permette di poter misurare la distanza tra segnali relativi all'esecuzione, ad

es., di una medesima attività motoria, ma con diverse velocità e/o con caratteristiche differenti. E' questo il caso del cammino etc. in cui ha interesse discriminare/classificare le attività svolte da soggetti giovani o anziani, o da soggetti sani o con patologie, che eseguono stessi movimenti ma con modalità differenti.

Tra le attività motorie quotidiane da riconoscere e studiare è stato scelto un sottoinsieme significativo per lo studio complessivo della qualità della vita come suggerito dalle più usate scale di valutazione funzionale, e quindi il cammino, la salita e la discesa delle scale. In seguito l'insieme delle attività da esaminare verrà esteso. Il segnale in ingresso  $X(k)$  è il segnale acquisito tramite accelerometri piezoresistivi biassiali ADXL202 posti sulla gamba. Da questi segnali sono stati ricavati i Template di riferimento  $Y(k)$  per ogni canale (asse dell'accelerometro) e per ogni tipo di attività, tramite il primo 30% dei campioni acquisiti, mediante normalizzazione e media. Il resto del segnale è stato usato nella parte di test dell'algoritmo. I test sono stati effettuati su segnali acquisiti su 5 soggetti. Per ognuno sono stati ricavati i 6 template, uno per ogni attività e per ogni canale di acquisizione (piano radiale e longitudinale) e i test sono stati effettuati confrontando il segnale in ingresso con ognuno dei 3 template relativi alle tre diverse attività per ogni canale. L'attività riconosciuta viene individuata come quella del template che ha fornito, in uscita all'algoritmo, la distanza minore con il segnale in ingresso. I test sono stati effettuati usando tutti e due gli algoritmi per valutarne la differente efficacia e le possibili modifiche future. In questa applicazione sono state messe a confronto le prestazioni del DTW con quelle del DDTW

Le percentuali di riconoscimento usando l'algoritmo del DDTW sono state più alte rispetto a quelle ottenute tramite il DTW ( Tabella 10 e 11 ).

Segnale relativo al piano radiale		
Motor Activity	DDTW	DTW
<i>Walk</i>	86%	84%
<i>Stair Up</i>	93%	93%
<i>Stair Down</i>	90%	78%

**Tabella10 - % riconoscimento relative al piano radiale**

<b>Segnale relativo al piano longitudinale</b>		
<b>Motor Activity</b>	<b>DDTW</b>	<b>DTW</b>
<i>Walk</i>	100%	82%
<i>Stair Up</i>	100%	91%
<i>Stair Down</i>	100%	81%

**Tabella 11- % riconoscimento relative al piano longitudinale**

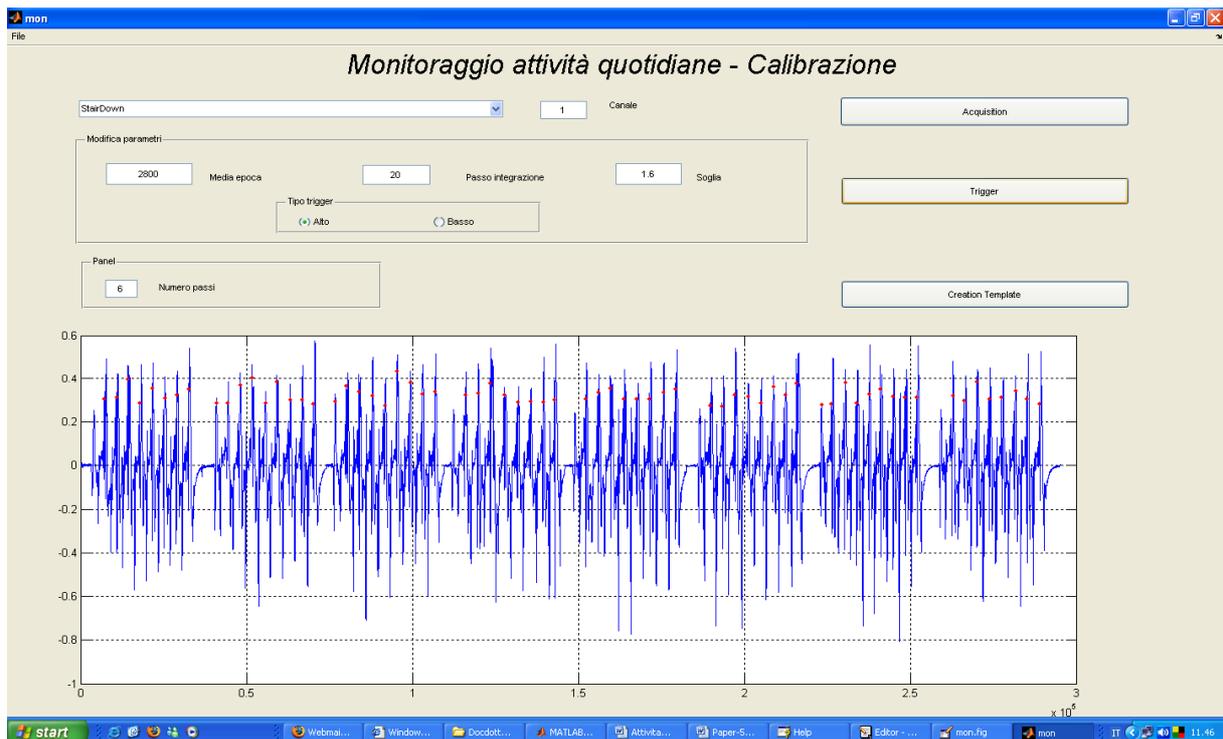
## **6.2 La classificazione gerarchica : applicazione alle ADL**

Una seconda fase del lavoro è stata orientata a cercare un metodo per classificare le attività del soggetto che fosse il più versatile possibile, sia per rendere più veloce la classificazione sia per ottimizzarne le risorse in uso.

Analizzando i risultati della prima fase del lavoro, si è visto come il canale verticale (che per semplicità chiamerò canale1) ha dato migliori risultati in termini di classificazione. Si è pensato allora di sfruttare i due canali in maniera indicata “gerarchica” nel senso di stabilire una gerarchia di intervento/utilizzazione dei dati dai sensori. In tal modo, la classificazione è stata affidata prima al solo canale1 e, qualora i risultati di questa prima fase non fossero soddisfacenti, si aggiungono all’algoritmo le informazioni derivanti dal secondo canale, che vanno ad integrare le prime.

Le motivazioni di questo approccio sono ovvie, nel senso di cercare di scegliere il set minimo di sensori che possa dare la migliore discriminazione delle varie attività compatibilmente con i requisiti di semplicità ed usabilità del dispositivo, introducendo elementi di complicazione solo se necessario ed a ragion veduta.

Il primo canale viene acquisito e segmentato in epoche ed ognuna viene poi confrontata tramite il DTW con tutti e tre i Template (uno per ogni attività), ricavati nella fase di calibrazione, per quel soggetto e per quel canale.



**Figura 40 - Interfaccia per la calibrazione**

Le distanze calcolate vengono fornite ad un decisore con soglia che analizza i due valori più bassi di distanze e decide se è il caso o meno di chiamare in causa il secondo canale.

La soglia resta la criticità di questo lavoro dato, in quanto viene ricavata in modo empirico dall'osservazione dei dati. Pertanto, l'algoritmo va ulteriormente approfondito e caratterizzato.

Una volta che viene richiesto l'uso del canale2, l'algoritmo analizza anche l'epoca corrispondente per il secondo canale e calcola con il DTW le distanze con i 3 Template disponibili per questo secondo canale. Le distanze calcolate vengono sommate con quelle ricavate con il confronto del canale1 e l'algoritmo classifica l'attività in base alla distanza cumulativa minima.

Ho cercato di riassumere brevemente il procedimento descritto con il grafico di Figura 41.

Per testare l'algoritmo sono stati creati dei percorsi della durata media di un minuto, che mettono insieme segnali provenienti da attività diverse:

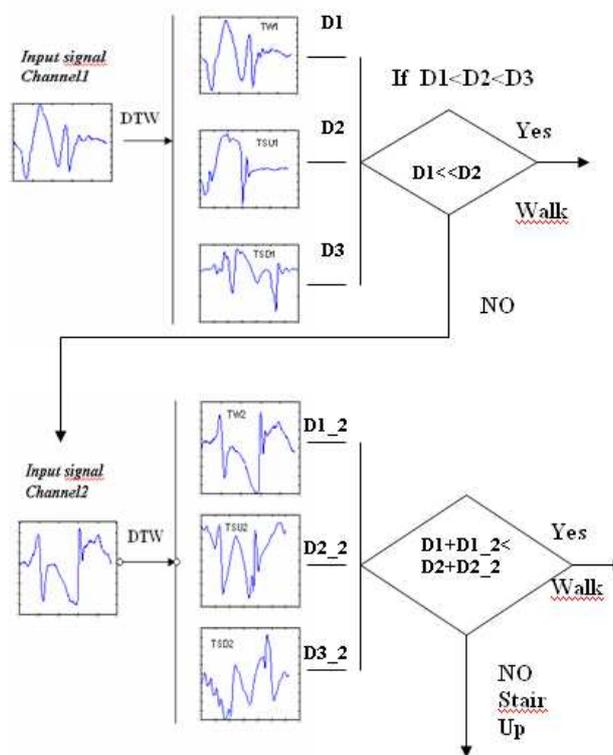
*Percorso 1:* 12 passi, 9 salite di gradini, 12 passi e 9 discesa di gradini;

*Percorso 2:* 9 salite di gradini, 12 passi, 9 salite di gradini, 2 passi, 9 discese di gradini;

*Percorso 3:* 9 discese di gradini, 12 passi, 9 discese di gradini, 2 passi, 9 salite di gradini;

*Percorso 4:* 12 passi, 9 discese di gradini, 12 passi e 9 salite di gradini.

Le percentuali di riconoscimento sono state soddisfacenti e sono riassunte nella tabella 3.



**Figura 41 - Diagramma di flusso del classificatore**

Path	Classification performance	Dual axes use
<b>Path 1</b>	98%	26%
<b>Path 2</b>	98%	28%
<b>Path 3</b>	90%	30%
<b>Path 4</b>	97%	26%

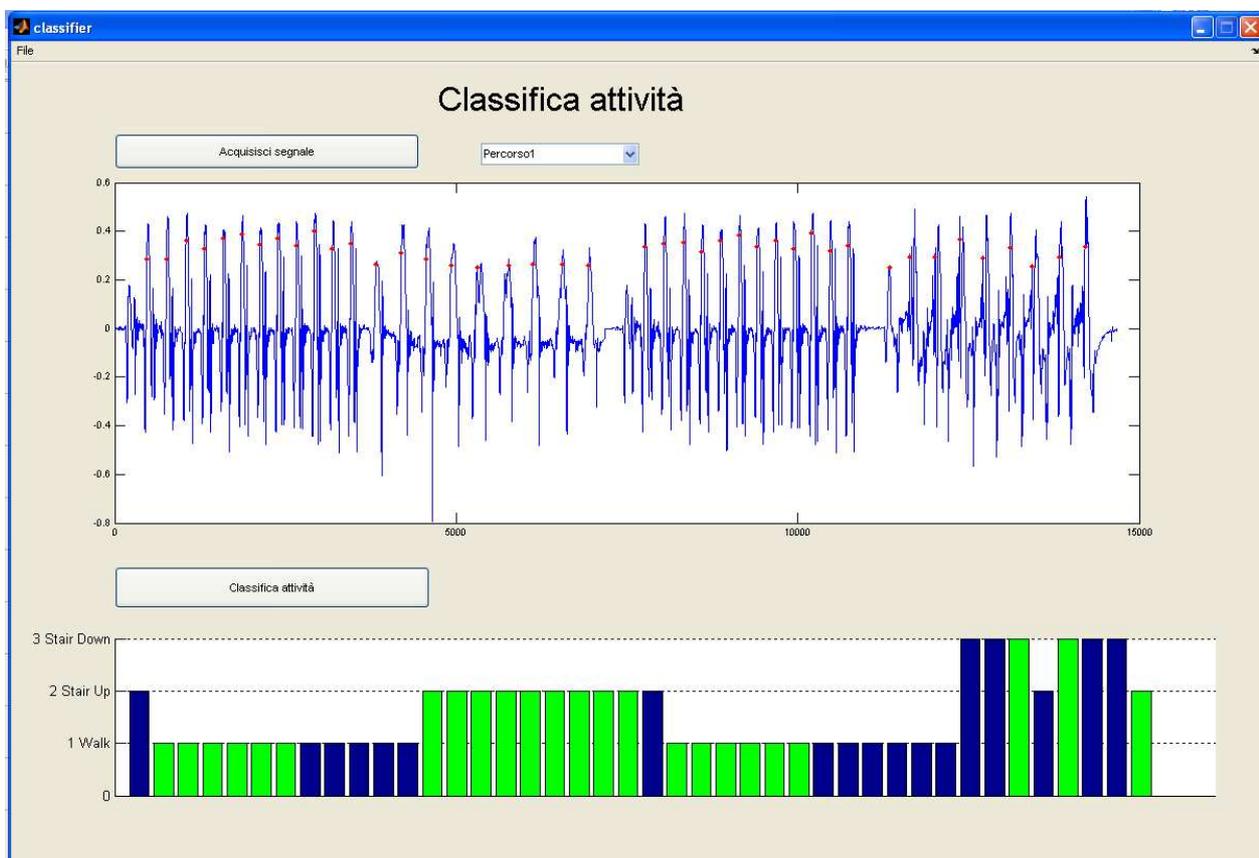
**Tabella 12-Percentuali di riconoscimento relative ai diversi percorsi**

Le prestazioni degli algoritmi sono state confrontate in termini di percentuali di riconoscimento. L'algoritmo gerarchico permette un notevole risparmio in termini di tempi di calcolo e di uso delle risorse. Queste caratteristiche risultano fondamentali nell'ottica di un uso dell'algoritmo per applicazioni real-time.

Anche nella fase di classificazione, per rendere più veloce e manifesta la fase di test dell'algoritmo, è stata realizzata una interfaccia grafica, con Matlab GUI 7.0, in cui selezionando il percorso, il risultato della classificazione viene visualizzato in formato grafico con un diagramma a barre (Figura 42).

Le barre di colore blu indicano le epoche in cui si è fatto uso del secondo canale per effettuare la classificazione.

E' evidente come l'intervento del secondo set di sensori sia particolarmente rilevante in corrispondenza alle transizioni tra diverse attività, che effettivamente rappresentano un punto critico di qualsiasi algoritmo di classificazione.



**Figura 42 – Interfaccia per la classificazione**

### 6.3 La classificazione cooperativa: applicazione su attività relative agli arti inferiori

Per l'applicazione dei concetti sulla classificazione bayesiana sono state scelte delle attività motorie quotidiane in un insieme ritenuto significativo per lo studio complessivo della qualità della vita come suggerito dalle più usate scale di valutazione funzionale, e quindi: il cammino, la salita e la discesa delle scale, che di seguito indicheremo con W (cammino), SU (salita) e SD (discesa). In seguito l'insieme delle attività da esaminare verrà esteso.

L'idea di base di questo lavoro è stata quella di mettere a confronto un'analisi di tipo bayesiano basata su *features* estratte nel dominio della frequenza, con tecniche di template matching, che usano segnali caratteristici nel dominio del tempo.

In particolare, nel caso sperimentale studiato, i segnali in ingresso vengono acquisiti tramite accelerometri piezoresistivi biassiali ADXL202 posti sulla gamba e le prove sono effettuate su 5 soggetti sani di età compresa tra i 25 e i 35 anni. Il 30% dei segnali acquisiti è stato usato per la fase di calibrazione e la parte restante per il test dell'algoritmo.

Dopo aver rivelato le singole attività, la fase di calibrazione prevede l'estrazione del *template* o segnale caratteristico, per ogni tipologia di attività, nel dominio del tempo. Le *features* estratte nel dominio della frequenza sono invece, per ogni attività, la coppia di valori data dal valore massimo e il valore minimo della frequenza media istantanea. Con queste coppie di valori estratti dai dati a disposizione per la calibrazione, sono state stimate media e varianza di una distribuzione gaussiana bivariata. Le tre attività hanno dimostrato di avere distribuzioni gaussiane non sovrapposte e dunque adeguate per un approccio probabilistico del problema (Figura. 43).

Per ogni attività è stata stimata dunque una densità di probabilità condizionata per il cammino ( $p(x | W)$ ), una per l'attività di salita delle scale ( $p(x | SU)$ ) e una per l'attività di discesa ( $p(x | SD)$ ):

$$p(x | W) = \frac{1}{2\pi\sigma_{x1W}\sigma_{x2W}} \exp \left[ -\frac{1}{2} \left( \frac{(x_1 - \mu_{x1W})^2}{\sigma_{x1W}} + \frac{(x_2 - \mu_{x2W})^2}{\sigma_{x2W}} \right) \right]$$

$$p(x | SU) = \frac{1}{2\pi\sigma_{x1SU}\sigma_{x2SU}} \exp \left[ -\frac{1}{2} \left( \frac{(x_1 - \mu_{x1SU})^2}{\sigma_{x1SU}} + \frac{(x_2 - \mu_{x2SU})^2}{\sigma_{x2SU}} \right) \right]$$

$$p(x | SD) = \frac{1}{2\pi\sigma_{x1SD}\sigma_{x2SD}} \exp \left[ -\frac{1}{2} \left( \frac{(x_1 - \mu_{x1SD})^2}{\sigma_{x1SD}} + \frac{(x_2 - \mu_{x2SD})^2}{\sigma_{x2SD}} \right) \right]$$

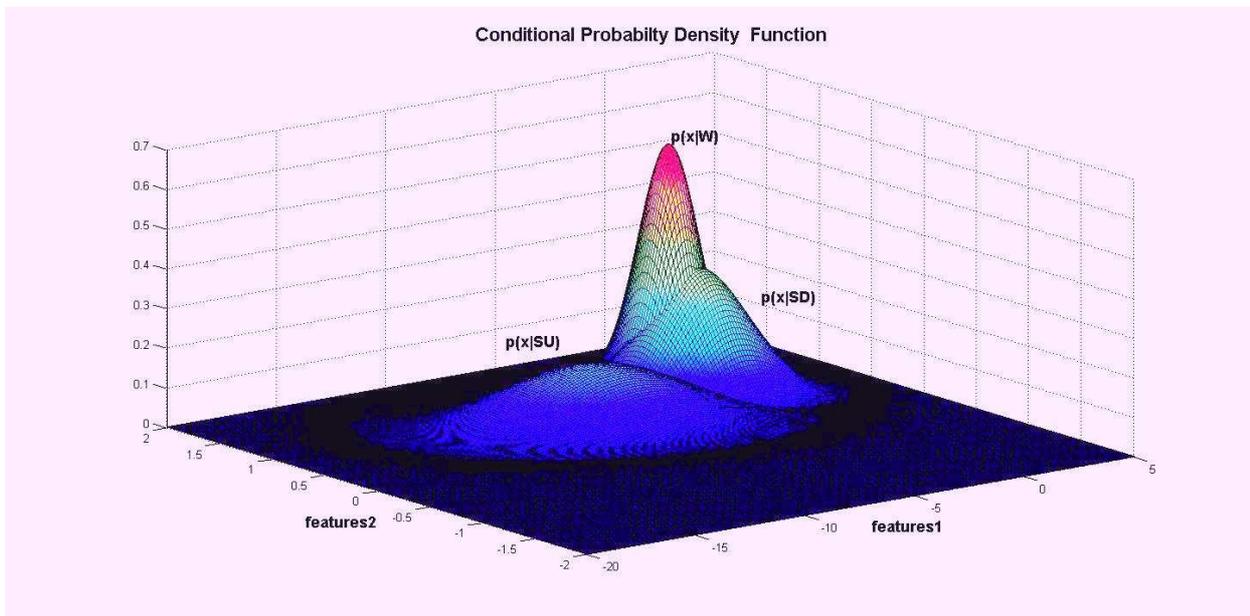


Figura 43 – Densità di probabilità condizionate per le tre attività

Si è supposto che tutte e tre le attività avessero la stessa probabilità a priori ( $P(W) = P(SU) = P(SD) = 1/3$ ). Da queste informazioni, tramite il teorema di Bayes è possibile stimare la probabilità a posteriori. Ma per classificare l'attività in questo caso è sufficiente l'informazione contenuta nella densità di probabilità a priori.

All'informazione di classificazione ottenuta nel dominio della frequenza si è pensato di aggiungere le informazioni ottenute con un altro criterio di classificazione ottenuto tramite il Template matching.

Nella fase di calibrazione si è stimato un segnale caratteristico nel dominio del tempo, che rappresenta il *template* per ogni specifica attività, da usare con l'algoritmo del DTW ( Dynamic Time Warping) per stimare misure di distanza.

L'algoritmo del DTW è un algoritmo che tramite deformazione non lineare di uno degli assi del segnale consente di calcolare un percorso minimo tra il segnale in ingresso e il segnale di riferimento e consente di calcolare una misura di distanza tra i due segnali. Il *template*, per ogni attività, è stato costruito come quell'attività elementare (passo, salita/discesa del gradino) che ha la distanza minore, calcolata con il DTW, da tutte le altre. La regola di classificazione per le tecniche di questo tipo vuole che si scelga come classe quella il cui *template* rappresentativo produce misure di distanza minori.

Il criterio generale proposto in questo metodo di classificazione, applicato ai segnali di test, è stato quello di scegliere come classe, e dunque attività, più probabile quella che rende massima questa relazione:

$$\frac{1}{DTW(x, T_i)} p(x|W_i) > \frac{1}{DTW(x, T_j)} p(x|W_j), \forall i \neq j, i := 1to3$$

in cui è massimo il prodotto tra la probabilità di appartenere ad una determinata classe (Numeratore) e l'inverso della distanza (DTW) dal segnale di riferimento di quella classe (Denominatore) . L'idea proposta di questa nuova regola di

classificazione nasce dall'esigenza di voler rafforzare la regola di classificazione bayesiana classica, tenendo conto anche delle caratteristiche che il segnale mantiene nel dominio del tempo. Infatti la distanza calcolata con l'algoritmo del Dynamic Time Warping consente di calcolare un parametro di similarità tra serie temporali che tiene conto anche delle diverse velocità con cui viene compiuto il gesto.

I risultati ottenuti sono mostrati in tabella 5 dove sono messi a confronto con i risultati di una semplice classificazione bayesiana.

<b>ATTIVITA'</b>	<b>Bayes + DTW</b>	<b>Bayes</b>
<i>Walk</i>	94%	80%
<i>Stair Up</i>	92%	79%
<i>Stair Down</i>	93%	75%

**Tabella 13: Percentuali di riconoscimento delle attività di un metodo composto Bayes + DTW con un solo metodo di Bayes**

Dai risultati emerge come il classificatore proposto produca risultati migliori rispetto ad un semplice classificatore bayesiano, a riprova del fatto di quanto gli andamenti nel tempo del segnale accelerometrico siano caratteristici della effettiva attività svolta.

## **6.4 La classificazione cooperativa: riconoscimento di attività su giovani e anziani tramite bayesiano a n dimensioni**

Per migliorare le performance del classificatore Bayesiano si è pensato di agire sulla scelta delle features, cercando di rendere più consistente la probabilità di rilevare l'attività.

In questo lavoro sono stati reclutati 5 soggetti, con età compresa tra 25 e 35 e si è fatto loro indossare una cintura con inserito un palmare hp x2700 e la box acquisition, descritta sopra.

Alla cintura era collegato un accelerometro biassiale ADXL202 posizionato sullo stinco della gamba destra. I soggetti hanno percorso un percorso misto della durata di circa 20 minuti, fatto di salite, discese, salite di gradini, discese di gradini e a differenti velocità (figura 25)



**Figura 44 – Set up sperimentale**

Il 30% dei segnali è stato usato per la fase di training, il resto per la fase di test del classificatore.

Nella fase di training sono state estratte 16 features (max, min, posizione relativa del max, posizione relativa del min, distanza tra il max e il min, numeri di zero crossing, distanza tra i minimi relativi, distanza tra i massimi relativi, freq max, freq min, mass e min del log dell'andamento frequenza media [75] massimo della derivata, min della derivata, massimo dell'integrale, min dell'integrale) ma il classificatore bayesiano ha lavorato nel dominio bidimensionale. Come spiegato nel paragrafo sulla dimensionalità dello spazio delle features, lo spazio, tramite le mappe di Sammon è stato mappato in un dominio bidimensionale e una rete neurale di tipo feed-forward è stata usata per la stima della funzione di mapping.

La funzione di mapping è stata usata per proiettare le 16 features calcolate per ogni features in ingresso, nella coppia di valori in ingresso al classificatore bayesiano.

Anche in questo caso la densità di probabilità condizionata è stata supposta una gaussiana bidimensionale e nella fase di training, per ogni attività, sono state stimate media e matrice di covarianza.

Ogni attività è stata riconosciuta, come media sui 5 soggetti con valori superiori al 90% (figura 45)

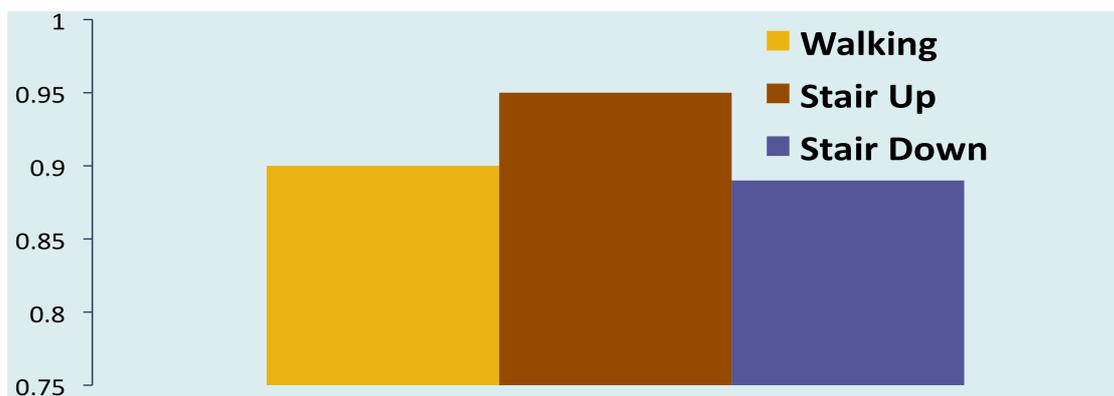


Figura 45

Si può concludere che, su 1467 attività correttamente rilevate, c'è stata una percentuale media di riconoscimento del 91%, con la maggior parte degli errori collocati su una misclassificazione tra passi su un terreno in pendenza, in discesa, e discese di gradini.

In queste misure si è supposta la probabilità a priori diversa per attività e proporzionale alla frequenza dell'attività compiuta. Nel caso di probabilità a priori fissa ( $1/3$ ,  $1/3$ ,  $1/3$ ) la media della percentuale di riconoscimento delle attività scende all'83%.

### 6.4.1 Confronto con le SVM

La classificazione tramite Support Vector Machines è stata applicata su un insieme di dati accelerometrici ricavati da 5 soggetti giovani (età compresa tra 25 e 35 anni). Le attività degli arti inferiori (camminare lentamente, velocemente, a velocità normale, salire e scendere le scale) sono state registrate da un singolo accelerometro biassiale posto sulla gamba, mentre i soggetti svolgevano un percorso misto della durata di circa 20 minuti. I dati sono stati registrati tramite una scheda di acquisizione, collegata ad un palmare Hp x2700, inseriti in una cintura indossata dall'utente. Il segnale acquisito dai due canali è stato campionato a 100Hz e filtrato tra 0.2 e 20Hz. Inoltre ogni attività è stata segmentata tramite algoritmo a integrazione e soglia con first guess threshold  $\sim 0.35$  m/s, adattata on-line date le caratteristiche dell'attività; bounce rejection con first guess 600 ms, poi adattata a 50% durata attività segmentate ( Figura 46) .

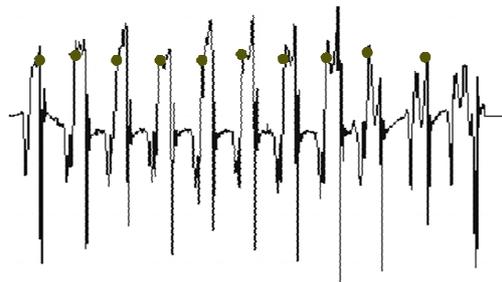
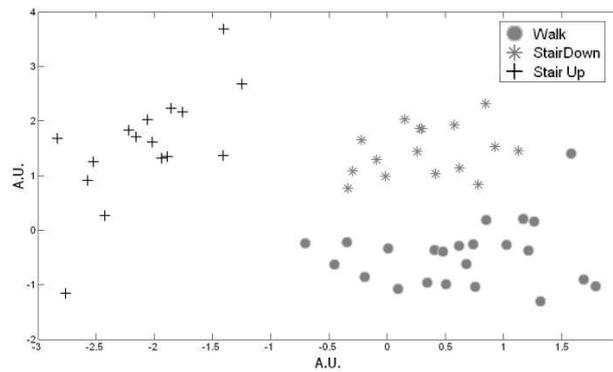


Figura 46

Per ogni attività rilevata sono state selezionate 16 features caratteristiche dell'attività, sia nel tempo che nella frequenza. Tramite le mappe di Sammon, applicate al training set composto dal 15% delle attività selezionate, esse sono state proiettate in un dominio 2D ( figura 47 ) . Questo insieme di training è stato usato per addestrare una rete neurale (feed-forward architecture, one hidden layer, 40 neurons) a 16 ingressi e 2 uscite, adatta a stimare la funzione di mapping.



**Figura 47**

La rete neurale ha stimato le features dell'insieme di training con una correlazione del 99%. Con i dati a disposizione si sono messi a confronto due diversi classificatori:

- Nell'approccio bayesiano la fase di training ha consentito la stima delle densità di probabilità condizionate a priori, una per attività. Si sono supposte gaussiane bidimensionali e con approccio parametrico sono state stimate medie e matrici di covarianza.

Il classificatore, sui dati di test, ha discriminato le attività applicando in teorema di Bayes e calcolando la massima probabilità a posteriori ( MAP )

- Nello schema con SVM (Mitchell-Demyanov-Malozemov optimization algorithm, con regularization constant value of 5) la rete neurale è stata considerata come la funzione di Kernel di un insieme di dati non linearmente separabili in un n dominio.

La particolarità di questo lavoro sta nel fatto che i dati di training sono cumulati di tutti e 5 i soggetti e dunque il classificatore opera su dati generali e indipendenti dai soggetti. I valori di performance sono riassunti in tabella 14 e 15 sia per i dati di training che per quelli di test.

<b>Training set</b>	<b>SVM</b>	<b>Bayes</b>
Walking	90.6%	91.9%
Stair Climbing	91.2%	90.9%
Stair Descending	90.3%	90.3%

**Tabella 14 - % di riconoscimento delle attività per i due classificatori analizzati applicati al training set**

<b>Testing</b>	<b>SVM</b>	<b>Bayes</b>
Walking	77.1%	84.2%
Stair Climbing	78.0%	87.1%
Stair Descending	74.2%	81.3%

**Tabella 15 - % di riconoscimento delle attività per i due classificatori analizzati applicati al test set**

I risultati sono incoraggianti considerando il fatto che in questo caso non si necessita di una fase di training perché la fase di training generale ha la presunzione di adattarsi ad ogni tipo di soggetto. Inoltre i risultati mostrano un comportamento migliore del classificatore bayesiano dell'ordine del 5%, imputabile alla possibilità dello stesso di adattare la probabilità a priori alle effettive attività svolte.

## **6.5 La classificazione adattiva: riconoscimento di attività su giovani e anziani**

L'obiettivo del lavoro riportato nel presente paragrafo è stato quello di riconoscere alcuni movimenti svolti da soggetti giovani e anziani, tramite l'uso di sensoristica indossabile e poco invasiva. La catena di acquisizione utilizzata è semplice da utilizzare, non invasiva ed è stata pensata in modo da rendere le attività le più naturali

possibili. Un sensore accelerometrico biassiale posizionato sullo stinco, tenuto fermo tramite una fascia elastica, è collegato ad una scheda di acquisizione della NI, collegata a sua volta ad un pocket pc della Hp. Il tutto è stato inserito in una cintura indossata dall'utente durante lo svolgimento delle attività. I movimenti selezionati, appartenenti alle cosiddette attività quotidiane, sono il cammino (W), svolto in maniera lenta e veloce, e la salita (SU) e la discesa delle scale (SD).

Nel nostro lavoro si è cercato di fare in modo che la stima dell'attività motoria quotidiana dipendesse in prima analisi da alcune features caratteristiche del segnale accelerometrico, posto sullo stinco, in tempo e in frequenza, e in seconda analisi dipendesse dalla storia delle attività compiute. Ovvero che la classificazione proceda di pari passo con l'attività che si sta compiendo. A questo scopo è stato utilizzato un classificatore bayesiano a 16 features inserito in una struttura del tipo filtro di Kalman con matrice di evoluzione dello stato stimata come se il sistema fosse una catena di Markov.

Lo studio è stato condotto su 24 soggetti, 12 giovani che chiameremo gruppo A e 12 anziani, che chiameremo gruppo B. Ai soggetti anziani è stato fatto firmare un modulo di consenso informato, in cui i soggetti venivano informati sull'intero protocollo e sugli eventuali rischi, ed è stato somministrato loro un questionario per valutare lo stato di salute generale e il livello funzionale, tramite scala FIM per il livello fisico. Tutti i soggetti del gruppo B avevano un livello di FIM  $> 60$  (13- 91). Nell'ambito della sperimentazione svolta, tutti i soggetti erano consapevoli che lo studio effettuato non aveva alcun fine diagnostico in senso stretto, ma permetteva un'analisi di tipo quantitativo di alcuni parametri relativi allo svolgimento di attività motorie. Il percorso comprendeva anche tratti a pendenza diversa. Il percorso è stato compiuto, per i soggetti del gruppo A, anche a velocità diverse, mentre per i soggetti del gruppo B, per evitare l'affaticamento dei soggetti si è chiesto loro di svolgerlo nella velocità che avessero ritenuto loro più opportuna. Durante lo svolgimento del percorso i soggetti sono stati affiancati da personale del laboratorio per la redazione di un diario delle prove.

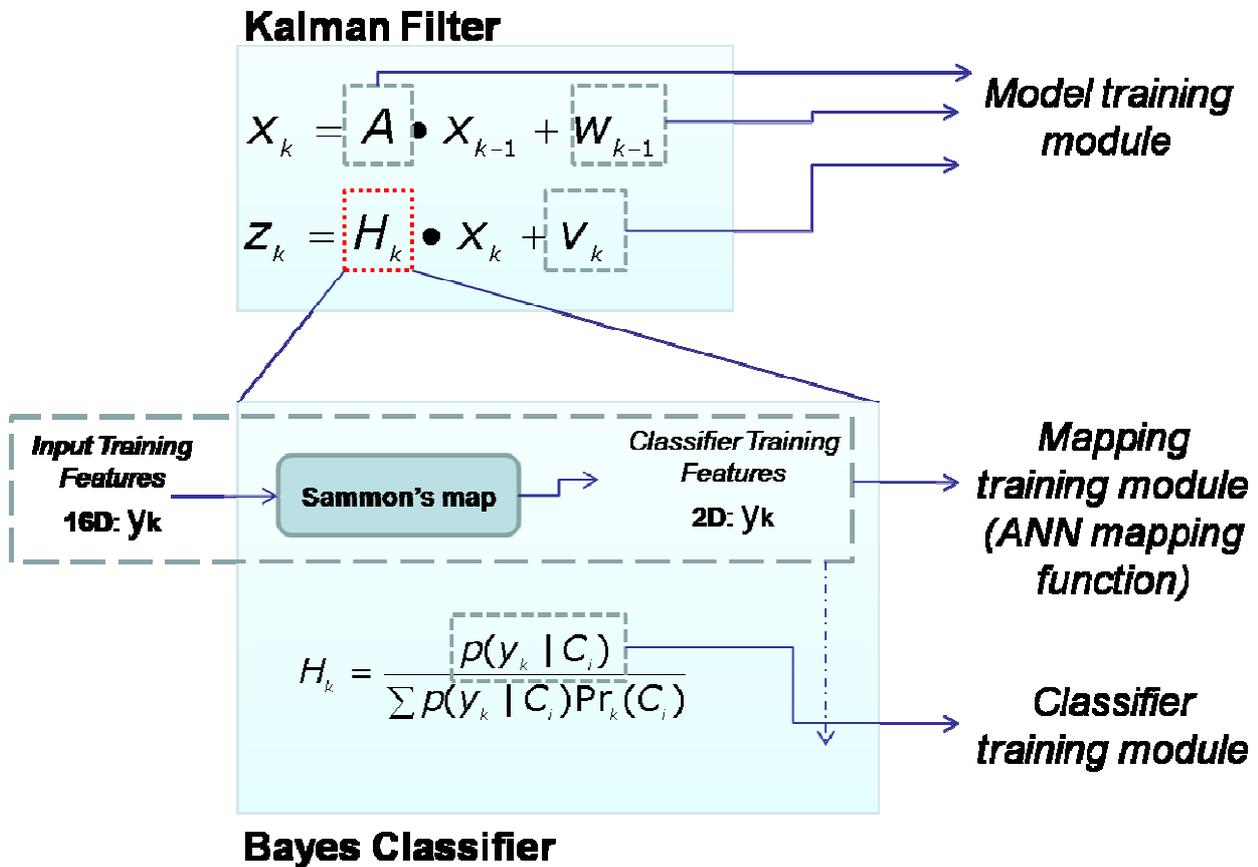


Figura 48 – Schema generale classificatore

Circa il 15% dei segnali acquisiti sono stati usati per la fase di training del classificatore, mentre il totale di tutte le attività dei soggetti relativi ai due gruppi è stata usata per la stima delle matrici di transizione degli stati, in quanto indicativa della probabilità delle attività complessive svolte dai soggetti durante le prove. Per alcuni soggetti anziani con indice funzionale <80 il percorso è stato più breve per evitare l'affaticamento del soggetto.

Il metodo usato per riconoscere le attività svolte, dopo una fase di training, in cui è stata stimata la matrice di transizione tra gli stati, prevede l'estrazione di 16 features per ogni canale e la riduzione della dimensione dello spazio delle features tramite le

mappe di Sammon e relativa ANN per la stima della funzione di mapping. Le features, nel nuovo dominio, vengono utilizzate in un classificatore bayesiano a due dimensioni con la particolarità di avere la probabilità a priori delle tre classi che varia durante lo svolgimento delle attività.

Questo sistema viene realizzato tramite l'utilizzo delle catene di Markov e del teorema di Bayes inserite in una struttura del tipo filtro di Kalman, in cui la variabile di stato, istante per istante, è il vettore delle probabilità a priori di ogni classe (schema generale figura 48).

Il classificatore è stato presentato in due versioni: uno che unisce le features estratte dai due canali per ricavarne uno spazio a 32 dimensioni (**Combined Mapping Approach**) ed un altro che lavora in parallelo su due spazi a 16 features (**Parallel Mapping Approach**) e integra i risultati sommando le probabilità sui due canali.

I dati sono stati analizzati a posteriori per ogni soggetto, anche se l'implementazione si presta anche per classificazioni in tempo reale, una volta stimata la funzione di mapping e densità di probabilità condizionate. Per ogni soggetto, terminato il percorso e scaricato il file .dat sul computer, viene elaborato tramite matlab 7.0 e fornisce in uscita un report con tutte le tipologie di attività compiute.

Ai soggetti anziani è stato anche fornito un report cartaceo con tutto il percorso compiuto, le calorie consumate e alcuni parametri statistici significativi relativi alla modalità di esecuzione del movimento. Nelle tabelle 16 e 17 di seguito sono elencate le diverse percentuali di riconoscimento relative alle diverse attività distinte tra il gruppo A e il gruppo B con il metodo 1 e il metodo 2.

Classifier		PMA			CMA		
Estimate activity		W	su	sd	w	su	sd
True activity	w	<b>0.96</b>	0.01	0.03	<b>0.95</b>	0.02	0.03
	su	0	<b>1</b>	0	0.01	<b>0.98</b>	0.01
	sd	0.18	0.05	<b>0.77</b>	0.18	0.7	<b>0.75</b>

**Tabella 16 - % of recognition for activities for A group**

Classifier		PMA			CMA		
Estimate activity		w	su	sd	w	su	sd
True activity	w	<b>0.96</b>	0.01	0.03	<b>0.95</b>	0.02	0.03
	su	0.19	<b>0.8</b>	0.01	0.01	<b>0.98</b>	0.01
	sd	0.18	0.05	<b>0.77</b>	0.18	0.7	<b>0.75</b>

Tabella 17 - % of recognition for activities for B group

Il maggior numero di errori sono stati rilevati nella fase di transizione tra gli stati e per i soggetti anziani la maggior parte di essi si sono concentrati nella seconda parte del segnale (Figura 49 e 50). Ciò è indicativo del fatto che i soggetti, essendo più affaticati verso la fine del percorso, hanno modificato i pattern della camminata rispetto alla fase di training

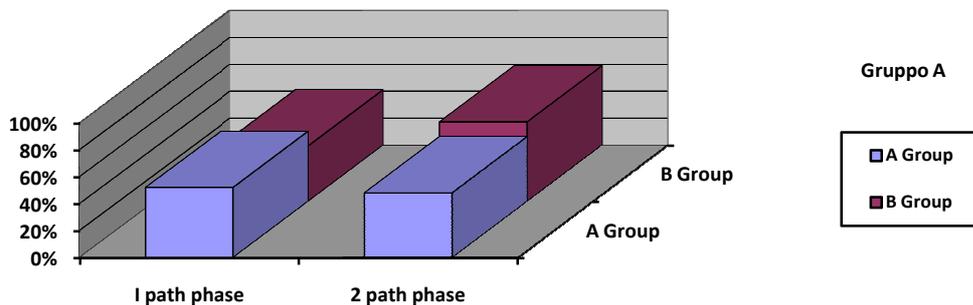


Figura 49– Errors distributions in the total path – PMA

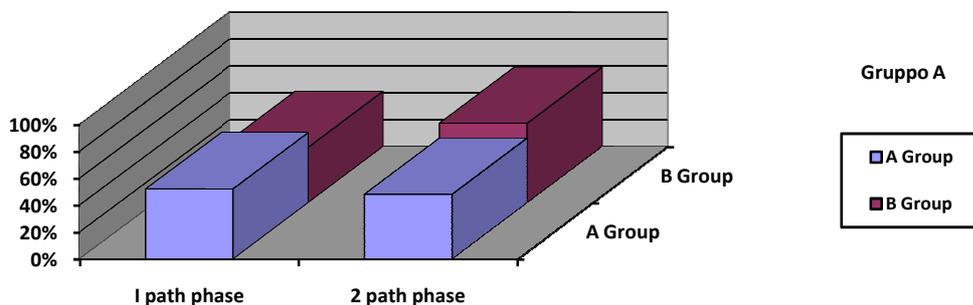


Figura 50 – Errors distributions in the total path – CMA

## 6.6 La classificazione precoce: riconoscimento di gesti dell'arto superiore

L'applicazione di seguito descritta è stata volta a testare l'algoritmo del DTW real time su dati registrati tramite il dispositivo di acquisizione della NI USB e il palmare hp2700, descritti nel paragrafo 4.1. I dati sono campionati ad una frequenza di 100Hz e filtrati tra 0.2 e 50Hz.

Il lavoro nasce da considerazioni preliminari che vedevano i gesti riconosciuti tramite il DTW già a partire dalle prime fasi di esecuzione del movimento (Figura 51).

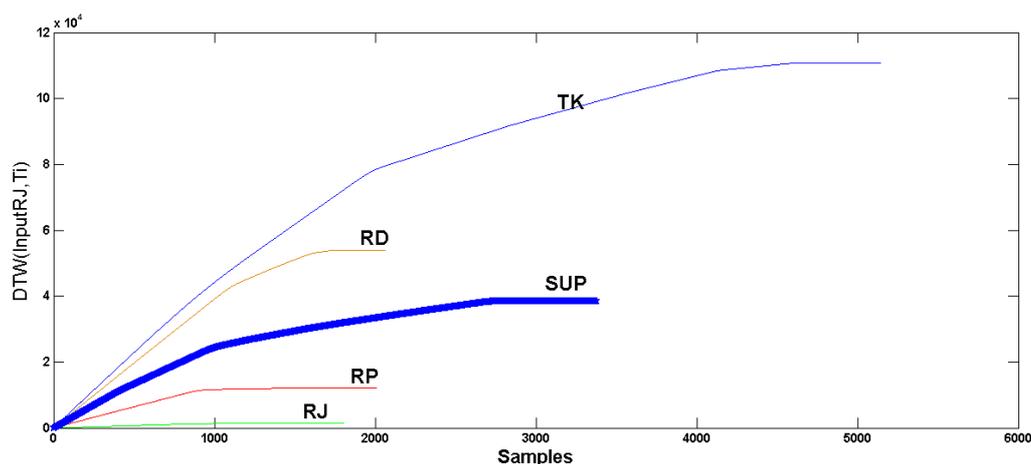


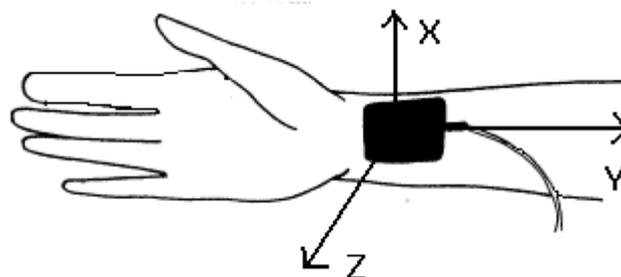
Figura 51 – Andamento della distanza in DTW tra un segnale di tipo RJ e tutti i Template

L'applicazione vera e propria relativa al riconoscimento precoce del gesto ha previsto l'applicazione dell'interfaccia Matlab con il dispositivo di acquisizione collegato a un accelerometro biassiale posti sul polso (figura 52).

I dati sono stati registrati su 10 soggetti giovani con età media 31.5 e tutti in buone condizioni di salute. Essi hanno effettuato una parte del protocollo completo previsto dalla Wolf Motor Function Test, una serie di esercizi previsti nella riabilitazione post stroke e che ricalca esercizi della vita quotidiana. In totale gli esercizi sono 15, i primi

sei sono semplici esercizi a tempo, mentre dal 7 al 15 sono esercizi di funzionalità che coinvolgono più segmenti corporei e ricalcano attività della vita quotidiana. Per questo motivo sono proprio questi 9 esercizi che vengono presi in considerazione nella nostra applicazione:

1. (ES7 della WMFT - **RD**): Raggiungere e recuperare un oggetto, del peso di una libbra, posto su un tavolo di fronte all'utente
2. (ES8 della WMFT - **RJ**): Il soggetto prende e porta alla bocca una lattina, nell'imitazione dell'atto di bere
3. (ES9 della WMFT - **RP**): Il soggetto cerca di sollevare una matita usando la mano nella configurazione a pinza
4. (ES11 della WMFT - **SP**): Il soggetto cerca di accatastare 3 pedine su una centrale
5. (ES12 della WMFT - **FC**): Il soggetto cerca di girare una carta usando la mano nella configurazione a pinza.
6. (ES13 della WMFT - **LD**): Il soggetto cerca di girare una chiave nella serratura da sinistra a destra.
7. (ES14 della WMFT - **FT**): Il soggetto prende un asciugamano sul tavolo, lo piega dal suo lato lungo e lo richiude con la stessa mano.
8. (ES15 della WMFT - **LB**): Il soggetto solleva un cesto e lo pone davanti al tavolo



**Figura 52 – Posizionamento dell'accelerometro triassiale sul posto**

Ogni esercizio è stato ripetuto 10 volte, 5 volte a velocità normale e 5 volte a velocità più sostenuta, per un totale di 240 (8 esercizi x 10 ripetizioni x 3 canali) serie di dati a disposizione per ogni soggetto. I dati così acquisiti, campionati a 100Hz, saranno utilizzati per la fase di training e per la creazione di un Template, per ogni gesto e per ogni canale, tramite l'algoritmo di creazione della median DTW, descritto precedentemente. Per testare l'algoritmo del RT\_DTW è stato ideato uno schema di classificazione che consenta di classificare i movimenti degli arti superiori il prima possibile, ovvero prima che il gesto termini. La fase di training è stata usata per ricavare i segnali di riferimento per tutti e 8 i movimenti e per ognuno dei tre canali dell'accelerometro, ma è servita anche per stimare la durata massima di esecuzione dei gesti.

Per ogni campione del segnale d'ingresso, la distanza parziale tra gli elementi della serie temporale in ingresso e tutti i segnali di riferimento è stimata tramite i vettori  $L$  e il valore  $L_{ni}$  (n-esimo *template* e i-esimo campione). Il vettore  $L$  è il vettore delle distanze cumulative parziali.

Il criterio di classificazione è stato pensato in questo modo: ad ogni passo (n-esimo) si seleziona il *template*, ovvero il movimento, che ha il valore minore di  $L_n$ . Quando questo valore di minimo si mantiene lo stesso per  $k$  campioni consecutivi, vengono memorizzati i  $k$  valori dei vettori  $L$  relativi al minimo e al minimo successivo.

Tra questi due andamenti di  $L$  viene calcolata la derivata per altri  $k$  campioni. Solamente se la derivata diverge in questo intervallo di  $k$  valori, rimanendo il minimo sempre lo stesso, il classificatore decide, altrimenti, se soltanto una delle due condizioni non viene rispettata, il classificatore libera i buffer e ricomincia a testare il minimo.

Lo schema è illustrato in figura 53.

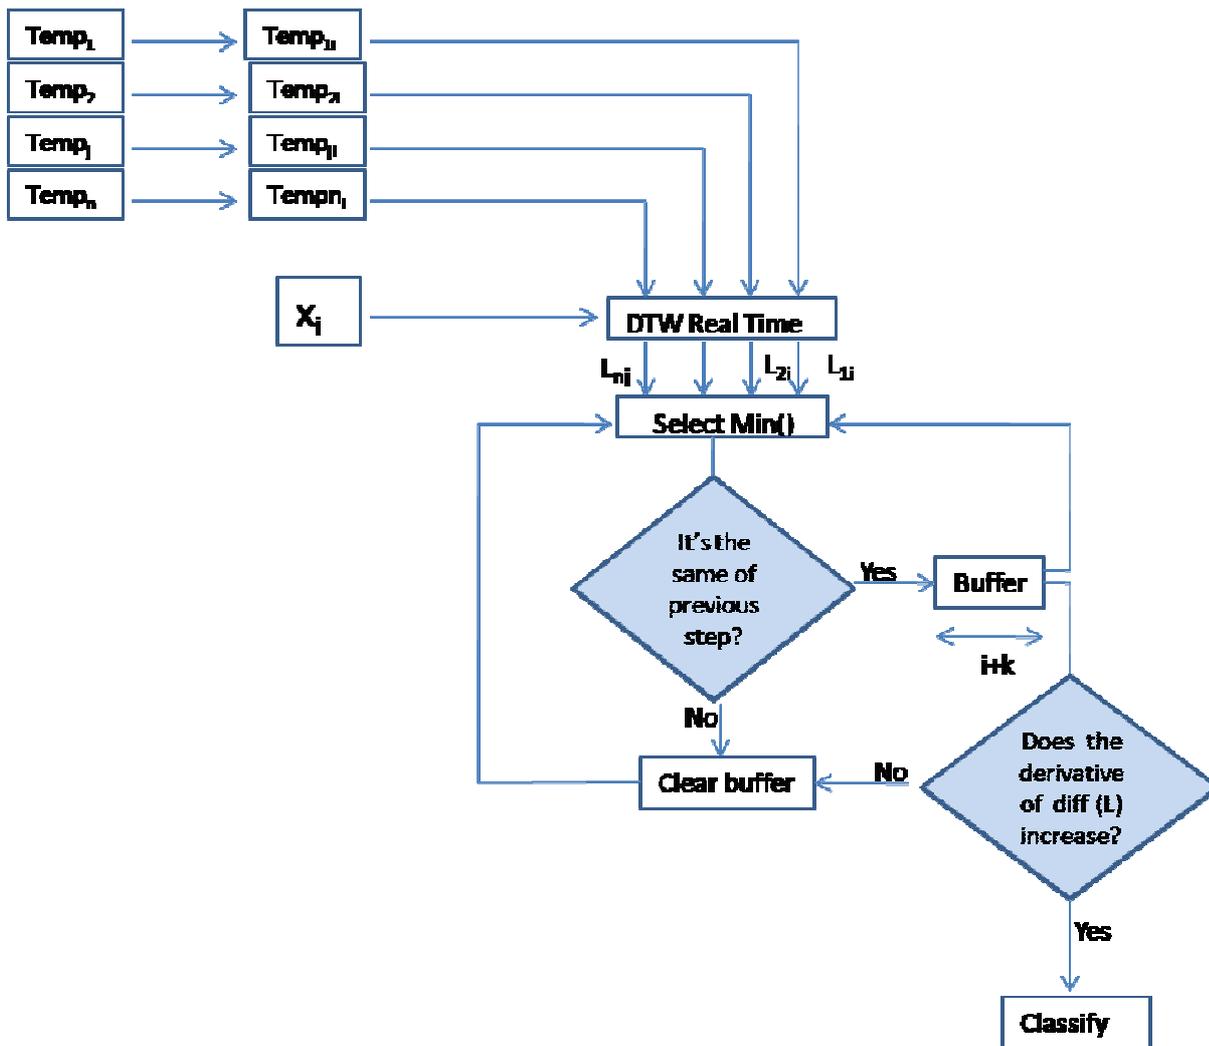


Figura 53– Lo schema del criterio di classificazione

$L_{ni}$  in questo schema è la somma dei vettori  $L$  del template  $n$ , al campione  $i$  per tutti e tre i canali.

Ogni volta che il valore di minimo cambia, il buffer viene svuotato e si ricomincia con la decisione. Se nessuna delle due condizioni si verifica, il classificatore utilizza tutto il segnale di ingresso e classifica in base all'ultimo valore cumulativo del vettore  $L$ . In base a questa formulazione la procedura risulta più efficiente qualora le serie da riconoscere sono simili nella loro prima parte.

Lo schema proposto può essere utilizzato con un unico canale, ma è applicabile a tutti e tre i canali data la monotonicità del vettore L, che consente che essi possano essere tranquillamente sommati senza perdere di generalità.

In questo caso L è il vettore di distanze parziali di tutti i canali in parallelo.

Ovviamente questa soluzione introduce un overhead proporzionale al numero dei canali ma migliora i valori in percentuale di riconoscimento, come verrà messo in evidenza nell'esposizione dei risultati.

I risultati in tabella 18 mostrano le percentuali di riconoscimento, divise per canali, dei due algoritmi: per l'algoritmo RT\_DTW da noi implementato e per quello nella formulazione classica del DTW.

I risultati mostrano una sostanziale sovrapposibilità dei risultati, il che dimostra come la nostra implementazione in tempo reale non altera le performance del nostro schema di classificazione.

	<i>DTW</i>	<i>RT_DTW</i>
<b>Channel1</b>		
Fast movements	93%	91%
Slow movements	88%	89%
Mean	<b>90.5%</b>	<b>90%</b>
<b>Channel2</b>		
Fast movements	92%	92%
Slow movements	90%	90%
Mean	<b>91%</b>	<b>91%</b>
<b>Channel3</b>		
Fast movements	91%	91%
Slow movements	90%	87%
Mean	<b>91.5%</b>	<b>89%</b>

**Table 18 - % of recognition for DTW and RT\_DTW algorithms**

La figura 54 rappresenta un semplice andamento del comportamento in tempo reale del valore di L, usato come metrica di distanza per il criterio di classificazione.

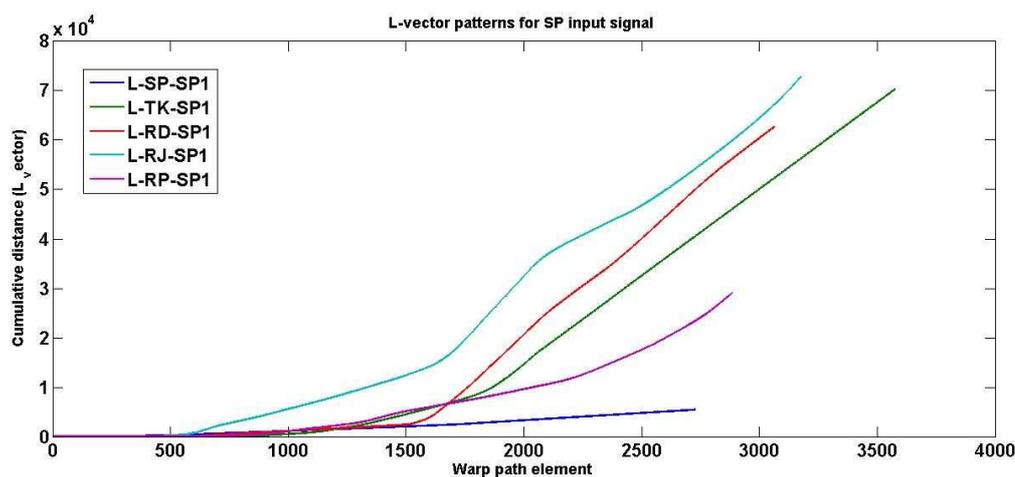
Come si può facilmente vedere, l'algoritmo del RT\_DTW classifica correttamente se il vettore L, riferito alla corretta classe, si mantiene sostanzialmente più basso degli altri vettori relative alle altre classi.

Nello schema di classificazione in cui vengono utilizzati tutti e tre i canali in paralleli le performance del classificatore migliorano come è possibile vedere in tabella 19:

**All channels**

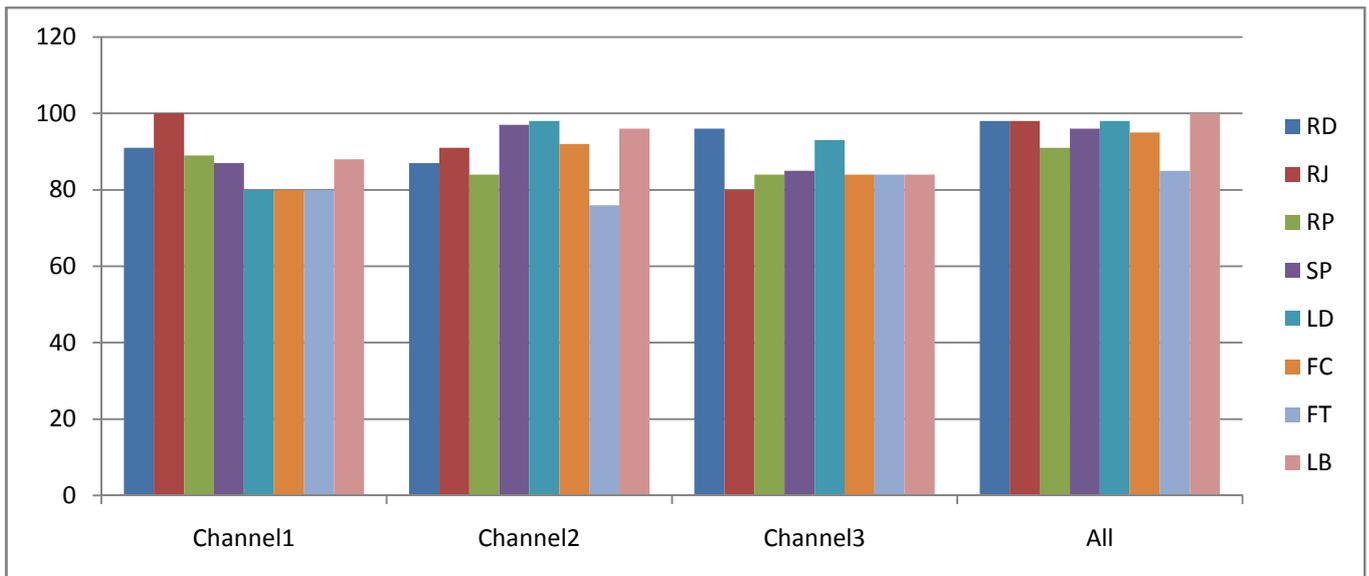
<b>Fast movements</b>	97%
<b>Slow movements</b>	96%
<b>Mean</b>	96,5%

**Tabella 19 - % di riconoscimento dei gesti con lo schema dei 3 canali in parallelo**

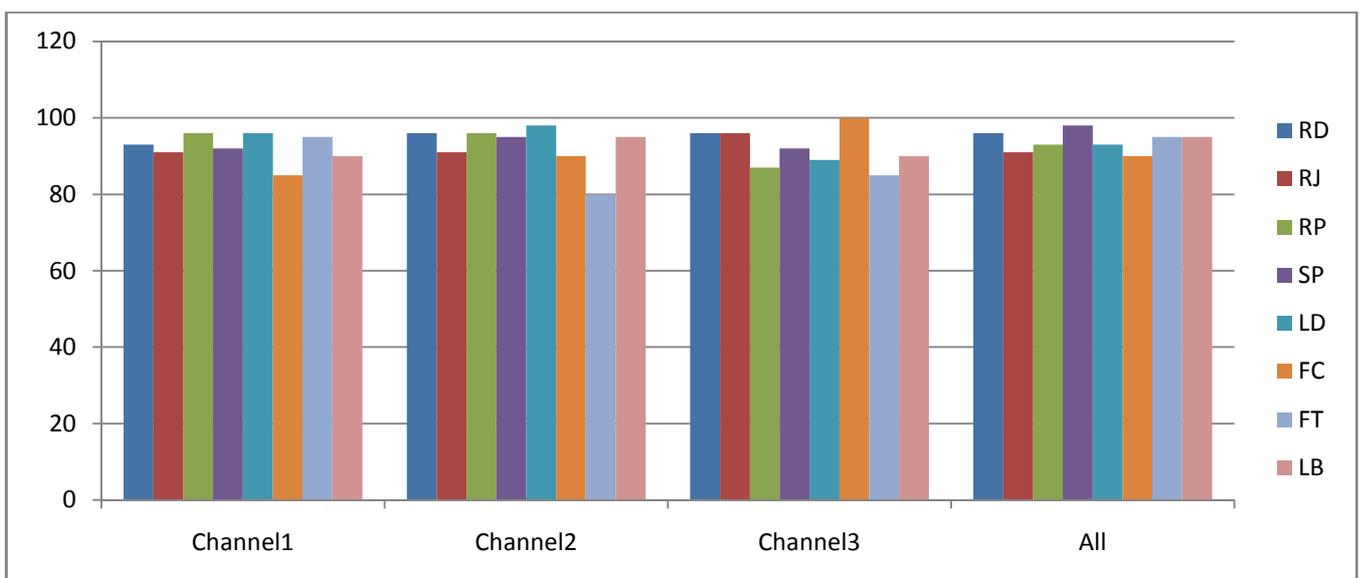


**Figura 54 – L-vector patterns**

Nelle figure seguenti (55 e 56) sono mostrati i risultati relativi alle percentuali di riconoscimento, divise per canali e per ognuno dei task motori, per i movimenti veloci e per quelli lenti



**Figura 55 - % di riconoscimento per i differenti tasks – Movimenti lenti**



**Figura 56 – % di riconoscimento per i differenti tasks – Movimenti veloci**

Il classificatore è stato anche testato per verificare i miglioramenti in termini di tempo di decisione (TD) allorché il nostro algoritmo viene applicato: i risultati sono riportati in termini di percentuale del tempo dell'esercizio in cui lo schema di classificazione riesce a classificare correttamente. I risultati sono riportati in tabella 20, prima per i tre canali separatamente e poi con l'utilizzo dello schema dei tre canali in parallelo. I dati rappresentano, per ogni canale e per diverse finestre

temporali, espresse da percentuali della durata del segnale in ingresso, le percentuali dei gesti correttamente riconosciuti e la accuratezza del risultato.

Ch1	$T_D < 60\%$	$T_D < 80\%$	$T_D < 90\%$	$T_D < 100\%$	Complete Signal
Fast	21%(75%)	41%(92%)	52%(95%)	55%(96%)	100(95%)
Slow	27% (78%)	41%(83%)	49%(82.5%)	52%(84%)	100(89%)
<b>Mean</b>	<b>24%(76.5%)</b>	<b>41%(87.5%)</b>	<b>50.5%(88.75%)</b>	<b>53.5%(90%)</b>	<b>100(92%)</b>

Ch2	$T_D < 60\%$	$T_D < 80\%$	$T_D < 90\%$	$T_D < 100\%$	Complete Signal
Fast	32%(82%)	51%(89%)	60%(87.5%)	67%(90%)	100(94%)
Slow	28%(86%)	52%(88%)	61%(84%)	66%(85%)	100(90%)
<b>Mean</b>	<b>30%(84%)</b>	<b>51.5%(88.5%)</b>	<b>60.5%(85.75%)</b>	<b>66.5%(87.5%)</b>	<b>100(92%)</b>

Ch3	$T_D < 60\%$	$T_D < 80\%$	$T_D < 90\%$	$T_D < 100\%$	Complete Signal
Fast	16%(87.5%)	34%(96%)	42%(97%)	51%(98%)	100(93%)
Slow	21%(86%)	34%(84%)	43%(87%)	48%(87.5%)	100(91%)
<b>Mean</b>	<b>18.5%(86.7%)</b>	<b>34%(90%)</b>	<b>42.5%(92%)</b>	<b>49.5%(92.75%)</b>	<b>100(92%)</b>

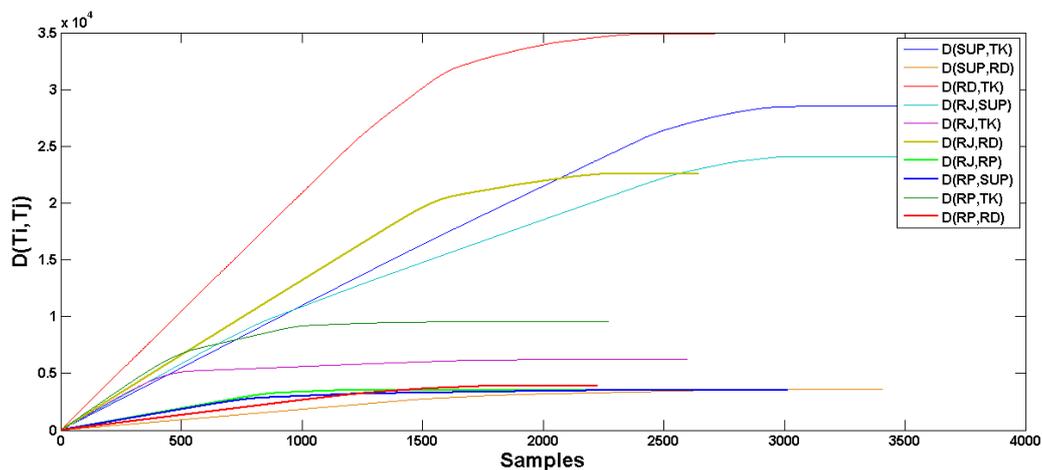
All	$T_D < 60\%$	$T_D < 80\%$	$T_D < 90\%$	$T_D < 100\%$	Complete Signal
Fast	34%(100%)	54%(96%)	63%(97.5%)	70%(99%)	100(97%)
Slow	24%(92%)	49%(94%)	54%(95%)	60%(96%)	100(96%)
<b>Mean</b>	<b>29%(96%)</b>	<b>51.5%(95%)</b>	<b>58.5%(96.25%)</b>	<b>65%(97.5%)</b>	<b>100(96.5%)</b>

**Tabella 20 – Percentuali di riconoscimento in differenti finestre temporali**

### 6.6.1 Applicazione per il riconoscimento di attività in tempo reale tramite alberi di decisione

Per migliorare l'impianto della classificazione, in uno schema generale che possa prevedere anche un numero più elevato di movimenti da riconoscere, si è cercato di introdurre l'utilizzo degli alberi di decisione.

A questo proposito la fase di training e il training set sono stati utilizzati anche per creare in automatico degli alberi di decisione. Si è supposto che l'albero dovesse tener conto delle similitudini tra i *template* e ramificarsi man mano che la distanza reciproca tra i *template*, espressa in termini di DTW, si facesse sempre più piccola. Essi sono stati costruiti soggetto per soggetto in base alle distanze relative di ogni *template* del gesto con tutti gli altri (Figura 52) e di conseguenza, per ogni movimento è stato costruito un albero di decisione. Esso sarà l'albero che verrà selezionato in base al movimento che avrà, nella prima fase del riconoscimento, la distanza minore da tutti i *template*.



**Figura 52– Esempio di distanze in DTW tra ogni Template con tutti gli altri per il soggetto 3**

In questa seconda fase tutti i soggetti ripeteranno di nuovo 5 volte ognuno degli otto esercizi precedentemente descritti e in tempo reale, verrà testato l'algoritmo di riconoscimento precoce del gesto.

L'algoritmo prevede una prima fase di DTW real time su blocchi di 20 campioni per volta e selezione automatica dell'albero più probabile di decisione da percorrere.

I risultati sono in fase di elaborazione.

## Conclusioni

I risultati ottenuti e validati dalle nostre applicazioni ci hanno fornito una idea sulle numerose possibilità offerte dall'utilizzo di sensoristica indossabile per fornire servizi innovativi di telemedicina. Dalle nostre considerazioni è emerso come è possibile abbattere i costi del sistema sanitario nazionale tramite applicazioni di telemonitoraggio e di teleriabilitazione, che utilizzino sensoristica a basso costo integrata con impianti teorici raffinati e dalle elevate performance.

In particolare, durante il nostro lavoro, abbiamo ampiamente dimostrato come è possibile riconoscere l'atto motorio, tipicamente gesti dell'attività di vita quotidiana (ADL), con percentuali sempre al di sopra del 90%, utilizzando accelerometri biassiali e triassiali posizionati sul corpo del paziente.

Ci siamo occupati di gesti compiuti con gli arti superiori, ad esempio gesti previsti da un test di indipendenza funzionale per pazienti post-ictus, come il Wolf Motor Function Test, e attività motorie tipiche degli arti inferiori. I protocolli sperimentali

hanno interessato sia persone giovani che persone anziane, in differenti contesti applicativi e testando differenti posizionamenti dei sensori sul corpo.

Le metodologie di classificazione che abbiamo implementato hanno spaziato dalle tecniche di Template Matching a quelle tipicamente probabilistiche, come il classificatore Bayesiano e le catene di Markov. Un approccio completamente innovativo, a questo proposito, ha utilizzato il filtro di Kalman per aggiornare, attività dopo attività, la probabilità a priori di uno schema di Bayes, rendendo così la classificazione adattiva rispetto ai movimenti che il soggetto sta compiendo. Tutte le tecniche hanno superato la difficoltà nel riconoscere un determinato movimento anche se viene eseguito ogni volta a differenti velocità. In tutti i casi l'obiettivo è stato sempre quello di migliorare le percentuali di riconoscimento del gesto, esplorando anche soluzioni cooperative di tecniche, senza perdere di vista i requisiti di basso costo, versatilità e facilità di utilizzo del set-up sperimentale.

Il punto fermo di tutte le analisi è stato definire una importante fase di calibrazione iniziale, sia per la definizione dei *template* che delle densità di probabilità condizionate, che ci ha permesso di ottenere risultati migliori in termini di percentuale di riconoscimento rispetto a tecniche non supervisionate o più generali.

Tutti gli algoritmi proposti hanno anche puntato al risparmio computazionale in modo da consentire applicazioni in tempo reale. L'attenzione al problema ha consentito, nell'ultima fase del lavoro, anche l'implementazione di una versione real-time del noto algoritmo del Dynamic Time Warping (da noi definito RT\_DTW). Tramite esso è stato possibile riconoscere circa un quarto dei gesti correttamente classificati in meno del 60% del tempo di esecuzione del gesto stesso.

Parallelamente a questa attività di ricerca c'è stata una attività di sviluppo volta alla realizzazione di sistemi hardware e interfacce per l'acquisizione e l'elaborazione dei dati provenienti da differenti tipologie di sensori. Questi sistemi ci hanno consentito di poter effettuare le campagne sperimentali in ambiente non controllato e simulando così un comportamento che fosse il più naturale possibile.

Tra gli sviluppi futuri del presente lavoro ci sono diverse possibilità riguardo al miglioramento delle performance di classificazione, in ottica sia adattiva che di tempo reale, ad esempio migliorando lo schema della classificazione che utilizza il RT\_DTW ma in un contesto fatto di alberi di decisione e regole di decisione dinamiche.

Naturalmente deve essere ampliato il set dei movimenti da riconoscere, cercando di proporre soluzioni che contengono il maggior numero possibile di attività quotidiane che un soggetto in condizioni normali/patologiche svolge.

Un altro importante elemento di sviluppo sarà dato dalla possibilità di integrare differenti sistemi e tipologie di sensori, che siano in grado ad esempio anche di fornire informazioni relative all'ambiente circostante l'utente. Tutte queste possibilità non possono darsi senza un approfondimento continuo delle tecniche di classificazione e senza la versatilità nel muoversi nell'immenso panorama teorico che esse comportano.

## Bibliografia

- [1] A. Godfrey, R. Conway, D. Meagher, and G. O' Laighin, "Direct measurement of human movement by accelerometry". *Medical Engineering and Physics*, vol. 30, no. 10, pp. 1364–1386, 2008.
- [2] L. Bao and S. Intille, "Activity recognition from user-annotated acceleration data.". *Lecture Notes in Computer Science*, vol. 3001, pp. 1–17, 2004.
- [3] N. Ravi, N. Dandekar, P. Mysore, and M. Littman, "Activity recognition from accelerometer data." . *Proceedings of the National Conference on Artificial Intelligence*, vol. 20, no. 3, pp. 1541, 2005.
- [4] U. Maurer, A. Rowe, A. Smailagic, and D. Siewiorek, "Location and Activity Recognition Using eWatch: A Wearable Sensor Platform" .*Lecture Notes in Computer Science*, vol. 3864, p. 86, 2006.
- [5] D. Huynh, "Human Activity Recognition with Wearable Sensors". *Ph.D.Thesis*, 2008.
- [6] N. Ravi, N. Dandekar, P. Mysore, and M. Littman, "Activity recognition from accelerometer data," .*Proceedings of the National Conference on Artificial Intelligence*, vol. 20, no. 3, pp. 1541, 2005

- [7] R. Muscillo, D. Bibbo, M. Schmid. "A combination of template matching and Bayesian estimation to detect and classify activities of daily living". 19th International Conference BIOSIGNAL, Brno, Czech Republic: June 29 - July 1, 2008.
- [8] M. Schmid, R. Muscillo, S. Conforto, "Classifying among motor activities executed at different speeds: SVM vs. MAP applied on features extracted from accelerometer data". I GNB Workshop on KDD in Bioingegneria, Pavia, Italy: February 20, 2009.
- [9] R. Muscillo, G. Severini, M. Schmid, T. D'Alessio. "Distinguishing among different lower limb physical activities through a Bayes' classifier applied on features extracted from single-axis accelerometer data". ISPGR 19th conference, Bologna, Italy: June 21-25, 2009
- [10] Muscillo R, Schmid M, Conforto S, D'Alessio T, "An adaptive Kalman-based Bayes estimation technique to classify walking activities in young and elderly healthy people through accelerometers". In I revisione "*Medical Engineering and Physics*"
- [11] J. He, H. Li, and J. Tan, "Real-time daily activity classification with wireless sensor networks using Hidden Markov Model". 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2007, pp. 3192–3195.
- [12] A. Krause, D. Siewiorek, A. Smailagic, and J. Farrington, "Unsupervised, dynamic identification of physiological and activity context in wearable computing". IEEE International Symposium on Wearable Computers, pp. 88–97, 2005.
- [13] J. Wu, L. Dong, and W. Xiao, "Real-time Physical Activity classification and tracking using wearable sensors". 6th International Conference on Information, Communications & Signal Processing, pp. 1–6, 2007
- [14] H. Thiruvengada, S. Srinivasan, and A. Gacic, "Design and implementation of an automated human activity monitoring application for wearable devices". IEEE International Conference on Systems, Man and Cybernetics, SMC, 2008, pp. 2252–2258
- [15] C. Doukas, I. Maglogiannis, A. Rouskas, A. Pneumatikakis, "Emergency incidents detection in assisted living environments utilizing sound and visual perceptual components". Proceedings of the 2nd International Conference on Pervasive Technologies Related to Assistive Environments, Corfu, Greece, 1999, Article No.14
- [16] C. Doukas, I. Maglogiannis, N. Katsarakis and A. Pneumatikakis, "Enhanced Human Body Fall Detection Utilizing Advanced Classification of Video and Motion Perceptual Components". Artificial Intelligence Applications and Innovations III, Volume 296/2009, 185-193
- [17] G. Williams, K. Doughty, K. Cameron and D. Bradley, "A smart fall and activity monitor for telecare applications". Proc. 20th Annual Int. Conf. of the IEEE Engineering in Medicine and Biology Society, 1998.
- [18] K. Doughty, R. Lewis and A. McIntosh, "The design of a practical and reliable fall detector for community and institutional telecare" J. Telemed. Telecare 6 S150–4, 2000.
- [19] S.C. Jacobsen, T. J. Petelenz and S. Peterson. United States Patent Office Document 6,160,478, 2000

- [20] J. M. Birnbach and S. Jorgensen. United States Patent Application 20020116080, 2002
- [21] T. J. Petelenz, S.C. Peterson and S.C. Jacobsen. United States Patent Office Document 6,433,690, 2002
- [22] M.L. Lehrman, A.R. Owens, M.E. Halleck and E.L. Massman. United States Patent Office Document 6,501,386, 2002
- [23] M. Mathie, J. Basilakis and B. Celler. "A system for monitoring posture and physical activity using accelerometers", 23rd Annual Int. Conf. IEEE Engineering in Medicine and Biology Society (Istanbul, 25–28 Oct. 2001)
- [24] R. Salleh, D. MacKenzie, M. Mathie and B. Celler. "Low power tri-axial ambulatory falls monitor", Proc. 10th Int. Conf. on Biomedical Engineering (Singapore, 6–9 Dec. 2000)
- [25] D. Giansanti, V. Macellari and G. Maccioni "New neural network classifier of fall-risk based on the Mahalanobis distance and kinematic parameters assessed by a wearable device". *Physiol. Meas.* **29** N11-N19, 2008
- [26] M. Gietzelt, G. Nemitz, K.H. Wolf, H.M. Zu Schwabedissen, R. Haux, M. Marscholke. "A clinical study to assess fall risk using a single waist accelerometer". *Informatics for Health and Social Care*, December 2009, Vol. 34, No. 4, Pages 181-188
- [27] D. Istrate, E. Castelli, M. Vacher, L. Besacier, J.F. Serignat, "Information extraction from sound for medical telemonitoring". *Information Technology in Biomedicine*, IEEE Transactions on, Volume 10, Issue 2, April 2006 Page(s): 264 - 274
- [28] X. Feng, J.M. Winters, "An interactive framework for personalized computer-assisted Neurorehabilitation". *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11(5), 518-526.
- [29] R. Muscillo, M. Schmid, S. Conforto. "The median point DTW template to classify upper limb gestures performed at different speeds". *MBEC '08*, Antwerp, Belgium: November 23-27, 2008
- [30] M. Gneo, R. Muscillo, M. Goffredo, S. Conforto, M. Schmid, T. D'Alessio. "Real-time adaptive neural predictors for upper limb gestures blind recognition". 11th International Congress of the IUPESM - Medical Physics and Biomedical Engineering World Congress 2009, Munich, Germany: September 7-12, 2009
- [31] M.K. Holden, T.A. Dyar, L. Dayan-Cimadoro, "Telerehabilitation Using a Virtual Environment Improves Upper Extremity Function in Patients With Stroke", *Neural Systems and Rehabilitation Engineering*, IEEE Transactions on. Volume 15, Issue 1, March 2007 Page(s): 36 - 42
- [32] R. Muscillo, M. Schmid, S. Conforto, T. D'Alessio "Early recognition of upper limb motor tasks through accelerometers: real-time implementation of a DTW-based algorithm". *inviato a Computers in Biology and Medicine*
- [33] H. Xiuqing, L. Haomin, W. Jinlan, Z. Yongfeng, L. Lisha, L. Yimin, "A novel real-time physiological parameters telemonitoring system with the audio/video communication function" *Information Technology and Applications in Biomedicine*, 2008. ITAB 2008. International

Conference on, Volume, Issue, 30-31 May 2008 Page(s):474 - 476

- [34] P. Leijdekkers, V. Gay, E. Lawrence, "Smart Homecare System for Health Tele-monitoring" Digital Society, 2007. ICDS apos;07. First International Conference on the Volume, Issue, 2-6 Jan. 2007 Page(s):3 - 3
- [35] M. Gutierrez, P. Lemoine, D. Thalmann, F. Vexo, "Telerehabilitation: Controlling Haptic Virtual Environments through Handheld Interfaces"
- [36] Lord S R, Lloyd D G and Li S K 1996 Sensori-motor function, gait patterns and falls in community-dwelling women Age Ageing 25 292-99, 1996
- [37] Hausdorff J M, Edelberg H K, Mitchell S L, Goldberger A L and Wei J Y Increased gait unsteadiness in community-dwelling elderly fallers Arch. Phys. Med. Rehabil. 78 278-83, 1997
- [38] Fernie G R, Gryfe C I, Holliday P J and Llewellyn A Relationship of postural sway in standing to incidence of falls in geriatric subjects Age Ageing 11 11-6, 1982
- [39] Luukinen H, Koski K, Laippala P and Kivela S L Predictors for recurrent falls among the home-dwelling elderly Scand. J. Prim. Health Care 13 294-9, 1995
- [40] Kamen G, Patten C, Du C and Sison S An accelerometry-based system for the assessment of balance and postural sway Gerontology 44 40-5, 1998
- [41] Guimaraes R M and Isaacs B, Characteristics of the gait in old people who fall Int. Rehabil. Med. 2 177-80, 1980
- [42] Munro B J, Steele J R, Bashford G M, Ryan M and Britten N 1998 A kinematic and kinetic analysis of the sit-to-stand transfer using an ejector chair: implications for elderly rheumatoid arthritic patients J. Biomech. 31 263-71
- [43] Kerr K M, White J A, Barr D A and Mollan R A 1997 Analysis of the sit-stand-sit movement cycle in normal subjects Clin. Biomech. 12 236-45
- [44] Mayagoitia R E, Lotters J C, Veltink P H and Hermens H 2002 Standing balance evaluation using a triaxial accelerometer Gait Posture 16 55-9
- [45] Moe-Nilssen R 1998 Test-retest reliability of trunk accelerometry during standing and walking Arch. Phys. Med. Rehabil. 79 1377-85
- [46] Steele B G, Holt L, Belza B, Ferris S M, Lakshminaryan S and Buchner D M 2000 Quantitating physical activity in COPD using a triaxial accelerometer Chest 117 1359-67
- [47] Ng A V and Kent-Braun J A 1997 Quantitation of lower physical activity in persons with multiple sclerosis Med. Sci. Sports Exerc. 29 517-23
- [48] Fehling P C, Smith D L, Warner S E and Dalsky G P 1999 Comparison of accelerometers with oxygen consumption in older adults during exercise Med. Sci. Sports Exerc. 31 171-5

- [49] Bussmann J B, Hartgerink I, van der Woude L H and Stam H J 2000b Measuring physical strain during ambulation with accelerometry *Med. Sci. Sports Exerc.* 32 1462–71
- [50] Bouten C V, Verboeket-van de Venne W P, Westerterp K R, Verduin M and Janssen J D 1996 Daily physical activity assessment: comparison between movement registration and doubly labeled water *J. Appl. Physiol.* 81 1019–26
- [51] Miller D J, Freedson P S and Kline G M 1994 Comparison of activity levels using the Caltrac accelerometer and five questionnaires *Med. Sci. Sports Exerc.* 26 376–82
- [52] Meijer E P, Goris A H C, Wouters L and Westerterp K R 2001 Physical inactivity as a determinant of the physical activity level in the elderly *Int. J. Obes.* 25 935–9
- [53] Kochersberger G, McConnell E, Kuchibhatla M N and Pieper C 1996 The reliability, validity, and stability of a measure of physical activity in the elderly *Arch. Phys. Med. Rehabil.* 77 793–5
- [54] Coleman K J, Saelens B E, Wiedrich-Smith MD, Finn J D and Epstein L H 1997 Relationships between TriTrac-R3D vectors, heart rate, and self-report in obese children *Med. Sci. Sports Exerc.* 29 1535–42
- [55] Epstein L H, Paluch R A, Coleman K J, Vito D and Anderson K 1996 Determinants of physical activity in obese children assessed by accelerometer and self-report *Med. Sci. Sports Exerc.* 28 1157–64
- [56] Trost S G, Kerr L M, Ward D S and Pate R R 2001 Physical activity and determinants of physical activity in obese and non-obese children *Int. J. Obes.* 25 822–9
- [57] Bouten C V, Koekkoek K T, Verduin M, Kodde R and Janssen J D 1997a A triaxial accelerometer and portable data processing unit for the assessment of daily physical activity *IEEE Trans. Biomed. Eng.* 44 136–47
- [58] Bouten C V, Sauren A A, Verduin M and Janssen J D 1997b Effects of placement and orientation of body-fixed accelerometers on the assessment of energy expenditure during walking *Med. Biol. Eng. Comput.* 35 50–6
- [59] H.J. Montoye, et al., "Estimation of energy expenditure by a portable accelerometer", *Med. Sci. Sports Exerc.* 15:403-407, 1983.
- [60] Bouten C V, Westerterp K R, Verduin M and Janssen J D 1994 Assessment of energy expenditure for physical activity using a triaxial accelerometer *Med. Sci. Sports Exerc.* 26 1516–23
- [61] Cooper A R, Page A, Fox K R and Misson J 2000 Physical activity patterns in normal, overweight and obese individuals using minute-by-minute accelerometry *Euro. J. Clin. Nutr.* 54 887–94
- [62] Cooper A R, Page A S, Foster L J and Qahwaji D 2003 Commuting to school: are children who walk more physically active? *Am. J. Prev. Med.* 25 273–6
- [63] Ekelund U et al 2001 Physical activity assessed by activity monitor and doubly labeled water in children *Med. Sci. Sports Exerc.* 33 275–81

- [64] Pate R R, Freedson P S, Sallis J F, Taylor W C, Sirard J, Trost S G and Dowda M 2002 Compliance with physical activity guidelines: prevalence in a population of children and youth *Ann. Epidemiol.* 12 303–8
- [65] Trost S G, Pate R R, Sallis J F, Freedson P S, Taylor W C, Dowda M and Sirard J 2002 Age and gender differences in objectively measured physical activity in youth *Med. Sci. Sports Exerc.* 34 350–5
- [66] Bouten C V, Koekkoek K T, Verduin M, Kodde R and Janssen J D. "A triaxial accelerometer and portable data processing unit for the assessment of daily physical activity" *IEEE Trans. Biomed. Eng.* 44 136–47, 1997
- [67] P. H. Veltink, H. B. Bussmann, W. de Vries, W. L. Martens, and R. C. Van Lummel, "Detection of static and dynamic activities using uniaxial accelerometers," *IEEE Trans Rehabil Eng.* vol. 4, pp. 375-85, Dec 1996.
- [68] R. Muscillo, S. Conforto, M. Schmid, T. D'Alessio. "Minimizing the Set Up for ADL Monitoring through DTW Hierarchical Classification on Accelerometer Data". *WSEAS Transactions on biology and biomedicine*, 3(5), 2008
- [69] Muscillo R, Conforto S, Schmid M, Caselli P, D'Alessio T. Resolving ADL Activities Variability through Derivative Dynamic Time Warping applied on Accelerometer Data. *Proceedings of the 29th International Conference of the IEEE EMBS 2007*; 1:4930-33.
- [70] M. Sekine, T. Tamura, M. Akay, T. Fujimoto, T. Togawa, Y. Fukui, Discrimination of walking patterns using wavelet-based fractal analysis, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 10(3), 2002, pp. 188–196.
- [71] A. Mori, S. Uchida, R. Kurazume, R. Taniguchi, T. Hasegawa, and H. Sakoe, "Early Recognition and Prediction of Gestures toward Intelligent Man-Machine Interfaces". *The Second Joint Workshop on Machine Perception and Robotics (MPR2006)*, Fukuoka, Japan
- [72] M. J. Mathie, B.G. Celler, N.H. Lovell, AC.F. Coster, "Classification of basic daily movements using a triaxial accelerometer". *Med Biol Eng Comput.* 2004 Sep;42(5):679-87.
- [73] Lee, S. and Crawford, M.M., "Multi-channel/Multi-sensor Image Classification Using Hierarchical Clustering and Fuzzy Classification," *Proceedings of the 2000 International Geoscience and Remote Sensing Symposium*, Honolulu, Hawaii, July 24-28, 2173-2177, 2000
- [74] N. Cesa-Bianchi, C. Gentile, L. Zaniboni, "Hierarchical classification: combining Bayes with SVM", *ACM International Conference Proceeding Series*; Vol. 148, *Proceedings of the 23rd international conference on Machine learning*, 2006
- [75] Conforto S, D'Alessio T. "Real time monitoring of muscular fatigue from dynamic surface myoelectric signals using a complex covariance approach". *Med Eng Phys* 1999; 21:225-34.
- [76] Bobick, A. and J. Davis, "Real-time Recognition of Activity Using Temporal Templates." *IEEE Workshop on Applications of Computer Vision*, Sarasota, FL, 4 pages, December 1996

- [77] Sakoe H, Chiba S, “ Dynamic programming algorithm optimization for spoken word recognition”. *IEEE Transactions on Acoustics, Speech and Signal Processing*. 1978 26(1): 43- 49, 1978, ISSN: 0096-3518
- [78] Aminian, K., et al., Spatio-temporal parameters of gait measured by an ambulatory system using miniature gyroscopes. *Journal of Biomechanics*, 2002. 35(5): p. 689-699.
- [79] Salarian, H. Russmann, F. J. G. Vingerhoets, P. R. Burkhard and K.Aminian, "Ambulatory monitoring of physical activities in patients with Parkinson's disease," *IEEE Transactions on Biomedical Engineering*, vol. 54, pp. 2296-2299,2007
- [80] Sabatini, A.; Martelloni, C.; Scapatello, S. & Cavallo Filippo. Assessment of walking features from foot inertial sensing.*IEEE Transactions on biomedical engineering*, 52 (3):1--9, 2005.
- [81] M. Brandes, W. Zijlstra, S. Heikens, R. van Lummel, D. Rosenbaum, “Accelerometry based assessment of gait parameters in children,” *Gait & Posture* 24 (2006) 482-486.
- [82] B. Auvinet, G. Berrut, C. Touzard, L. Moutel, N. Collet, D. Chaleil, and E. Barrey, “Gait abnormalities in elderly fallers,” *Journal of Aging and Physical Activity*, 2003, 11, 40-52.
- [83] D. Alvarez, R.C. Gonzàlez, A. Lòpez and J. C. Alvarez, “Comparison of step length estimators from wearable accelerometer devices,” *Proceedings of the 28th IEEE. EMBS Annual International Conference*. New York City, USA, Aug 30-Sept 3, 2006
- [84] B.Auvinet, G. Berrut, C. Touzard, L. Moutel, N. Collet, D. Chaleil, E. Barrey, “Reference data for normal subjects obtained with an accelerometric device,” *Gait and Posture* 16 (2002) 124-134.
- [85] R. Senden, B. Grimm, I.C. Heyligers, H.H.C.M. Savelberg, K. Meijer, “Acceleration-based gait test for healthy subject: Reliability and reference data,” *Gait and Posture* 30 (2009) 192-196
- [86] E. Rocon, J. M. Belda-Lois, A. F. Ruiz, M. Manto, J. C. Moreno, and J. L. Pons,” *Design and Validation of a Rehabilitation Robotic Exoskeleton for Tremor Assessment and Suppression*”. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 15, no. 3, September 2007
- [87] Kabada M.P., Ramakrishnan, M.E., Gainey, W.J., Gorton, G. and Cochran, G.V.B., “Reproducibility of kinematic, kinetic, and electromyographic data in normal adult gait”. *Journal of Orthopedic Research*, 7, (1989) 849-860.
- [88] Steinwender, G., Saraph, S., Scheiber, S., Zwick, E.B. and Uitz, C., “Intrasubject repeatability of gait analysis data in normal and spastic children”. *Clinical Biomechanics*, 15(2), (2000),134–139