



ATTICUS

Ambient-intelligent Tele-monitoring System

Codice progetto: ARS01_00860

Deliverable D7.2

Definizione degli algoritmi per il sistema ATTICUS



**UNIVERSITÀ
DEGLI STUDI
DEL MOLISE**



Consorzio Italia



Data: Maggio 2021

Leader OR	UNIMOL
Obiettivo realizzativo (OR)	OR7 – Realizzazione di algoritmi predittivi e decisionali
Attività	7.2 – Definizione degli algoritmi per il sistema ATTICUS
Descrizione dell'attività <i>(come da capitolato)</i>	Questa attività prevede la definizione degli algoritmi predittivi e decisionali da usare nel sistema ATTICUS. Sulla base dei requisiti derivati con l'OR1 e sfruttando le conoscenze acquisite attraverso l'attività A6.1, si potranno scegliere le tecniche più adeguate in base al contesto.
Partner coinvolti nell'attività	
Stato del documento	Final draft
Confidenzialità	Ristretta

Indice del documento

1	Introduzione	8
2	Algoritmi relativi al livello 1 del DSS	9
2.1	Free Fall Detection	9
2.2	L'algoritmo di Compressive Sensing	12
3	Algoritmi relativi al livello 2 del DSS	14
3.1	Algoritmi che intervengono nella detection di anomalie cardiache	14
3.1.1	L'algoritmo di Pan-Tompkins per la detection dei picchi R	14
3.1.2	L'algoritmo per il rilevamento delle aritmie	17
3.1.3	L'algoritmo per la <i>detection</i> di Fibrillazione Atriale	17
3.1.4	L'algoritmo per l'identificazione della morfologia del battito	22
3.2	Algoritmi che intervengono nella detection di anomalie respiratorie	22
3.2.1	Individuazione di anomalie sulla frequenza respiratoria	23
3.2.2	Individuazione di anomalie sull'intensità del respiro	25
3.3	Algoritmi che intervengono nella <i>detection</i> in base ai dati inerziali	26
3.3.1	Fall-Detection	27
3.3.2	Human Activity Recognition	29
3.4	Algoritmi che intervengono nella detection di anomalie termiche	30
3.4.1	Le euristiche per il colpo di calore	30
3.4.2	Le euristiche per la valutazione della temperatura corporea	30
3.5	Algoritmi che intervengono nella detection di stati di stress	30
3.6	Algoritmi che intervengono nella detection di anomalie comportamentali	31
3.6.1	Algoritmo di detection di comportamenti anomali	32
3.6.2	Veglia	34
3.6.3	Rimozione del wearable	35
3.6.4	Uscita di casa	36
3.7	Algoritmi per il monitoraggio degli spostamenti	37
3.7.1	L'algoritmo di outdoor tracking	37
4	Algoritmi relativi al livello 3 del DSS	41
4.1	Algoritmi che intervengono nella detection di anomalie cardiache	41
4.1.1	Extrasistoli	41
4.1.2	Tachicardia Ventricolare	46
		3

4.1.3	Fibrillazione Atriale	53
4.1.4	Scompensi Cardiaci	58
4.1.5	Blocchi Cardiaci	62
4.1.6	Slivellamento del segnale rispetto alla linea isoelettrica	64
	Riferimenti bibliografici	66

Indice delle tabelle

Tabella 1. La tabella mostra la differenza di altitudine di una caduta e il tempo che impiega un oggetto a cadere. Supponendo che il primo campione soddisfi la condizione impostata dal parametro soglia, è possibile rilevare un evento di caduta libera di durata 1/ODR.	11
Tabella 2. Esempio di dataset per l'individuazione di anomalie relative alla veglia.....	33
Tabella 3. Algoritmi confrontati dagli autori e relativi risultati di discriminazione [18].....	47
Tabella 4. Dataset preparato per la sperimentazione atta alla definizione di una soglia di discriminazione .	51

Indice delle figure

Figura 1. Riconoscimento di caduta libera: parametri di soglia e durata.....	10
Figura 2. Schema di sensing basato sulla matrice di rilevamento [1]	13
Figura 3. I principali step di elaborazione previsti dall'algoritmo di Pan-Tompkins [3].....	16
Figura 4. Esempio applicativo dell'algoritmo di Pan-Tompkins [4]	16
Figura 5. Valutazione della distanza temporale tra i picchi R.....	18
Figura 6. Separazione delle istanze AF e non-AF in base al valore di entropia definito da Zhou et al. [5].....	20
Figura 7. Accuratezza ottenuta dal metodo di Zhou et al. [5] sui principali database elettrocardiografici.	20
Figura 8. Analisi grafica del metodo proposto da Zhou et al [5].	21
Figura 9. Esempio applicativo della tecnica di zero-crossing per la valutazione degli attraversamenti per lo zero di un'onda respiratoria.....	24
Figura 10. Esempio di fenomeno di degradamento dell'intensità del respiro	26
Figura 11. L'impatto e l'analisi della postura su base accelerometrica [9].....	28
Figura 12. Le componenti angolari per il rilevamento della postura.	29
Figura 13. Identificazione dei pericoli	40
Figura 14. Episodio di PVC, indicato dalla freccia.....	42
Figura 15. Esempio di segnale con il complesso QRS distorto a causa del PVC	43
Figura 16. Il diagramma a blocchi dell'algoritmo per il rilevamento in tempo reale degli episodi di PVC.....	45
Figura 17. Ritmo sinusale e relativi slope ottenuti nel segnale binario previsto dal metodo	49
Figura 18. Ritmo con episodio di VT e relativi slopes ottenuti nel segnale binario previsto dal metodo.....	50
Figura 19. Analisi visiva delle soglie	52
Figura 20. Analisi in termini di Accuracy per l'individuazione della soglia ottimale.....	52
Figura 21. Workflow di AMELIA	53
Figura 22. Rappresentazione di un battito cardiaco completo in AMELIA.....	56
Figura 23. Dal battito cardiaco all'istanza di input per l'analizzatore morfologico	57
Figura 24. Esempi dei ritmi etichettati nell'esempio proposto.	60
Figura 25. Esempio ipotetico che illustra la segmentazione del battito cardiaco e i processi in allineamento. In (c), [a] significa il numero intero (floor) di a.....	63
Figura 26. Definizione teorica della linea isoelettrica	64
Figura 27. Identificazione della linea isoelettrica a partire da dati fisiologici.	65

1 Introduzione

In questo documento verranno riportati gli algoritmi scelti per il sistema ATTICUS ai fini del rilevamento di anomalie corporee e della generazione di allarmi. Tali operazioni saranno portate a termine da un sistema di supporto alle decisioni (DSS) diviso in tre livelli. Il livello 1 opererà direttamente sul dispositivo hardware collegato al capo indossabile (S-WEAR); il livello 2 sarà installato sia sull'applicazione per dispositivi mobili (MyATTICUS) sia nel dispositivo di ambient intelligence (S-BOX); il livello 3 sarà, infine, installato presso la centrale di monitoraggio. Più è alto il livello del DSS, più le analisi effettuate saranno complesse e richiederanno grandi moli di dati.

Il documento è organizzato come segue: il Capitolo 2 descrive gli algoritmi implementati nel DSS di livello 1 (S-WEAR), il Capitolo 3 riporta gli algoritmi del DSS di livello 2 (S-BOX e MyATTICUS) e, infine, nel Capitolo 4 gli algoritmi di individuazione di anomalie del DSS di livello 3.

2 Algoritmi relativi al livello 1 del DSS

Al livello 1 del *Decision Support System* di ATTICUS verrà utilizzato esclusivamente l'algoritmo di Free Fall Detection, inteso come algoritmo che rileva un'anomalia.

Per quanto riguarda invece gli algoritmi in generale, sul Firmware della componente elettronica di ATTICUS, verrà integrato anche un algoritmo di *compressive sensing*, già presentato nel deliverable 5.4 e riportato anche in questo documento per completezza (paragrafo 2.2).

2.1 Free Fall Detection

L'algoritmo di *Free Fall Detection* sarà disponibile nella componente elettronica di ATTICUS, in quanto implementato direttamente sul sensore inerziale scelto.

La casa produttrice del sensore espone, tramite il datasheet¹ di riferimento, i dettagli dell'algoritmo integrato nel firmware del sensore ed i parametri configurabili, al fine di ottenere una *detection* ottimistica o più robusta.

Per definizione, per *free fall* s'intende il moto di un oggetto quando la gravità è l'unica forza che agisce su di esso. In realtà si tratta di una situazione in cui l'oggetto è solitamente in caduta libera. Il rilevamento della caduta libera è stata una delle prime applicazioni degli accelerometri MEMS (*Micro Electro-Mechanical Systems*) utilizzati nei dischi rigidi dei computer. Gli accelerometri MEMS sono in grado di riconoscere la caduta libera, perché si tratta di una sorta di movimento dinamico con accelerazione. Quando un dispositivo è appoggiato su un tavolo, per esempio, l'accelerometro MEMS rileva una forza specifica che presenta direzione opposta della gravità terrestre e mantiene il dispositivo in una posizione immobile. In questa situazione, l'accelerometro emette un valore di accelerazione di 1 g. Quando si verifica la caduta libera, la forza specifica - di cui sopra - viene rimossa

¹ https://www.st.com/resource/en/design_tip/dm00500824-setting-up-freefall-recognition-with-sts-mems-accelerometers-stmicroelectronics.pdf

e l'accelerometro non rileva alcuna accelerazione su nessun asse. Questo è utilizzato dalla funzione di riconoscimento della caduta libera incorporata negli accelerometri MEMS della ST.

Quando un dispositivo è in caduta libera, l'accelerazione, misurata lungo tutti gli assi dell'accelerometro, va a zero.

Per il riconoscimento degli eventi ci sono due parametri da impostare: la soglia e la durata.

- La **soglia** definisce un'ampiezza (zona di caduta libera - vedi Figura 1). Le accelerazioni su tutti e tre gli assi devono essere più piccole della soglia per generare un *interrupt*;
- la **durata** definisce un periodo di tempo minimo per il quale le accelerazioni misurate su tutti gli assi devono essere più piccole della soglia. La durata dipende dall'ODR (*Output Data Rate*) selezionato (1LSB equivale a $1/ODR$). Può anche essere interpretato come il numero di campioni consecutivi che devono essere più piccoli della soglia.

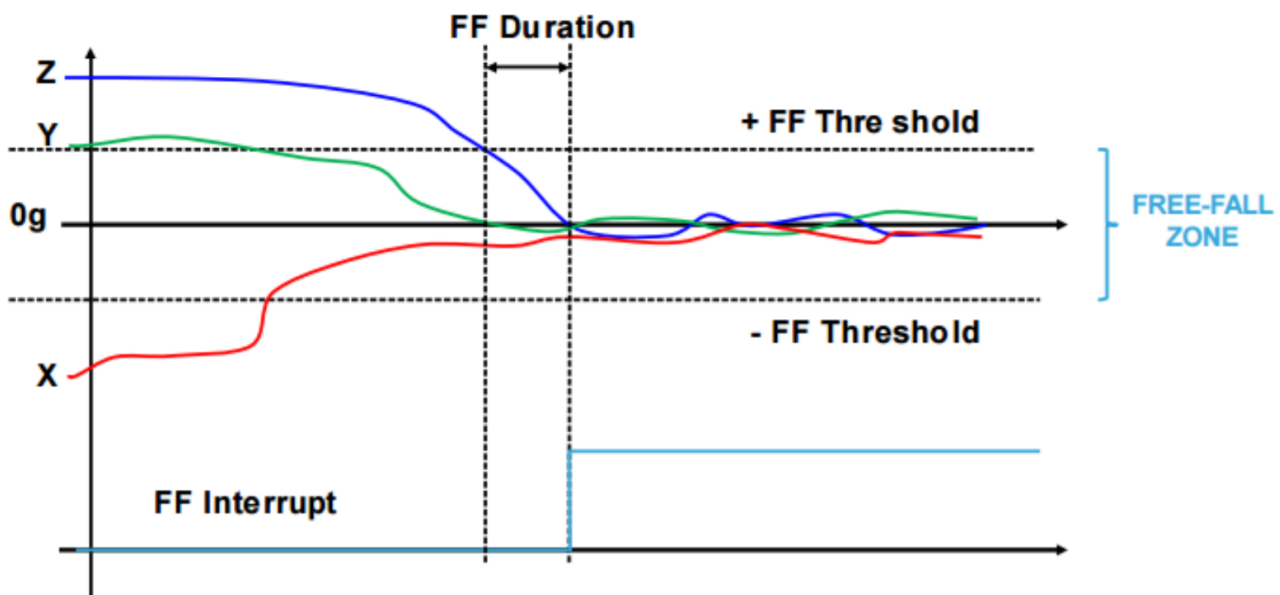


Figura 1. Riconoscimento di caduta libera: parametri di soglia e durata.

La soglia può essere utilizzata per regolare la sensibilità del riconoscimento della caduta libera.

Una soglia più bassa imposta un requisito più elevato su un evento che viene definito come caduta libera. Sembra opportuno tenerla bassa, tuttavia questa scelta potrebbe comportare la perdita di alcune cadute libere, soprattutto quelle brevi. La durata può essere utilizzata per rifiutare il riconoscimento di un falso positivo. Una durata maggiore eviterà il rilevamento della caduta libera nel caso in cui ci siano solo movimenti casuali. È utile per mettere a punto, caso per caso, sia la soglia che la durata. In questo modo si possono ottenere risultati più precisi. Quando si utilizza il riconoscimento di caduta libera, il fondo scala dell'accelerometro deve essere impostato sull'opzione più bassa disponibile. In alcuni casi sarà anche necessario modificare l'ODR del sensore (un ODR più alto significa una maggiore sensibilità nel riconoscimento degli eventi e anche la possibilità di rilevare eventi di caduta libera più brevi).

La lunghezza di un evento di caduta libera può essere calcolata con questa formula:

$$y(t) = \frac{1}{2} g t^2$$

dove $y(t)$ è l'altitudine percorsa, t è il tempo e g è l'accelerazione di gravità.

Tabella 1. La tabella mostra la differenza di altitudine di una caduta e il tempo che impiega un oggetto a cadere. Supponendo che il primo campione soddisfi la condizione impostata dal parametro soglia, è possibile rilevare un evento di caduta libera di durata $1/ODR$.

Attitude difference [mm]	Free-fall time [ms]
10	45.2
20	63.9
100	142.8
500	319.3
1000	451.5

2.2 L'algoritmo di Compressive Sensing

In ATTICUS, si provvederà ad integrare un classificatore morfologico di un segnale di battito, a partire da una tecnica di compressione presentata in [1]. A livello fisico, la compressione viene eseguita nei seguenti passi:

- all'inizio il nodo IoMT acquisisce gli N campioni del segnale ECG alla frequenza di Nyquist. In questo modo viene costruito il vettore N;
- viene valutato un valore di soglia in base ai campioni acquisiti;
- viene costruito un vettore di campionamento p. Esso contiene 1 se i campioni, in valore assoluto, sono più alti del valore di soglia e zero, altrimenti;
- quindi la matrice di rilevamento Φ viene costruita come matrice circolare di p. La prima riga della matrice di rilevamento è costituita dal vettore p, la seconda riga è il vettore p ritardato in modo circolare di una quantità definita dal rapporto di compressione. La matrice di rilevamento è composta dimensionalmente da M righe ed N colonne;
- viene eseguita la moltiplicazione tra la matrice di rilevamento ed il vettore x per ottenere y;
- sia il vettore y compresso che il vettore p vengono trasmessi al server;
- viene acquisito un nuovo vettore di N campioni e la procedura viene ripetuta.

Per analizzare meglio il processo di costruzione della matrice di rilevamento, si può osservare la Figura 2.

Il vettore x viene acquisito, da quel vettore viene stimato il valore medio e poi rimosso dal vettore. Viene applicato poi il valore assoluto al vettore acquisito ed al quale è stato rimosso il valore medio. Il valore di soglia x-esimo si ottiene come il 5% del massimo del vettore x_a . Il valore del 5% è stato scelto sperimentalmente dagli autori.

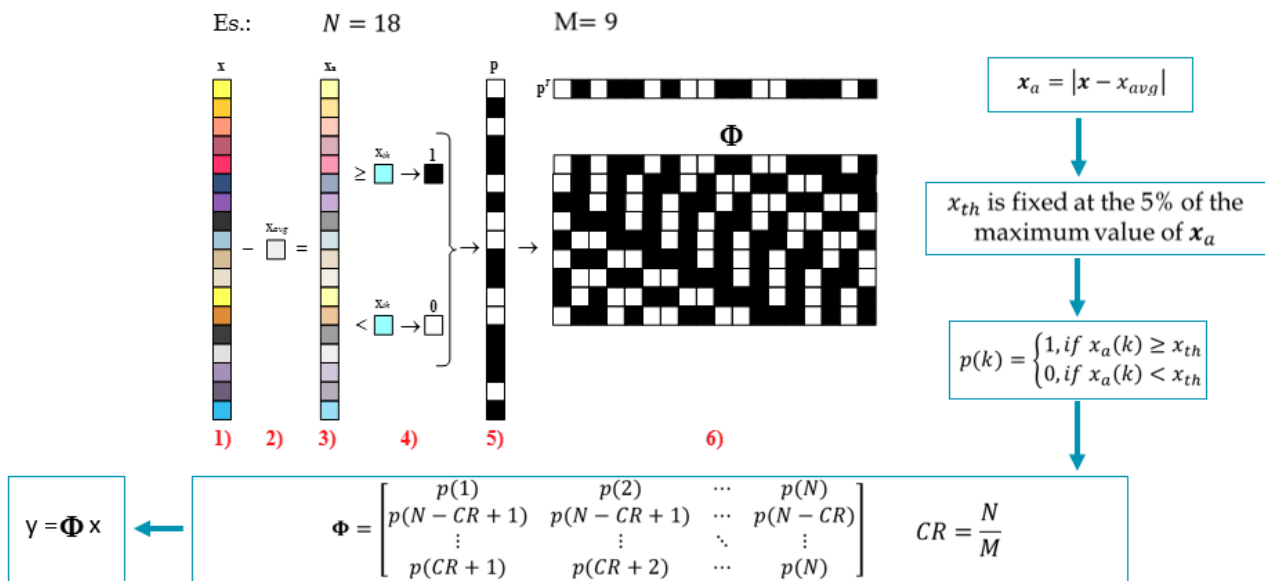


Figura 2. Schema di sensing basato sulla matrice di rilevamento [1]

Ogni valore del vettore p viene scelto in base alle seguenti condizioni: se l'elemento x_a è superiore al valore di soglia, l'elemento corrispondente in p viene posto uguale a 1, altrimenti è fissato a 0.

In Figura 2 (Figura 14), i valori uguali 1 sono disegnati come quadrati neri ed i valori 0 sono disegnati come quadrati bianchi. La matrice di rilevamento è costruita secondo il vettore p come una matrice circolante in cui ogni riga è traslata del rapporto di compressione quantità $CR = N/M$. Ad esempio nella figura il rapporto di compressione è 2. In questo caso la seconda riga è traslata di 2 rispetto alla prima riga. La matrice di rilevamento ha una dimensione di $M \times N$.

Essendo il vettore p quello con più informazioni del segnale originale, in ATTICUS si valuterà l'integrazione di un classificatore della morfologia del battito cardiaco basato su modelli di intelligenza artificiale (come proposto in [2]) da applicarsi a segnali compressi (come proposto in [1]).

3 Algoritmi relativi al livello 2 del DSS

Al livello 2 del *Decision Support System* di ATTICUS verranno utilizzati diversi algoritmi di detection. In questa sezione, gli algoritmi scelti per ogni tipo di *detection* sono raggruppati per sorgente dell'anomalia. Alcuni di questi algoritmi sono stati già dettagliati nel deliverable 5.4.

Si riportano anche nel presente documento, in quanto utili per chiarire determinate dinamiche che intervengono nella *detection*.

3.1 Algoritmi che intervengono nella detection di anomalie cardiache

In questo paragrafo, verranno analizzati gli algoritmi che intervengono nella detection di anomalie cardiache.

3.1.1 L'algoritmo di Pan-Tompkins per la detection dei picchi R

Il DSS di livello due avrà a disposizione informazioni posizionali, rispetto al tempo, dei picchi R di un segnale elettrocardiografico. Questa informazione viene acquisita ed elaborata dalla componente elettronica del DSS di livello 1 ma viene utilizzata ai fini decisionali dal DSS di livello 2.

Dal datasheet del costruttore, è possibile rilevare che le informazioni posizionali sui picchi R derivano da una versione generalizzata dell'algoritmo di Pan-Tompkins [3].

Gli step di *processing* basilari previsti dall'algoritmo di Pan-Tompkins, raffigurati in Figura 3, prevedono le seguenti elaborazioni:

- **Filtro passa banda:** Il filtro passa banda riduce l'influenza del rumore muscolare, l'interferenza a 50 (o 60, a seconda della posizione geografica) Hz, il movimento della linea di base e l'interferenza delle onde T. La banda passante auspicabile per massimizzare l'energia QRS è di circa 5-15 Hz. Gli autori, per ragione pratica, hanno proposto una cascata di filtri passa-basso e passa-alto per ottenere una banda passante di 3 dB da circa 5-15 Hz, ragionevolmente vicino all'obiettivo di progetto.

- **Filtro derivativo:** dopo il filtraggio, il segnale viene differenziato per fornire le informazioni sulle pendenze dei complessi QRS.
- **Quadratura:** questa elaborazione rende tutti i dati positivi ed esegue un'amplificazione non lineare dell'uscita del filtro derivativo, enfatizzando le frequenze più alte (cioè, prevalentemente le frequenze dell'ECG).
- **Integrazione di una finestra mobile:** lo scopo dell'integrazione delle finestre mobili è quello di ottenere informazioni sulle caratteristiche della forma d'onda in aggiunta alla pendenza dell'onda R. La relazione tra la forma d'onda ottenuta a partire dall'integrazione della finestra mobile ed il complesso QRS risulta molto importante. Il numero di campioni N nella finestra mobile diventa fondamentale. Generalmente, la larghezza della finestra dovrebbe essere approssimativamente la stessa del complesso QRS più ampio possibile. Se la finestra è troppo larga, la forma d'onda di integrazione fonderà insieme i complessi QRS e T. Se è troppo stretta, alcuni complessi QRS produrranno diversi picchi nella forma d'onda di integrazione. Questi possono causare difficoltà nei successivi processi di rilevamento QRS. La larghezza della finestra viene determinata empiricamente.
- **Fiducial Mark:** il complesso QRS corrisponde al fronte di salita della forma d'onda di integrazione. La durata temporale del fronte di salita è pari alla larghezza del complesso QRS. Da questo fronte di salita si può determinare un punto di riferimento per la posizione temporale del complesso QRS (in base alla caratteristica della forma d'onda desiderata da marcare, come la pendenza massima o il picco dell'onda R).
- **Confronto a soglia adattivo:** in questa fase, vengono coinvolti una serie di confronti a soglia adattivi per la discriminazione posizionale del picco R.

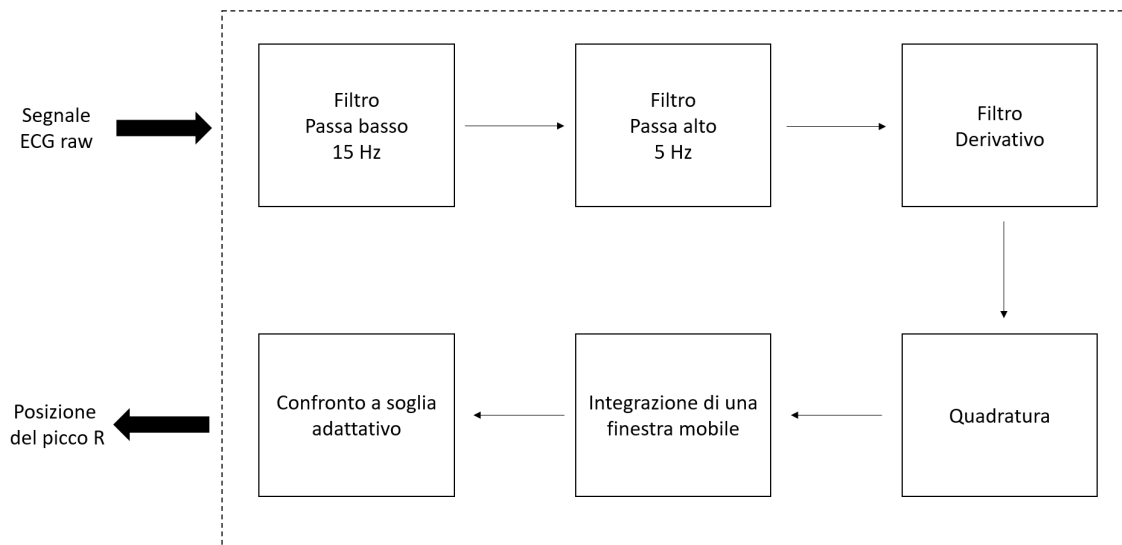


Figura 3. I principali step di elaborazione previsti dall'algorithm di Pan-Tompkins [3]

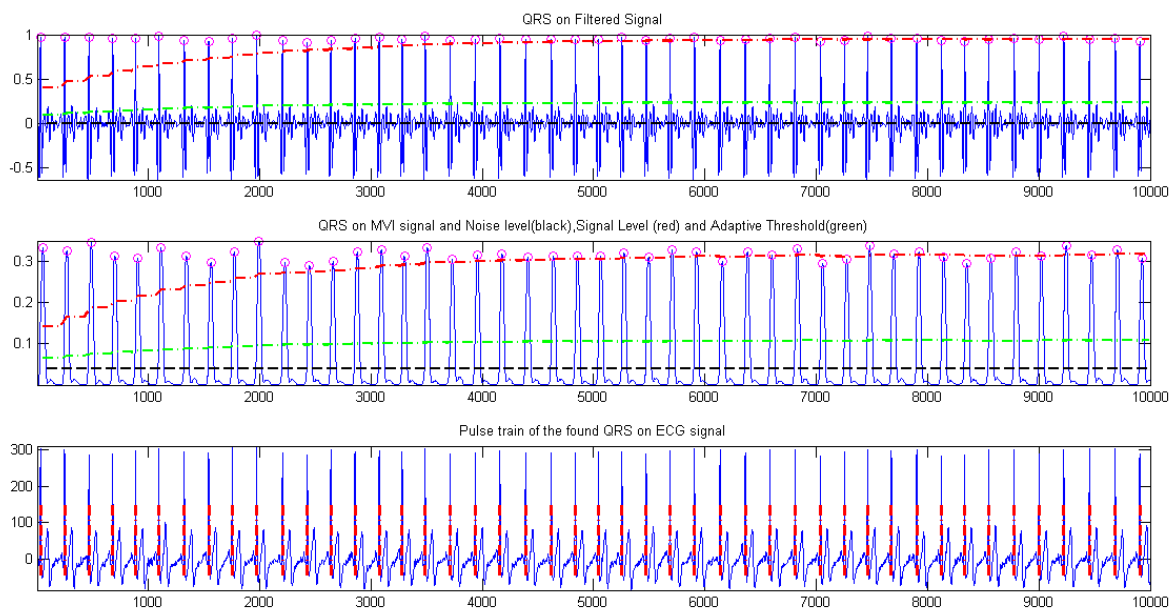


Figura 4. Esempio applicativo dell'algorithm di Pan-Tompkins [4]

3.1.2 L'algoritmo per il rilevamento delle aritmie

Una volta ottenuta la posizione in tempo reale dei picchi R, è possibile ottenere una stima della frequenza cardiaca, semplicemente rapportando un valore in samples o nel tempo rispetto ad un minuto. Una volta ottenuta tale informazione, sarà possibile eseguire opportuni confronti a soglia per rilevare eventuali condizioni di tipo:

- **Tachiaritmia:** se la frequenza cardiaca rilevata eccede una soglia personale dell'utente monitorato;
- **Bradiritmia:** se la frequenza cardiaca rilevata risulta al di sotto di una soglia personale dell'utente monitorato.

Le soglie personalizzate, decise opportunamente dagli operatori del sistema caso per caso, saranno comunicate dal software di monitoraggio alla S-BOX/MyATTICUS, così che l'algoritmo possa usarle per effettuare la *detection*.

3.1.3 L'algoritmo per la *detection* di Fibrillazione Atriale

Nell'ottica di realizzare ed integrare una componente per l'identificazione automatica di eventi di fibrillazione atriale nel sistema di supporto alle decisioni di ATTICUS, si è optato per l'implementazione del metodo proposto da Zhou *et al.* [5], uno dei metodi con maggiore riscontro in letteratura scientifica. La sperimentazione di tale metodo sul MIT-BIH Atrial Fibrillation Database, database di riferimento nello stato dell'arte, dimostra prestazioni eccezionali del metodo, con valori di sensitivity, specificity, e accuracy pari, rispettivamente, a 97,37%, 98,44% e 97,89%.

Il metodo proposto da Zhou *et al.* [5] prevede quattro passi:

- Creazione di una sequenza di valori di frequenza cardiaca;
- Generazione di una dinamica simbolica;
- Valutazione dell'entropia di Shannon adattata;

- Confronto del valore di entropia ottenuto con una soglia identificata a priori.

Per quanto riguarda il passo 1, l'algoritmo prevede una preelaborazione dell'ECG digitale che restituisca l'identificazione dei picchi relativi alle onde R per ogni complesso QRS. A tal proposito, è possibile utilizzare l'approccio di Pan-Tompkins.




Figura 5. Valutazione della distanza temporale tra i picchi R.

Dopo l'identificazione dei picchi R, è possibile calcolare la distanza tra i picchi R. Nello specifico, essendo la frequenza di campionamento un parametro noto a-priori, è possibile calcolare una sequenza di valori di frequenza cardiaca in battiti al minuto (bpm). Ad esempio, nel caso in Figura 5, supponendo una frequenza di campionamento di 250 Hz, la sequenza di frequenze cardiache può essere valutata come segue:

$$hr(1) = 250/fs = 1 \text{ s} \text{ è } hr(1) = 60/1 = 60 \text{ bpm}$$

$$hr(2) = 230/fs = 0,92 \text{ s} \text{ è } hr(2) = 60/0,92 = 65,21 \text{ bpm}$$

$$hr(3) = 240/fs = 0,94 \text{ s} \text{ è } hr(3) = 63,82 \text{ bpm}$$

Sia quindi $hr(n)$ la funzione contenente la sequenza di valori di frequenza cardiaca. Sulla base di tali valori, è possibile ottenere una dinamica simbolica (con valori assumibili nel range $[0,63]$).

Nella funzione di mappatura saranno codificate le informazioni sullo stato istantaneo di ogni battito cardiaco. Al fine di esplorare il comportamento caotico della serie simbolica e generare diversi stati istantanei della frequenza cardiaca, è applicato un template di 3 simboli (ad esempio, una parola contenente 3 simboli successivi).

Nell'ottica di misurare l'irregolarità del ritmo, è misurata l'entropia della sequenza di word, utilizzando una variante dell'entropia di Shannon [5].

Questa misura entropica si basa sull'osservazione di una finestra temporale di lunghezza N di 127 word consecutive (l'insieme A), sulla quale sono analizzati gli elementi caratteristici del ritmo.

In seguito, per ognuno degli elementi caratteristici, viene calcolata la probabilità di occorrenza nell'insieme A .

In base alla funzione entropica appena descritta, è stata quindi identificata una soglia per classificare ogni battito cardiaco come FA (fibrillante) o non-FA (normale). Nello specifico, se il valore dell'entropia è superiore alla soglia, il battito è fibrillante, altrimenti il battito è sano.

La soglia è stata calcolata dagli autori sul *Long Term Atrial Fibrillation Database (LTAfDB)*; nello specifico, attraverso un processo di *trial & error* è stata identificata la soglia che offre sul LTAfDB la migliore accuratezza di classificazione in termini di ROC, in modo da bilanciare *sensitivity* e *specificity*. Il valore identificato è 0.639, che, come mostrato in Figura 6 consente un'identificazione dei battiti molto precisa (notare la netta separazione tra le istanze AF e non-AF, a cui è assegnato uno specifico valore di entropia).




Figura 6. Separazione delle istanze AF e non-AF in base al valore di entropia definito da Zhou et al. [5]

Un riepilogo grafico del metodo proposto da Zhou *et al.* può essere apprezzato in Figura 6, mentre i risultati di accuratezza ottenuti dal metodo sui principali database elettrocardiografici sono riportati in Figura 7. Dai risultati ottenuti è facile dedurre che il metodo di Zhou *et al.* [5] ha un'elevata precisione e affidabilità.

Method	Feature	Year	Database	Key techniques	Results			
					Se(%)	Sp(%)	PPV(%)	ACC(%)
This method	HR	2015	AFDB	Symbolic dynamics+Shannon Entropy	97.37	98.44	97.89	97.99
			AFDB†		97.31	98.28	97.89	97.84
			AFDB‡		98.43	98.46	97.92	98.45
			MITDB		97.83	87.41	47.67	88.51
			NSRDB		NA	99.68	NA	NA
			AFDB+NSRDB		97.36	99.32	96.86	98.98
			AFDB†+NSRDB		97.31	99.31	96.83	98.96
			AFDB‡+NSRDB		98.43	99.35	96.82	99.19

† Records "00735" and "03665" excluded.

‡ Records "04936" and "05091" excluded.

NA indicates not applicable because there is no beat with AF reference annotation in this database.

Figura 7. Accuratezza ottenuta dal metodo di Zhou et al. [5] sui principali database elettrocardiografici.




Figura 8. Analisi grafica del metodo proposto da Zhou et al [5].

Al livello 2 del DSS di ATTICUS, quindi, una volta acquisito un quantitativo minimo di dati elettrocardiografici, sarà possibile ottenere una sequenza minima di frequenze cardiache e su questa applicare l’algoritmo proposto.

3.1.4 L'algoritmo per l'identificazione della morfologia del battito

Un'altra tipologia di *detection* che verrà eseguita in ATTICUS prevederà l'analisi morfologica di un segnale relativo ad un singolo battito cardiaco. La classificazione sarà effettuata in base allo standard ANSI/AAMI EC57:1998 (*American National Standard redatto dall'associazione per l'Advancement of Medical Instrumentation*).

Lo standard prevede che i diversi tipi di battito cardiaco, disponibili nel dataset della letteratura scientifica *MIT-BIH Arrhythmia Database*² [6] vengano suddivisi in 5 classi:

- battito normale (**N**),
- battito ectopico ventricolare (**V**),
- battito ectopico sopraventricolare (**S**),
- fusione di un battito ectopico normale e ventricolare (**F**)
- battito di tipo sconosciuto (**Q**).

Al livello 2 del DSS tale classificazione verrà eseguita su una versione compressa del segnale di battito. Il lavoro da cui si è preso spunto per l'ideazione del detector specifico è stato già ampiamente dettagliato nel deliverable 5.4 e verrà richiamato anche nel prosieguo del presente documento.

3.2 Algoritmi che intervengono nella detection di anomalie respiratorie

In questo paragrafo, verranno analizzati gli algoritmi che intervengono nella detection di anomalie cardiache.

² <https://physionet.org/content/mitdb/1.0.0/>

3.2.1 Individuazione di anomalie sulla frequenza respiratoria

Per individuare anomalie sulla frequenza respiratoria è, innanzitutto, necessario determinare quest'ultima a partire dal segnale. Questo dato viene calcolato utilizzando una tecnica di *zero crossing*, ad onde respiratorie pre-elaborate [7].

La tecnica prevede di valutare il periodo in cui campioni successivi fanno registrare una variazione di segno. In tal caso, diventa fondamentale conservare l'informazione dell'istante temporale in quanto indicativa di un attraversamento del segnale per lo zero.

Una volta ottenuti tutti gli attraversamenti per lo zero - in una determinata finestra temporale - si possono valutare le varie lunghezze tra gli attraversamenti temporali. Se rapportate nel tempo, queste lunghezze daranno indicazioni sulle durate dei singoli cicli respiratori.

Attraverso una semplice elaborazione, è possibile, infine, ottenere il numero del ciclo dei respiri al minuto, definito come *bpm (breaths per minute)*.




Figura 9. Esempio applicativo della tecnica di zero-crossing per la valutazione degli attraversamenti per lo zero di un'onda respiratoria

Una volta ottenute le informazioni descritte precedentemente, sarà possibile eseguire opportuni confronti a soglia per rilevare eventuali condizioni di anomalia. Nello specifico, si sono definite euristiche utili a individuare le seguenti anomalie:

- **Tachipnea:** se la frequenza respiratoria rilevata eccede una soglia personale dell'utente monitorato;
- **Bradipnea:** se la frequenza respiratoria rilevata risulta al di sotto di una soglia personale dell'utente monitorato;
- **Sleep Apnea:** se la frequenza respiratoria rilevata risulta al di sotto di una soglia personale dell'utente monitorato durante il sonno.

Anche in questo caso, esattamente come per le anomalie riguardanti la frequenza cardiaca, le soglie vengono comunicate al dispositivo che installa il DSS di livello due dal software di monitoraggio, dopo che sono state decise, assistito per assistito, da uno specialista.

3.2.2 Individuazione di anomalie sull'intensità del respiro

La *flat-line* è uno dei parametri critici quando si analizza un'onda del respiro [31]. Questa permette di determinare se l'intensità del respiro è costante e permette di identificare eventuali episodi di affievolimento del respiro dovuti ad un decremento dell'intensità del respiro.

In ATTICUS, dunque, verrà integrato un detector che si occuperà di segnalare eventuali fenomeni di degrado dell'intensità del respiro.

La detection avverrà a partire dall'analisi dei picchi respiratori. Questa, dunque, integrerà parte dell'elaborazioni previste al paragrafo precedente, ovvero quelle propedeutiche al calcolo della frequenza respiratoria.

La conoscenza delle posizioni dei picchi e delle intensità relative ai picchi nell'onda del respiro permetterà di definire un'analisi basata sulla valutazione delle ampiezze in una finestra di cinque cicli respiratori.

Si veda un esempio nella figura seguente.




Figura 10. Esempio di fenomeno di degradamento dell'intensità del respiro

3.3 Algoritmi che intervengono nella *detection* in base ai dati inerziali

In questo paragrafo, verranno analizzati gli algoritmi che intervengono nella *detection* di anomalie ed attività derivanti dai dati inerziali. Entrambi questi algoritmi sono stati già presentati nel deliverable 5.4. Per semplicità, verranno riportati i punti più importanti anche di seguito.

3.3.1 Fall-Detection

Nell'ambito di ATTICUS, verrà utilizzato un metodo automatico basato su reti neurali, come proposto recentemente nel lavoro in [8]. Gli autori impiegano il deep learning nella *fall detection* e propongono un modello di Rete Neurale Convoluzionale (CNN) – etichettato come **CNN-3B3Conv** – e ne valutano le prestazioni. Queste poi sono state comparate con i lavori di riferimento della letteratura scientifica che utilizzano approcci basati su altre architetture di reti neurali, quali *Long-Short Term Memory* (LSTM).

I risultati sperimentali suggeriscono che il modello CNN proposto (che utilizza una tecnica di *Data Augmentation* per la fase di training) presenti risultati migliori di *fall detection* rispetto a metodi basati su LSTM [9]. Inoltre, verrà valutata l'aggiunta delle informazioni sulle variazioni di postura dell'assistito in seguito ad una caduta.

Identificata una potenziale caduta, il sistema di supporto alle decisioni di livello due del sistema ATTICUS avrà il compito di rigettare un potenziale false positive o confermare l'episodio, attraverso un'elaborazione specifica più complessa di quella attuata dal componente elettronico.

Nello specifico, per un'accurata identificazione di cadute, si valuterà di integrare anche alcuni step previsti dal metodo proposto da Mao et al. [9]. Gli autori riportano che il processo di caduta di un individuo può essere suddiviso in tre fasi:

- *inizio*: il corpo umano perde l'equilibrio e "cade" verso il terreno;
- *impatto*: il corpo umano cade a terra e viene a contatto con il terreno;
- *postura*: il corpo umano rimane a terra per almeno un breve periodo di tempo.

Durante queste tre fasi, l'accelerazione del corpo umano cambia bruscamente, così come mostrato nella Figura 11. Nello specifico, il valore del *Root Mean Square* (RMS) dell'accelerazione del corpo umano è molto prossima allo zero durante la fase iniziale, per poi bruscamente raggiungere il suo picco durante l'impatto. Dopodiché, l'RMS rimane quasi stabile con leggere fluttuazioni durante la

fase di postura. Ciò suggerisce che l'analisi del RMS dell'accelerazione, attraverso un opportuno valore soglia, è un ottimo indicatore per una caduta. Tuttavia, altre attività fisiche, come ad esempio il saltare, potrebbero portare ad una brusca accelerazione del corpo umano e quindi ad un'identificazione errata della caduta.

Al fine di mitigare tale problema, Mao *et al.* [9] hanno proposto un metodo per l'identificazione delle cadute che oltre a considerare l'RMS dell'accelerazione del corpo umano, analizza anche la postura dello stesso dopo l'aumento di accelerazione. La postura è analizzata attraverso un algoritmo che fa uso dell'angolo di Eulero, una quantità che rappresenta l'orientamento spaziale di un corpo. In questo modo, gli autori utilizzando una soglia per l'RMS dell'accelerazione pari a 2.3 g e posizionando un singolo accelerometro all'altezza della vita, riescono ad indentificare cadute con un livello di accuratezza pari al 100%.




Figura 11. L'impatto e l'analisi della postura su base accelerometrica [9]

In ATTICUS, l'identificazione avverrà considerando l'approccio automatico alla *detection* basato su reti neurali con l'aggiunta dell'informazione sulla postura del corpo umano, così come suggerito da Mao *et al.* [10].




Figura 12. Le componenti angolari per il rilevamento della postura.

3.3.2 Human Activity Recognition

Per l'integrazione di un modello di *detection* automatica dell'attività dell'assistito, verrà integrato nel DSS di livello 2 di ATTICUS un approccio basato su reti neurali, così come proposto nel lavoro di Okai *et al.* [11].

In questa ricerca, gli autori propongono un'architettura di rete neurale ricorrente ed un approccio di *Data Augmentation* per costruire modelli robusti e accurati per l'HAR. Hanno confrontato i modelli LSTM con le reti ad architettura GRU (*Gate Recurrent Unit*).

In questo studio empirico, hanno anche valutato alcune relazioni tra le posizioni ideali dei sensori nei partecipanti e nei tipi di attività svolte. Gli approcci proposti sono stati testati su un dataset che ha visto il coinvolgimento di 35 partecipanti che hanno svolto 16 attività sedentarie, ambulatoriali e di stile di vita in un ambiente semi-strutturato. I risultati presentati, mostrano chiaramente che i modelli sono in grado di rilevare queste attività in modo robusto.

3.4 Algoritmi che intervengono nella detection di anomalie termiche

In questo paragrafo, verranno analizzati gli algoritmi che intervengono nella detection di anomalie ed attività derivanti dai dati di temperatura. Entrambi questi algoritmi sono stati già presentati nel deliverable 5.4. Per semplicità, verranno riportati gli *highlight* anche di seguito.

3.4.1 Le euristiche per il colpo di calore

Attraverso l'analisi costante della temperatura, il sistema di supporto alle decisioni del sistema ATTICUS identifica una particolare situazione di stress termico che potrebbe portare ad un colpo di calore. La detection avverrà attraverso la procedura descritta da Palma *et al.* [12]: un allarme è generato se il battito cardiaco dell'assistito è superiore ad una soglia f (di default pari a 100 bpm) e si registra un cambiamento di temperatura corporea pari a $0.1^{\circ}\text{C}/\text{min}$ per un periodo di tempo t (di default pari a 20 minuti).

3.4.2 Le euristiche per la valutazione della temperatura corporea

Questo detector, sulla base del valore di temperatura corporea rilevato dalla sensoristica, eseguirà un opportuno confronto a soglia per stabilire se l'assistito superi o meno un determinato valore personale di temperatura con gravità gialla.

3.5 Algoritmi che intervengono nella detection di stati di stress

Il rilevamento del livello di stress dell'assistito in ATTICUS verrà implementato sulla base del lavoro proposto in [13]. In questo articolo viene presentata un approccio basato su Reti Neurali Artificiali

per la classificazione dello stress. Usando una rete con architettura a due livelli di tipo *back-propagation* si è ottenuto un ottimo strumento per la classificazione della condizione del paziente. Utilizzando un numero sufficiente di parametri appropriati per l'addestramento, la Rete Neurale è in grado di fornire risultati precisi e affidabili con una precisione del 99% e una sensibilità del 98%.

Come dati di addestramento, gli autori hanno utilizzato informazioni di frequenza cardiaca, frequenza respiratoria e di risposta galvanica della pelle acquisiti in un determinato tempo.

3.6 Algoritmi che intervengono nella detection di anomalie comportamentali

In questo paragrafo verranno descritti gli algoritmi che intervengono nell'individuazioni di anomalie che riguardano, in generale, il comportamento degli assistiti. La metodologia definita prevede l'utilizzo di un algoritmo generico di *detection* di comportamenti anomali: tale algoritmo, istanziato per ogni specifico comportamento, permette di determinare la probabilità che una persona adotti il comportamento monitorato in uno specifico momento. Se il comportamento monitorato è, ad esempio, lo stare svegli, l'algoritmo sarà in grado di segnalare situazioni in cui la persona è sveglia durante la notte, quando tale comportamento risulta essere raramente adottato dall'assistito. Oltre all'algoritmo di base, è prevista la presenza, per ogni comportamento considerato, di un algoritmo in grado di individuare se il comportamento viene adottato o meno in un dato momento. Seguendo l'esempio precedente, è prevista la presenza di un algoritmo in grado di individuare se, in un dato momento, l'assistito è sveglio o sta dormendo.

L'algoritmo di *detection* utilizzato prevede una prima fase di addestramento, in cui si osservano i comportamenti dell'assistito e si raccolgono dati, al fine di definire quali sono i comportamenti *normali*. In questa fase, l'algoritmo non sarà in grado di individuare anomalie comportamentali. Successivamente, tuttavia, l'algoritmo farà, contemporaneamente, (i) raccolta di nuovi dati, al fine di aggiungere evidenze relative all'adozione dei comportamenti monitorati, (ii) individuazione automatica di comportamenti anomali. Si noti che i dati comportamentali di ogni assistito verranno conservati nel dispositivo S-BOX: per ogni assistito, dunque, esisterà un modello diverso, in base ai

comportamenti specifici della persona. Questo permette da un lato di evitare la comunicazione di dati potenzialmente sensibili al sistema centrale, dall'altro di avere modelli calibrati sulla specifica persona.

Di seguito, verrà prima descritto in dettaglio l'algoritmo di *detection* di comportamenti anomali; successivamente, verranno elencati i comportamenti che saranno monitorati nel sistema ATTICUS e verranno descritti gli algoritmi usati in ATTICUS per individuare l'adozione di tali comportamenti.

3.6.1 Algoritmo di detection di comportamenti anomali

Si assuma di monitorare un comportamento C di un assistito A . In ogni dato momento, l'assistito può adottare il comportamento C ($C_A = 1$) o meno ($C_A = 0$). Si assuma anche l'esistenza di un algoritmo D , specifico per C , in grado di determinare il valore di C_A in ogni dato momento, in base ai dati ottenibili dal dispositivo S-WEAR. L'algoritmo di *detection* di anomalie comportamentali di C_A prevede due fasi: quella di *addestramento* e quella di *individuazione* di anomalie. Mentre la prima viene sempre eseguita, in modo da poter apprendere anche cambiamenti nelle abitudini dell'assistito, la seconda viene eseguita solo dal momento in cui si hanno abbastanza dati.

Addestramento. Viene memorizzato lo stato iniziale di C_A (C_A^L) individuato da D . Ogni minuto viene eseguito nuovamente D per aggiornare C_A . Quando C_A cambia valore (risulta essere diverso da C_A^L) viene registrata un'istanza in memoria, contenente data e ora in cui il cambiamento è avvenuto e valore di C_A . Viene, quindi, aggiornato C_A^L e vengono ripetute le operazioni precedentemente descritte. Una volta al giorno viene eseguita una procedura che, date le istanze contenenti le date e gli orari in cui sono stati cambiamenti di valore relativi al comportamento, viene aggiornato un *dataset* contenente le seguenti caratteristiche:

- *Fascia oraria*: indica una specifica fascia oraria (es: dalle 18:00 alle 19:00);
- *Giorno della settimana*: indica un giorno della settimana (es: lunedì);
- *Giorno festivo*: indica se il giorno era festivo o feriale;

- *Durata*: indica per quanto tempo (in minuti), nella fascia oraria e nel giorno della settimana di riferimento, il comportamento C è stato adottato;

Per estrarre tali istanze a partire dai dati grezzi memorizzati dall'algoritmo, si parte dalla prima istanza, si considerano gli intervalli di un'ora e, per ognuno di essi, si conta il numero di minuti che C_A ha assunto valore 1. Il giorno della settimana e il fatto che il giorno sia festivo o meno vengono determinati a partire dalla data che si sta analizzando.

Un esempio di *dataset* concreto è fornito in Tabella 2: com'è possibile notare, in questo caso, un primo giorno d'esempio (lunedì) l'assistito è stato sveglio tra l'una e le due di notte per un minuto (riga uno); al contrario, un altro lunedì (riga due), l'assistito ha dormito sempre in quella stessa fascia oraria (durata 0); nella terza riga, infine, si può notare come l'assistito fosse sveglio durante l'intera ora.

Festivo	Fascia oraria	Giorno	Durata
No	1:00-2:00	Lunedì	1
No	1:00-2:00	Lunedì	0
Sì	16:00-17:00	Domenica	60

Tabella 2. Esempio di dataset per l'individuazione di anomalie relative alla veglia.

Individuazione. Per individuare se l'assistito sta adottando un dato comportamento in maniera anomala, viene innanzitutto memorizzato lo stato iniziale di C_A (C_A^L) individuato da D , insieme l'ora x in cui è stato registrato. Ogni minuto viene determinato se l'adozione del comportamento risulta essere anomala, in base al dataset raccolto e, successivamente, viene eseguito nuovamente D per aggiornare C_A^L . Per determinare se il comportamento è anomalo, quando $C_A^L = 1$ (il comportamento viene effettivamente adottato) viene eseguita una procedura per inferire la probabilità che l'assistito abbia il comportamento C per un tempo superiore al tempo passato da x , nelle circostanze temporali di riferimento: se tale probabilità è inferiore all'1%, viene inviato un warning al DSS di livello superiore. Per determinare tale probabilità, si eseguono i seguenti passi:

- si individuano le caratteristiche del giorno e dell'ora in questione, ovvero *fascia oraria*, *giorno della settimana* e *festività*;
- si estrae dal dataset l'insieme S delle istanze che hanno le caratteristiche precedentemente individuate;
- si calcola il tempo t passato dal momento in cui l'adozione del comportamento è iniziata, ovvero x ;
- si seleziona il sottoinsieme di istanze V di S contenente le istanze i tali che la durata registrata di i è maggiore o uguale a t ;
- si stima la probabilità attraverso la formula $\frac{|C|}{|S|}$.

In altre parole, l'algoritmo controlla quante volte, in passato, la persona ha adottato il comportamento C per più di t minuti nelle stesse circostanze temporali attuali. La dimensione dell'insieme S indica il *supporto* della predizione: maggiore è $|S|$, maggiore è la fiducia dell'algoritmo nella predizione, poiché questa è basata su più dati. Per evitare predizioni basate su un supporto non sufficiente, l'algoritmo ignora i casi in cui il supporto è inferiore a dieci istanze.

3.6.2 Veglia

Un primo comportamento che viene monitorato da ATTICUS è lo stato di veglia. Si noti che questo vuol dire che il sistema sarà in grado di individuare casi in cui l'assistito è sveglio in maniera anomala in alcune ore del giorno, ma non viceversa (ovvero, che l'assistito dorma in maniera anomala), dato che quest'ultima circostanza può essere dovuta a molteplici cause non necessariamente indicanti un problema di salute. Al contrario, se una persona è sveglia a un orario anomalo (es: di notte), questo può indicare un malore, uno stato di ansia, che potrebbero sfuggire agli altri detector di anomalie fisiologiche.

Algoritmo per l'individuazione dello stato di sonno/veglia.

Diversi algoritmi proposti in letteratura fanno uso di dati cardiaci per discriminare lo stato di veglia dal sonno negli individui. Tra questi, il lavoro proposto da Casal e colleghi [32] utilizza una serie di 70 descrittori, calcolati dalla frequenza cardiaca, per la discriminazione automatica dello stato di veglia/sonno. In particolare, le feature da calcolare sono le seguenti:

- Features basate su *Approximate Entropy* (una misura della regolarità dei dati);
- Features basate su *Sample Entropy* (per superare i problemi di bias dell'Approximate EntropyAp. Per superare questa limitazione, è stato proposto questo stimatore, largamente indipendente dalla lunghezza del record e che mostra una maggiore coerenza rispetto ad ApEn);
- Features basate su *Fuzzy Entropy* (simile al Sample Entropy ma il kernel viene calcolato attraverso una funzione fuzzy);
- Features basate su *Dispersion Entropy* (computazionalmente, meno dispendiose di quelle calcolate ai suddetti punti).

Inoltre, vi è un ulteriore set di features da calcolare in domini tempo-frequenza o solo nel dominio della frequenza.

In ATTICUS si implementerà un detector di stati di veglia/sonno sulle base delle suddette feature.

3.6.3 Rimozione del wearable

Idealmente, gli assistiti del sistema ATTICUS indossano sempre il wearable. Nella realtà, tuttavia, possono esistere circostanze in cui l'assistito ha necessità di rimuovere il dispositivo (ad esempio, per lavarsi). Non indossare il wearable a un orario anomalo e, soprattutto, per un tempo anomalo può comportare un rischio per l'assistito e può anche indicare che l'assistito ha avuto un malore mentre il wearable non può monitorare i suoi parametri vitali. Se, ad esempio, quando fa la doccia,

l'assistito impiega al più 30 minuti e, in un dato giorno, impiega più di 40 minuti, il sistema identifica un'anomalia.

Algoritmo per l'individuazione della rimozione del wearable.

Questo detector si baserà sulle informazioni ottenibili nel registro STATUS 0x01 negli ultimi 4 bit del sensore MAX3001. Per la detection, occorrerà configurare una soglia CNFG_GEN. In questo modo, sarà possibile stabilire quando un sensore perde il contatto con la pelle.

La combinazione di questa informazione su tutti i sensori del corpetto di ATTICUS permetterà di discriminare la completa rimozione del wearable.

3.6.4 Uscita di casa

Se l'assistito è fuori casa a orari anomali e per una durata superiore alla norma, è possibile che stia correndo un pericolo che non viene esplicitamente monitorato dal sistema ATTICUS: ad esempio, è possibile che l'assistito si sia perso o che abbia avuto un incidente, sebbene non tanto grave da modificarne i parametri vitali (es: incidente automobilistico). Anche in questo caso, non viene monitorato il comportamento opposto (ovvero, i casi in cui l'assistito è in casa quando, normalmente, esce) poiché, di nuovo, questo comportamento comporta una categoria di rischio generalmente minore.

Algoritmo per l'individuazione delle uscite di casa.

L'uscita di casa dell'assistito verrà valutata in base alla posizione geografica dello stesso. Se risulterà oltre una distanza prefissata dalla sua abitazione (es: 500m), il sistema discriminerà tale stato come "Fuori casa".

3.7 Algoritmi per il monitoraggio degli spostamenti

In questo paragrafo, verranno analizzati gli algoritmi che intervengono nelle analisi di indoor localization ed outdoor tracking.

3.7.1 L'algoritmo di outdoor tracking

Per il tracciamento della posizione outdoor, uno specifico detector di ATTICUS si occuperà di monitorare gli spostamenti delle persone in modo da allertare prontamente un intervento di un *caregiver* o di staff specializzato.

Tramite il software QGIS3 sarà possibile interrogare le mappe di Open Street Map attraverso il tool QuickOSM4, il quale permetterà di prelevare dati dalla piattaforma Open source, utilizzando semplici parole chiave.

Verranno considerate come zone di rischio importanti:

- **Binari dei treni:** i treni, al giorno d'oggi, viaggiano ad alte velocità e fanno fatica a frenare in prossimità di una persona sui binari. Inoltre, verranno rimossi dai record ottenuti tutti i segmenti di binario che fossero: dismessi, in costruzione, tunnel, sottopassaggi etc. ovvero quelli in cui i treni non circolano.
- **Fiumi, ruscelli, laghi e qualsiasi altro corso d'acqua:** tali zone sono considerate rischiose in quanto un utente poco esperto, anche senza corrente d'acqua può inciampare, sbattere la testa o comunque provocarsi gravi lesioni. Sono state escluse dalle scelte i corsi d'acqua identificati come: sotterranei, in prossimità di ponti.
- **Limiti costieri.**

³ Software utilizzato per analisi del territorio geografico

⁴ Plugin per QGIS utilizzato per estrapolare dati geografici

Le suddette zone verranno estrapolate dalla mappa, regione per regione e fuse fra loro andando a formare un unico layer di vettori in formato di coordinate ESPG:32632 WGS84.

Questo detector nasce principalmente con l'obiettivo di aiutare le persone che in età avanzata sono affette da demenza senile o dal morbo di Alzheimer. Ovviamente, tale tecnologia risulta poi esportabile anche in domini formati da persone sane e di età diversa, come i minori. Secondo il Commissario straordinario del Governo, si stima che dal 1974 al 31 marzo 2019 siano scomparsi 122.508 minori, di cui solo 80.464 sono stati ritrovati⁵.

La maggior parte delle applicazioni disponibili in rete, che forniscono funzionalità per il monitoraggio degli utenti, si limitano a tracciare la posizione geografica e consentono lo scambio di messaggi. Il punto forte, che caratterizza il sistema Colin, si incentra sulla pre-analisi svolta al fine di identificare tutte le zone di rischio nel territorio italiano, al fine di eseguire calcoli automatici per permettere una classificazione del livello di pericolosità, in base alla distanza dell'utente dai luoghi identificati come rischiosi. Inoltre, il sistema è composto da un assistente di bordo, in grado di ricondurre l'utente da una zona di rischio, verso una zona sicura. I principali svantaggi del sistema sono rappresentati:

- dalla necessità di una connessione internet continua e sufficientemente performante;
- il bisogno di una visibilità del cielo discreta;
- l'obbligo di portare con sé il proprio smartphone.

Al momento, tali limitazioni sono dovute principalmente a mancanza di tecnologie sufficientemente sviluppate ed alla volontà di rendere accessibile il sistema a tutti gli utenti.

Il DSS di livello due avvierà un servizio costantemente attivo in background sullo smartphone dell'assistito (nell'applicazione MyATTICUS) a partire dalla prima apertura. Il suo obiettivo è quello di ottenere la posizione geografica, eseguire le triangolazioni con i poligoni delle zone di rischio e

⁵ https://www.interno.gov.it/sites/default/files/slides_minori_scomparsi.pdf

identificare il livello di pericolosità in cui l'utente si trova. Nel momento in cui la posizione dell'utente cambia, il servizio aggiorna la posizione geografica ed effettua i controlli.

Il servizio in background sarà ottimizzato per garantire il minor consumo di batteria possibile, andando a rimodulare i parametri di interazione dell'app con i sensori di geolocalizzazione. Le modifiche consistono nel definire la potenza del segnale GPS, la precisione del segnale GPS, la frequenza di aggiornamento della posizione (trovando un giusto rapporto fra tempo di aggiornamento e stima dei metri percorsi dall'ultima posizione registrata). Questo meccanismo consente di risparmiare energia nella maggior parte della giornata, in cui generalmente l'utente si trova in zone a rischio zero, e concentrare gli sforzi in caso di necessità.

Il sistema di rilevamento dei rischi consiste in cinque diverse fasi:

1. richiesta della posizione geografica;
2. caricamento dei poligoni delle zone di rischio in un raggio di 250 metri intorno alla posizione dell'utente;
3. controllo della posizione: se la posizione esce dalla cornice (raggio di 250 metri intorno alla posizione dell'utente caricata nell'ultimo aggiornamento) della mappa dei poligoni delle zone di rischio, allora riesegue il punto 2;
4. triangolazione dei punti di controllo dei poligoni delle zone di rischio con la posizione geografica dell'utente;
5. calcolo della minima distanza perpendicolare al poligono; il livello di pericolosità è determinato comparando tale distanza, con delle categorie di pericolosità, impostate di default a:
 - a. rischio basso per una distanza compresa fra 60 e 40 metri;
 - b. rischio medio per una distanza compresa fra 40 e 10 metri;
 - c. rischio alto per una distanza compresa fra 10 e 0 metri.

Quando viene individuata una situazione di anomalia, il DSS di livello due invia un allarme se il rischio è alto.




Figura 13 Identificazione dei pericoli

Nella Figura 13 si mostra un esempio in cui tre utenti (A, B e C) sono nei pressi di un fiume (poligono con forma irregolare e continua da sinistra verso destra) e un lago (poligono a forma di cerchio irregolare posto nella parte superiore destra dell'immagine):

- *utente A*: la sua posizione geografica giace ad una distanza maggiore di 60 metri da un qualsiasi poligono di rischio, per cui è identificato come in una zona con livello di rischio nullo;
- *utente B*: la sua posizione geografica si trova ad una distanza compresa fra i 40 e i 10 metri dal poligono che identifica un fiume. Il livello di rischio ad egli associato è rischio medio;
- *utente C*: la sua posizione geografica è ad una distanza inferiore ai 10 metri dal poligono che identifica un fiume, e dunque è in una zona con livello di rischio alto.

4 Algoritmi relativi al livello 3 del DSS

Al livello 3 del *Decision Support System* di ATTICUS verranno utilizzati diversi algoritmi di detection. In questa sezione, gli algoritmi scelti per ogni tipo di *detection* sono raggruppati per sorgente dell'anomalia.

4.1 Algoritmi che intervengono nella detection di anomalie cardiache

Gli algoritmi relativi alla sorgente "cuore" sono descritti di seguito, in base al tipo di patologia riscontrata.

4.1.1 Extrasistoli

Gli episodi di extrasistoli ventricolari (comunemente definiti in letteratura come PVC, *Premature Ventricular Contractions*) verranno rilevati utilizzando un algoritmo descritto principalmente nel lavoro proposto in [14].

Una PVC riguarda un battito cardiaco la cui origine non è in un nodo sinuatriale ma nell'altra area dei ventricoli, di solito le fibre di Purkinje. La PVC è una delle aritmie ventricolari più comuni. Secondo i dati dell'elettrocardiogramma, durante le indagini di grandi gruppi, la PVC viene rilevata nel 5% della popolazione durante le visite mediche di routine [15].

Sebbene la maggior parte di tali aritmie sia rappresentata da singole PVC, sono possibili anche forme complesse. Il metodo principale per la diagnostica della PVC è il monitoraggio Holter, che implica una registrazione a lungo termine del segnale ECG.

Dopo diversi giorni di monitoraggio, un cardiologo interpreta i dati raccolti dal dispositivo. Anche altri metodi, come il monitoraggio ambulatoriale continuo o periodico dell'ECG, aiutano ad associare i sintomi osservati a disturbi del ritmo cardiaco ed a rilevare episodi asintomatici di ischemia miocardica. I consulenti medici solitamente assegnano il monitoraggio Holter 24 ore su 24 o 48 ore quando si verificano (o possono verificarsi) episodi di aritmia almeno una volta al giorno.



Figura 14. Episodio di PVC, indicato dalla freccia

Gli stati potenzialmente pericolosi nell'identificazione di episodi di PVC riguardano:

- la frequenza delle occorrenze di episodi di PVC (**raro** se minore di 30 per ora e **frequente** se più di 30 per ora);
- la densità, intesa come più battiti PVC consecutivi;
- la durata degli episodi di PVC;
- il tempo di apparizione in diastole (precoce, medio, tardivo).

L'algoritmo proposto dagli autori prevede inizialmente di impostare una *sliding window* (finestra scorrevole) di 10 secondi e di calcolare il valore di riferimento della durata media dell'intervallo RR [16].

Questo valore è valido solo per la prima finestra scorrevole.

Inoltre, l'algoritmo ricalcola questo valore per ogni nuova finestra, considerando così la variabilità individuale della frequenza cardiaca normale (ritmo sinusale dovuto all'attività respiratoria).

L'RRM è una media aritmetica della durata del normale ciclo cardiaco per la precedente finestra scorrevole. L'RRM è pari a 1 secondo per la prima finestra scorrevole, mentre per la seconda e per le finestre scorrevoli successive sarà corretto come media aritmetica della durata dei normali cicli cardio nella finestra scorrevole.

Quindi, utilizzando l'algoritmo di Pan-Tompkins modificato, sarà possibile rilevare l'onda R dell'ECG per ogni intervallo cardiaco corrente, sia normale che patologico (PVC) con una forma distorta (Fig.15).




Figura 15. Esempio di segnale con il complesso QRS distorto a causa del PVC

Per rilevare l'onda R del segnale dell'elettrocardiogramma in tempo reale, gli autori hanno utilizzato la modifica del noto algoritmo Pan-Tompkins, che ha un buon tasso di rilevazione (almeno il 95%), e con l'aumento delle moderne capacità degli smartphone e dei tablet, la sua implementazione non richiede una grande quantità di risorse hardware [17].

La qualità dei segnali ECG registrati può variare a seconda dello stato attuale del paziente e delle influenze esterne (varie fonti di interferenza), pertanto, l'algoritmo sviluppato include una serie di blocchi di base, il cui numero può essere aumentato se necessario (in caso di un alto livello di interferenza) per aumentare l'affidabilità del suo lavoro.

Allo stesso tempo, blocchi separati possono essere eseguiti sia a livello strumentale (filtraggio analogico e amplificazione dei segnali), sia a livello digitale dopo la conversione analogico-digitale dei segnali.

Dopo l'elaborazione del segnale ECG, il rilevamento delle onde R ed il calcolo degli intervalli RR, si forma la finestra scorrevole di $TSW = 10$ secondi con l'offset pari ad un normale ciclo cardiaco del seno. La durata della finestra determina il tempo di elaborazione e di analisi di tutti i cicli cardiaci all'interno della finestra.

Lo spostamento successivo della finestra avviene solo dopo che l'analisi delle caratteristiche dei cicli cardiaci al suo interno è stata completata. Così, la dimensione della finestra di 10 secondi riduce il tempo di elaborazione e di analisi e l'offset della finestra pari alla durata di un ciclo cardiaco aumenta l'affidabilità dell'algoritmo.

All'interno della finestra scorrevole, l'algoritmo valuta la durata dell'intervallo RR_i corrente e calcola il rapporto $K_i = R_i/RRM$ per ogni i -esimo ciclo cardiaco corrente, dove RRM è il valore medio dell'intervallo del normale ciclo cardiaco del seno per la posizione precedente della finestra scorrevole. Nella fase successiva, controlla se la durata dell'intervallo RR_i corrente è normale ($0.9 < K_i < 1.1$). In questo caso, i valori di soglia vengono impostati in base alla variabilità della frequenza cardiaca individuale del paziente.

Nel caso considerato, viene utilizzato un intervallo di offset del 10 percento della durata RR_i rispetto al valore medio. Se il rapporto K_i non rientra nell'intervallo dei valori normali, l'algoritmo esegue un'ulteriore analisi dell'intervallo RR corrente per il rilevamento della presenza di PVC. Per eseguire

questa operazione, l'algoritmo verifica se il valore corrente del rapporto K_i cade in un intervallo di soglia più stretto ($0.4 < K_i < 0.9$).

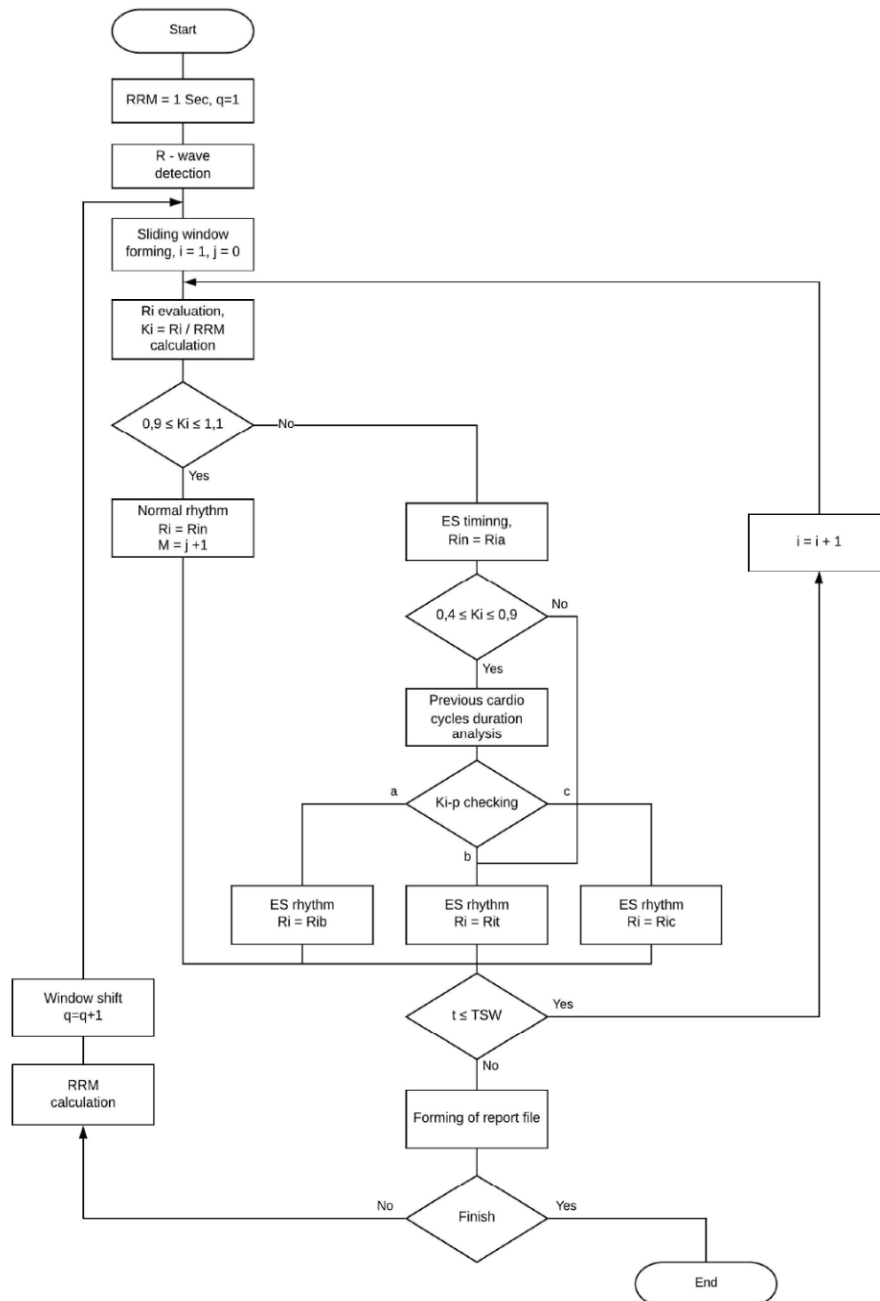


Figura 16. Il diagramma a blocchi dell'algoritmo per il rilevamento in tempo reale degli episodi di PVC

Se questa condizione è vera (ovvero, viene rilevato una PVC), per valutare la frequenza di comparsa delle PVC e per distinguere le PVC per tipo, l'algoritmo prevede di analizzare la durata dei cicli cardiaci precedenti e di determinare il numero di cicli cardiaci normali che precedono le PVC identificate.

I tipi di PVC sono i seguenti:

- **bigeminy** (condizione **a**) - i PVC si alternano a un normale ciclo cardiaco sinusale o appaiono due impulsi aggiuntivi nell'intervallo di un normale ciclo cardiaco;
- **trigeminy** (condizione **b**) - i PVC appaiono dopo due cicli cardiaci sinusali;
- **quadrigeminy** (condizione **c**) - i PVC appaiono dopo tre normali complessi QRS.

Tutti i cicli cardiaci all'interno di una finestra scorrevole della durata di un *TSW* vengono controllati per verificare la presenza di impulsi PVC aggiuntivi.

Il contatore dei cicli cardiaci aumenta di un $i = i + 1$ dopo l'analisi delle caratteristiche del ciclo in corso ed inizia l'analisi delle caratteristiche del ciclo cardiaco successivo. Se la durata del ciclo cardiaco successivo supera la durata dell'attuale finestra scorrevole, viene generato un rapporto finale per questa finestra, viene calcolato l'intervallo *RR* medio per i cicli cardiaci sinusali (i cicli cardiaci con PVC non vengono conteggiati) e la finestra scorrevole viene spostata di un ciclo cardiaco.

4.1.2 Tachicardia Ventricolare

Gli episodi di tachicardia ventricolare verranno rilevati utilizzando un algoritmo descritto principalmente nel lavoro proposto in [18].

Nell'articolo, gli autori confrontano diversi algoritmi per la discriminazione della tachicardia ventricolare e della fibrillazione ventricolare rispetto ad un ritmo sinusale, come mostrato in Tabella 3.

Tabella 3. Algoritmi confrontati dagli autori e relativi risultati di discriminazione [18]

Methods	NSR-VT	NSR-VF	VT-VF
Slope Histogram (kurtosis)	0.9480	0.9463	0.5714
Slope Histogram (variance)	0.9191	0.8725	0.6571
Slope Count	0.9653	0.9799	0.6857
Slope Complexity	0.8439	0.9664	0.7714
Complexity	0.6185	0.8121	0.7286

In ATTICUS, l'interesse maggiore è stato posto sulla discriminazione tra ritmo di Tachicardia Ventricolare (VT) e ritmo sinusale (NSR). Per questo, si è optato per l'integrazione del metodo che ha fatto registrare metriche di classificazione migliore: il metodo denominato *Slope Count*, in quanto ha permesso di ottenere una *Overall Accuracy* superiore al 96.5 %.

Il rationale dietro questo metodo va ricercato nella natura morfologica di un ritmo di Tachicardia Ventricolare, che mostra repentini e ravvicinati cambiamenti di segno nel segnale elettrocardiografico.

Le pendenze del segnale dell'ECG sono di piccolo valore e variano in modo uniforme man mano che il segnale avanza nel tempo, ad eccezione dei complessi QRS in cui si osserva un brusco cambiamento. Tuttavia, ci sono molte variazioni di segnale in ritmi di VT (Tachicardia Ventricolare) e VF (Fibrillazione Ventricolare) e le loro pendenze cambiano in modo permanente nel tempo. Questo stimola la motivazione ad utilizzare la pendenza come caratteristica discriminante per il rilevamento delle aritmie cardiache.

La pendenza è definita come la derivata prima del segnale come rappresentato dalla seguente equazione:

$$m = \frac{f(n) - f(n - h)}{h}$$

dove h rappresenta la distanza tra due campioni, utilizzati per la derivazione. Se h è selezionato di grandi dimensioni, la pendenza può mancare le transizioni veloci del segnale e se selezionato di piccole dimensioni può essere influenzato dal rumore ad alta frequenza.

Pertanto, per fare un *trade-off*, è stata eseguita una differenziazione in cinque punti ed il segnale di pendenza è stato ottenuto come

$$M = \{mj \mid j = 1, \dots, WL * fs/h\}$$

dove WL è la lunghezza della finestra in secondi e fs è la frequenza di campionamento.

Sulla base di questa fase iniziale, è stato sviluppato questo metodo basato sull'analisi della pendenza. Lo pseudo codice dell'algorithm. che è adatto per applicazioni in tempo reale, è descritto in dettaglio nel seguito:

- **STEP 1:** Porre la variabile *count* = 0, prendere il primo secondo del segnale originale e calcolare tutti gli *slope*, definendo il vettore $PrSL = \{mi \mid i=1, \dots, fs/5\}$;
- **STEP 2:** Calcolare gli *slope* nel prossimo segmento di segnale di 1 secondo (definendo il vettore SL);
- **STEP 3:** Concatenare PrSL ed SL in modo da ottenere un vettore di 2 secondi. Applicare l'operatore di valore assoluto al vettore e poi trovare il picco, definito *ms*;
- **STEP 4:** Per ogni *slope* nel vettore di 2-sec, se la pendenza è positiva e più grande di una soglia di $0.2 * ms$, allora - se l'ultima pendenza che aveva verificato il superamento della soglia era negativa - ne viene assegnata una al relativo segmento dei campioni di lunghezza h . **Altrimenti**, se era positiva, cioè si è persa una pendenza con segno negativo, allora ne viene assegnata una al corrispondente segmento se la loro distanza supera $7*h$.

La stessa procedura viene eseguita per le pendenze inferiori a $-0.2*ms$.

Per ognuna delle condizioni sopra menzionate, la variabile *count* viene aumentato di un'unità;

- **STEP 5:** PrSL = SL e tornare indietro al passo 2.

In questo modo la soglia di pendenza viene selezionata per ogni 2 secondi del segnale di pendenza, ma viene aggiornata ogni secondo. Pertanto, l'analisi deve essere eseguita su finestre di 8 secondi (cioè un secondo di preelaborazione e 7 secondi di processo del segnale).

Gli autori di questo lavoro non hanno specificato la soglia numerica – da applicare sulla variabile *count* - che permetta di discriminare un segnale ECG dalla durata di 8 secondi che contenga un episodio di VT da un episodio di ritmo sinusale.




Figura 17. Ritmo sinusale e relativi slope ottenuti nel segnale binario previsto dal metodo




Figura 18. Ritmo con episodio di VT e relativi slopes ottenuti nel segnale binario previsto dal metodo

Un contributo che abbiamo dato al presente progetto è basato su una sperimentazione atta a ricercare la soglia migliore, in termini di massimizzazione dell’AUC e dell’*overall accuracy*.

La sperimentazione del lavoro per l’individuazione di tachicardia ventricolare si è svolto utilizzando i database di Physionet, da cui si è estratto i ritmi sinusali normali dal *MIT-BIH Normal Sinus Rhythm* database ed i ritmi di tachicardia ventricolare sono stati estratti dai seguenti database: (1) MIT-BIH arrhythmia database, (ii) MIT-BIH malignant ventricular arrhythmia e (iii) CU ventricular tachyarrhythmia.

Sono stati selezionati tutti i ritmi più lunghi di 8 secondi, annotati come tachicardia ventricolare (secondo le annotazioni di Physionet), ottenendo un totale di 16 pazienti, 380 finestre da 8 secondi per un totale di 3040 secondi di ECG.

Per bilanciare il dataset, sono state selezionate 21 finestre casuali da 8 secondi per tutti i pazienti presenti all'interno del database MIT-BIH Normal Sinus Rhythm così da ottenere un totale di 378 finestre per complessivi 3024 secondi di ECG, e quindi avere una divisione equa del dataset, come mostrato in Tabella 4.

Tabella 4. Dataset preparato per la sperimentazione atta alla definizione di una soglia di discriminazione

Ritmo	Numero di record	Conteggio degli slopes	Secondi
NSR	18	378	3024
VT	16	380	3040

Come prima analisi abbiamo applicato l'algoritmo proposto dagli autori sull'intero dataset. Da questa analisi abbiamo notato come la soglia che discrimina in maniera ottimale i ritmi normali dai ritmi di tachicardia ventricolare risulta essere pari a 91.

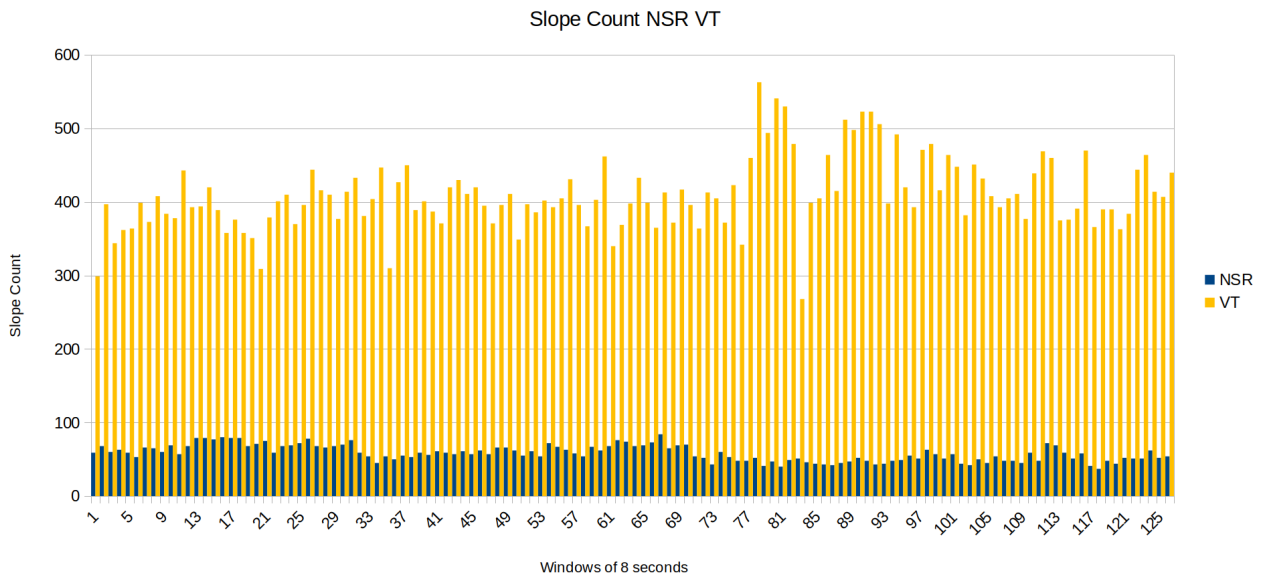


Figura 19. Analisi visiva delle soglie




Figura 20. Analisi in termini di Accuracy per l'individuazione della soglia ottimale

4.1.3 Fibrillazione Atriale

Gli episodi di Fibrillazione Atriale, al livello tre del DSS, verranno rilevati utilizzando un algoritmo ideato nell'ambito del progetto ATTICUS. L'approccio è stato denominato AMELIA (AutoMatic dEtection of atrial fibrillation for heALthcare).

Un episodio di FA viene diagnosticato da un medico quando la morfologia del battito cardiaco è anormale e vi è un'aritmia simultanea. AMELIA mira a simulare il più possibile tale comportamento. Il *workflow* di AMELIA è rappresentato in Figura 21.

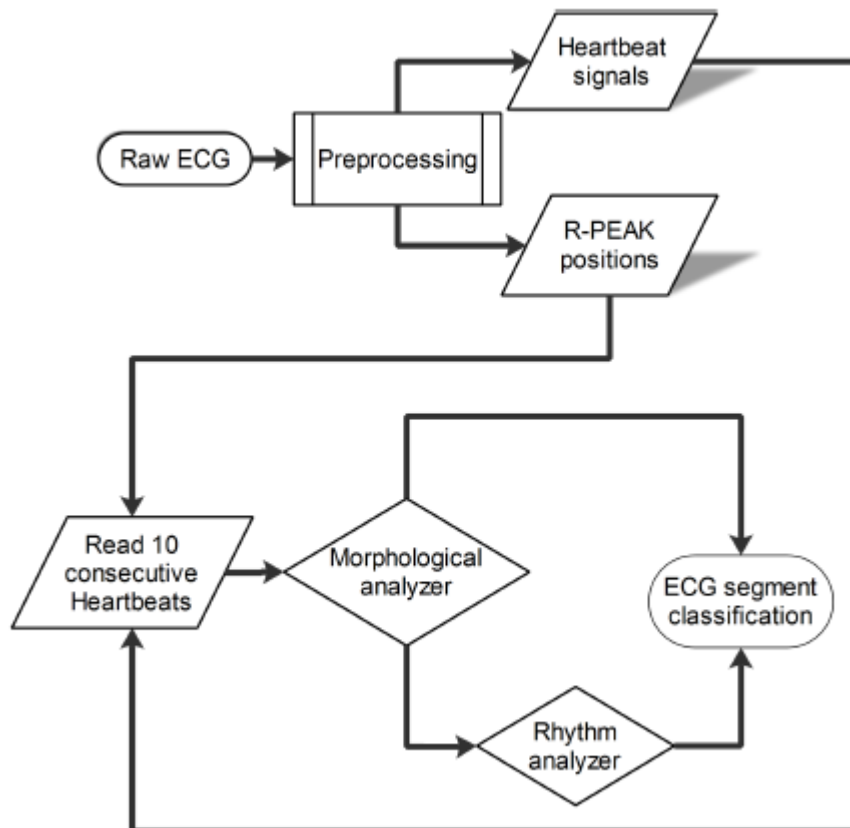


Figura 21. Workflow di AMELIA

Nella fase di preelaborazione dell'ECG *raw*, AMELIA estrae tutti i segnali del battito cardiaco e tutte le posizioni di picco R. Questi segnali sono sottoposti ad un analizzatore morfologico.

Se la morfologia del battito cardiaco è anormale, l'analizzatore morfologico attiva l'analizzatore del ritmo. L'analizzatore di ritmo prende come input le posizioni dei picchi R estratte e cerca di consolidare il *warning* iniziale identificato dall'analizzatore morfologico.

Se l'analizzatore di ritmo identifica, attraverso l'analisi di dieci intervalli R-R consecutivi, un'aritmia, allora viene identificato un episodio di FA. In caso contrario, l'avvertimento iniziale dell'analizzatore morfologico viene respinto.

In questo caso, la morfologia anomala del battito cardiaco potrebbe essere dovuta ad una classificazione errata della rete neurale o solo a qualche tipologia di rumore nell'ECG.

Nelle prossime sottosezioni forniremo maggiori dettagli su ogni componente di AMELIA.

Definizione di battito cardiaco: È necessario chiarire il concetto di segnale di battito cardiaco. In AMELIA, un segnale di battito cardiaco è un segmento grezzo dell'ECG incluso tra due picchi R consecutivi. La scelta di definire un segnale di battito cardiaco in questo modo è dovuta alla considerazione che le caratteristiche morfologiche - osservabili durante gli episodi di FA – sono:

- l'assenza di onde P;
- le potenziali onde di fibrillazione al suo posto.

Il concetto di segnale di battito cardiaco è affrontato anche nel lavoro di Xu *et al.* [19] con la differenza che gli autori lo definiscono come il segnale tra i due punti medi di tre picchi R consecutivi. Abbiamo deciso di lavorare con la dinamica del cuore inclusa tra due picchi R consecutivi perché i fenomeni di Fibrillazione sono iscritti tra questi punti.

Abbiamo usato il metodo di Pan-Tompkins per ottenere tutti i segnali di battito cardiaco attesi di un dato segnale ECG completo.

Un battito cardiaco completo è rappresentato da un vettore definito come:

$$hbs = u_1, u_2, \dots, u_N$$

dove u_1 e u_N rappresentano le ampiezze grezze dei campioni corrispondenti alla posizione del picco R sinistro e destro rispettivamente (si veda Figura 22). Vale la pena notare che - al fine di fornire istanze a lunghezza fissa alla componente dell'analizzatore morfologico - tutti i segnali del battito cardiaco sono stati sottoposti ad un processo di *downsampling*.

N è la lunghezza fissa di ogni segnale di battito cardiaco completo.

Analizzatore morfologico: L'analizzatore morfologico ha il compito di analizzare la morfologia di un battito cardiaco. L'input di questo componente è rappresentato da un battito cardiaco. Idealmente, l'uscita è OK se la morfologia del battito cardiaco è normale e AF se la morfologia del battito cardiaco non ha l'onda P e mostra forme d'onda fluttuanti (onde f), cioè le caratteristiche morfologiche di un battito cardiaco in presenza di un evento AF.




Figura 22. Rappresentazione di un battito cardiaco completo in AMELIA

La classificazione morfologica del battito cardiaco si basa su una Rete Neurale Ricorrente (*RNN*, *Recurrent Neural Network*) [20] con più cellule LSTM.

La scelta è giustificata dalla considerazione che le cellule LSTM si adattano meglio alla classificazione delle serie temporali [21] (come nel caso dell'ECG).

Analizzatore di ritmo: L'analizzatore di ritmo mira a identificare il ritmo normale o l'aritmia valutando un buffer di dieci battiti consecutivi. È opinione comune dei cardiologi considerare dieci battiti cardiaci consecutivi come un numero sufficiente per diagnosticare la fibrillazione atriale. Questo numero è confermato anche dai lavori di [22], [23] dove è stato valutato un minimo di 3 e 6 battiti cardiaci consecutivi.




Figura 23. Dal battito cardiaco all'istanza di input per l'analizzatore morfologico

In dettaglio, l'analizzatore di ritmo classifica ogni battito come breve, lungo o normale. Considerando che la frequenza cardiaca normale durante il riposo per gli adolescenti è di circa 70-120 battiti al minuto (bpm) e per gli adulti è di circa 60-90 bpm [24], ogni battito è classificato come segue:

- *breve* se $bpm > 120$,
- *lungo* se $bpm < 50$ e
- *normale* altrimenti.

Una volta che l'analizzatore di ritmo ha tamponato ed etichettato dieci battiti cardiaci consecutivi, calcola l'entropia del buffer B. L'entropia è una misura logaritmica del numero di stati con una significativa probabilità di essere occupati:

$$H(B) = - \sum_{i \in \{short, long, normal\}} p_i \cdot \log(p_i)$$

dove p_i è la probabilità che il battito appartenga all' i -esima categoria di battito. Ciò significa che maggiore è l'entropia dei battiti cardiaci, maggiore è la probabilità che il ritmo sia instabile e quindi che vi sia un'aritmia.

Quando l'entropia è superiore a δ , il ritmo è considerato anormale.

Combinando gli approcci: L'algoritmo in Figura 22 mostra come l'analizzatore morfologico e l'analizzatore di ritmo sono combinati per rilevare gli eventi AF.

Per ogni segnale di battito cardiaco, viene istanziato un buffer *hbsi* di lunghezza fissa contenente le ampiezze del segnale. Il buffer *hbsi* viene quindi sottoposto all'analizzatore morfologico, che ne fornisce la classificazione. Quando la morfologia viene classificata come AF, viene creato un nuovo buffer di battiti cardiaci. Una volta che il buffer di battiti cardiaci ha raggiunto la dimensione massima (impostata come 10, nel nostro caso), viene sottoposto all'analizzatore di ritmo.

Sulla base delle informazioni sull'entropia valutate, viene fornita una classificazione in termini di ritmo. Se anche il ritmo viene identificato come IRREGOLARE, viene generato un *warning*.

4.1.4 Scompensi Cardiaci

Gli episodi di Scompensi Cardiaci congestizi verranno rilevati utilizzando un algoritmo descritto principalmente nella guida *“Signal Classification Using Wavelet-Based Features and Support Vector Machines”*⁶.

I segnali dell'elettrocardiogramma umano possono essere classificati attraverso l'estrazione delle *feature* basata su *wavelet* e su un classificatore di tipo SVM (*Support Vector Machine*). Il problema

⁶ <https://it.mathworks.com/help/signal/examples/ecg-classification-using-wavelet-features.html>

della classificazione dei segnali viene semplificato trasformando i segnali ECG grezzi in un insieme molto più piccolo di caratteristiche che servono, in aggregato, per differenziare le diverse classi. I dati utilizzati in questo esempio sono disponibili pubblicamente su PhysioNet.

Questo esempio utilizza i dati ECG ottenuti da tre gruppi, o classi, di persone:

- persone con aritmia cardiaca;
- persone con insufficienza cardiaca congestizia;
- persone con ritmo sinusale normale.

L'esempio utilizza 162 registrazioni ECG da tre database PhysioNet:

- Database di aritmia MIT-BIH (Arrhythmia);
- Database di ritmo sinusale normale MIT-BIH (NSR);
- Database di insufficienza cardiaca congestizia MIT-BIH (BIDMC).

In totale, vi sono 96 registrazioni di persone con aritmia, 30 registrazioni di persone con insufficienza cardiaca congestizia, e 36 registrazioni di persone con ritmo sinusale normale.

L'obiettivo è quello di addestrare un classificatore a distinguere tra aritmia (ARR), insufficienza cardiaca congestizia (CHF) e ritmo sinusale normale (NSR).

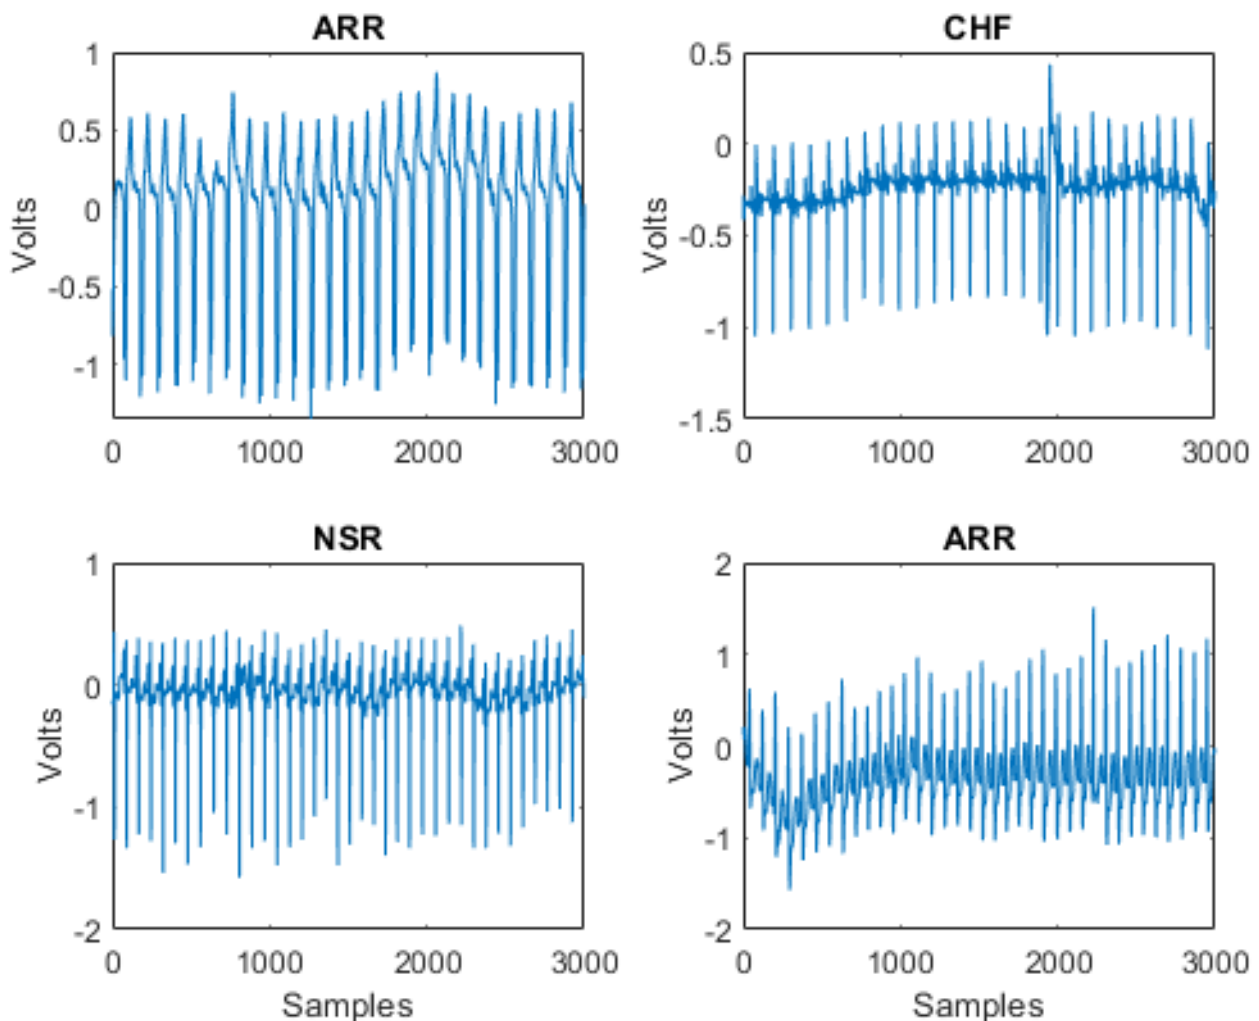


Figura 24. Esempi dei ritmi etichettati nell'esempio proposto.

Questo esempio utilizza le seguenti caratteristiche estratte su 8 blocchi di ogni segnale della durata di circa un minuto (8192 campioni):

- Coefficienti del modello autoregressivo (AR) di ordine 4 [27];
- Valori di entropia Shannon (SE) per la massima sovrapposizione della trasformazione discreta di pacchetti wavelet (MODPWT) di livello 4 [28];

- Stime di leader wavelet multifrattale del secondo cumulante degli esponenti di scalatura e della gamma di esponenti Holder [29].

Inoltre, le stime della varianza di *wavelet* multiscala sono estratte per ogni segnale per l'intera lunghezza dei dati [30]. Viene utilizzata una stima imparziale della varianza *wavelet*. Ciò richiede che nelle stime della varianza siano usati solo livelli con almeno un coefficiente di *wavelet* non influenzato dalle condizioni al contorno. Per una lunghezza del segnale di 2^{16} (65.536) e il wavelet 'db2' si ottengono 14 livelli.

Queste caratteristiche sono state selezionate sulla base di ricerche pubblicate che dimostrano la loro efficacia nella classificazione delle forme d'onda ECG.

I coefficienti AR per ogni finestra sono stimati utilizzando il metodo Burg. In [27], gli autori hanno utilizzato metodi di selezione dell'ordine dei modelli per determinare che un modello $AR(4)$ ha fornito il miglior adattamento per le forme d'onda ECG in un problema di classificazione simile. In [28], una misura teorica dell'informazione, l'entropia di Shannon, è stata calcolata sui nodi terminali di un albero di pacchetti wavelet ed utilizzata con un classificatore random forest.

Qui si usa la trasformata di pacchetto *wavelet* non decimata, *modwpt*, fino al livello 4.

Come caratteristiche vengono utilizzate due misure frattali stimate con i metodi wavelet. In seguito, si usa l'ampiezza dello spettro di singolarità ottenuto da *dwtleader* come misura della natura multifrattale del segnale ECG [29]. Può essere usato anche il secondo cumulante degli esponenti di scala. Gli esponenti di scalatura sono esponenti basati sulla scala che descrivono il comportamento della legge di potenza nel segnale a diverse risoluzioni.

Il secondo cumulante rappresenta a grandi linee l'allontanamento degli esponenti di scala dalla linearità.

La varianza di *wavelet* per l'intero segnale è ottenuta usando *modwtvar*. La varianza di wavelet misura la variabilità di un segnale per scala o , in modo equivalente, la variabilità di un segnale su intervalli di frequenza in banda di ottava.

In totale ci sono 190 caratteristiche: 32 caratteristiche AR (4 coefficienti per blocco), 128 valori di entropia di Shannon (16 valori per blocco), 16 stime frattali (2 per blocco) e 14 stime di varianza di wavelet.

4.1.5 Blocchi Cardiaci

Gli episodi di Scompensi Cardiaci congestizi verranno rilevati principalmente utilizzando un modello di classificazione, adatto a discriminare tra battiti normali e blocchi di branca.

Per decidere le analisi dei dati da effettuare per poi creare il dataset da fornire al classificatore, eseguiremo uno studio comparativo – nel deliverable della progettazione degli algoritmi – tra il lavoro descritto nel lavoro proposto in [2] ed il lavoro esposto nel paragrafo precedente (3.1.4).

Il lavoro proposto in [2] è stato già dettagliato nel deliverable 5.4. Si riportano, di seguito, le idee principali.

Per estrarre un battito cardiaco completo dal segnale dell'ECG, gli autori hanno dunque dovuto definire cos'è un battito cardiaco completo ed eseguire la segmentazione opportuna del segnale ECG. Poiché il picco R di solito si verifica intorno alla metà di un battito cardiaco, hanno optato per usarlo come punto di ancoraggio per localizzare un battito cardiaco completo. Hanno inoltre assunto che il picco R si trovi al centro del suo corrispondente battito cardiaco; in tal modo, si assume che il confine di un battito cardiaco completo si trovi al centro di due picchi R successivi. Sulla base di questa ipotesi, un battito cardiaco completo comprende i campioni tra i due punti medi di tre picchi R consecutivi. La Fig. 30 mostra un esempio di battito cardiaco completo e la sua relazione con i battiti precedenti e successivi.

Poiché l'approccio presentato su questo lavoro è basato su modelli di classificazione automatici, il dataset delle istanze ha dovuto subire un processo di *alignment*, in modo da ottenere segnali di eguale lunghezza. Per ogni battito cardiaco, dunque, deve essere impostato un numero fisso di campioni (D). Così, gli autori hanno misurato le durate di tutti i battiti cardiaci segmentati ed hanno trovato un valore che è superiore al 95% di tutte le durate. Negli esperimenti, D è risultato essere 417 e questo valore è stato applicato a tutti i battiti cardiaci completati. Si noti che questa procedura richiede l'applicazione di *zero-padding* e di troncamento per la maggior parte dei battiti cardiaci.




Figura 25. Esempio ipotetico che illustra la segmentazione del battito cardiaco e i processi in allineamento. In (c), $\lfloor a \rfloor$ significa il numero intero (floor) di a .

Con questa tecnica di *alignment*, gli autori hanno ottenuto risultati ad elevata accuratezza globale.

Per tale ragione, in ATTICUS verrà integrato un metodo di classificazione, per la discriminazione di un battito di blocco di branca rispetto ad un battito relativo ad un ritmo sinusale, basato su questi due tipi di processing ma eventualmente arricchito di:

- derivazioni multiple (almeno due);
- domini multipli (Fourier, etc.).

4.1.6 Slivellamento del segnale rispetto alla linea isoelettrica

Gli episodi di eventuali slivellamenti della linea elettrocardiografica, rispetto alla linea isoelettrica, verranno rilevati in base all'applicazione di una tecnica di detection basata sull'analisi del coefficiente angolare.




Figura 26. Definizione teorica della linea isoelettrica

Per linea isoelettrica, si intende il livello orizzontale di registrazione elettrocardiografica nel momento in cui non vi è attività cardiaca, cioè tra le onde T e P.

Per valutare eventuali soprasslivellamenti o sottoslivellamenti rispetto all'isoelettrica, si opererà per la divisione del segnale ECG in battiti delimitati da due picchi R consecutivi.




Figura 27. Identificazione della linea isoelettrica a partire da dati fisiologici.

La tecnica di elaborazione dell'ECG che permetterà di ottenere una porzione di segnale, come quella delimitata dai cerchi blu in Figura 27, prevede i seguenti step:

- valutazione della distanza fisiologica dall'onda R fino alla fine dell'onda T;
- valutazione della distanza fisiologica dall'onda R fino alla precedente onda P;
- utilizzando i punti delle ascisse ottenuti ai punti precedenti e cerchiati in blu, selezione della linea isoelettrica, ovvero della porzione di segnale tra l'onda T e l'onda P.

L'eventuale slivellamento verrà valutato in base al valore del coefficiente angolare che descrive la pendenza "orizzontale" della linea isoelettrica.

Riferimenti bibliografici

- [1] E. Balestrieri, L. D. Vito, F. Picariello, I. Tudosa and etal., "A novel method for Compressed Sensing based sampling of ECG signals in medical-IoT era," IEEE Intern. Symp. on Medical Measurements & Applications (MeMeA), 2019.
- [2] S. Xu e etal, «Towards End-to-End ECG Classification with Raw Signal Extraction and Deep Neural Networks,» IEEE Journal of Biomedical and Health Informatics, p. 1–1, 2018.
- [3] J. Pan e W. Tompkins, «A real-time QRS detection algorithm,» IEEE transactions on biomedical engineering, n. 3, pp. 230-236, 1985.
- [4] H. Sedghamiz, "Matlab implementation of Pan Tompkins ECG QRS detector," DataCite: Cambridge, UK, 2014.
- [5] X. Zhou e etal, «A Real-Time Atrial Fibrillation Detection Algorithm Based on the Instantaneous State of Heart Rate,» PLOS ONE, vol. 10(9), 2015.
- [6] G. Moody e R. Mark, «The impact of the MIT-BIH Arrhythmia Database,» IEEE Eng in Med and Biol, vol. 20(3), pp. 45-50, 2001.
- [7] F. Schrumpf e etal, «Derivation of the respiratory rate from directly and indirectly measured respiratory signals using autocorrelation,» Current Directions in Biomedical Engineering, vol. 2(1), 2016.
- [8] G. Santos and etal, "Accelerometer-based human fall detection using convolutional neural networks," Sensors, vol. 19.7, p. 1644, 2019.
- [9] T. Theodoridis and etal, "Human fall detection from acceleration measurements using a Recurrent Neural Network," Precision Medicine Powered by pHHealth and Connected Health, pp. 145-149, 2018.
- [10] A. Mao e etal, «Highly Portable, Sensor-Based System for Human Fall Monitoring,» Sensors, vol. 17(9), p. 2096, 2017.
- [11] J. Okai and etal, "Building robust models for Human Activity Recognition from raw accelerometers data using Gated Recurrent Units and Long Short Term Memory Neural Networks," 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2019.
- [12] O. Palma e etal, «Heat stroke detection system based in IoT,» Proceedings of the 2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM), pp. 420-425, 2017.
- [13] B. Alic and etal, "Classification of stress recognition using Artificial Neural Network," 5th Mediterranean Conference on Embedded Computing (MECO), 2016.

- [14] A. Anisimov and etal, "Extrasystole Episodes Detection Algorithm in Real Time Mode," Ural Symposium on Biomedical Engineering, Radioelectronics and Information Technology (USBREIT), 2019.
- [15] A. Perez-Silva e etal, «Frequent ventricular extrasystoles: significance, prognosis and treatment,» The E-Journal of the ESC Council for Cardiology Practice, vol. 9, n. 17, 2011.
- [16] N. Tuyen and etal, "The algorithm of atrial fibrillation detection and alarm signal formation in the system of ECG remote monitoring," Biomedical Engineering, vol. 52, no. 1, pp. 51-55, 2018.
- [17] T. Nguyen and etal, "A remote cardiac rhythm monitoring system for detecting episodes of atrial fibrillation," Biomedical Engineering, vol. 51, no. 3, pp. 189-194, 2017.
- [18] S. Mohammad-Taheri and etal, "Slope analysis based methods for detection of ventricular fibrillation and ventricular tachycardia," 24th Iranian Conference on Electrical Engineering (ICEE), vol. IEEE, pp. 1100-1103, 2016.
- [19] S. Xu and etal, "Towards end-to-end ECG classification with raw signal extraction and deep neural networks," IEEE journal of biomedical and health informatics, vol. 23, no. 4, pp. 1574-1584, 2018.
- [20] S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural computation, vol. 9, no. 8, pp. 1735-1780, 1997.
- [21] F. Karim, "LSTM fully convolutional networks for time series classification," IEEE access, vol. 6, pp. 1662-1669, 2017.
- [22] R. Kurzweil and etal, "Atrial fibrillation," U.S. Patent No. 7,596,405, 2009.
- [23] V. Zurro and etal, "Detection of Atrial Persistent Rhythm Based on P-wave Recognition and RR Interval Variability," Computers in cardiology, 1995.
- [24] D. Limmer and etal, "Emergency Care workbook Computers in Cardiology," p. 214, 2005.
- [25] G. Laudato, "Combining Rhythmic and Morphological ECG Features for Automatic Detection of Atrial Fibrillation," 13th International Conference on Health Informatics, (Biostec 2020), La Valletta, Malta.
- [26] A. Goldberger and etal, "PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals," Circulation, vol. 101, no. 23, pp. 215-220, 2003.
- [27] Q. Zhao and etal, "ECG feature extraction and classification using wavelet transform and support vector machines," IEEE International Conference on Neural Networks and Brain, vol. 2, pp. 1089-1092, 2005.
- [28] T. Li and etal, "ECG classification using wavelet packet entropy and random forests," Entropy, vol. 18, no. 8, p. 285, 2016.

- [29] R. Leonarduzzi and etal, "Wavelet leader based multifractal analysis of heart rate variability during myocardial ischaemia," Engineering in Medicine and Biology Society (EMBC), 2010 - Annual International Conference of the IEEE..
- [30] E. Maharaj and etal, "Discriminant analysis of multivariate time series: Application to diagnosis based on ECG signals," Computational Statistics and Data Analysis, vol. 70, pp. 67-87, 2014.
- [31] A. Thommandram and etal, "Detection of apnoea from respiratory time series data using clinically recognizable features and kNN classification," 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2013.
- [32] R. Casal and etal, "Sleep-wake stages classification using heart rate signals from pulse oximetry" Heliyon (vol. 5-10), Elsevier, 2019