



UNIVERSITA' POLITECNICA DELLE MARCHE
FACOLTA' DI INGEGNERIA

Corso di Laurea triennale Ingegneria Biomedica

**Creazione di un dataset di benchmark di segnali vibrocardiometrici
carotidei per applicazioni di machine learning**

**Creation of a benchmark dataset of carotid vibrocardiometric signals
for machine learning applications**

Relatore:

Prof. Scalise Lorenzo

Correlatori:

Prof. Frontoni Emanuele

Ing. Antognoli Luca

Tesi di Laurea di:

Tolli Alessandro

A.A. 2019 / 2020

Indice

Introduzione	1
Stato dell'arte	3
Capitolo 1 – Strumenti e metodi	10
1.1 Banco di prova e acquisizione	10
1.1.1 Elettrocardiogramma	11
1.1.2 Vibrometro Laser Doppler	13
1.1.3 Acquisizione	15
1.2 Creazione Dataset	18
1.3 Machine Learning	19
1.4 Algoritmi usati	20
1.4.1 Decision Tree	20
1.4.2 Random Forest	23
1.4.3 Support Vector Machine	24
1.4.4 K-Nearest Neighbors	28
1.5 Hyperparameter tuning	29
1.6 Metriche usate	31
Capitolo 2 – Risultati	36
Capitolo 3 – Conclusioni	41
Bibliografia	43
Ringraziamenti	46

Introduzione

Negli ultimi decenni, grande attenzione è stata data alla valutazione di dinamiche cardiovascolari con tecniche non invasive e senza contatto, come la Vibrometria Laser Doppler (LDV). La LDV usa un fascio di luce e sfrutta tecniche interferometriche per misurare la velocità, insieme alla direzione del raggio, di un punto sulla superficie [1]. In origine, LDV era usato per testare le vibrazioni meccaniche in particolari strutture (turbine a vento [2] e eliche [3]) oppure per rilevare difetti nella costruzione e, nello stesso tempo, evitare il contatto diretto con le superfici [4].

Più di recente, la LDV ha trovato applicazioni in campo biomedico, specialmente quando è richiesto un approccio non a contatto. Esempi includono misurare la vibrazione della membrana timpanica [5][6] e la valutazione della funzione cardiovascolare [7][8].

Puntando il laser sul collo, sopra la carotide, il segnale LDV può essere usato per misurare l'impulso esterno carotideo che è correlato alla frequenza cardiaca (HR) [9]. La LDV, essendo una misura senza contatto, non interferisce con la misurazione della frequenza cardiaca. Inoltre i dispositivi di misura a contatto, come l'elettrocardiografo (ECG) può presentare delle limitazioni in certe condizioni, come ad esempio nel caso di soggetti che presentano gravi bruciature o in un ambiente predisposto a risonanze magnetiche [10]. In queste condizioni la LDV può rappresentare una ragionevole alternativa.

Ai giorni nostri, le analisi di segnale LDV si basano fortemente su approcci qualitativi o dipendenti da parametri. Comunque, questi approcci possono non essere in grado di affrontare l'alta variabilità di segnali LDV tra i soggetti. Quest'ultima dipende da diversi fattori, tra cui la frequenza cardiaca, l'andamento della respirazione e lo stress fisico e mentale. Per affrontare questa variabilità,

possono essere usati approcci di machine learning, i quali hanno mostrato un grande potenziale nel campo delle analisi di dati medici [11].

Lo scopo di questo progetto è di sviluppare un framework basato su machine learning per determinare i battiti cardiaci nel segnale LDV carotideo. Inoltre, basandosi sulle ipotesi di ricerca che i modelli machine learning possano determinare i battiti da segnali LDV acquisiti dall'arteria carotidea, i contributi più significativi di questo scritto sono sintetizzati nei seguenti punti:


1. Rilevazione del battito cardiaco da segnale LDV: sviluppo di un framework machine learning per rilevare il battito cardiaco da un segnale LDV acquisito dalla carotide;
2. Verifica esauriente su veri segnali LDV: verifica sui segnali LDV acquisiti da 28 soggetti per investigare sperimentalmente le ipotesi di ricerca;
3. Creazione di un dataset basato su LDV e battito: collezione del primo e più grande dataset (basato su segnale LDV e battito) di segnali LDV raccolti da 28 soggetti (per un totale di 55274 segnali classificati), che può essere usato per favorire ricerche future basate su machine learning nel campo dell'analisi di segnali cardiaci mediante LDV;

Dopo alcune ricerche, questo è il primo tentativo di rilevare in modo automatico, tramite machine learning, il battito cardiaco partendo da un segnale LDV. Il dataset sarà reso disponibile online per promuovere la ricerca in questo campo.

Stato dell'arte

Molte delle applicazioni di LDV nel campo biomedico riguardano il sistema cardio circolatorio. Il laser infatti identifica, usando una misura senza contatto, un cambiamento della dimensione del vaso sanguigno, causato dal passaggio di volumi differenti di sangue, correlato ad una variazione del battito cardiaco.

Nel progetto [12] portato avanti da Sara Casaccia, Erik J. Sirevaag, Edward J. Richter, Luigi Casacanditella, Lorenzo Scalise e John W. Rohrbaugh, si è usato un processo di ri-respirazione (respirando cioè in un sacchetto di carta) per provocare cambiamenti individuali nelle funzionalità cardiache e vascolari. Questo processo è noto per i diversi effetti provocati, come ad esempio la variazione di gas nel sangue. Infatti, la crescita di anidride carbonica (ipercapnia) produce cambiamenti nella circolazione cerebrale e sistemica. Lo studio si è focalizzato su 35 individui. L'impulso laser è stato misurato in una porzione di pelle in corrispondenza dell'arteria carotidea.



A fini di confronto e validazione, sono state anche ottenute diverse misure convenzionali della funzione cardiovascolare (in cui particolare attenzione è stata

rivolta all'elettrocardiogramma), sulla pressione sanguigna continua dall'arteria radiale e sulle misurazioni delle prestazioni del miocardio mediante cardiografia di impedenza (ICG).

Durante il periodo di rirespirazione, la ventilazione è aumentata. Tra gli effetti cardiovascolari comuni prodotti si annoverano l'incremento della pressione arteriosa media e della resistenza vascolare sistemica e la riduzione della gittata sistolica (SV) e del tempo di transito degli impulsi (PPT - tempo impiegato da un impulso generato dal passaggio del bolo sanguigno per viaggiare dal cuore ad un punto periferico del sistema cardiovascolare). Questi effetti sono stati coerenti con un modello di stimolazione α -adrenergica. Durante gli immediati segmenti post-rirespirazione, al contrario, la pressione sanguigna media era sostanzialmente inalterata, ma la pressione sanguigna dell'impulso aumentava, così come PTT e SV, mentre la resistenza vascolare sistemica diminuiva, un modello coerente con gli effetti β -adrenergici in combinazione con gli effetti diretti di ipercapnia sul sistema vascolare. Le misure dell'attività cardiovascolare derivate dalla velocità dell'impulso laser e dalle forme d'onda di spostamento hanno rivelato modelli di cambiamenti che rispecchiavano i risultati ottenuti usando misure convenzionali. In particolare, il rapporto tra il picco massimo nell'impulso di velocità e spostamento del LDV (in un intervallo sistolico precoce) rispecchiava da vicino gli effetti di gittata sistolica convenzionali. Inoltre, i cambiamenti nel rapporto di aumento (calcolati come ampiezza massima dell'impulso di spostamento laser durante la sistole / ampiezza alla fine dell'onda incidente) erano molto simili ai cambiamenti nella resistenza vascolare sistemica. Le frequenze cardiache misurate dall'ECG e dal LDV erano quasi identiche. Questi risultati preliminari suggeriscono che le misure derivate usando la tecnica LDV senza contatto possono fornire misure surrogate per quelle ottenute usando la cardiografia ad impedenza.

Oltre a rilevare il battito cardiaco, molti ricercatori lavorano sulla velocità delle onde dell'impulso, che misura la velocità di propagazione delle onde del polso lungo l'albero arterioso ([13, 14, 15, 16, 17]). Anche in questi casi, per l'analisi vengono proposti approcci sensibili ai parametri. Tutti i metodi rilevati si basano principalmente su approcci di filtraggio sensibili ai parametri.

In un progetto [18] portato avanti dal professor Scalise Lorenzo, G. Cosoli, L. Casacanditella, S. Casaccia e J.W. Rohrbaugh è stata effettuata una misurazione senza contatto della pressione sanguigna attraverso una tecnica basata su LDV. Questo lavoro ha lo scopo di dimostrare la possibilità di valutare la pressione arteriosa senza la necessità di mettere alcun elemento in contatto fisico con il soggetto (ad eccezione della calibrazione del segnale). Gli autori hanno sviluppato una tecnica per la misurazione senza contatto della pressione arteriosa (BP) come manifestata nell'arteria carotidea, basata sull'uso di LDV. Esso produce un segnale che può essere correlato alla forma d'onda dell'impulso di pressione continua. Pertanto, il segnale supporta il calcolo di alcuni intervalli di tempo fisiologicamente importanti. Nell'articolo è stato proposto un confronto con la forma d'onda della pressione registrata usando la tonometria tradizionale di appianazione: la forma d'onda ha una forma analoga e, nel complesso, fornisce le stesse caratteristiche nell'asse temporale. Più in dettaglio, i risultati mostrano che la pressione arteriosa sistolica ha una deviazione media dell'8% rispetto al valore di riferimento (ottenuto da dati tonometrici). Gli aspetti fondamentali da considerare sono il laser di precisione che punta perpendicolarmente al sito di misurazione (per ottimizzare il rapporto segnale-rumore), le condizioni di misurazione (ad es. il soggetto deve rimanere il più fermo possibile) e anche le proprietà riflettenti della pelle del soggetto, che può essere migliorata applicando una lozione o un nastro riflettente adeguato. Sono stati valutati i principali fattori che contribuiscono all'incertezza delle misure LDV, al fine di identificare i modi per migliorare le prestazioni.


L'attuale valore di incertezza del 15% non è trascurabile, ma non supera di gran lunga quello dei dispositivi di misurazione BP standard.

In un altro progetto [19] i ricercatori si sono focalizzati sul rilevamento della stenosi carotidea dalle vibrazioni della pelle mediante la LDV. La diagnosi precoce della stenosi carotidea asintomatica può aiutare a identificare gli individui a rischio di ictus. Un nuovo metodo basato su LDV potrebbe consentire il rilevamento senza contatto della stenosi a partire dalle vibrazioni della pelle del collo a causa di disturbi del flusso indotti dalla stenosi. Sono stati eseguiti test sperimentali fluidodinamici con acqua su un modello di biforcazione carotidea specifico del paziente gravemente affetto da stenosi. Le misure sono state prese in base a vari regimi di flusso fisiologico sia in una versione conforme che a parete rigida del modello, da 1 a 4 diametri a valle della stenosi. Un catetere di pressione inter-arteriosa è stato posizionato come riferimento. L'aumento del flusso ha portato al corrispondente aumento della densità spettrale di potenza (PSD) della pressione e delle registrazioni LDV nell'intervallo 0–500 Hz. Il modello rigido porta a un PSD più elevato. Il PSD del segnale LDV era meno dipendente dalla posizione di misurazione a valle della pressione. La forza dell'associazione tra PSD e livello di flusso, materiale del modello e posizione di misurazione era massima nell'intervallo 0–50 Hz, tuttavia informazioni utili sono state trovate fino a 200 Hz. Questa dimostrazione del concetto suggerisce che il LDV ha il potenziale per rilevare il flusso disturbato indotto dalla stenosi. Ulteriori studi di validazione computazionale e clinica sono in corso per valutare la sensibilità e la specificità della tecnica per lo screening clinico.


Un altro progetto [20] (a cura di Andrea Di Donato, Lorenzo Scalise e Leonardo Zappelli) si è focalizzato sulla luce laser che illumina una superficie ruvida e genera fenomeni di macchioline nello spazio attorno alla superficie. Nell' articolo, gli autori propongono un sensore di LDV senza contatto, utilizzando i fenomeni macchioline, per la valutazione della velocità e dello spostamento del target a basse frequenze di

vibrazione. Il sensore è realizzato utilizzando pochi componenti ottici in una configurazione ottica molto semplice. Viene riportata la metodologia per la determinazione sperimentale e analitica della sensibilità del sensore e sono stati utilizzati due algoritmi di elaborazione dei punti per valutare la migliore funzione di correlazione incrociata per la misurazione della velocità target. Gli algoritmi si basano sulla correlazione binaria e sull'analisi rapida della trasformata di Fourier. Vengono riportati i risultati sperimentali derivanti dal confronto di entrambe le tecniche proposte. Inoltre, i risultati ottenuti con il sensore a punti proposto sono stati confrontati con i sistemi di misurazione di riferimento. I risultati mostrano che questo sensore senza contatto è caratterizzato da una ridotta complessità ottica e basso costo. Sembra essere particolarmente adatto per l'uso nell'analisi di superfici ruvide a bassa velocità.

Esempio di un ECG classico



Esempio di un tracciato LDV



In questo progetto, invece, viene proposto un framework di apprendimento automatico (machine learning) per automatizzare la procedura di rilevamento del battito e renderla più robusta alla variabilità intrinseca del e tra i soggetti, codificata naturalmente nel segnale LDV. Il machine learning (abbreviato ML per comodità) comprende meccanismi che permettono a una macchina intelligente di migliorare le proprie capacità e prestazioni nel tempo. Quest'ultima, quindi, sarà in grado di imparare a svolgere determinati compiti migliorando, tramite l'esperienza, le proprie capacità, le proprie risposte e funzioni.

L'uso del machine learning è consigliato in caso di attività o problemi complessi che implicano l'utilizzo di una grande quantità di dati e molte variabili e se non si dispone di formule o equazioni. Per esempio, questa tecnica è una buona opzione per gestire situazioni come queste: regole e equazioni scritte a mano troppo complesse (come nel riconoscimento facciale e vocale), regole di un'attività che cambiano continuamente (come nella rilevazione di frodi nei registri delle transazioni), in presenza di una continua evoluzione della natura dei dati (come nel trading automatico, nella previsione del fabbisogno energetico e delle tendenze di acquisto). Ogni giorno nascono nuove applicazioni del machine learning, anche se non sempre si tratta di successi incondizionati.

Le auto a guida autonoma sono un buon esempio in cui possiamo ritrovare attività semplici e che funzionano molto bene, come gli assistenti per il parcheggio e il mantenimento della corsia stradale, e attività complesse e dai risultati ancora incerti, come la guida autonoma senza intervento o supervisione umana, dove c'è ancora molta strada da fare (perdonateci il gioco di parole).

Nel campo dei giochi, l'apprendimento automatico ha portato a risultati strepitosi con dama, scacchi, shogi e con il gioco del Go, fino a poco tempo fa ritenuto troppo complesso per poter essere padroneggiato da un computer. A Novembre 2019, dopo aver ricevuto numerose sconfitte da parte del progetto AlphaGo di Google¹ il campione mondiale di Go Lee Se-dol ha annunciato il suo ritiro dal gioco professionale dichiarando che la IA è ormai imbattibile.

La traduzione automatica delle lingue è ormai usata da molti con soddisfazione, sebbene alcune coppie linguistiche funzionino meglio di altre, e molte traduzioni automatiche abbiano ancora bisogno di un intervento di correzione da parte di traduttori umani. Il riconoscimento vocale e la conversione della voce in testo scritto funzionano abbastanza bene per le persone con accenti tradizionali, ma non così bene per le persone con forti accenti regionali. Le prestazioni dipendono dai set di dati di apprendimento utilizzati dai vari produttori. L'analisi automatica dei sentimenti sui social media (social media sentiment analysis) ha un tasso di successo ragionevolmente buono, probabilmente perché i set di dati per l'apprendimento sono numerosi e di facile accesso. La valutazione automatica dei curriculum vitae è un'area controversa. Amazon ha dovuto ritirare il proprio sistema interno a causa di alcuni errori di campionamento che hanno causato il declassamento di tutte le domande di lavoro presentate da donne.

¹ AlphaGo è un software per il gioco del go (gioco da tavolo strategico per due giocatori) sviluppato da Google DeepMind. È stato il primo software in grado di sconfiggere un maestro umano nel gioco senza handicap e su un goban di dimensioni standard (19×19). Per ulteriori informazioni, cfr con Google's AlphaGo AI Go player has defeated Ke Jie

Capitolo 1 – Strumenti e metodi

In questa sezione si parlerà dei metodi e degli strumenti utilizzati per l'acquisizione, l'analisi e l'elaborazione dei dati ottenuti dai soggetti che si sono offerti per la creazione del dataset.

1.1 Banco di prova e acquisizione

1.2 Creazione Dataset

1.3 Machine Learning

1.4 Algoritmi usati

1.5 Hyperparameter tuning


1.6 Metriche usate

1.1 Banco di prova e acquisizione

I segnali LDV sono stati acquisiti da 28 soggetti in salute (7 maschi e 22 ragazze) di età compresa tra i 21 e i 25 anni. Tutti si sono offerti volontari dopo essere stati informati sulle dinamiche e aver firmato un'informativa sulla privacy, per il trattamento dei dati. Alcuni soggetti sono stati campionati più volte ognuno, grazie alla loro disponibilità. Il database prevedeva acquisizioni ottenute da 29 soggetti, tuttavia un soggetto è stato successivamente escluso a causa del segnale pieno di rumore e disturbi.

1.1.1 Elettrocardiogramma

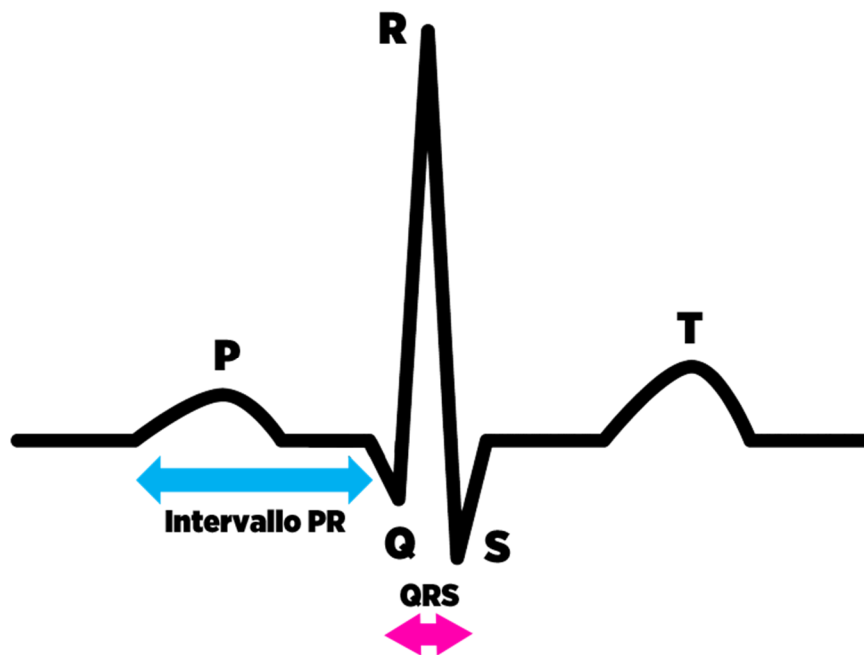
La funzionalità cardiaca è comunemente controllata attraverso l'analisi dell'elettrocardiogramma (ECG), che rappresenta il grafico dell'andamento del potenziale cardiaco rispetto al tempo. Attraverso l'ECG è possibile valutare le alterazioni del ritmo cardiaco, della propagazione dell'impulso elettrico e del miocardio, dovute a ischemia (danneggiamento delle coronarie). La sequenza cardiaca ha una natura elettrica e visto che il corpo è conduttivo, è possibile misurarla direttamente sulla superficie corporea. L'ECG registrato si basa sul principio fisiologico del Triangolo di Einthoven è il principio, proposto ai primi del Novecento dal medico fisiologo Willem Einthoven.



Si considera un uomo con le braccia estese e si individua un triangolo equilatero, dove un lato è la distanza tra i due polsi e gli altri due la distanza tra i polsi e la caviglia (nel nostro caso, destra). La distanza di un punto dagli altri due, considerati insieme, è la misura della corrente di quel punto. L'utilità di tale triangolo consiste

nel fatto che la forza elettrica che origina a livello cardiaco può essere rappresentata come un vettore che viene guardato dalle diverse angolazioni. Le tre derivazioni bipolari (questo il nome dei nostri tre punti: polso destro, polso sinistro, caviglia destra) registrano quindi l'attività elettrica cardiaca da come questa risulta dalla sua proiezione sul lato del triangolo.

Il segnale ECG è composto da una forma d'onda che si ripete per la durata del campionamento, ad ogni battito. È possibile individuare le curve fondamentali che compongono tale onda.



La curva P corrisponde alla depolarizzazione atriale. Il tratto QRS corrisponde alla depolarizzazione dei ventricoli e il tratto T alla successiva ripolarizzazione. L'intervallo PR (misurato dall'inizio della curva P all'inizio del complesso QRS) viene valutato con il fine di determinare se l'impulso di conduzione dagli atri ai ventricoli sia normale. Il complesso QRS è una misura della depolarizzazione del ventricolo sinistro, dato che l'impulso che si sviluppa da quest'ultimo è molto più grande di quello del ventricolo destro. La durata del QRS è molto significativa a

livello diagnostico: se è breve significa che i ventricoli si depolarizzano rapidamente ed è quello che ci si aspetta; una lunghezza eccessiva manifesta una depolarizzazione lenta, che può essere causata da una disfunzione del sistema di conduzione. Il tratto T chiude l'onda con la ripolarizzazione delle cellule contrattili ventricolari.



1.1.2 Vibrometro Laser Doppler

Il vibrometro laser Doppler costituisce il punto di riferimento per misure di vibrazione senza contatto.

L'effetto Doppler è un cambiamento apparente della frequenza o della lunghezza d'onda di un'onda percepita da un osservatore che si trova in movimento rispetto alla sorgente delle onde. Per quelle onde che si trasmettono in un mezzo (ad esempio: aria, acqua, etc) come le onde sonore, la velocità dell'osservatore e

dell'emettitore vanno considerate in relazione a quella del mezzo in cui sono trasmesse le onde. L'effetto Doppler totale può quindi derivare dal moto di entrambi, ed ognuno di essi è analizzato separatamente. È importante far notare che la frequenza del suono emesso dalla sorgente non cambia. Dato che la frequenza aumenta se sorgente e osservatore si avvicinano, mentre diminuisce in caso di allontanamento, il vibrometro, costituito da un sensore ottico di precisione, è utilizzato per determinare la velocità e lo spostamento di vibrazione in un determinato punto, in questo caso la porzione di pelle sopra la carotide, la quale, pulsando ad ogni battito, crea uno spostamento.

Il laser utilizzato per questo progetto è un laser classe 2 (sicuro per gli occhi) Polytech PDV-100 vibrometro digitale. Il sensore LDV utilizza una sorgente laser al neon elio (HeNe) con una lunghezza d'onda di 633 nm e una risoluzione della velocità vibratoria di 0,02 m/s. L'output del dispositivo è una tensione analogica con un fattore di conversione di 5 mm/s/V.




1.1.3 Acquisizione

In questi campionamenti il segnale elettrocardiografico (ECG) e quello di LDV vengono tracciati e disposti l'uno sopra l'altro.

L'acquisizione ha una durata di 10 minuti. Il soggetto viene fatto stendere su una brandina, successivamente vengono applicati tre elettrodi secondo la configurazione di Einthoven. Un vibrometro a laser doppler viene poi posto di fianco e puntato, mediante un treppiedi, sulla carotide del soggetto. La testa ottica laser è stata posizionata verticalmente a circa 70 cm dalla pelle del collo, al fine di ottenere una potenza del segnale adeguata. Il laser era puntato sul collo del soggetto a circa 1-2 cm sotto il seno carotideo destro, in corrispondenza della parete dell'arteria carotide. La posizione carotidea è stata rilevata manualmente dalla palpazione.

Viene presentata un'illustrazione di come è stato svolto il campionamento, con il soggetto steso su una brandina e gli elettrodi applicati e collegati al PowerLab.




Per collegare il segnale LDV con quello ECG viene usato un Powerlab, un dispositivo di acquisizione dati (DAQ) progettato per un'acquisizione precisa, coerente e affidabile. Nel progetto si utilizza un PowerLab 4 / 25T2.



Il PowerLab viene successivamente collegato ad un computer che, tramite il software LabChart, riceve e mostra i segnali provenienti dagli elettrodi e dal laser collegati. I due segnali (LDV ed ECG) sono stati registrati in modo sincrono con un convertitore A/D a 24 bit e una frequenza di campionamento di 500z Hz.

In rosso il segnale LDV, in verde il segnale ECG




Già da questa figura è possibile notare la corrispondenza tra i picchi del segnale ECG e i picchi di quello LDV, che si discostano di poco. Si riportano inoltre la media e deviazione standard dell'età dei soggetti coinvolti nel progetto.

N° Soggetti	Età (media \pm deviazione standard)
28	22 \pm 1,5

1.2 Creazione Dataset

Il segnale ECG è stato usato come riferimento per identificare il battito cardiaco e consentire la classificazione del segnale LDV usando la procedura seguente. L'algoritmo Pan Tompkins [21] è stato usato per individuare il battito cardiaco nel segnale ECG, andando ad identificare i picchi R del complesso QRS.

Per ogni battito trovato nel segnale ECG, è stato usato un algoritmo a finestra scorrevole per estrarre la porzione di segnale LDV contenente quello stesso battito. Si chiami W_d la dimensione della finestra in esame e $W_{overlap}$ la finestra di sovrapposizione con un nuovo battito.



La finestra, con dimensione W_d , inizia dal primo battito registrato sull'ECG e viene man mano spostata di W_s campioni, dove W_s è la finestra di spostamento. Questo processo continua finché il numero dei campioni sovrapposti con una nuova finestra di battito è minore dell'80% di W_d . Tutte le finestre di spostamento, ad eccezione della prima, sono rinominate in modo da contrassegnarle dall'assenza di battito (no-beat). La prima finestra è categorizzata come contenente battito (beat). In seguito il processo ricomincia dal nuovo battito identificato nell'ECG.

In questa procedura si è usata una W_d di 75 punti e una W_s di 15 punti. Tutte le finestre contenenti battito sono state incluse nel dataset. Per ogni finestra di battito, è stata selezionata una finestra casuale non contenente il battito dallo stesso soggetto. Sono state ottenute 55274 finestre equamente bilanciate tra le due classi di battito e no-battito.

1.3 Machine Learning

Nel Machine Learning vengono usati algoritmi matematici e statistici generici che, esposti a una determinata serie di dati in una fase iniziale definita “di addestramento” (training) e passando per una seconda fase di valutazione dei risultati con ottimizzazione dei parametri, ricavano autonomamente la funzione – non sempre conosciuta e non sempre conoscibile dallo sviluppatore – in grado di individuare in una differente serie di dati (dati di esecuzione), il valore più probabile di y , indicando eventualmente un grado di confidenza nella stima. In un problema risolto dalla funzione $y=f(x)$, è il programmatore a descrivere nel dettaglio come funziona “ $f(x)$ ”, nel ML, invece, la $f(x)$ viene ricavata da sola. Il sistema composto da algoritmo addestrato, dati e parametri operativi viene chiamato modello.

Vi sono differenti modalità di apprendimento, tutte efficaci, che differiscono non solo per gli algoritmi utilizzati, ma soprattutto per lo scopo per cui sono realizzate le macchine stesse. A seconda del tipo di algoritmo utilizzato per permettere l’apprendimento alla macchina, ossia a seconda delle modalità con cui la macchina impara ed accumula dati e informazioni, si possono suddividere tre differenti sistemi di apprendimento automatico: supervisionato, non supervisionato e per rinforzo. I tre modelli di apprendimento sono utilizzati in maniera differente a seconda della macchina su cui si deve operare, garantendo così sempre la massima performance e il migliore risultato possibile per la risposta agli stimoli esterni.

1.4 Algoritmi usati

Un algoritmo è supervisionato quando utilizziamo un dataset che contiene delle variabili, una delle quali è un'etichetta. In base al dataset, e tenendo come 'ancora' l'etichetta, l'algoritmo apprenderà (in vari modi) a classificare un dataset completamente nuovo, ma che non contiene l'etichetta, in base alle informazioni del primo dataset già classificato.


Per eseguire la classificazione della finestra del segnale LDV in battito e no-battito, sono stati considerati quattro algoritmi applicati nel machine learning: Decision Tree (DT), Random Forest (RF), Support Vector Machine (SVM) e K-Nearest Neighbors (KNN).

1.4.1 Decision Tree (DT)

L'albero decisionale è un tipo di algoritmo di apprendimento supervisionato che viene utilizzato principalmente per problemi di classificazione e funziona sia con variabili discrete (e allora si parla di classificazione) o continue (in questo caso di regressione). Un algoritmo popolare che ci permette di raggiungere questo scopo è sicuramente il CART (Classification and Regression Trees).

In altre parole, un albero CART (classification and regression tree) è un albero decisionale binario che viene costruito dividendo ripetutamente un nodo in due nodi figlio, a partire dal nodo radice che contiene l'intero esempio di apprendimento.

Un albero è una raccolta di entità chiamate nodi collegati tra loro tramite frecce o linee. Ogni nodo contiene un valore e può avere o meno nodi figli, mentre le frecce indicano le decisioni/regole che un albero può prendere o meno.



Ogni nodo padre rappresenta una singola variabile di input (x) e un punto di divisione per quella variabile (supponendo che la variabile sia numerica). I nodi foglia dell'albero contengono una variabile di output (y) che viene utilizzata per fare una previsione. I nodi sono A, B, C, D, E F e sono collegati da delle linee che indicano delle relazioni di parentela tra i vari nodi.


Il nodo A viene detto nodo radice ed è il punto di partenza dell'albero. Esso si compone di tre figli: il nodo B, il nodo C e il nodo D. L'unico nodo senza genitore è il nodo radice.

Il nodo B ha a sua volta due figli: il nodo E ed F. Questi ultimi due insieme ai nodi C e D sono chiamati nodi foglia perché si trovano nella parte inferiore dell'albero e non hanno figli. I nodi foglia rappresentano i risultati che vogliamo ottenere dal problema e che ci servono per fare previsioni su nuovi dataset.

La profondità di un albero è definita come il numero di livelli, escluso il nodo radice. L'albero sopra ha una profondità di 2 poiché il nodo B, il nodo C e il nodo D sono tutti su un livello e il nodo E il nodo F sono su un secondo livello.

In altre parole, il numero di livelli è il numero di figli che dobbiamo attraversare dalla radice al nodo foglia più lontano. Sebbene il nodo radice A, sia al suo livello, di solito non lo includiamo quando contiamo la profondità di un albero (se dovessimo considerarlo, lo chiameremo livello 0).

L'albero sopra è un albero generale, ma non è un albero binario. Gli alberi decisionali sono alberi binario. Un esempio di albero binario viene mostrato nella seguente immagine.



La condizione affinché un albero sia considerato binario è che ciascun nodo genitore deve avere al massimo 2 nodi figlio.

Se volessimo per caso rappresentare su un albero binario una variabile continua, che possiede più di due valori, l'albero viene suddiviso in più livelli, in modo che ogni nodo padre abbia solamente due nodi figli.

1.4.2 Random Forest (RF)

L'algoritmo Random Forest, o delle foreste casuali in italiano, è un algoritmo di apprendimento supervisionato.

Rappresenta un tipo di modello ensemble, che si avvale del bagging come metodo di ensemble e l'albero decisionale come modello individuale. Ciò significa che una foresta casuale combina molti alberi decisionali in un unico modello. Individualmente, le previsioni fatte dagli alberi decisionali potrebbero non essere accurate, ma combinate insieme, le previsioni saranno in media più vicine al risultato.


Il risultato finale restituito dal Random Forest altro non è che la media del risultato numerico restituito dai diversi alberi nel caso di un problema di regressione, o la classe restituita dal maggior numero di alberi nel caso la Random Forest sia stata utilizzata per risolvere un problema di classificazione.

1.4.3 Support Vector Machine (SVM)


Il Support Vector Machine (SVM) è un algoritmo che può essere utilizzato sia per scopi di classificazione che di regressione. L'algoritmo SVM ottiene la massima efficacia nei problemi di classificazione binari.

L'SVM è basato sull'idea di trovare un iperpiano che divida al meglio un set di dati in due classi. Per comprenderne il funzionamento è bene definire alcuni concetti chiave, che sono i seguenti.


Iperpiano o limite di decisione lineare: per un'attività di classificazione con solo due dimensioni spaziali x_1 e x_2 (o x e y), un iperpiano è raffigurato come una linea che separa e classifica un insieme di dati. A 3 dimensioni, un iperpiano è rappresentato da un piano (il rettangolo in blu) come puoi vedere nell'immagine seguente. Con più di tre dimensioni viene definito genericamente "iperpiano".



Support Vector: definiti anche vettori di supporto in italiano, essi sono i punti dati più vicini all'iperpiano. Tali punti dipendono dal set di dati che si sta analizzando e se vengono rimossi o modificati alterano la posizione dell'iperpiano divisorio. Per questo motivo, possono essere considerati gli elementi critici di un set di dati.




Margine: è definito come la distanza tra i vettori di supporto di due classi differenti più vicini all'iperpiano. Alla metà di questa distanza viene tracciato l'iperpiano, o retta nel caso si stia lavorando a due dimensioni.



Il Support Vector Machine ha l'obiettivo di identificare l'iperpiano che meglio divide i vettori di supporto in classi. Per farlo esegue i seguenti step:

1. Cerca un iperpiano linearmente separabile o un limite di decisione che separa i valori di una classe dall'altro. Se ne esiste più di uno, cerca quello che ha margine più alto con i vettori di supporto, per migliorare l'accuratezza del modello.
2. Se tale iperpiano non esiste, SVM utilizza una mappatura non lineare per trasformare i dati di allenamento in una dimensione superiore (se siamo a due dimensioni, valuterà i dati in 3 dimensioni). In questo modo, i dati di due classi possono sempre essere separati da un iperpiano, che sarà scelto per la suddivisione dei dati.

Un iperpiano linearmente separabile è un iperpiano cui è semplice distinguere due classi. Nella seguente immagine è possibile trovare più di un iperpiano linearmente separabile (che sono assimilabili a delle rette essendo a due dimensioni): linea rossa, linea nera e linea verde.




Teoricamente, è possibile disegnare un numero infinito di linee rette per separare le palline blu dalle palline rosse. Il problema è trovare quale tra le infinite rette risulti ottimale, ossia quella che generi il minimo errore di classificazione su una nuova osservazione.

Infatti, più lontano dall'iperpiano si trovano i nostri punti dati, più siamo fiduciosi che essi siano stati classificati correttamente. Pertanto, desideriamo che i nostri punti dati siano il più lontano possibile dall'iperpiano, pur rimanendo nella parte corretta.

Quindi, quando vengono aggiunti nuovi dati di test, il modello decide la classe che assegniamo ad essa. Questo è ciò che fa il Support Vector Machine nella pratica, quando trova un iperpiano linearmente separabile.

Nell'esempio, secondo quanto affermato è la retta nera la linea che massimizza la distanza tra i vettori di supporto e l'iperpiano stesso.



1.4.4 K-Nearest Neighbors (KNN)

KNN è un algoritmo di apprendimento supervisionato, il cui scopo è quello di predire una nuova istanza conoscendo i data points che sono separati in diverse classi.

Dentro ad ogni classe vengono associati dei data points o istanze, il cui insieme definisce il set di dati. Pertanto possiamo supporre di visualizzare suddette classi su un asse cartesiano dove l'asse delle ordinate rappresenta una caratteristica mentre l'asse delle ascisse ne rappresenta un'altra. Esse rappresentano le caratteristiche del problema (si noti che se ne potrebbero usare anche di più di due).

Il suo funzionamento si basa sulla somiglianza delle caratteristiche: più un'istanza è vicina a un data point, più il KNN li considererà simili.

Solitamente la somiglianza viene calcolata tramite la distanza euclidea (o un qualche altro tipo di distanza a seconda del problema in esame). Minore sarà la distanza e maggiore sarà la somiglianza tra data point e l'istanza da prevedere.

Oltre alla distanza, l'algoritmo prevede di fissare un parametro k , scelto arbitrariamente, che identifica il numero di data points più vicini. Quando k è piccolo, stiamo limitando la regione di una determinata previsione e costringendo il nostro classificatore ad essere "più cieco" rispetto alla distribuzione generale. Al contrario, un k grande riduce l'impatto della varianza causato da un errore casuale, ma corre il rischio di ignorare piccoli dettagli che potrebbero essere rilevanti. Alcuni autori suggeriscono di impostare k uguale alla radice quadrata del numero di osservazioni nel set di dati di addestramento

L'algoritmo valuta le k minime distanze così ottenute. La classe che ottiene il maggior numero di queste distanze è scelta come previsione.

Il KNN è uno strumento non parametrico, ossia non fa alcuna ipotesi sulla distribuzione dei dati che analizza.

Di conseguenza, KNN potrebbe e probabilmente dovrebbe essere una delle prime scelte per uno studio di classificazione quando c'è poca o nessuna conoscenza precedente sulla distribuzione dei dati.

In aggiunta, si può affermare che la fase di addestramento è piuttosto veloce. La mancanza di generalizzazione fa sì che KNN conservi tutti i dati di allenamento. Ciò significa che tutti i dati di addestramento (o la maggior parte di essi) sono necessari durante la fase di test.

1.5 Hyperparameter tuning

L'ottimizzazione dell'iperparametro (hyperparameter tuning) è il problema di scegliere un set di iperparametri ottimali per un algoritmo di apprendimento. Un iperparametro è un parametro il cui valore viene utilizzato per controllare il processo di apprendimento. Al contrario, i valori di altri parametri vengono appresi nel processo.

Gli iperparametri sono scelti quindi per il training di un modello, che regolano il processo di training stesso e questi valori in genere rimangono costanti durante tutto il processo.

Negli scenari di Machine Learning, le prestazioni del modello dipendono in larga misura dai valori degli iperparametri selezionati. La prestazione di classificazione è stata valutata usando la validazione incrociata secondo il principio del "lascia un

soggetto fuori” [22]. Ogni volta venivano utilizzati i dati di un soggetto per testare le prestazioni del classificatore addestrato con il dataset di tutti i restanti soggetti.

Gli iperparametri per ogni classe sono stati recuperati tramite la ricerca a griglia (grid-search) e tramite convalida incrociata di 5 volte sul set di addestramento. Lo spazio della ricerca a griglia per γ e C nell’algoritmo SVM è stato impostato su: [0.001, 0.01, 0.1] e [1, 10,100], rispettivamente. Per il RF, lo spazio di ricerca a griglia è stato impostato su [3, 4, 5] per la profondità massima dell'albero e [50, 100, 150, 200, 250, 300, 350, 400, 450, 500, 600] per il numero massimo di alberi. La massima profondità dell'albero nell’algoritmo DT è stata recuperata con uno spazio di ricerca a griglia di [5, 20] con quattro valori distribuiti uniformemente. I valori della griglia sono stati impostati empiricamente osservando le prestazioni sul set di convalida, ovvero escludendo il set di test dalla regolazione dell'iperparametro. Il numero di vicini per KNN è stato scelto in uno spazio uguale a [3, 5, 7, 9]. I valori di profondità dell'albero e il numero di vicini sono stati impostati in questo modo per prevenire overfitting.

1.6 Metriche usate

Le metriche sono utilizzate per valutare le prestazioni di un classificatore. In questo progetto è stata utilizzata la matrice di confusione (meglio conosciuta come confusion matrix). Nel campo del machine learning e nella classificazione statistica, una matrice di confusione è una tabella in cui le previsioni sono rappresentate nelle colonne e lo stato effettivo è rappresentato dalle righe (a volte questo è invertito, con istanze reali in colonne e previsioni nelle righe).

La tabella è un'estensione della matrice di confusione nell'analisi predittiva e rende facile vedere se si è verificato un errore di denominazione e se le previsioni sono più o meno corrette.

Da questa tabella, quindi, è possibile comprendere le performance di un modello predittivo di classificazione in modo da determinare quanto questo modello sia accurato ed efficace.

Possiamo avere una matrice di confusione a 2 Classi, che viene utilizzata per prevedere il risultato di un classificatore binario (Sì/No, Vero/Falso, e così via), oppure una matrice di confusione multi-classe, in cui si tenta di prevedere le performance di un modello predittivo formato da più di due classi.

Un classificatore binario produce, come detto poc'anzi, output con due valori di classe o etichette, come Sì / No e 1/0, per dati di input conosciuti. La classe di interesse viene solitamente indicata come "positiva" e l'altra come "negativa".

Per comprendere meglio l'incrocio tra valori effettivi e previsti alla matrice di confusione vengono associati i seguenti termini:

- True positive (TP, o veri positivi): sono i casi in cui si prevede correttamente che la classe sia positiva (1);

- True negative (TN, o veri negativi): il modello ha previsto correttamente che la classe sia negativa (0);
- False positive (FP, o falsi positivi): sono i casi in cui si prevede erroneamente che la classe sia positiva (1 (conosciuti anche come errori di I tipo)).
- False negative (FN, o falsi negativi): il modello prevede erroneamente che la classe sia negativa (0) (conosciuti anche come errori di II tipo).

Tra le metriche base e più diffuse della matrice di confusione possiamo trovare:

- Error Rate (o Tasso di errore): è il tasso di errore (ERR) e viene calcolato come il numero di tutti i pronostici errati diviso per il numero totale del set di dati. Il miglior tasso di errore è 0, mentre il peggiore è 1.

$$ERR = \frac{FP + FN}{TN + FP + FN + TP}$$

- Accuracy (o accuratezza): indica l'accuratezza del modello come dice il nome. Pertanto, la migliore accuratezza è 1, mentre la peggiore è 0. Può anche essere calcolato da $1 - ERR$, o dalla seguente formula:

$$Accuracy = \frac{TP + TN}{TN + FP + FN + TP}$$

- Precision (o precisione): La precisione è l'abilità di un classificatore di non etichettare un'istanza positiva che è in realtà negativa. Per ogni classe è definito come il rapporto tra veri positivi e la somma di veri e falsi positivi. Detto in un altro modo, "per tutte le istanze classificate come positive, quale percentuale era corretta?". La formula di calcolo della precisione è la seguente:

$$Precision = \frac{TP}{TP + FP}$$

- Recall (o richiamo): detta anche sensitivity o true positive rate, è la capacità di un classificatore di trovare tutte le istanze positive. Per ogni classe è definito come il rapporto tra i veri positivi e la somma dei veri positivi e dei falsi negativi. Detto in altri termini, "per tutte le istanze che erano effettivamente positive, quale percentuale è stata classificata correttamente?". La formula di calcolo del richiamo è la seguente:

$$Recall = \frac{TP}{TP + FN}$$

- False positive rate (o rateo falsi positivi): Il tasso di falsi positivi (FPR) viene calcolato come il numero di previsioni positive errate diviso per il numero totale di negativi. Il miglior tasso di falsi positivi è 0 mentre il peggiore è 1. Può anche essere calcolato come $1 - \text{specificità}$.

$$FPR = \frac{FP}{TN + FP} = 1 - SP$$

- F-score (o punteggio f): è una media armonica ponderata delle metriche *Precision* e *Recall* in modo tale che il punteggio migliore sia 1 e il peggiore sia 0. Come regola generale, la media ponderata di F1 dovrebbe essere utilizzata per confrontare i modelli di classificatore, non la precisione globale.

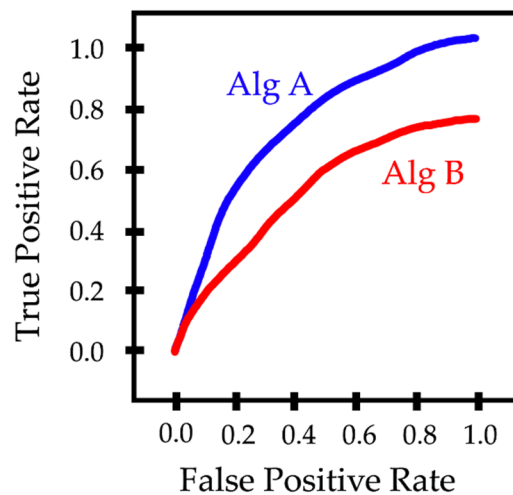
$$F - score = \frac{2 \times Recall \times Precision}{Recall + Precision}$$

- Curva ROC: le curve ROC (Receiver Operating Characteristic, anche note come Relative Operating Characteristic) sono degli schemi grafici per un classificatore binario. Lungo i due assi si possono rappresentare il True Positive Rate (TPR, frazione di veri positivi) e False Positive Rate (FPR, frazione di falsi positivi). In altre parole, si studiano i rapporti fra allarmi veri (hit rate) e falsi allarmi. La curva ROC viene creata tracciando il valore del True Positive Rate (TPR, frazione di veri positivi) rispetto al False Positive Rate (FPR, frazione di falsi positivi) a varie impostazioni di soglia. Può anche essere pensato come un diagramma della potenza in funzione dell'errore di tipo I.

La curva ROC è quindi il tasso dei veri positivi in funzione del tasso dei falsi positivi. Le curve ROC passano per i punti (0,0) e (1,1), avendo inoltre due condizioni che rappresentano due curve limite:

- o una che taglia il grafico a 45°, passando per l'origine. Questa retta rappresenta il caso del classificatore casuale (linea di «nessun beneficio») e l'area sottesa AUC (Area Under the Curve) è pari a 0,5.
- o la seconda curva è rappresentata dal segmento che dall'origine sale al punto (0,1) e da quello che congiunge il punto (0,1) a (1,1), avendo un'area sottesa di valore pari a 1, ovvero rappresenta il classificatore perfetto, poiché si ha un TPR massimo e un FPR minimo nel punto 0;1.

Si supponga di avere due algoritmi (rispettivamente Alg A e Alg B) per l'elaborazione dei dati contenuti nel dataset di riferimento, le cui rispettive curve ROC sono esemplificate nella figura.



Come si può vedere Alg A si avvicina di più all'angolo superiore sinistro del diagramma (punto 0;1) e la relativa area (AUC) sottesa alla curva è maggiore rispetto a quella sottesa a Alg B. Il primo algoritmo quindi avrà una performance superiore al secondo.

Capitolo 2 – Risultati

Di seguito sono riportati i risultati della classificazione ottenuti sul set di dati del battito LDV. In prima istanza vengono riportate le matrici di confusione; successivamente, i risultati sono mostrati in termini di: (a) richiamo (Rec), (b) precisione (Prec) e (c) punteggio f1 (f1) per le classi beat e no-beat. I risultati sono ottenuti utilizzando Random Forest (RF), Albero decisionale (DT), K-Nearest Neighbor (KNN) e il Support Vector Machines (SVM).

Random Forest

True Label	no-beat	25159	2478
	beat	4589	23048
		no-beat	beat
		Predicted Label	

KNN

True Label	no-beat	26247	1390
	beat	4835	22802
		no-beat	beat
		Predicted Label	

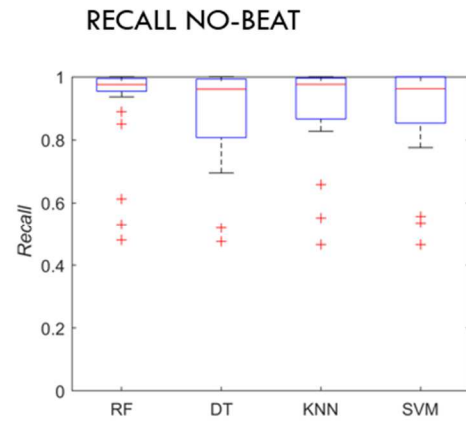

DT

True Label	no-beat	26705	1932
	beat	6082	21555
		no-beat	beat
		Predicted Label	

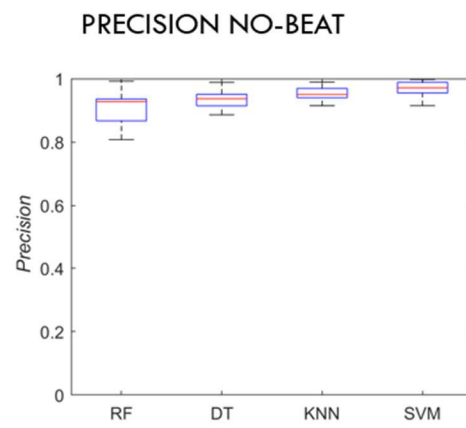
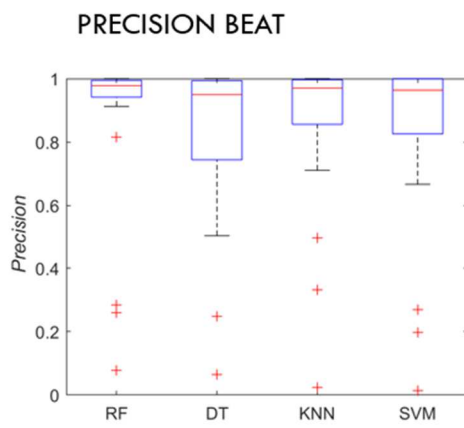
SVM

True Label	no-beat	26655	982
	beat	5263	22374
		no-beat	beat
		Predicted Label	


a) Recall



b) Precision



c) F1 score

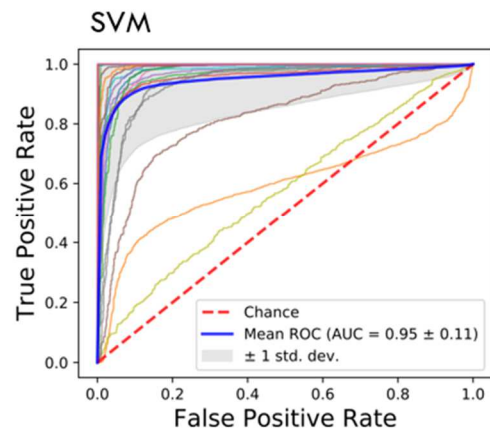
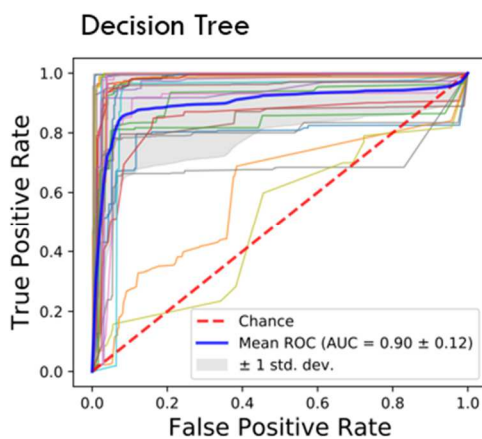
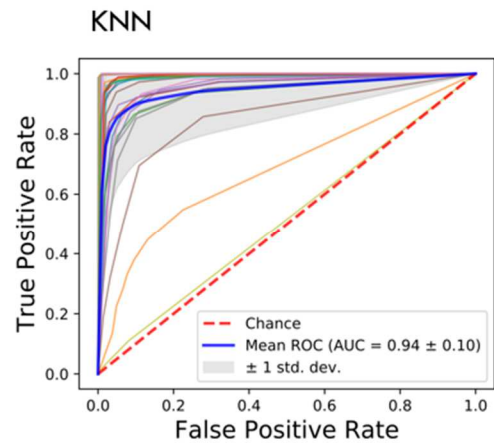



Per valutare le prestazioni di classificazione, è stata calcolata l'area (AUC) sotto la curva delle caratteristiche operative del ricevitore (ROC), in cui ogni curva si riferisce ad un soggetto. Le prestazioni di classificazione sono ottenute durante la classificazione del set di dati del battito LDV con Random Forest (RF), Decision Tree (DT), K-Nearest Neighbours (KNN) e Support Vector Machine (SVM).

Nella tabella viene riportato un richiamo delle classificazioni (Rec i), precisione (Prec i) e F1-score ($f1$ i) è riportato per la classe beat ($i = 1$) e no-beat ($i = 0$).

	<i>Prec</i>		<i>Rec</i>		<i>f1</i>	
	<i>beat</i>	<i>no-beat</i>	<i>beat</i>	<i>no-beat</i>	<i>beat</i>	<i>no-beat</i>
<i>RF</i>	0.98	0.93	0.92	0.98	0.93	0.93
<i>DT</i>	0.95	0.94	0.93	0.96	0.93	0.94
<i>KNN</i>	0.97	0.95	0.94	0.98	0.95	0.95
<i>SVM</i>	0.96	0.97	0.96	0.96	0.96	0.98

ROC (Receiver Operating Characteristic)




Il SVM ha ottenuto prestazioni migliori rispetto agli altri classificatori, con valori medi per f1, Rec e Prec rispettivamente di 0,96, 0,96, 0,96. La tabella mostra il valore di media di Prec, Rec e f1 per le classi beat e no-beat. Non sono state rilevate differenze statistiche tra i quattro modelli in termini di f1 ($p = 0,98$) e Prec ($p = 0,98$) per la classe di beat. Invece, sono state trovate delle differenze statistiche confrontando il Rec della classe beat di SVM rispetto a quello di RF e DT.

Pertanto, il classificatore SVM è stato utilizzato per ulteriori indagini sulle prestazioni. La curva ROC, per ciascun soggetto, viene tracciata insieme alla curva media. L'AUC ottenuta ha raggiunto un valore medio di 0,95 per SVM, con una deviazione standard pari a 0,11. Le curve ROC per gli altri classificatori sono mostrate per completezza.


L'algoritmo SVM ha correttamente classificato 22374 campioni, con solo 5263 (un ordine di 189 magnitudo inferiore) finestre di segnale errate. L'algoritmo RANDOM FOREST è risultato il più stabile e verrà usato per futuri confronti con altri metodi di machine learning usando lo stesso dataset.

Capitolo 3 – Conclusioni

Come detto poc'anzi, l'algoritmo SVM ha ottenuto le migliori prestazioni. Questi risultati hanno messo in evidenza la capacità di SVM di gestire uno spazio di funzionalità ad alta dimensione (che era elevato se confrontato con il numero di soggetti presenti nel dataset del LDV) e la sua robustezza nell'affrontare le componenti del rumore del segnale LDV. Conclusioni simili sono state tratte in campi di ricerca affini [23][24].



(a)



(b)

- a) Segnale ECG con battiti standard dorati (rettangoli grigi centrati con il picco R dal segnale ECG)
- b) Probabilità di uscita (linea blu verticale) per la classe di battito (beat-class) ottenuta con SVM.

I battiti nel segnale ECG sono mostrati con rettangoli per una migliore visibilità.

Tutti i classificatori hanno raggiunto prestazioni simili. Questo potrebbe essere attribuito alle caratteristiche del dataset del LDV: la presenza di soggetti sani e simili in età, che hanno riferito di avere uno stile di vita normale; gli atleti, ad esempio, possono sviluppare dinamiche cardiovascolari (ad es. bradicardia, sindrome cardiaca dell'atleta) che possono influire sulle prestazioni del modello di dataset proposto.

Per simulare uno scenario applicativo reale, è stata valutata la prestazione del SVM su un segnale LDV a lunghezza intera. Le prestazioni raggiunte sono state paragonate a quella ottenuta quando si utilizza il dataset di LDV.

Un'altra limitazione del metodo presentato potrebbe essere vista nel numero relativamente piccolo di soggetti acquisiti per la creazione del dataset. Per attenuare questo problema, è stato pianificato di rilasciare il dataset LDV alla comunità scientifica affinché altri ricercatori possano integrare i loro dati.

In questo documento, è stato presentato un innovativo modello basato sul machine learning per rilevare il battito cardiaco dal segnale LDV. I risultati raggiunti testando l'algoritmo sul dataset LDV (il primo dataset disponibile pubblicamente in questo campo), hanno suggerito che il segnale LDV può essere pienamente sfruttato per riportare i battiti cardiaci. Ciò può spostare la ricerca verso modelli per acquisire parametri cardiaci con misure senza contatto, particolarmente importanti quando le condizioni della pelle dei pazienti sono critiche (ad es. in caso di ustioni gravi o parto estremamente prematuro).

Rilasciando questo dataset, basato su LDV, alla comunità scientifica, si spera di stimolare i ricercatori a tradurre l'uso della tecnologia LDV nella pratica clinica attuale.

Bibliografia

- [1] P. Castellini, M. Martarelli, E. Tomasini, Laser doppler vibrometry: Development of advanced solutions answering to technology's needs, *Mechanical Systems and Signal Processing* 20 (2006) 1265-1285
- [2] S. Yang, M. S. Allen, Output-only modal analysis using continuous scan laser doppler vibrometry and application to a 20 kW wind turbine, *Mechanical Systems and Signal Processing* 31 (2012) 228-245.
- [3] P. Castellini, C. Santolini, Vibration measurements on blades of naval propeller rotating in water, in: *Second International Conference on Vibration Measurements by Laser Techniques: Advances and Applications*, volume 2868, International Society for Optics and Photonics, 1996, pp. 186-194.
- [4] P. Castellini, G. Revel, E. Tomasini, Laser doppler vibrometry: a review of advances and applications, *The Shock and Vibration Digest* 30 (1998) 443-456.
- [5] R. L. Goode, G. Ball, S. Nishihara, K. Nakamura, Laser doppler vibrometer (LDV)-a new clinical tool for the otologist., *The American Journal of Otology* 17 (1996) 813-822.
- [6] A. Jakob, M. Bornitz, E. Kuhlisch, T. Zahnert, New aspects in the clinical diagnosis of otosclerosis using laser doppler vibrometry, *Otology & Neurotology* 30 (2009) 1049-1057.
- [7] U. Morbiducci, L. Scalise, M. De Melis, M. Grigioni, Optical vibrocardiography: A novel tool for the optical monitoring of cardiac activity, *Annals of Biomedical Engineering* 35 (2007) 45-58.
- [8] A. D. Kaplan, J. A. OrSullivan, E. J. Sirevaag, P.-H. Lai, J. W. Rohrbaugh, Hidden state models for noncontact measurements of the carotid pulse using a laser doppler vibrometer, *IEEE Transactions on Biomedical Engineering* 59 (2011) 744-753.
- [9] B. Sztrymf, F. Jacobs, D. Chemla, C. Richard, S. C. Millasseau, Validation of the new Complior sensor to record pressure signals non-invasively, *Journal of Clinical Monitoring and Computing* 27 (2013) 613-619.

- [10] H. Kugel, C. Bremer, M. Püschel, R. Fischbach, H. Lenzen, B. Tombach, H. Van Aken, W. Heindel, Hazardous situation in the MR bore: induction in ECG leads causes fire, *European Radiology* 13 (2003) 690-694.
- [11] J. L. Rojo-Álvarez, M. Martínez-Ramón, J. Muñoz-Marí, G. Camps-Valls, From signal processing to machine learning (2018).
- [12] Sara Casaccia, Erik J. Sirevaag, Edward J., Luigi Casacanditella, Lorenzo Scalise e John W. Rohrbaugh, Decoding carotid pressure waveforms recorded by laser Doppler vibrometry: Effects of rebreathing.
- [13] M. De Melis, U. Morbiducci, L. Scalise, E. P. Tomasini, D. Delbeke, R. Baets, L. M. Van Bortel, P. Segers, A noncontact approach for the evaluation of large artery stiffness: a preliminary study, *American Journal of Hypertension* 21 (2008) 1280-1283.
- [14] A. Campo, P. Segers, J. Dirckx, Laser doppler vibrometry for in vivo assessment of arterial stiffness, in: *IEEE International Symposium on Medical Measurements and Applications*, IEEE, 2011, pp. 119-121.
- [15] A. Campo, P. Segers, H. Heuten, I. Goovaerts, G. Ennekens, C. Vrints, R. Baets, J. Dirckx, Non-invasive technique for assessment of vascular wall stiffness using laser doppler vibrometry, *Measurement Science and Technology* 25 (2014) 065701.
- [16] A. Campo, H. Heuten, I. Goovaerts, G. Ennekens, C. Vrints, J. Dirckx, A non-contact approach for PWV detection: application in a clinical setting, *Physiological Measurement* 37 (2016) 990.
- [17] S. Casaccia, E. Sirevaag, E. Richter, J. O'Sullivan, L. Scalise, J. Rohrbaugh, Features of the non-contact carotid pressure waveform: Cardiac and vascular dynamics during rebreathing, *Review of Scientific Instruments* 87 (2016) 102501.
- [18] L. Scalise, G. Cosoli, L. Casacanditella, S. Casaccia and J. W. Rohrbaugh, "The measurement of blood pressure without contact: An LDV-based technique," 2017 *IEEE International Symposium on Medical Measurements and*

- Applications (MeMeA), Rochester, MN, 2017, pp. 245-250, doi: 10.1109/MeMeA.2017.7985883.
- [19] Viviana Mancini, Daniela Tommasin, Yanlu Li, Jonathan Reeves, Roel Baets, Steve Greenwald, Patrick Segers, on behalf of the CARDIS consortium, Detecting carotid stenosis from skin vibrations using Laser Doppler Vibrometry – An in vitro proof-of-concept, PLoS One. 2019; 14(6): e0218317. Published online 2019 Jun 20. doi: 10.1371/journal.pone.0218317
- [20] A. Di Donato, L. Scalise and L. Zappelli, "Noncontact speckle-based velocity sensor [laser Doppler vibrometer]," in IEEE Transactions on Instrumentation and Measurement, vol. 53, no. 1, pp. 51-57, Feb. 2004, doi: 10.1109/TIM.2003.821482.
- [21] J. Pan, W. J. Tompkins, A real-time QRS detection algorithm, IEEE Transactions on Biomedical Engineering 32 (1985) 230-236.
- [22] T.-T. Wong, Performance evaluation of classification algorithms by k fold and leave-one-out cross validation, Pattern Recognition 48 (2015) 2839-2846.
- [23] C. Calamanti, S. Moccia, L. Migliorelli, M. Paolanti, E. Frontoni, Learning-based screening of endothelial dysfunction from photoplethysmographic signals, Electronics 8 (2019) 271.
- [24] S. Moccia, E. De Momi, M. Guarnaschelli, M. Savazzi, A. Laborai, L. Guastini, G. Peretti, L. S. Mattos, Confident texture-based laryngeal tissue classification for early stage diagnosis support, Journal of Medical Imaging 4 (2017) 034502.

Ringraziamenti

“Esiste un solo bene, la conoscenza, ed un solo male, l'ignoranza.” - Socrate

Le prime persone a cui devo dire grazie e a cui dedico questo traguardo sono i miei genitori, fonte di sostegno e di coraggio, che mi hanno trasmesso la passione per lo studio e la voglia di raggiungere questo obiettivo più di qualsiasi altra cosa. Senza mia madre e mio padre, non avrei avuto la possibilità di studiare e frequentare questa università, mi hanno dato la forza di non arrendermi davanti alle delusioni, mi hanno sempre spronato a dare il massimo perché sapevano quanto io valessi. Durante questo percorso ci sono stati alti e bassi, con periodi in cui il rendimento non era proporzionale all'impegno, ma nonostante questo, potevo sempre considerare i miei genitori come due pilastri, qualcuno con cui potermi sfogare e consigliare. Grazie per aver creduto in me.

Ringrazio mia sorella per essermi stata vicina, soprattutto negli ultimi tempi, quando gli esami rimasti sembravano insormontabili, senza mai farmi mancare il suo sostegno e i suoi preziosi consigli.

Ringrazio il prof. Scalise e l'ing. Antognoli, relatore e correlatore di questa tesi di laurea, per il supporto che mi hanno fornito per il tirocinio, la stesura di questa tesi e per le conoscenze che hanno messo a mia disposizione.

Giunti a questo punto non posso non ringraziare i miei amici e colleghi di corso. Ringrazio Michele, Christian, Gianluca e Davide, ragazzi con cui ho stretto un forte legame durante questi anni: abbiamo condiviso attimi di gioia e di tristezza, ma che nonostante tutto mi sono rimasti accanto in questi anni di Università. Senza i miei amici, senza le giornate passate in facoltà, le notti d'estate in casa, le lezioni, i seminari, le ore al bar, le attese agli appelli, le ansie pre-esame, tutto sarebbe stato più cupo: grazie per avermi trasmesso entusiasmo e serenità.

Ai miei amici Antonio, Federica e Claudio, che mi hanno aiutato molto e mi sono stati sempre vicini, soprattutto nei momenti del bisogno, in cui non sarei mai sopravvissuto alle ansie e alle paranoie di questi lunghi anni, dico grazie di cuore.

Un ringraziamento particolare va a Luca, che ho conosciuto, sfortunatamente, solo qualche anno fa, una persona piena di entusiasmo e altruismo, che mi ha aiutato molto e mi ha sempre spronato, che mi ha sempre parlato sinceramente perché si vedeva quanto ci tenesse alla nostra amicizia.

Durante questo percorso ho ritrovato amici che non vedevo da tempo e scoperto nuove amicizie, Simone, Luca, Lorenzo, Valeria, Manuel, Simone (Corty), Giulia, Barie, Daniele, Alessandro, Jacopo e Davide, grazie per tutte le passeggiate, giocate e momenti pieni di divertimento e allegria.

Viaggiando verso città nuove ho legato con alcune persone che si sono rivelate molto importanti, Martina e Pierfrancesco, che mi hanno dimostrato come l'amicizia non conosca distanza, se si basa su un sentimento reale. Grazie.

Un grazie speciale a Federica, la mia ragazza, la persona che più di tutte è stata capace di capirmi e di sostenermi nei momenti difficili. Il nostro incontro è avvenuto per caso, ma fin da subito, avevamo entrambi capito che sarebbe nato qualcosa di bello. Nell'affrontare ciò che la vita ti riserva, mi hai mostrato una forza di volontà enorme. Le giornate ad Ancona sono diventate meno monotone, ho ritrovato la voglia di uscire per una camminata o una pizza, con te, mi hai incoraggiato a sperimentare nuove idee, scoprire nuove passioni e coltivarle, affrontare positivamente le sfide (universitarie e della vita), di mettermi in gioco e di capire che, in fondo, gli ostacoli esistono per essere superati. Grazie di tutto, ti amo.