



UNIVERSITÀ
DEGLI STUDI
DI PADOVA



DIPARTIMENTO DI INGEGNERIA DELL'INFORMAZIONE

CORSO DI LAUREA IN INGEGNERIA BIOMEDICA

**“MONITORAGGIO REMOTO DELL'EPILESSIA:
DISPOSITIVI WEARABLE, ELABORAZIONE DEL
SEGNALE E SICUREZZA DEI DATI”**

Relatore: Prof. Giovanni Sparacino

Laureanda: Alice Stefano

ANNO ACCADEMICO 2025 – 2026

Data di laurea 25/09/2026

Abstract

L'epilessia è una delle condizioni neurologiche gravi più diffuse, con oltre 70 milioni di persone interessate nel mondo e quasi l'80% dei casi concentrato nei Paesi a basso e medio reddito. Questa malattia presenta due grandi limiti: le crisi epilettiche sono imprevedibili e spesso non riconosciute dal paziente stesso, inoltre, l'assistenza tradizionale si basa su visite ambulatoriali occasionali, che non restituiscono un quadro completo della frequenza reale degli eventi. A ciò, si aggiunge il rischio di morte improvvisa e inattesa, specialmente nelle crisi tonico-cloniche notturne e non assistite, per le quali la supervisione può avere un ruolo protettivo. Il monitoraggio continuo a distanza potrebbe quindi essere una soluzione ideale per superare queste problematiche.

Questo lavoro esamina in modo critico il percorso del dato nel monitoraggio remoto dell'epilessia, dalla sua acquisizione sul corpo del paziente fino alla sua trasmissione protetta, attraverso una rassegna della letteratura scientifica recente. Per prima cosa, vengono analizzati i dispositivi indossabili, da cui si osserva che per le crisi tonico-cloniche generalizzate ci sono grandi risultati (con sensibilità tra il 90% e il 96% e tassi di falsi allarmi tra 0,2 e 0,67 ogni 24 ore), mentre per le crisi focali senza componente motoria è più difficile rilevare con efficacia le crisi. Una soluzione potrebbe essere l'utilizzo di sistemi multimodali che, grazie all'unione di segnali di natura differente, riescono ad individuare con maggiore precisione le crisi, permettendo così di agire immediatamente. Si studia, poi, ciò che riguarda l'elaborazione del segnale, dalla rimozione degli artefatti, che non ammette una soluzione unica, al Compressive Sensing, che unisce acquisizione e compressione in un unico passaggio, riduce la banda, la memoria e l'energia richiesta. Il lavoro si conclude con un approfondimento in appendice, dove si esamina la protezione del dato: la crittografia convenzionale non è sostenibile su dispositivi a risorse limitate, mentre gli algoritmi leggeri raggiungono un compromesso accettabile tra sicurezza, prestazioni e consumo. Da questo lavoro è chiaro come nelle prospettive future sia necessario sviluppare nuovi sistemi che permettano un monitoraggio continuo a distanza, combinando l'utilizzo di energia come risorsa limitata e garantendo contemporaneamente un grado di efficacia che soddisfi i bisogni dei pazienti.

Indice

Capitolo 1 Epilessia: origine, impatto, monitoraggio	1
1.1 L'epilessia e le crisi epilettiche	1
1.2 Impatto sulla vita quotidiana e limiti dell'assistenza sanitaria tradizionale.....	2
1.3 Prospettive ed esigenze del monitoraggio continuo a distanza	3
1.4 Obiettivi dell'elaborato	6
Capitolo 2 Dispositivi wearable per il monitoraggio dell'epilessia	8
2.1 Tipologie di dispositivi indossabili	9
2.1.1 Applicazioni per il monitoraggio dell'attività neurologica.....	10
2.1.2 Applicazioni per il monitoraggio dei parametri fisiologici.....	13
2.2 Monitoraggio multimodale e integrazione tra segnali.....	14
2.3 Vantaggi e limiti dei dispositivi wearable.....	15
2.4 Accettabilità e comfort a lungo termine da parte dei pazienti.....	17
2.5 Dal dispositivo alla rete: trasmissione e protezione dei dati	18
Capitolo 3 Elaborazione del segnale EEG per la rilevazione delle crisi epilettiche	21
3.1 Pre-elaborazione del segnale e riduzione del rumore del segnale.....	21
3.2 Compressive Sensing: principi teorici e vantaggi per l'EEG.....	24
3.3 Caso applicativo: rilevazione di crisi su segnale EEG compresso	30
3.4 Confronto delle prestazioni: sensibilità, specificità, accuratezza.....	32
Capitolo 4 Conclusioni.....	35
4.1 Sintesi dei principali risultati	35
4.2 Sfide aperte: qualità del segnale, autonomia energetica, affidabilità	36
4.3 Prospettive future	38
Appendice A.....	39
A.1 Minacce e vulnerabilità nei dispositivi wearable e nelle trasmissioni wireless	39
A.2 Crittografia leggera per dispositivi a risorse limitate	40
A.3 Bilanciamento tra sicurezza, prestazioni e consumo energetico	44
Bibliografia	47

Capitolo 1

Epilessia: origine, impatto, monitoraggio

1.1 L'epilessia e le crisi epilettiche

L'epilessia è una malattia cronica neurologica, caratterizzata dalla presenza di crisi epilettiche ricorrenti e non provocate, ovvero scariche elettriche eccessive e anomale di gruppi di neuroni cerebrali. La definizione clinica di epilessia formulata da ILAE (Lega Internazionale contro l'Epilessia) si basa su tre criteri:

- almeno due crisi non provocate avvenute a una distanza superiore alle 24 ore
- una singola crisi non provocata quando il rischio di recidiva è alto (oltre il 60% nei 10 anni successivi)
- la diagnosi di una sindrome epilettica.

L'ILAE stabilisce inoltre che l'epilessia si definisce risolta nei seguenti casi: se la sindrome epilettica è età-dipendente ed ormai l'età in cui si manifesta è stata superata. Altrimenti nel caso in cui una persona sia libera da crisi per almeno 10 anni e non assuma farmaci antiepilettici da almeno 5 anni [1]. L'epilettogenesi è il processo attraverso il quale un cervello non epilettico diventa in grado di generare crisi epilettiche spontanee e ricorrenti. Le crisi epilettiche sono provocate da uno squilibrio tra segnali eccitatori (glutammato) e segnali inibitori (GABA). Questo mancato equilibrio è la causa di gruppi di neuroni che diventano improvvisamente ipereccitabili ed ipersincroni, causando così la scarica epilettica e alterando il funzionamento della rete neuronale. Al contrario, in alcuni casi, anche un'eccessiva inibizione può comportare crisi epilettiche. Nelle epilessie generalizzate, le reti che causano le crisi epilettiche sono ampiamente distribuite e coinvolgono in entrambi gli emisferi le strutture talamocorticali, mentre nelle epilessie focali interessano un solo emisfero, tipicamente nelle zone limbiche o neocorticali.

Dal punto di vista epidemiologico, l'epilessia è una delle condizioni neurologiche gravi più comuni: colpisce oltre 70 milioni di persone nel mondo, con quasi l'80% dei casi nei Paesi a basso e medio reddito [2]. L'incidenza nei Paesi ad alto reddito è di circa 50 per 100.000 all'anno, con picco nei bambini con età inferiore ad 1 anno e negli adulti sopra i 50 anni, massima sopra i 70 anni. Nei Paesi a basso reddito l'incidenza è ancora più alta

(oltre 80–100 per 100.000). Sicuramente un debole sistema sanitario, le carenze igienico-sanitarie e un alto rischio d'infezioni contribuiscono in modo rilevante. La maggior parte delle prognosi è favorevole, specialmente nei Paesi ad alto reddito, dove oltre due terzi dei pazienti raggiungono una remissione a lungo termine, mentre fino a un terzo presenta un'epilessia farmacoresistente.

1.2 Impatto sulla vita quotidiana e limiti dell'assistenza sanitaria tradizionale

L'epilessia è una malattia che incide profondamente sulla qualità della vita di chi ne soffre [2]. Le crisi sono spontanee e non prevedibili, e a questa imprevedibilità si accompagnano conseguenze cognitive e psicosociali che rendono la malattia un carico rilevante, soprattutto per i pazienti che continuano ad avere crisi.

A questo si aggiunge una profonda disomogeneità nell'accesso alle cure. Infatti, il tasso di mortalità è spesso superiore in Paesi meno sviluppati, con cause molto differenti. Le comorbilità sono la causa di morte più importante, soprattutto subito dopo la diagnosi. Fino a un terzo delle morti premature è attribuibile direttamente o indirettamente all'epilessia. La SUDEP (morte improvvisa inattesa) ha infatti un'incidenza di 1,2 per 1000 anni-persona, con picco tra i 20 e i 40 anni [2]. La causa principale sta nel fatto che è spesso non assistita, legata al sonno e preceduta da una convulsione, seguita da apnea e asistolia. Le convulsioni frequenti, specie notturne, sono il principale fattore di rischio, e la supervisione notturna da parte di un testimone può essere protettiva. Per questo motivo, dispositivi per il monitoraggio continuo domiciliare migliorerebbero questa grave situazione.

Inoltre, oltre il 50% dei pazienti ha almeno un problema medico aggiuntivo: disturbi psichiatrici o condizioni somatiche. Ad oggi non esiste ancora una cura definitiva, nonostante farmaci o altri dispositivi medici possano aiutare a mantenere controllata la malattia. Ad esempio, l'EEG non definisce l'epilessia, ma aiuta a determinare il tipo e il rischio di recidiva; la video-EEG a lungo termine, invece, può dare diagnosi definitiva nei casi difficili. Tra le ultime novità della telemedicina ci sono i dispositivi indossabili che possono aiutare nel rilevamento delle crisi.

Oltre a questi limiti clinici, il problema principale sta nel fatto che oltre il 75% delle persone con epilessia attiva non riceve alcun trattamento. Questo divario terapeutico si concentra nei Paesi a basso e medio reddito, nonostante siano disponibili terapie efficaci e a basso costo. Infatti, nei Paesi a basso e medio reddito, la quota di pazienti non trattati oscilla dal 30% a oltre il 90% e la causa più rilevante è la mancanza di accesso ai medici, poiché la maggior parte dei pazienti vive in aree rurali, mentre i medici si concentrano nelle città. Le altre cause principali sono l'impossibilità di procurarsi i farmaci con continuità e l'impossibilità di sostenerne il costo. Per queste situazioni particolari nel [3] si spiega che l'Organizzazione Mondiale della Sanità ha proposto di abilitare operatori sanitari non medici alla diagnosi e alla gestione dell'epilessia, il che richiede però un supporto specialistico continuo che può essere fornito solo per via telematica. Questo problema non è confinato ai soli Paesi poveri. La carenza globale di neurologi ed epilettologi è stimata attorno al 19% e contribuisce in misura significativa al divario terapeutico, mentre fino al 70% dei pazienti potrebbe raggiungere la libertà dalle crisi, se fosse diagnosticato e trattato correttamente [5].

1.3 Prospettive ed esigenze del monitoraggio continuo a distanza

La telemedicina, ed in particolare la teleneurologia, può diventare la soluzione a molte di queste problematiche. Per teleneurologia si intende l'impiego della tecnologia per erogare a distanza assistenza e formazione neurologica, in modalità sincrona o asincrona [6]. Questa ha avuto un forte sviluppo con l'avvento del COVID-19, dove le interazioni umane erano limitate. Ad oggi, con le nuove tecnologie, essa ha il potenziale di migliorare e ampliare l'accesso alle cure per miliardi di persone, esattamente come è già successo con il *telestroke*. Nei contesti a basse risorse, la teleneurologia potenzia le capacità delle risorse locali attraverso formazione, supporto diagnostico e consulenza; nei contesti ad alte risorse, invece, sposta l'assistenza dall'ospedale e dall'ambulatorio verso il domicilio e i dispositivi mobili, integrando comunicazioni asincrone e professionisti con competenze diverse.




Fig. 1.1 - Rappresentazione globale degli studi condotti sulla telemedicina [5]

La telemedicina fornisce quindi un grande aiuto nella sanità globale, poiché è in grado di migliorare l'accesso alle cure per tutti i pazienti, assicurando quindi un buon rapporto costo-efficacia. La revisione di ambito della Task Force ILAE ha incluso 201 studi pubblicati fino a maggio 2025, di cui circa il 70% proveniente da Paesi ad alto reddito, documentando un'accuratezza diagnostica compresa tra il 75% e il 97%, un risparmio di circa 30 dollari statunitensi per consulenza, livelli elevati di soddisfazione tra i pazienti (87-95%) e tra i medici (74-94%), e una riduzione del 45% delle mancate presentazioni agli appuntamenti [5].

Riportato in [3] è il distretto di Myagdi in Nepal in cui serve un totale di una settimana di viaggio di andata e ritorno per una sola consulenza. Dall'esperienza nepalese nel distretto rurale di Myagdi, dove sono stati formati all'utilizzo di un'applicazione diagnostica abitanti del posto, la quota di pazienti non trattati è scesa dal 43% al 9%.

Oltre a ciò, in [4] viene espresso come si stanno sempre più sviluppando i dispositivi indossabili, in alcuni casi caratterizzati dall'utilizzo dell'intelligenza artificiale. Gli algoritmi che studiano l'attività elettrodermica e i dati accelerometrici, implementati in dispositivi multimodali da polso approvati dalla FDA, si sono dimostrati efficaci nel

rilevare le crisi tonico-cloniche generalizzate, contribuendo a ridurre gli eventi avversi e la SUDEP. In uno studio citato nell'articolo questi sistemi hanno raggiunto una sensibilità del 100% con un tasso di falsi allarmi di 0,42 al giorno. Inoltre, alcuni modelli dedicati alla predizione delle crisi hanno raggiunto sensibilità del 96,8% e specificità del 95,5%.

In [6] è documentato inoltre lo sviluppo di un'applicazione per smartphone abbinata a uno smartwatch con il potenziale di rilevare le crisi, quantificarle e avvisare familiari o medici, per allertare i servizi di emergenza sulla base della durata della crisi o delle variazioni dei parametri vitali.

Restano tuttavia ostacoli rilevanti, esposti in modo particolare in [5]. Uno dei problemi principali, citato nei vari articoli, è la mancanza o la ridotta disponibilità della tecnologia stessa, specialmente nei Paesi sottosviluppati. Spesso la connessione internet non è disponibile o i dispositivi non sono compatibili con le tecnologie necessarie a garantire gli standard di protezione dei dati sanitari. Anche l'educazione sociale impatta molto sull'utilizzo a distanza dei dispositivi: specialmente i gruppi vulnerabili sono caratterizzati da una scarsa alfabetizzazione digitale, dunque continuano a preferire incontri di persona. Dal lato clinico, i medici segnalano l'impossibilità di eseguire l'esame obiettivo e la difficoltà a costruire un rapporto con i pazienti nuovi, oltre ad essere preoccupati riguardo al carico di lavoro ulteriore. Dal punto di vista legale, inoltre, ci sono problematiche legate alla responsabilità, dal momento che mancano accordi legislativi tra i vari servizi sanitari.

La soluzione proposta è un modello di cura ibrido (*blended care*), che combini visite in presenza e remote, riservando le visite in presenza per valutazioni iniziali o complesse, insieme al miglioramento dell'alfabetizzazione digitale e di quadri medico-legali standardizzati.

Una sfida ulteriore, di natura tecnica, riguarda il dato stesso. Infatti, reperire un grande numero di dati, garantirne la sicurezza e la privacy, conservare la risorsa energetica, ripulirli dal rumore e al tempo stesso preservarne l'efficacia, è un lavoro molto complesso. Queste motivazioni in particolare saranno esaminate anche nel corso di questo lavoro.




Fig. 1.2 - Crescita annuale del numero di studi sulla teleneurologia [6]

- a. Distinzione tra studi relativi all'ictus e ad altre condizioni neurologiche
- b. Distinzione tra studi condotti su sensori indossabili e su smartphones

1.4 Obiettivi dell'elaborato

Dai vari studi condotti nell'ambito dell'epilessia, la necessità principale per i pazienti è avere dei dispositivi che consentano la sorveglianza continua della loro malattia, diminuendo così il rischio di SUDEP. Il monitoraggio a distanza pone delle grandi sfide in merito al viaggio che i dati neuronali devono compiere, dall'acquisizione, all'elaborazione e alla protezione.

Lo scopo del presente lavoro è quello di analizzare le varie tipologie di dispositivi che consentono di monitorare la malattia dell'epilessia a distanza, considerando quali siano i migliori per adattarsi alle varie soluzioni. Inoltre, è importante esaminare quali sono le modalità per acquisire i dati necessari e renderli utilizzabili, ripulendoli dal rumore di artefatti. Si considerano le funzionalità relative ai vari dispositivi indossabili impiegati per l'acquisizione del segnale, le loro architetture sensoriali e i vincoli energetici che ne condizionano l'uso continuativo. Si affronta poi il tema dell'elaborazione del segnale

EEG, con la tecnica del Compressive Sensing, per risolvere il problema della grande quantità di dati che si trasmettono dal paziente alle strutture sanitarie. Infine, vengono trattati i temi della sicurezza e della privacy del dato durante il suo percorso verso l'esterno, con particolare attenzione all'appendice sulla crittografia leggera, adatta a dispositivi con risorse computazionali ed energetiche limitate.

L'obiettivo complessivo non è quindi proporre una nuova soluzione tecnica, ma valutare criticamente ognuno di questi step fondamentali per la ricerca della telemedicina, affinché possano garantire un monitoraggio domiciliare affidabile, sostenibile e sicuro.

Capitolo 2

Dispositivi wearable per il monitoraggio dell'epilessia

L'epilessia è una condizione neurologica che causa crisi epilettiche imprevedibili, che i pazienti registrano sui propri diari, condividendoli poi con i medici al momento delle visite. Gli studi che sono stati condotti in [7] nei centri di monitoraggio video-EEG dimostrano però che circa la metà o più delle crisi non viene riconosciuta o ricordata dai pazienti stessi, specialmente se queste accadono durante la notte. Questo diventa un problema se il medico non comprende che le crisi sono soltanto sottostimate, valutando in modo errato l'efficacia della terapia. Per risolvere questa problematica, una delle soluzioni più promettenti sfrutta i dispositivi wearable che, grazie alla loro architettura, sono in grado di monitorare, in clinica o presso il proprio domicilio, parametri fisiologici per un periodo prolungato. Specialmente nei casi di crisi tonico-cloniche generalizzate, caratterizzate da movimenti ritmici e intensi della muscolatura, è più probabile che avvengano incidenti come cadute o traumi. Inoltre, le crisi tonico-cloniche sono il tipo di crisi più associato al rischio di morte improvvisa e inattesa (SUDEP). Anche per motivi di sicurezza, i dispositivi wearable assumono un ruolo importante, con lo scopo di rilevare le crisi epilettiche e permettere un intervento rapido, avvisando i *caregiver* o i familiari.

I dispositivi indossabili, o *wearable devices*, sono strumenti applicati al corpo che registrano diversi segnali fisiologici e comportamentali. Questi sensori indossabili potrebbero integrare la valutazione clinica della malattia fornendo dati continui sui diversi sintomi correlati all'epilessia. Questi dispositivi vengono utilizzati per il monitoraggio della salute, per la gestione delle malattie croniche, per le diagnosi e i trattamenti oppure per la riabilitazione [15].

Lo scopo di questo capitolo è raccogliere e analizzare le varie tipologie di dispositivi indossabili disponibili: il loro funzionamento, i vantaggi, i limiti e l'accettabilità da parte dei pazienti.

2.1 Tipologie di dispositivi indossabili

I dispositivi indossabili per il monitoraggio dell'epilessia si distinguono in due grandi categorie: quelli che registrano segnali cerebrali e quelli che registrano segnali fisiologici periferici. La scelta dipende dal tipo di crisi da rilevare, dal contesto di utilizzo e dalle esigenze del paziente. In particolare, il tipo di crisi determina quali segnali fisiologici devono essere registrati: le crisi tonico-cloniche generalizzate, che coinvolgono il movimento degli arti, richiedono sensori di movimento o elettromiografia, mentre le crisi non motorie possono richiedere sensori come l'EDA o la frequenza cardiaca, o una combinazione di questi.

What is Wearable?

This review focuses on how wearable devices can be used to aid chronic, lifetime epilepsy management. Devices that may be comfortable for a few hours, or even a day may not be classed as wearable for life.



Smartwatches

Highly popular lifestyle tech device

Signals: Heart rate, O2 saturation, skin temperature, skin conductance, accelerometry, ECG (in development)



Smart rings

Similar to smartwatches but with different movement artefacts

Signals: Heart rate, O2 saturation, skin temperature



Arm Bands

Sensors mounted on a band around the upper arm. Some devices may be placed with adhesive stickers

Signals: Heart rate, muscle activity, oxygen saturation, skin temperature, skin conductance, accelerometry



Smart phones

More and more people now carry a smart phone at all times.

Signals: Location, accelerometry, many aspects of external environment



Stick-on sensor patches

Subtle patches stuck anywhere on the body that are either re-useable or easily replaced at regular intervals, such as EEG electrodes placed behind the ear, or blood-glucose arm patches.

Signals: EEG/ECG/EMG, accelerometry, glucose, cortisol (in development)



Devices worn elsewhere

Approximately watch sized devices that are worn elsewhere, such as glasses, arm bands, chest bands (??)

Fig. 2.1 - Forme di Wearable Sensors [13]

2.1.1 Applicazioni per il monitoraggio dell'attività neurologica

L'EEG è uno strumento in grado di registrare l'attività elettrica cerebrale, permettendo di osservare da vicino il fenomeno epilettico. Per questo motivo è in grado di rilevare un ampio numero di crisi, specialmente quelle senza manifestazione motoria.

In particolare, in [9] si identificano cinque grandi categorie di tecnologie EEG per il monitoraggio a distanza, dai sistemi non invasivi ai sensori intracranici.

- EEG ambulatoriale (A-EEG): è un sistema composto da elettrodi EEG standard su cuffia portatile, senza alcuna registrazione video. I suoi benefici sono: produrre buoni risultati in pazienti con indicazioni diverse e contribuire alla gestione terapeutica. Allo stesso tempo, però, l'assenza della registrazione video limita la diagnosi poiché non permette di riconoscere le varie fasi della crisi.
- Telemetria video-EEG domiciliare (HVET): è un sistema di elettrodi EEG da scalpo con un dispositivo di registrazione video a domicilio. Permette quindi di registrare dati in condizioni più vicine alla vita reale, consentendo una riduzione dei tempi e dei costi di viaggio e permettendo una buona utilità clinica: uno studio mostra un'interpretazione accurata in oltre il 90% dei casi (97% a domicilio e 91% in ospedale). Allo stesso tempo, non permette di monitorare per più di 2/3 giorni, con una qualità video inferiore a quella ospedaliera, con possibile difficoltà nell'uso delle attrezzature.
- Sensori indossabili EEG: è un sistema formato da singoli elettrodi applicati allo scalpo o a delle cuffie. Ad esempio, l'Epitel Epilog, integrato nella piattaforma REMI, usa sensori wireless monopezzo resistenti all'acqua, indossabili fino a 7 giorni continuativi. Questi sensori sono una buona opzione di monitoraggio remoto non invasiva, nonostante la posizione dell'elettrodo che meglio predice la crisi vari tra individui e non sia costante. Inoltre, sfruttando pochi elettrodi, è più vulnerabile al rumore, oltre ad avere una memoria limitata.



Fig. 2.2 - Sensore EEG indossabile Epilog. [Epitel Inc., epitel.com]

- EEG sub-scalpo: è un sistema formato da elettrodi impiantati sotto il cuoio capelluto, minimamente invasivi. Un esempio è il dispositivo UNEEG SubQ. Grazie a questo dispositivo è possibile il monitoraggio ultra a lungo termine (oltre 7 mesi) con una qualità del segnale elevata che permette una migliore diagnosi, gestione e previsione delle crisi. Il limite principale è la sensibilità al rumore dovuto all'attività muscolare. Inoltre, l'impianto non è accettabile da tutti i pazienti e copre solo una piccola area della superficie corticale.




Fig. 2.3 - Impianto sottocutaneo UNEEG SubQ. [UNEEG Medical A/S, uneeg.com]

- EEG intracranico: è un sistema di elettrodi posizionati sulla superficie del cervello. Due esempi sono: RNS NeuroPace e il NeuroVista. Questi dispositivi sono utili per il monitoraggio e la previsione a lungo termine e possono essere utilizzati anche come stimolazione elettrica terapeutica. Il limite principale è l'invasività: uno studio ha rilevato 11 eventi avversi nei primi quattro mesi, due dei quali gravi.

Categoria	Durata tipica	Mobilità	Punto di forza	Limite principale
EEG ambulatoriale	15–96 h	Ridotta: cuffia, cavi e modulo di controllo ostacolano il movimento	Diagnosi e gestione terapeutica a costi inferiori rispetto al ricovero	Nessun video, ingombro
Video-EEG domiciliare	1,5–3 giorni	Limitata al domicilio, telecamere fisse	Contesto reale e costo pari a circa 2/3 del video-EEG in ospedale	Monitoraggio di 1–3 giorni, montaggio complesso
Sensori indossabili	5–10 giorni	Libera	Confortevoli, poca manutenzione, impermeabile	Pochi elettrodi, artefatti, qualità marginale
EEG sub-scalpo	3-8 mesi	Libera	Monitoraggio ultra-lungo termine con segnale stabile di qualità	Copre solo una piccola area corticale
EEG intracranico	Da settimane ad anni	Libera	Consente previsione delle crisi e neurostimolazione responsiva	Invasivo, effetti avversi gravi

Tab. 2.1 - Caratteristiche, vantaggi e limiti dei principali tipi di dispositivi per EEG [9]

2.1.2 Applicazioni per il monitoraggio dei parametri fisiologici

I sensori che si trovano principalmente su arti e tronco misurano segnali fisiologici correlati alle crisi, ma non direttamente cerebrali. La linea guida ILAE/IFCN ha identificato i segnali più utilizzati: accelerometria, elettromiografia di superficie, frequenza cardiaca ed ECG, fotopletismografia, attività elettrodermica [7].

- Accelerometria (ACM): registra i movimenti del corpo tramite sensori triassiali. È il segnale più usato per il rilevamento delle crisi tonico-cloniche generalizzate, che producono movimenti ritmici e intensi degli arti durante la fase clonica. In [15] hanno ottenuto sensibilità tra il 90% e il 92% per le crisi tonico-cloniche. Il limite è che non rileva crisi non motorie e che i movimenti quotidiani possono generare falsi positivi.
- Elettromiografia di superficie (sEMG): misura l'attività elettrica dei muscoli, distinguendo l'attivazione muscolare fisiologica dal movimento delle convulsioni. Rileva le crisi durante la fase tonica, fornendo un allarme più tempestivo rispetto all'accelerometria, e riesce a rilevare bene le varie fasi della crisi, permettendo di descriverne anche la gravità [14].
- Fotopletismografia (PPG): misura tramite un sensore ottico le variazioni del volume sanguigno attraverso la riflessione della luce sulla pelle. Viene spesso integrato nei dispositivi da polso per misurare la frequenza cardiaca. La qualità del PPG peggiora a causa dei movimenti del braccio e della luce ambientale, con il rischio di diventare inutilizzabile durante le crisi convulsive.
- Attività elettrodermica (EDA): misura le modificazioni della conduttività cutanea legate al sistema nervoso autonomo. Viene solitamente combinata con accelerometria (come il dispositivo Empatica Embrace [13]) e ECG per consentire di rilevare crisi prive di componente motoria. Un caso documentato di SUDEP ha mostrato un aumento drammatico dell'EDA prima del decesso, suggerendo che si tratti di un parametro molto importante.
- Elettrocardiografia (ECG): registra l'attività elettrica del cuore. Infatti, le crisi epilettiche possono provocare variazioni della frequenza cardiaca, un parametro importante per la rilevazione.

In [12] viene inclusa anche la temperatura cutanea: misurata da alcuni dispositivi multimodali come l'Empatica E4 (a 4 Hz), ma raramente usata come segnale primario per il rilevamento delle crisi.




Fig. 2.4 - Collocazione corporea dei sensori indossabili per il monitoraggio delle crisi e segnali registrati da ciascuna sede, classificati per grado di validazione [13]

2.2 Monitoraggio multimodale e integrazione tra segnali

Nessun singolo segnale è in grado di rilevare tutti i tipi di crisi. Le crisi tonico-cloniche producono movimenti evidenti rilevabili da strumenti come l'accelerometria, ma le crisi focali solitamente si presentano senza manifestazioni motorie ampie, rendendo necessario l'utilizzo di sensori come l'EDA o l'EEG. Per questo, i dispositivi multimodali, che combinano insieme più segnali, sono considerati generalmente più versatili ed efficaci.

Tra i dispositivi più studiati in ambito multimodale ci sono i braccialetti da polso di Empatica. L'Empatica E4 è un braccialetto da polso che registra accelerometria triassiale a 32 Hz, EDA a 4 Hz, temperatura cutanea a 4 Hz e PPG a 64 Hz. Questo dispositivo è stato utilizzato sia in ambienti ambulatoriali che in situazioni di ricovero, dove ha ottenuto una sensibilità del 94,5% e tasso di falsi allarmi di 0,2/24h per le crisi tonico-cloniche generalizzate. L'Embrace, versione clinica dello stesso produttore, invece, combina EDA e accelerometria e dimostra che le prestazioni erano inferiori usando un solo parametro rispetto ad entrambi, confermando che i sensori multimodali sono caratterizzati da una sensibilità maggiore [13]. Il NightWatch, indossato sul braccio, misura accelerometria e

PPG e ha ottenuto una mediana di rilevamento dell'86% per le crisi motorie maggiori notturne [7].

Un esempio concreto del vantaggio dei sensori multimodali è lo studio pilota in [8], condotto su trenta pazienti tra i 19-77 anni ricoverati con sospetta o confermata epilessia, che ha combinato EEG retroauricolare, ECG e accelerometria per il rilevamento delle crisi focali. Soltanto tre pazienti hanno avuto più di cinque crisi e sono quindi stati analizzati con un classificatore SVM paziente-specifico. Nei due casi con crisi focali non motorie la combinazione di EEG ed ECG ha rilevato tutte le crisi con un tasso di falsi allarmi di 13 e 5 per 24 ore, inferiore a quello dell'EEG da solo; nel paziente con crisi toniche notturne l'aggiunta dell'accelerometria offriva il compromesso migliore, pur restando a 20 falsi allarmi per 24 ore con una sensibilità del 91%. Lo studio conferma quindi che l'integrazione di più segnali migliora il rilevamento rispetto all'EEG da solo, nonostante i valori ottenuti restino ancora lontani dall'uso clinico, e ogni sensore aggiuntivo comporti più dati da gestire, maggiore consumo energetico e maggiore complessità computazionale.

2.3 Vantaggi e limiti dei dispositivi wearable

I dispositivi wearable hanno diversi benefici tra cui: migliorare la registrazione della frequenza delle crisi, distinguere crisi epilettiche da eventi differenti, aiutare a riconoscere crisi che il paziente non ricorda, fornire maggiore autonomia e sicurezza al paziente, facilitare il monitoraggio prolungato, ridurre il tempo per analizzare grandi quantità di dati e in futuro, si spera, la capacità di inviare allarmi per prevenire incidenti [7, 13].

Un altro dei vantaggi principali dell'utilizzo di questi dispositivi è la continuità. Una registrazione di settimane o mesi migliora il processo di diagnosi rispetto ad una semplice visita ambulatoriale o un breve ricovero.

Il monitoraggio notturno è particolarmente importante per la prevenzione della SUDEP: la combinazione di non condividere la camera da letto e avere almeno una crisi tonico-clonica all'anno comporta un rischio di SUDEP 67 volte maggiore [7]. Un sistema di rilevamento automatico con allarme al *caregiver* renderebbe possibile un intervento tempestivo e una risposta più rapida. Inoltre, l'EEG sub-scalpo permette il monitoraggio ultra a lungo termine (fino a 230 giorni) senza impatto sulla mobilità e senza obbligare il

paziente ad un ricovero prolungato, monitorando con una buona qualità il segnale per un lungo periodo di tempo [9].

Purtroppo, ad oggi, dagli studi che sono stati proposti in merito ai dispositivi wearable utilizzati per il telemonitoraggio emergono ancora tante problematiche ([7], [11], [12], [13], [16]). Le principali che vengono sottolineate in modo più ricorrente sono:

- I falsi allarmi: un dispositivo con sensibilità elevata, ma numerosi falsi allarmi non è clinicamente utile. Questo perché una sovrastima del numero reale di crisi provoca ansia, perdita di fiducia e abbandono della tecnologia.
- La durata della batteria e la qualità del segnale: la raccolta di segnali complessi a frequenza elevata riduce la durata della batteria. Il monitoraggio dell'epilessia dovrebbe essere idealmente continuo, ma la durata limitata della batteria può creare intervalli privi di dati e compromettere la registrazione. La qualità di PPG, accelerometria e EDA può inoltre diminuire durante i movimenti del braccio o quando il dispositivo cambia posizione.
- La mancanza di standard: diversi gruppi di ricerca adottano metodi differenti e riportano informazioni eterogenee o incomplete, rendendo difficile il confronto tra studi e la replica. Diventa così difficile confrontare le prestazioni di dispositivi diversi e stabilire quale sia realmente il migliore.
- La privacy e sicurezza: il 59,6% dei pazienti esprime preoccupazione per la privacy e la riservatezza. I dispositivi indossabili, infatti, possono raccogliere informazioni sanitarie, posizione geografica e abitudini quotidiane dei pazienti. La trasmissione di grandi quantità di dati attraverso le connessioni mobili aumenta il rischio di perdita o manipolazione dei dati stessi. La trasmissione e la condivisione di dati sanitari richiedono il rispetto di normative come il GDPR e l'adozione di procedure di anonimizzazione.
- La responsabilità clinica: se un dispositivo non rileva una crisi oppure produce un falso allarme, possono sorgere problemi di responsabilità etiche e legali del produttore, del medico o del sistema sanitario.

2.4 Accettabilità e comfort a lungo termine da parte dei pazienti

Le risposte e i feedback dei pazienti sono importanti per capire effettivamente quanto questi dispositivi verrebbero usati per favorire il progresso nelle cure terapeutiche, ciò viene spiegato principalmente in [11] e [17].

Le preferenze dei pazienti e dei *caregiver* sono state esaminate in una revisione sistematica che ha incluso 22 studi con 3.299 partecipanti. I risultati mostrano che le valutazioni dei pazienti si basano principalmente su accuratezza, design, comfort e costo.

- 1) Accuratezza. Secondo il giudizio dei pazienti, affinché i dispositivi wearable vengano effettivamente utilizzati, la sensibilità deve essere almeno del 90%, con possibilità di rilevamento delle crisi in tempo reale. Un altro tema molto affrontato è quello dei falsi allarmi. La tolleranza ad essi dipende dalla frequenza delle crisi: chi ha almeno una crisi a settimana accetta 1-2 falsi allarmi alla settimana, chi ha meno di una crisi a settimana tollera solo 1-2 falsi allarmi al mese.
- 2) Design e forma del dispositivo. Le persone con epilessia preferiscono dispositivi integrabili in oggetti di uso quotidiano come smartwatch o braccialetti; in particolare gli orologi da polso sono stati identificati come la forma preferita per il monitoraggio delle crisi. Le opzioni meno gradite sono fasce per la testa o cappelli, telecamere e i dispositivi EEG applicati alla testa.
- 3) Comfort e autonomia. Il comfort e la durata della batteria influenzano molto l'utilizzo dei dispositivi da parte dei pazienti per un lungo periodo. Generalmente i dispositivi da polso o le applicazioni da smartphone risultavano più comode rispetto ai sistemi applicati agli arti o al torace. Per quanto riguarda i sistemi di EEG, gli elettrodi cutanei possono diventare scomodi. Molti pazienti richiedono anche l'impermeabilità dei dispositivi. Anche la durata della batteria è un requisito importante, la maggior parte dei pazienti richiede un'autonomia della batteria di almeno 24 ore.
- 4) Costo. Il prezzo è uno dei motivi principali, infatti, tra il 9,6% e il 38% degli utenti non ha acquistato un dispositivo per motivi economici. Il 67% dei pazienti non userebbe un dispositivo se non coperto dall'assicurazione. La maggior parte dei

partecipanti desidera un costo inferiore a 300 dollari e un abbonamento mensile inferiore a 20 dollari.

L'accettazione di questi strumenti dipende inoltre dalla facilità di uso e dalla fiducia nelle capacità del dispositivo. Si può sottolineare inoltre una grande differenza tra i pazienti e i *caregiver*. Mentre i *caregiver* preferiscono metodi di monitoraggio più intrusivi, come telecamere e microfoni per il timore delle crisi notturne, i pazienti preferiscono dispositivi da polso per il monitoraggio continuo con video o la presenza di una persona fisica. Questo perché hanno più timore per la sicurezza dei loro dati ma, soprattutto, perché ritrovano più libertà quotidiana.

In conclusione, i dispositivi wearable per il monitoraggio dell'epilessia hanno dimostrato un potenziale significativo, soprattutto per le crisi tonico-cloniche generalizzate. Il rilevamento delle crisi focali non motorie rimane invece una sfida aperta: lo studio multimodale ha dimostrato che la combinazione di EEG retroauricolare ed ECG può raggiungere alte sensibilità del 100%, a costo di subire numerosi falsi allarmi. Inoltre, lo studio proposto dimostra che alcuni dispositivi sono in grado di riconoscere crisi epilettiche con buona accuratezza, ma questo non assicura che questi dispositivi siano anche clinicamente validati, dal momento che non c'è ancora una certezza su beneficio clinico concreto.

2.5 Dal dispositivo alla rete: trasmissione e protezione dei dati

I dati raccolti dai dispositivi indossabili non restano sul dispositivo stesso, ma seguono un flusso dal sensore al cloud, mediante un'architettura a strati [21].

1. Strato fisico (sensori). Dispositivi wearable e impiantabili, come pacemaker cardiaci, defibrillatori, monitor di glicemia/pressione/frequenza cardiaca/EEG, raccolgono i segnali sanitari dal paziente e li convertono in dati leggibili. La maggior parte di questi dispositivi sono alimentati a batteria, ciò significa che l'efficienza energetica è critica.

2. Dispositivi intermedi (opzionali). Poiché i piccoli dispositivi wearable e impiantabili non hanno capacità di elaborazione, un dispositivo mobile o stazionario raccoglie i dati dai sensori, li elabora parzialmente e li trasmette ai sistemi back-end e ai database. Proprio questo strato permette una comunicazione bidirezionale tra i dispositivi e le applicazioni utilizzate.

3. Strato rete (trasmissione). I componenti IoT si connettono tra loro e condividono i dati tramite protocolli come Bluetooth, ZigBee, 5G, Wi-Fi, RFID, 6LoWPAN, LoRaWAN e Wireless Sensor Network (WSN).

4. Strato applicazione (servizi). È lo strato più alto, connette le informazioni ricevute a database e alla rete IoT, la quale offre servizi e-health all'utente.

5. Smart Hospital e Cloud. Nella maggior parte dei casi la rete IoT è direttamente connessa ai sistemi di cartelle cliniche e database ospedalieri, così il personale riceve i dati in tempo reale e risponde alle emergenze. La rete deve poi connettersi a Internet e alle piattaforme cloud per comunicare con sistemi near-patient e altre strutture sanitarie, creando così dei servizi sanitari personalizzati per ogni utente.

In sintesi: sensore wearable → dispositivo intermedio → rete wireless → sistema ospedaliero/cloud → personale sanitario.




Fig. 2.5 - strati di architettura IoT [21]

Nel caso particolare dell'epilessia, i sensori IoT acquisiscono i segnali EEG direttamente dal cuoio capelluto, misurando le onde cerebrali e fornendo informazioni in tempo reale sul funzionamento del cervello, con la possibilità di fornire avvisi tempestivi e migliorando il benessere generale.

I sistemi IoT-based integrano strumenti, monitorano sensori e trasferiscono informazioni sanitarie su canali pubblici, determinando molti vincoli di sicurezza per evitare l'intercettazione e gli attacchi sconosciuti. Tutto ciò causa un problema molto complesso. Spesso i medici possono servirsi di strumenti come gli Electronic Health Records (EHR), per diagnosticare e identificare le malattie. Tuttavia, la gestione di questi record elettronici richiede un ambiente sicuro che garantisca l'autenticazione, l'integrità e la riservatezza delle informazioni. Altre motivazioni riguardano la natura sensibile dei dati che contengono informazioni private riguardo ai vari pazienti. Solo gli utenti autorizzati devono avere accesso ai dati medici, che devono restare cifrati durante la trasmissione nella rete IoT, per evitare implicazioni legali ed etiche.

Il problema alla base rimane il fatto che algoritmi pesanti in grado di garantire una sicurezza elevata non possono però essere usati su wearable devices piccoli, poiché consumerebbero una quantità di energia spropositata per le loro capacità. La complessità diventerebbe troppo elevata e la loro capacità di monitorare per lungo tempo andrebbe così persa. Proprio per questo motivo sono state sviluppate nuove tecniche di crittografia leggera [21].

La diffusione dei sistemi IoT sanitari, le principali minacce alla trasmissione, gli algoritmi di crittografia leggera e il compromesso tra sicurezza, prestazioni e consumo energetico sono approfonditi in Appendice A.

Capitolo 3

Elaborazione del segnale EEG per la rilevazione delle crisi epilettiche

3.1 Pre-elaborazione del segnale e riduzione del rumore del segnale

Il problema principale legato all'utilizzo di sensori indossabili come EEG sta nel fatto che questi dispositivi devono monitorare l'attività cerebrale per lungo tempo, analizzando una grandissima quantità di dati, nonostante siano dotati di batterie con una capacità limitata. Per riuscire ad aumentare la loro efficacia, monitorando le attività cerebrali per un periodo di tempo prolungato, bisogna adottare delle tecniche per ridurre la quantità di operazioni che questi strumenti devono sostenere. Inoltre, essendo dispositivi che non godono di una grande memoria, è necessario che i dati rilevati dai sensori vengano compressi il più possibile, mantenendo invariato il significato delle informazioni da trasmettere. Per questo motivo è stata sviluppata l'idea di utilizzare il Compressive Sensing [19].

Questa tecnica deve però far fronte ad altre problematiche differenti. Per esempio, il segnale rilevato dai dispositivi è spesso contaminato da discrepanze dovute al rumore causato da diversi artefatti di varia natura. Se il rumore è causato da artefatti estrinseci (rumore ambientale, interferenza elettromagnetica, difetti degli elettrodi, movimenti dei cavi), il problema si può facilmente risolvere applicando un filtro, che elimini le frequenze non compatibili con quelle del segnale di interesse. Se invece gli artefatti sono di natura fisiologica, e quindi definiti intrinseci (movimento degli occhi, attività cardiaca o muscolare), il problema diventa più complesso. Questo perché è difficile rimuovere frequenze che si sovrappongono a quelle dell'EEG.

La rimozione del rumore a un segnale è quindi lo step più importante della pre-elaborazione di un segnale. In [18] vengono proposte alternative diverse per risolvere questo problema.



Fig. 3.1 - Artefatti fisiologici del segnale EEG [18]

Per rimuovere il rumore da un segnale vengono utilizzate molte tecniche differenti:

- Metodi basati su canale di riferimento: per funzionare serve un secondo sensore che registra l'artefatto puro (EOG per gli occhi, ECG per il cuore). L'algoritmo stima quanto quell'artefatto contamina il canale EEG e lo sottrae. Senza riferimento, questo metodo non funziona, pertanto, non viene adottato se il problema è muscolare perché un riferimento pratico non esiste. Alcuni esempi di questi metodi sono:
 - Regressione
 - Filtraggio adattivo
 - Filtraggio Wiener
- Metodi basati su decomposizione del segnale: parte da un solo canale e lo scompone in diversi strati di frequenza. Riconosce l'artefatto perché ha caratteristiche diverse dall'EEG in uno o più strati, lo scarta e ricostruisce il segnale. Non ha bisogno di altri canali, quindi funziona con un singolo elettrodo, ma fatica quando la frequenza dell'artefatto si sovrappone a quella del cervello. Alcuni esempi di questi metodi sono:
 - Wavelet transform
 - Empirical Mode Decomposition (EMD)
 - Sparse decomposition
- Metodi basati su separazione delle sorgenti: usa molti canali contemporaneamente. Sfrutta il fatto che ogni elettrodo registra un segnale diverso delle stesse sorgenti, e da questi segnali stima le sorgenti originali separandole. Non ha bisogno di riferimento, ma ha bisogno di almeno tanti canali quante sono le sorgenti da separare; quindi, non funziona con un solo elettrodo. Ad esempio:
 - Blind Source Separation (BSS): PCA, ICA, CCA.

Dal momento che non esiste un singolo metodo per risolvere questo problema, la soluzione migliore che si può adottare è quella di usare tecniche ibride. La review descrive tre combinazioni principali.

1) EMD-BSS

Si decompone il segnale con EMD per poi passare ad un algoritmo ICA o CCA che stima le sorgenti. Si rimuovono le componenti dell'artefatto e si ricostruisce.

Dagli studi fatti, la variante EEMD-ICA ha dimostrato le migliori prestazioni rispetto a ICA singolo e wavelet-ICA su segnali EEG reali. La variante MEMD-CCA è promettente per artefatti muscolari in scenari a pochi canali, ma con costo computazionale elevato che ne limita l'uso offline.




Fig. 3.2 - Percorso del metodo EMD-BSS [18]

2) Wavelet-BSS

Si decompone il segnale con ICA o CCA, poi le componenti ICA sospette di contenere artefatti vengono passate a Wavelet transform. Si rimuovono così le componenti errate e si ricostruisce corretto.

Questa combinazione supera il limite della ICA da sola (che richiede numero di sorgenti uguale alle misurazioni) e il limite della wavelet da sola (che non separa artefatti spettralmente sovrapposti).




Fig. 3.3 - Percorso del metodo WT-BSS [18]

3) BSS-SVM

Dopo la decomposizione del segnale tramite BSS, vengono estratte caratteristiche di tipo temporale, spaziale e statistico da ciascuna componente; una SVM classifica automaticamente le componenti corrispondenti agli artefatti, le quali vengono rimosse prima di procedere alla ricostruzione del segnale pulito.

Questo metodo evita di dover selezionare manualmente le componenti da scartare, evidenziando il grande vantaggio dell'automaticità.




Fig. 3.4 - Percorso del metodo BSS-SVM [18]

Nonostante siano state sviluppate numerose tecniche per rimuovere gli artefatti indesiderati, non esiste un unico metodo ottimale per tutti i tipi di artefatti. La soluzione migliore rimane quella di combinare i vari metodi insieme garantendo al contempo un'elevata accuratezza e un'efficienza algoritmica adeguata.

3.2 Compressive Sensing: principi teorici e vantaggi per l'EEG

Il Compressive Sensing e le nuove ingegnerie neurali emergenti hanno lo scopo di dover far fronte alle problematiche derivanti dall'utilizzo di EEG, come il monitoraggio dell'epilessia.

La teoria del Compressive Sensing è stata introdotta da Donoho per l'acquisizione dei dati [19]. La grandissima quantità di dati derivanti dall'utilizzo di questi strumenti rende difficile il loro utilizzo a lungo termine, considerando anche il fatto che la loro unica fonte di energia è quella di piccole batterie. Il Compressive Sensing è utile quindi come soluzione per il grande volume di big data provenienti da questi studi, per migliorare la velocità con cui questi dati vengono processati e per salvaguardare l'utilizzo dell'energia dei dispositivi, preservando quindi la loro durata nel tempo.

Dal momento in cui ogni singolo elettrodo traccia lo sviluppo di una grande popolazione di neuroni in un solo momento, l'attività corticale diventa particolarmente attiva. Oltre a

utilizzare strumenti che possiedono una memoria, si sta cercando di sviluppare sempre più dispositivi con capacità wireless, quindi trasmissione dei dati ad altri dispositivi attraverso reti. Più dati si vogliono inviare però, più le sfide diventano complesse. Comprimere dati EEG con metodi come DCT, DWT o codifica *run-length* non è efficiente, dal momento che questi dati devono essere precedentemente salvati e poi compressi in un secondo momento. La tecnica del Compressive Sensing permette di unire questi due step indipendenti in un unico passaggio: acquisire e comprimere i dati contemporaneamente. L'acquisizione basata su questo metodo viene implementata con un operatore che sottocampiona casualmente i dati in ingresso e fornisce misure compresse.

La teoria del Compressive Sensing funziona bene con segnali che possono essere rappresentati da un numero significativo di k coefficienti (cioè segnali k -sparsi) su una base a N dimensioni. In altre parole, il Compressive Sensing si basa sulla sparsità dei dati e può essere utilizzato per campionare il segnale sparso al di sotto del limite di Nyquist-Shannon, consentendone la ricostruzione da un numero di campioni molto inferiore. Inoltre, il Compressive Sensing offre una riduzione sostanziale del tempo e della banda per la trasmissione, riducendo di conseguenza i requisiti hardware e di potenza dei dispositivi.

La banda (o *bandwidth*) è la quantità di dati che un dispositivo può trasmettere in un certo tempo, misurata in bit per secondo. Il problema è che la banda utilizza la batteria: più dati si trasmettono, più energia consuma il trasmettitore wireless. Il Compressive Sensing svolto su EEG garantisce un risparmio nell'acquisizione e nella trasmissione del segnale, migliorando quindi l'elaborazione del segnale in condizioni di risorse limitate.

In termini generali, il framework EEG basato su Compressive Sensing può essere suddiviso in modo ampio in quattro fasi principali.




Fig. 3.5 - Diagramma a blocchi degli studi EEG basati su CS [19]

Il risultato di diversi studi ha dimostrato che l'approccio Compressive Sensing ha raggiunto ottimi risultati per ciò che riguarda accuratezza e riduzione della complessità hardware del sistema.

Da un punto di vista matematico, sia x il segnale di interesse di dimensione $N \times 1$. Un vettore di misure y può essere calcolato utilizzando una matrice di misura Φ di dimensione $M \times N$. Il modello di campionamento del segnale è dato dalla relazione:

$$y = \Phi x$$

dove $x \in R^N$ è il segnale in ingresso, $\Phi \in R^{M \times N}$ è la matrice di misura del Compressive Sensing e $y \in R^M$ è il vettore delle misure compresse. N rappresenta il numero di campioni del segnale originale, mentre M rappresenta il numero di misure acquisite. Generalmente nel Compressive Sensing si ha $M \ll N$, per cui il numero di misure in y è molto inferiore rispetto ai campioni del segnale originale x .

Due condizioni importanti devono essere soddisfatte affinché il Compressive Sensing sia efficiente:

- la sparsità del segnale in ingresso
- l'incoerenza tra la matrice di misura Φ e la base di sparsità.

Rappresentazione sparsa

Un segnale x si dice k -sparso se possiede solo k coefficienti non nulli su N totali. In altre parole, quasi tutta l'informazione è concentrata in pochi valori e il resto è zero.

Il Compressive Sensing funziona perché se un segnale è sparso allora non serve più acquisire tutti gli N campioni ma bastano M (con $M \ll N$) misure per catturare tutta l'informazione di cui abbiamo bisogno.

Fortunatamente l'EEG è un segnale NEAR-SPARSE nel dominio del tempo: quasi ogni campione ha un valore diverso da zero ma, la maggior parte dell'informazione è concentrata in pochi coefficienti anche se non in modo evidente. Per renderlo veramente sparso, bisogna prima trasformarlo in un altro dominio usando un dizionario (o base di sparsità) Ψ , cioè una matrice che proietta il segnale in un dominio dove solo pochi coefficienti contengono tutta l'informazione.

Sia s un segnale discreto di lunghezza N . Si può rappresentare nella base ortonormale Ψ come:

$$x = \Psi s = \sum_{i=1}^N s_i \Psi_i$$

dove s è il vettore dei coefficienti nel dominio trasformato e Ψ_i sono i vettori di base, chiamati atomi, ovvero le funzioni elementari che compongono il dizionario. Il segnale EEG viene espresso come combinazione lineare di questi atomi, e se pochi atomi bastano per ricostruirlo quasi completamente, il segnale è sparso in quel dizionario.

A questo punto, x e s rappresentano lo stesso segnale ma il primo nel dominio del tempo, il secondo nel dominio Ψ . Se s ha pochi coefficienti non nulli, il segnale è sparso in quel dominio.

Sostituendo nell'equazione del Compressive Sensing:

$$y = \Phi x = \Phi \Psi s = A s$$

dove $A = \Phi \Psi$ è una matrice $M \times N$ che trasforma e comprime il segnale sparso s nel vettore di misure y di dimensione $M \times 1$.

In [19] vengono poi descritte altre famiglie di dizionari fissi:

- Gabor
- DCT (discrete cosine transform)
- Wavelet
- B-spline e spline

I dizionari fissi (Gabor, DCT, Wavelet) hanno però una difficoltà: assumono a priori una struttura del segnale e usano funzioni di base predefinite. Per questo motivo, a volte può non riuscire a identificare correttamente la struttura reale dell'EEG. In alternativa, come possibile soluzione, stanno emergendo sempre di più i dizionari data-driven, in grado di adattarsi meglio alle diverse situazioni.

Matrice sensing

La sensing matrix, o matrice di misura, è la matrice Φ che moltiplica il segnale x per produrre le misure compresse $y = \Phi x$. È ciò che determina quali campioni del segnale

vengono effettivamente acquisiti. La sua progettazione è importante per due motivi principali: comprime il segnale al sensore e deve permettere la ricostruzione al ricevitore. Se Φ è mal progettata, la ricostruzione sarà inaccurata o impossibile.

Come da requisito fondamentale del Compressive Sensing, la matrice Φ deve essere il più possibile incoerente rispetto alla base di sparsità Ψ . Ciò significa che Φ deve essere il più possibile diversa da Ψ .

Per garantire l'incoerenza, la scelta migliore e più comune è usare una matrice casuale, che per natura è quasi ortogonale a qualsiasi base fissata. Le matrici casuali si dividono in Gaussian, Bernoulli e Sparse Binary.

- 1) La Gaussian è la più usata per l'EEG: genera voci casuali con distribuzione gaussiana. Ha un errore di ricostruzione basso, ma non è adatta ai dispositivi wireless, perché un generatore gaussiano su hardware consuma troppa energia.
- 2) La Bernoulli è più semplice: genera voci binarie, con meno operazioni di moltiplicazione. Ma ha ancora problemi di consumo di spazio e potenza su hardware.
- 3) La Sparse Binary ha pochi elementi non nulli (uno per colonna), quindi richiede pochissime moltiplicazioni. È la raccomandata per le wireless body sensor networks: occupa meno memoria, consuma meno energia e ha prestazioni sufficienti. Il limite è che la qualità di ricostruzione è inferiore rispetto alle matrici casuali complete.

Oltre alle matrici casuali si possono utilizzare anche le matrici deterministiche, le quali hanno complessità computazionale bassa e spazio ridotto.

La scelta della matrice risulta quindi essere un compromesso tra qualità di ricostruzione e consumo energetico.




Fig. 3.6 - Classificazione di matrici sensing [19]

Algoritmi di ricostruzione

La ricostruzione è la parte più complessa del Compressive Sensing. Infatti, recuperare il segnale originale x dalle misure compresse y è difficile, perché si tratta di risolvere un sistema sottodeterminato: ci sono infinite soluzioni possibili per $y = \Phi x$ quando $M \ll N$. Gli algoritmi di ricostruzione cercano la soluzione più sparsa, cioè quella con il minor numero di coefficienti non nulli, riducendo l'errore tra segnale originale e segnale ricostruito.

Il problema di base, che lavora con una minimizzazione della norma l_0 , è NP-hard e non risolvibile in tempo ragionevole. Per questo si passa ad una minimizzazione della norma l_1 (la somma dei valori assoluti dei coefficienti di l_0), dando origine al *basis pursuit* (BP), un problema efficientemente risolvibile. La norma l_1 è una approssimazione della norma l_0 che mantiene lo stesso obiettivo, ma con un problema matematico molto più semplice. La norma l_1 spinge molti coefficienti verso zero perché penalizza i valori piccoli quasi quanto quelli grandi, favorendo soluzioni con pochi coefficienti non nulli.

Gli algoritmi di ricostruzione si dividono in sei categorie principali, ciascuna con un diverso compromesso tra accuratezza, velocità e robustezza al rumore.

La scelta dell'algoritmo dipende dal contesto applicativo: OMP è preferibile quando la velocità è prioritaria, CoSaMP per una qualità di ricostruzione superiore, BPDN per misurazioni rumorose e BSBL per segnali con struttura a blocchi sparsi, come l'EEG [19].

Ricostruzione free

Per alcune applicazioni non serve ricostruire il segnale: le caratteristiche possono essere estratte direttamente dalle misure compresse. Questo approccio si chiama *compressive feature learning* o *reconstruction-free Compressive Sensing*.

Il vantaggio è la drastica riduzione della complessità computazionale e del tempo di elaborazione. Altri hanno proposto un sistema di rilevamento crisi che usa direttamente le misure EEG compresse e le elabora in modo automatico, assicurando un grande vantaggio per la velocità di elaborazione dei dati.

3.3 Caso applicativo: rilevazione di crisi su segnale EEG compresso

In [20] viene descritto uno studio originale che propone un metodo per rilevare le crisi epilettiche su segnale EEG compresso. L'epilessia è un disturbo neurologico che richiede una diagnosi accurata. L'EEG è quindi uno strumento utile per analizzare le condizioni fisiologiche e patologiche negli umani, oltre che avere diverse applicazioni nella medicina. Il Compressive Sensing cerca quindi di ridurre la complessità computazionale e trovare i metodi che possono essere utili per registrare segnali EEG per lunghi periodi, con accuratezza elevata e utilizzando una parte di memoria ridotta.

In [20] si propone un approccio innovativo nell'utilizzo del Compressive Sensing come metodo di decomposizione.

Due dataset sono usati:

- Il primo è del Neurology and Sleep Centre di New Delhi: lo studio è stato fatto su 10 pazienti, ognuno con 16 elettrodi a una frequenza di 200 Hz. Le frequenze di taglio del filtro sono state impostate a 0,5 e 70 Hz. Il dataset prevedeva tre classi: pre-ictale, interictale e ictale.
- Il secondo è il dataset di Bonn University: lo studio è stato fatto su 5 pazienti, con 100 segmenti EEG per classe a una frequenza di 173,61 Hz. Le frequenze di taglio del filtro sono state impostate a 0,53-40 Hz. Il dataset prevedeva tre classi: normale, interictale e ictale.




Fig. 3.7 - Campioni del segnale EEG sui dataset pre-ictale, interictale, ictale [19]

Questo studio è diviso in quattro fasi principali:

Fase 1, pre-elaborazione. I segnali EEG iniziali vengono filtrati con un filtro Butterworth passa-banda del quarto ordine, con frequenze di taglio di 0,5 e 60 Hz, per rimuovere il rumore della linea elettrica.

Fase 2, Compressive Sensing. I segnali dei 1024 campioni vengono moltiplicati direttamente per una matrice di misura a distribuzione normale, senza alcuna trasformazione del segnale e senza ricostruzione. Il modello è:

$$y[m] = \Phi x[n]$$

dove $x[n]$ è il segnale EEG, Φ è la matrice di misura e $y[m]$ è il vettore compresso, con $m \ll n$.

Tre rapporti di compressione sono testati: 1/2 (512 misure), 1/4 (256 misure) e 1/8 (128 misure).

Il valore di m dipende dalla lunghezza n e dalla sparsità k del segnale, secondo la relazione

$$m \gtrsim c \cdot k \log(n/k)$$

dove c è una costante positiva.

Fase 3, estrazione dell'energia. L'energia del segnale compresso è l'unica caratteristica estratta, calcolata come:

$$E = \sum_{n=0}^{\infty} |x(n)|^2$$

L'energia media risulta significativamente diversa tra le tre classi: ictale (21×10^6), interictale ($1,2 \times 10^6$) e pre-ictale ($0,6 \times 10^6$). La differenza di energia tra le tre classi è stata confermata mediante un test ANOVA a una via con livello di confidenza del 95% e soglia di significatività $p < 0,05$. I p-value per i confronti ictale vs interictale, ictale vs pre-ictale e ictale vs non-ictale risultano tutti nell'ordine di 10^{-10} o 10^{-11} , indicando una differenza di energia nettamente significativa. Il confronto interictale vs pre-ictale, invece, presenta un p-value di 0,032: pur essendo al di sotto della soglia di significatività, questo valore è molto più alto rispetto agli altri scenari, indicando che le energie dei segnali interictali e pre-ictali sono simili. Per questo motivo lo scenario interictale vs pre-ictale non è stato incluso nella fase di validazione, poiché la scarsa differenza di energia tra le due classi non avrebbe permesso una classificazione affidabile.

Fase 4, classificazione. L'energia viene fornita a una SVM con quattro kernel: lineare, quadratico, cubico e RBF. La validazione usa cross-validation a 5 e 10 fold.

3.4 Confronto delle prestazioni: sensibilità, specificità, accuratezza

Le metriche che utilizza in [20] sono accuratezza, sensibilità e specificità. L'accuratezza misura la prestazione complessiva, la sensibilità la proporzione di crisi reali rilevate e la specificità la proporzione di periodi senza crisi correttamente identificati.

Dai confronti tra le varie misure del precedente studio si stabilisce che il rapporto di compressione che fornisce le migliori prestazioni in tutti gli scenari è quello 1/8.

Dal dataset eseguito sui dati di New Delhi, a 10-fold CV, questi sono i risultati migliori stabiliti nei tre diversi scenari, con kernel differenti e CR diversi.

SCENARIO	KERNEL MIGLIORE	CR 1/8	RAW
Ictal vs interictale	Cubico	100%	100%
Ictal vs pre-ictale	Cubico	95%	93%
Ictal vs non-ictale	Lineare	96,7%	95,3%

Tab. 3.1 - Confronto tra prestazioni del dataset di New-Delhi a 10-fold [20]

Dal Dataset eseguito sui dati di Bonn, 10-fold CV si ha un valore di accuratezza del 99% con CR 1/8 nello scenario ictale vs non-ictale, confermando l'affidabilità del metodo anche con alti rapporti di compressione.

Per confermare che la compressione del segnale non compromette l'informazione, sono stati eseguiti test per calcolare i valori di entropia di Shannon, *approximate entropy* e *sample entropy* del segnale compresso a 1/8, osservando che i valori sono approssimativamente uguali a quelli del segnale originale.

Entropy	Sample of ictal		Sample of preictal	
	Original	Compressed	Original	Compressed
Shannon entropy	0.999	0.987	0.998	0.998
Approximate entropy	2.3298	2.2654	2.3353	2.3244
Sample entropy	2.1601	2.1125	2.2287	2.2685

Fig. 3.8 - Valori di entropia su segnale EEG originale e compresso a 1/8 per classi preictali e ictali [20]

I kernel non lineari (quadratico, cubico, RBF) performano meglio di quello lineare perché l'attività cerebrale non è linearmente separabile. La compressione delle dimensioni ha sicuramente un effetto positivo sul tempo di calcolo, contribuendo allo sviluppo di sistemi di rilevamento più veloci.

Inoltre, la variazione tra kernel è bassa. In ogni scenario, la differenza di accuratezza tra i vari tipi di kernel è di pochi punti percentuali. Questo indica che il metodo non dipende criticamente dalla scelta del kernel, rendendolo applicabile a sistemi reali con un certo grado di robustezza.

Purtroppo, nello studio non è stato considerato anche il tasso di falsi allarmi. Senza il quale, non è possibile stabilire se il sistema genererebbe allarmi accettabili in un monitoraggio continuo. Inoltre, i risultati ottenuti derivano da *cross-validation* a 5 e 10

fold su dataset pre-registrati. Non c'è monitoraggio continuo né artefatti da movimento domiciliare, che potrebbero incidere invece sulle prestazioni dello strumento.

In conclusione, le prestazioni ottenute mediante validazione incrociata su dataset EEG rappresentano una dimostrazione di fattibilità computazionale, ma non equivalgono a una validazione clinica prospettica in condizioni di telemonitoraggio reale. Per arrivare alla pratica clinica servirebbero studi prospettici con misurazione del tasso di falsi allarmi, aderenza e qualità del segnale in condizioni domiciliari.

L'integrazione tra tecniche di rimozione degli artefatti, Compressive Sensing e classificazione del segnale rappresenta una svolta importante specialmente nell'elaborazione del segnale EEG acquisito in ambiente domiciliare.

Il Compressive Sensing è un metodo molto utile specialmente per dispositivi a risorse limitate, come gli impianti EEG a batteria. Tuttavia, non esiste una soluzione universale: nessun algoritmo funziona bene per ogni problema e per tutte le applicazioni. La scelta dell'algoritmo di ricostruzione, della matrice di misura e del dizionario deve adattarsi alla natura del segnale e al contesto.

Capitolo 4

Conclusioni

4.1 Sintesi dei principali risultati

Il lavoro svolto ha compreso tutto il percorso completo del dato nel monitoraggio remoto dell'epilessia: dalla sua generazione sul corpo del paziente, all'acquisizione sul dispositivo, fino alla sua compressione ed elaborazione. Questi passaggi non sono tra loro indipendenti ma, le decisioni che vengono prese in merito a ciascuno di essi si ripercuotono poi sul resto. Questo perché, la scelta dei dispositivi, della modalità di elaborazione o degli algoritmi di crittografia devono tutti tenere in conto della quantità di energia e di memoria disponibili, garantendo elevate prestazioni.

Dal punto di vista clinico, la motivazione del monitoraggio continuo è giustificata da varie argomentazioni. Per esempio, il fatto che i diari delle crisi compilati dai pazienti spesso non riportano la frequenza reale degli eventi, e questa sottostima si traduce poi in decisioni terapeutiche spesso incorrette. Oltre a ciò, si considera il rischio di SUDEP, concentrato nelle crisi tonico-cloniche notturne e non assistite. Per migliorare questa situazione i dispositivi wearable affidabili potrebbero mandare un allarme ai *caregiver*, garantendo in intervento immediato.

Dal punto di vista tecnologico, l'analisi dei dispositivi ha mostrato un quadro differente tra crisi tonico-cloniche generalizzate e le altre tipologie. Nelle prime, infatti, esistono evidenze eseguite con studi di fase 3, dai cui risultati si osserva una sensibilità compresa tra il 90% e il 96% e un tasso di falsi allarmi tra 0,2 e 0,67 ogni 24 ore. Per tutte le altre tipologie di crisi, in particolare per le focali non motorie, l'evidenza si ferma a studi di fase 1 e 2.

Inoltre, lo studio pilota multimodale analizzato nel Capitolo 2 lo evidenzia: la combinazione di EEG retroauricolare ed ECG ha rilevato la totalità delle crisi in due pazienti, ma con 13 e 5 falsi allarmi ogni 24 ore, e nel paziente con crisi toniche focali il compromesso migliore restava 84% di sensibilità con 8 falsi allarmi al giorno. Da questo ed altri studi la conclusione ricorrente è che nessun segnale singolo copre tutti i tipi di

crisi e che l'integrazione multimodale è la direzione più promettente, considerando però l'aumento di dati da acquisire, elaborare e trasmettere.

Il Capitolo 3 ha affrontato il problema dell'elaborazione del segnale acquisito. La rimozione degli artefatti resta un problema senza soluzione unica: i vari metodi basati su canale di riferimento, decomposizione e separazione delle sorgenti hanno ciascuno un limite strutturale, e le combinazioni ibride offrono le prestazioni migliori, nonostante si debba considerare un alto costo computazionale. Per migliorare invece il problema della grande quantità di volume dei dati, si può usare il metodo del Compressive Sensing: unendo acquisizione e compressione in un unico passaggio, si riduce la banda, la memoria e l'energia senza che si debbano prima salvare i dati del segnale. Il caso applicativo studiato mostra che, con un rapporto di compressione di 1/8 e considerando come unica caratteristica l'energia si ottiene un valore di accuratezza pari o superiore a quello del segnale grezzo (100% ictale contro interictale, 95% contro pre-ictale, 96,7% ictale contro non ictale), con valori di entropia abbastanza invariati rispetto all'originale. Bisogna però considerare che questi dati sono presi da dataset preregistrati, senza tasso di falsi allarmi e senza artefatti da movimento domiciliare. Esiste quindi una validazione scientifica, ma la reale efficacia deve ancora essere dimostrata.

In Appendice A, infine, si studiano i vari metodi per criptare i dati ottenuti da questi segnali, considerando la scarsità di risorse energetiche. La crittografia convenzionale, infatti, non è sostenibile su piccoli dispositivi wearable, mentre gli algoritmi leggeri raggiungono un compromesso accettabile: LEAIoT mostra riduzioni di risorse dell'ordine dell'87,9% rispetto alla versione leggera di AES, e nel confronto sistematico su otto cifrari RECTANGLE emerge come il più stabile all'aumentare della dimensione dei file e il più regolare nelle prestazioni sui diversi modelli di classificazione.

4.2 Sfide aperte: qualità del segnale, autonomia energetica, affidabilità

Affinché questi dispositivi possano essere realmente utilizzati nella pratica clinica ci sono diverse sfide da affrontare.

Innanzitutto, il tasso di falsi allarmi. La sensibilità elevata di un dispositivo può essere uno dei motivi principali per il grande numero di falsi allarmi. Essi sono un problema

perché generano ansia e sfiducia nei pazienti, che spesso decidono di interrompere l'utilizzo di questi dispositivi. Generalmente i pazienti con crisi frequenti possono tollerare uno o due falsi allarmi a settimana quelli con crisi rare uno o due al mese.

Secondariamente si pone il problema della qualità del segnale al di fuori di strutture sanitarie, come gli ospedali. Confrontando i risultati dei vari studi, si nota come tutti i risultati migliori provengano da ambienti come unità di monitoraggio, dove il paziente è a riposo, gli elettrodi sono controllati e gli artefatti sono limitati. A domicilio cambiano il movimento, la posizione del dispositivo, il contatto degli elettrodi e la collaborazione del paziente. Diventa quindi necessario compiere più prove sperimentali in ambienti che si avvicinano alla realtà quotidiana, dove si possono considerare effettivamente i risultati ottenuti.

Tra i problemi più importanti, c'è sicuramente quello dell'energia. Infatti, scegliere una frequenza di campionamento per i sensori, sceglierne il numero, gli algoritmi di rimozione degli artefatti, i metodi di compressione e di crittografia sono tutte decisioni che influenzano la stessa batteria. I pazienti richiedono un'autonomia di almeno 24 ore con la possibilità di non interrompere la registrazione. Nessuno degli studi analizzati però misura il bilancio energetico lungo tutti gli step che il dato compie, ma solo singolarmente. Ciò rende impossibile prevedere il comportamento di un sistema reale che le implementi tutte insieme.

Come già espresso in precedenza, i dispositivi wearable raccolgono i dati sanitari dei pazienti e le loro abitudini. La trasmissione di questi dati su reti pubbliche li espone però a intercettazione, alterazione dei loro dati o attacchi alla disponibilità del servizio. Servono quindi dei buoni sistemi di crittografia che impediscano questo ostacolo. Ciò diventa un grande limite, considerando anche l'assenza di quadri legislativi che parlino di responsabilità etica e legale.

Infine, l'ultima problematica affrontata è di tipo metodologico. Gli studi e gli articoli in merito ai dispositivi per il monitoraggio continuo a distanza dell'epilessia sono molto diversi nei protocolli, nelle metriche e nella completezza dei report, al punto che il confronto diretto tra dispositivi è spesso impraticabile. Senza una standardizzazione delle fasi di validazione, è difficile portare la ricerca ad un livello superiore.

4.3 Prospettive future

Per una prospettiva futura, risulta necessario aumentare l'attività di ricerca e condurre nuove campagne sperimentali, necessarie a superare i limiti attuali e convalidare l'efficacia di questi modelli su dati più ampi. Servono, quindi, più studi di fase 3 e 4 condotti a domicilio, di durata prolungata, che riportino diversi fattori: la sensibilità, il tasso di falsi allarmi, il tempo di malfunzionamento del dispositivo, l'aderenza e la qualità del segnale. Superato questo limite, si potrà, oltre che dimostrare la fattibilità, evidenziare il beneficio clinico, oggi ancora assente.

Inoltre, i sistemi paziente-specifici, sperimentati sulle caratteristiche individuali, hanno mostrato prestazioni superiori a quelli generici e universali, che sono invece più complessi da utilizzare.

Sarebbe, poi, molto utile avere dispositivi flessibili nel regolare la soglia di durata minima. Infatti, in questo modo si può migliorare il compromesso tra sensibilità e falsi allarmi allo scopo del monitoraggio: alta sensibilità quando si vuole quantificare la frequenza delle crisi per una revisione successiva, basso tasso di falsi allarmi quando il sistema deve generare un allarme in tempo reale. Se questi due parametri vengono considerati in situazioni diverse, invece che trovare un modello che vada bene universalmente, si avranno dei risultati migliori in un contesto più realistico.

Ancor di più, la progettazione combinata di compressione, classificazione e cifratura, invece della loro ottimizzazione separata, potrebbe essere una soluzione in merito all'utilizzo dell'energia.

Infine, uno dei fattori non tecnici più importanti da considerare saranno i giudizi da parte dei pazienti. Dagli studi emergono che, le preferenze dei pazienti indicano con chiarezza dispositivi non evidenti in forma di orologio, impermeabili, con autonomia di almeno un giorno, costo inferiore ai 300 dollari e abbonamento sotto i 20 dollari mensili, con il rimborso assicurativo come discriminante decisiva.

In definitiva, il monitoraggio remoto dell'epilessia diventerà parte della pratica clinica solo quando sensore, algoritmo, protezione del dato e sostenibilità economica saranno progettati come un sistema unico e coordinato.

Appendice A

A.1 Minacce e vulnerabilità nei dispositivi wearable e nelle trasmissioni wireless

La diffusione dell'Internet of Things (IoT) ha aperto nuove prospettive nel monitoraggio sanitario a distanza. L'IoT consiste in un insieme di dispositivi molto diversi tra loro che si connettono gli uni con gli altri per garantire nuovi servizi e capacità innovative che migliorino la salute dei pazienti, garantendo sempre una alta qualità che sia accessibile a tutti. Questi sistemi devono avere delle caratteristiche importanti come: interoperabilità, virtualizzazione, decentralizzazione, disponibilità in tempo-reale e modularità.

L'integrazione dell'IoT nei servizi sanitari, allo stesso tempo, solleva preoccupazioni significative riguardo alla sicurezza e alla privacy a causa della natura sensibile dei dati raccolti, trasmessi ed elaborati dai dispositivi. Molte vulnerabilità che possono compromettere la sicurezza del paziente, intervenendo sulle proprie informazioni personali. Riuscire ad interferire con la trasmissione dei dati permette ai malintenzionati di attaccare la privacy dei consumatori oltre che fabbricare errati dati sanitari, che comportano in seguito diagnosi inaccurate. I dispositivi wearable utilizzati in telemedicina sono per lo più impiantabili o indossabili, ed essi si connettono e disconnettono continuamente a reti di comunicazione che possono essere private o sconosciute. L'utilizzo di queste reti permette a persone esterne di intercettare la trasmissione e di modificare i dati sanitari sensibili.

Le minacce principali si articolano in tre categorie principali:

- Privacy dei dati
- Integrità dei dati
- Disponibilità dei sistemi

La prima riguarda l'intercettazione delle comunicazioni: intercettazione e monitoraggio del traffico dati sono i due attacchi principali che violano la privacy dei dati.

La seconda riguarda l'integrità dei dati: senza adeguata protezione, l'autenticazione utente viene interrotta e dispositivi non autorizzati possono accedere ai dati, alterarli per scopi malevoli o fabbricare dati sanitari errati da trasmettere agli altri componenti della rete,

portando a diagnosi inaccurate e comunicazione inaffidabile tra paziente e operatore sanitario.

La terza riguarda la disponibilità del sistema: gli attacchi Denial of Service (DoS) e Distributed Denial of Service (DDoS) interferiscono con i processi di comunicazione e rendono il sistema non disponibile agli utenti finali sfruttando vulnerabilità di rete.

Queste minacce hanno conseguenze cliniche dirette. Anche un piccolo ritardo in operazioni critiche può minacciare la vita dell'utente; in applicazioni che richiedono risposte immediate per allertare servizi medici, alcuni tipi di attacchi possono ritardare queste funzionalità e rendere inutile il lavoro del sistema. L'impropria protezione dei dati ha inoltre implicazioni legali ed etiche, perché può essere sfruttata da entità esterne per attaccare il benessere dell'utente.

Per contrastare queste minacce, si stanno sempre più sviluppando meccanismi di machine learning che migliorano la sicurezza facilitando lo sviluppo di Intrusion Detection Systems (IDS), capaci di identificare e prevenire vari tipi di attacchi, inclusi gli attacchi DDoS. Questi modelli innovativi possono essere addestrati per identificare comportamenti anomali nei dispositivi IoT, prevenendo l'accesso non autorizzato ai dati dei pazienti.

A.2 Crittografia leggera per dispositivi a risorse limitate

La crittografia tradizionale, pur sapendo proteggere dati sensibili, ha nella maggior parte dei casi un carico rilevante in termini di risorse per essere implementata su dispositivi IoT, che hanno memoria, capacità di calcolo e batteria limitati. Gli algoritmi di crittografia leggera (*Lightweight Cryptography*, LWC) sono stati sviluppati proprio per risolvere questo problema: la loro particolarità consiste nell'essere caratterizzati da dimensioni ridotte, esecuzione veloce e livelli di sicurezza adeguati. Il loro obiettivo principale è bilanciare sicurezza e consumo di risorse, rendendoli adatti all'utilizzo su dispositivi IoT e altre piattaforme utilizzate nell'ambito della telemedicina.

La necessità di una crittografia leggera nasce quindi da un vincolo concreto: i cifrari comuni hanno un consumo troppo elevato e non possono essere utilizzati nei dispositivi IoT a causa delle loro limitazioni. Al contempo, però, il cifrario impiegato non deve limitare le altre funzionalità di cui tutti i dispositivi hanno bisogno, come sicurezza,

integrabilità, disponibilità e confidenzialità. Serve quindi una versione più leggera che riesca a compiere questi compiti nonostante le limitazioni dei dispositivi IoT.

Un altro fattore importante da considerare è la velocità con cui questi dispositivi criptano le informazioni e le inviano agli altri dispositivi. Il tempo con cui gli algoritmi di crittografia eseguono le loro operazioni diventa particolarmente importante quando ci troviamo in situazioni critiche, come la necessità di mandare allarmi immediati. Gli stessi algoritmi devono inoltre essere flessibili, ovvero la lunghezza della chiave e la velocità con cui questa viene elaborata deve poter essere modificata in base alle varie circostanze.

I fattori chiave che contraddistinguono un algoritmo LWC da altri per l'IoT sanitario sono cinque [22]:

- Dimensione della chiave: nei dispositivi medici IoT, che hanno generalmente poca memoria, chiavi più corte (64, 96 o 128 bit) sono più adatte, ottimizzando memoria e consumo energetico.
- Tempo di elaborazione: può essere ridotto diminuendo la dimensione dei blocchi. Poiché i sensori medici trasmettono spesso messaggi brevi, blocchi più piccoli aumentano l'efficienza.
- Consumo energetico: la potenza della batteria richiesta durante cifratura e decifratura è un fattore critico nel monitoraggio sanitario IoT.
- Requisiti di RAM: devono essere minimizzati per garantire il funzionamento corretto dei processi di monitoraggio medico in tempo reale. Questo comporta bilanciare le memorie RAM e ROM per ottimizzare le operazioni del dispositivo.
- Numero di round: Un "round" è un ciclo di operazioni elementari. Gli algoritmi LWC implementano generalmente logica di base e calcoli matematici semplici per rispettare i vincoli necessari a far funzionare correttamente i sistemi.

Il caso di LEAIoT [21]

LEAIoT è un algoritmo di crittografia leggera che combina due approcci: la crittografia simmetrica e quella asimmetrica, per poter sfruttare i rispettivi vantaggi. La crittografia simmetrica fornisce infatti maggiore velocità operativa con un numero minimo di risorse

di calcolo, mentre quella asimmetrica offre una migliore distribuzione delle chiavi, garantendo così la riservatezza del sistema.

Alla base di questo sistema c'è il principio della doppia cifratura: il dato non viene cifrato una sola volta, ma due volte con due metodi diversi, uno dopo l'altro. Ciò rende il dato finale molto più difficile da decifrare da chi prova ad entrare dall'esterno.

La cifratura

LEAIoT dà la possibilità di scegliere tra quattro opzioni per la dimensione della chiave simmetrica: 32, 64, 128 o 256 bit. La flessibilità della chiave è un'ottima caratteristica poiché permette di avere una protezione differente in base alle situazioni. In modo particolare, per l'ambiente IoT sanitario, è fortemente consigliata la chiave a 256 bit.

Il processo di cifratura si compone di due fasi successive:

Prima fase: cifratura simmetrica. Il testo in chiaro viene cifrato con una chiave simmetrica privata, chiamata n . Questa chiave è nota sia al mittente che al destinatario. L'algoritmo applica operazioni di crittografia sul testo usando questa chiave, producendo un primo testo cifrato. Questa fase è veloce e richiede poche risorse, ed è per questo motivo che la crittografia simmetrica è più leggera delle altre.

Seconda fase: cifratura asimmetrica (NLBC). Sul testo cifrato prodotto dalla crittografia simmetrica viene applicato un cifrario a blocchi lineare asimmetrico, chiamato NLBC. Questa fase utilizza due chiavi: una chiave pubblica n_1 e una chiave privata k , che è una matrice 3x3 in cui ogni elemento ha un valore compreso tra 1 e 36. Il cifrario NLBC trasforma ulteriormente il testo cifrato della prima fase, producendo il testo finale completamente sicuro.

La decifratura

La decifratura segue il percorso inverso, applicando le operazioni nell'ordine opposto e usando gli inversi delle tre chiavi di cifratura:

Prima fase: decifratura asimmetrica. Dal testo arrivato, utilizza le chiavi n_1^{-1} e k^{-1} , che sono l'inverso delle chiavi di cifratura. In pratica, l'algoritmo calcola l'inverso matematico di ciascuna chiave operando con modulo 37, ovvero lavorando solo con i numeri da 0 a

36 e prendendo il resto della divisione per 37. Applicando queste chiavi inverse al testo cifrato, si ottiene il testo parzialmente decifrato.

Seconda fase: decifratura simmetrica. Il testo parzialmente decifrato viene sottoposto a decifratura simmetrica usando la chiave SSK (Secure Symmetric Key), che è l'inverso modulare con modulo 37 della chiave n usata nella prima fase di cifratura. Il risultato è il testo in chiaro originale.

I metodi proposti: panoramica degli algoritmi.

Oltre alla proposta di LEA IoT, la ricerca sulla crittografia leggera per l'IoT sanitario ha portato allo sviluppo di altre metodologie. Uno studio rilevante affronta il problema della scelta dell'algoritmo LWC più adatto ai dispositivi IoT medici [22]. Valuta otto diversi algoritmi su Raspberry Pi 3, un microcontrollore con 1 GB di RAM e processore 1,2 GHz quad-core, che simula un dispositivo IoT. Per ogni algoritmo usa file di dimensioni crescenti: da 16 KB a 2048 KB.

- AES (Advanced Encryption Standard): standardizzato nel 2001, è ampiamente riconosciuto per la sua sicurezza, ma le sue elevate esigenze computazionali e di memoria lo rendono poco pratico per dispositivi a risorse limitate.
- PRESENT: introdotto nel 2007, è un cifrario a blocchi ultra-leggero con dimensione del codice ridotta e consumo energetico minimo.
- MSEA: sviluppato nel 2011, è un algoritmo a chiave simmetrica con basso carico computazionale, ottimizzato per la cifratura e decifratura di messaggi brevi.
- LEA: introdotto nel 2013, ha un design leggero, compatto ed efficiente energeticamente, utilizzando poca memoria.
- XTEA: algoritmo del 1995, molto semplice ed efficiente con requisiti minimi di codice e memoria.
- SIMON: rilasciato nel 2013, presenta un design leggero, economico ed efficiente in termini di potenza.
- PRINCE: introdotto nel 2012, caratterizzato da dimensione del codice ridotta, consumo energetico minimo.

- RECTANGLE: proposto nel 2007, ha dimensione del codice ridotta, bassi requisiti di memoria e buon rapporto efficienza-sicurezza.

A.3 Bilanciamento tra sicurezza, prestazioni e consumo energetico

Si deve cercare di raggiungere il giusto equilibrio tra alte performance e l'utilizzo minimo delle risorse disponibili.

I risultati di LEAIoT

Lo sviluppo di LEAIoT mostra dei buoni risultati in confronto all'implementazione originale su CPU. Infatti, la velocità di generazione delle chiavi è superiore del 99,9% per tutte le dimensioni di chiave. Il vantaggio derivante dalla velocità di cifratura e decifratura, invece, diminuisce progressivamente con la dimensione dei dati: 99,3% per 100 kilobit, 98,4% per 300 kilobit, 97,5% per 500 kilobit e 96,2% per 1000 kilobit.

I cicli di clock necessari per la generazione delle chiavi variano in base alla dimensione: 74 cicli per chiavi da 32 bit, 79 per 64 bit, 87 per 128 bit e 102 per 256 bit.

Il confronto con altri cifrari dimostra l'efficienza di LEAIoT: utilizza l'87,9% di risorse in meno rispetto alla versione leggera di AES, e riduce il consumo di risorse del 65,7% e 12,2% rispetto ai cifrari SNOW 3G e ZUC.

La conclusione è che lo schema proposto soddisfa efficacemente i requisiti prestazionali per lo *smart health* e può essere facilmente impiegato nei vari dispositivi della rete IoT, fornendo alti livelli di sicurezza alla struttura sanitaria, con un buon bilancio tra risorse e sicurezza [21].

Questo studio è stato svolto coinvolgendo generalmente tutti i dispositivi IoT, ma si può ben adattare anche ai sistemi usati per il telemonitoraggio dell'epilessia.

I risultati dello studio [22]

Tutti gli otto algoritmi sono stati integrati con cinque modelli di Machine Learning: Decision Tree, Random Forest, SVM, MLP e KNN. Le prestazioni di ognuno sono state valutate attraverso i valori di accuratezza, precisione, sensibilità ed F1-score (la media tra precisione e sensibilità). Lo scopo è identificare l'algoritmo che offra il miglior

compromesso tra sicurezza, consumo energetico ed efficienza computazionale per i dispositivi IoT clinici, tenendo conto dei loro vincoli specifici: velocità di elaborazione lenta, memoria limitata e banda ridotta.

ACCURATEZZA

File	Miglior algoritmo	Modello	Valore
16 KB	AES	KNN	0,98
64 KB	LEA / RECTANGLE	SVM	0,992
256 KB	AES	MLP	0,98
512 KB	AES	RF	0,956
1024 KB	AES	RF	0,943
2048 KB	AES	RF	0,938

PRECISIONE

File	Miglior algoritmo	Modello	Valore
16 KB	RECTANGLE	RF / SVM	0,98
64 KB	AES	RF	0,999
256 KB	RECTANGLE	DT	0,995
512 KB	AES	MLP	0,987
1024 KB	AES	RF	0,963
2048 KB	AES	RF	0,961

SENSIBILITA'

File	Miglior algoritmo	Modello	Valore
16 KB	AES	SVM	0,9923
64 KB	RECTANGLE	MLP	0,990
256 KB	AES	RF	0,985
512 KB	RECTANGLE	SVM	0,947
1024 KB	RECTANGLE	MLP	0,95
2048 KB	RECTANGLE	RF	0,94

F-1 SCORE

File	Miglior algoritmo	Modello	Valore
16 KB	AES	MLP	0,88
64 KB	RECTANGLE	RF	0,97
256 KB	RECTANGLE	RF	0,95
512 KB	AES	MLP	0,95
1024 KB	RECTANGLE	RF/MLP/KNN	0,99
2048 KB	RECTANGLE	MLP	0,99

Tab. A.1 - Confronto di prestazioni tra algoritmi di crittografia [22]

I dati di precisione mostrano una variabilità significativa tra algoritmi e dimensioni dei file, anche se per i file più piccoli (16 KB), la precisione è generalmente alta. L'F1-score conferma questo andamento. I modelli Random Forest e MLP mostrano generalmente le prestazioni migliori, mentre KNN ottiene generalmente i punteggi più bassi.

La conclusione dello studio è che RECTANGLE risulta l'algoritmo LWC più adatto ed efficiente per l'IoT sanitario, grazie alla sua velocità, efficienza, semplicità e flessibilità. Questo perché, nonostante non risulti sempre il metodo migliore, tra tutti RECTANGLE è tra gli algoritmi meno colpiti dall'aumento della dimensione del file e, allo stesso tempo, ha avuto ottime performance su tutti i modelli Machine Learning. Lo studio osserva inoltre che la precisione dei modelli diminuisce all'aumentare della dimensione del file, suggerendo la necessità di metodi di crittografia leggeri che riducano il carico computazionale.

Da entrambi gli studi si giunge ad un punto fondamentale: la scelta dell'algoritmo di crittografia leggera per l'IoT sanitario richiede un bilanciamento tra sicurezza, prestazioni e consumo energetico.

Bibliografia

- [1] Fisher, R. S., Acevedo, C. A., Arzimanoglou, A., et al. (2014). ILAE Official Report: A practical clinical definition of epilepsy. *Epilepsia*, 55(4), 475–482. <https://doi.org/10.1111/epi.12550>
- [2] Thijs, R. D., Surges, R., O'Brien, T. J., & Sander, J. W. (2019). Epilepsy in adults. *The Lancet*, 393(10172), 689-701. [https://doi.org/10.1016/S0140-6736\(18\)32596-0](https://doi.org/10.1016/S0140-6736(18)32596-0)
- [3] Patterson, V. (2019). Managing epilepsy by telemedicine in resource-poor settings. *Frontiers in Public Health*, 7, 321. <https://doi.org/10.3389/fpubh.2019.00321>
- [4] Alkhaldi, M., Joudeh, L. A., Ahmed, Y. B., & Husari, K. S. (2024). Artificial intelligence and telemedicine in epilepsy and EEG: A narrative review. *Seizure: European Journal of Epilepsy*, 121, 204-210. <https://doi.org/10.1016/j.seizure.2024.08.024>
- [5] Sahu, J. K., et al. (2026). Applications and impact of telemedicine for persons with epilepsy: A scoping review. *Seizure: European Journal of Epilepsy*, 136, 107-116. <https://doi.org/10.1016/j.seizure.2026.01.016>
- [6] Dorsey, E. R., Glidden, A. M., Holloway, M. R., Birbeck, G. L., & Schwamm, L. H. (2018). Teleneurology and mobile technologies: the future of neurological care. *Nature Reviews Neurology*, 14(5), 285-297. <https://doi.org/10.1038/nrneurol.2018.31>
- [7] Beniczky S., Wiebe S., Jeppesen J., et al. (2021). Automated seizure detection using wearable devices: A clinical practice guideline of the International League Against Epilepsy and the International Federation of Clinical Neurophysiology. *Clinical Neurophysiology*, 132(5), 1173-1184. <https://doi.org/10.1016/j.clinph.2020.12.009>
- [8] Nielsen J.M., Rades D., Kjaer T.W., et al. (2022). Towards a wearable multi-modal seizure detection system in epilepsy: A pilot study. *Clinical Neurophysiology*, 136, 40-48. <https://doi.org/10.1016/j.clinph.2022.01.005>
- [9] Milne-Ives M., Duun-Henriksen J., Blaabjerg L., et al. (2023). At home EEG monitoring technologies for people with epilepsy and intellectual disabilities: A scoping review. *Seizure: European Journal of Epilepsy*, 110, 137-147. <https://doi.org/10.1016/j.seizure.2023.05.007>
- [10] Macea J., Bhagubai M., Broux V., et al. (2023). *In-hospital and home-based long-term monitoring of focal epilepsy with a wearable electroencephalographic*

device: Diagnostic yield and user experience. *Epilepsia*, 64(4), 937-950.

<https://doi.org/10.1111/epi.17517>

[11] Sivathamboo S., Nhu D., Piccenna L., et al. (2022). Preferences and User Experiences of Wearable Devices in Epilepsy: A Systematic Review and Mixed-Methods Synthesis. *Neurology*, 99(13), e1380-e1392.

<https://doi.org/10.1212/WNL.0000000000200794>

[12] Bruno E., Böttcher S., Viana P.F., et al. (2021). Wearable devices for seizure detection: Practical experiences and recommendations from the Wearables for Epilepsy And Research (WEAR) International Study Group. *Epilepsia*, 62(10), 2307-2321. <https://doi.org/10.1111/epi.17044>

[13] Brinkmann B.H., Karoly P.J., Nurse E.S., et al. (2021). Seizure Diaries and Forecasting With Wearables: Epilepsy Monitoring Outside the Clinic. *Frontiers in Neurology*, 12, 690404. <https://doi.org/10.3389/fneur.2021.690404>

[14] Ryvlin P., Ciumas C., Wisniewski I., Beniczky S. (2018). Wearable devices for sudden unexpected death in epilepsy prevention. *Epilepsia*, 59(S1), 61-66.

<https://doi.org/10.1111/epi.14054>

[15] Johansson D., Malmgren K., Alt Murphy M. (2018). Wearable sensors for clinical applications in epilepsy, Parkinson's disease, and stroke: a mixed-methods systematic review. *Journal of Neurology*, 265(8), 1740-1752.

<https://doi.org/10.1007/s00415-018-8786-y>

[16] Lu L., Zhang J., Xie Y., et al. (2020). Wearable Health Devices in Health Care: Narrative Systematic Review. *JMIR mHealth and uHealth*, 8(11), e18907.

<https://doi.org/10.2196/18907>

[17] Karceski, S. (2022). Seizure Detection and Wearables: Integrating Technology in Patient Care. *Neurology*, 99, e1443-e1445.

<https://doi.org/10.1212/WNL.0000000000201236>

[18] Jiang, X., Bian, G.-B., & Tian, Z. (2019). Removal of Artifacts from EEG Signals: A Review. *Sensors*, 19(5), 987. <https://doi.org/10.3390/s19050987>

[19] Gurve, D., Delisle-Rodriguez, D., Bastos-Filho, T., & Krishnan, S. (2020). Trends in Compressive Sensing for EEG Signal Processing Applications. *Sensors*, 20(13), 3703. <https://doi.org/10.3390/s20133703>

[20] Wijayanto, I., Humairani, A., Hadiyoso, S., Rizal, A., Prasanna, D. L., & Tripathi, S. L. (2023). Epileptic seizure detection on a compressed EEG signal using energy measurement. *Biomedical Signal Processing and Control*, 85, 104872.

<https://doi.org/10.1016/j.bspc.2023.104872>

- [21] Aivaliotis, V., Tsantikidou, K., & Sklavos, N. (2022). IoT-Based Multi-Sensor Healthcare Architectures and a Lightweight-Based Privacy Scheme. *Sensors*, 22(11), 4269. <https://doi.org/10.3390/s22114269>
- [22] Chinbat, T., Madanian, S., Airehrour, D., & Hassandoust, F. (2024). Machine learning cryptography methods for IoT in healthcare. *BMC Medical Informatics and Decision Making*, 24(1). <https://doi.org/10.1186/s12911-024-02548-6>

PRESENTAZIONE DELL'ELABORATO



UNIVERSITA' DEGLI STUDI DI PADOVA
Dipartimento di Ingegneria dell'Informazione

Corso di Laurea in Ingegneria Biomedica

Relazione per la prova finale

«Monitoraggio remoto dell'epilessia: dispositivi wearable, elaborazione del segnale e sicurezza dei dati»

Relatore: Prof. Giovanni Sparacino

Laureanda: Alice Stefano

Matricola n.: 2110237

ANNO ACCADEMICO 2025/2026

1



Epilessia

L'epilessia è una malattia **cronica neurologica**, caratterizzata dalla presenza di crisi epilettiche ricorrenti e non provocate. Queste sono causate da uno **squilibrio** tra segnali eccitatori e segnali inibitori. L'**imprevedibilità** è l'aspetto che più incide sulla qualità vita dei pazienti, con rischio concreto di traumi.

Il trattamento standard prevede la somministrazione di farmaci antiepilettici e un monitoraggio basato su:

- Visite ambulatoriali
- Diari delle crisi
- Video-EEG in ricovero



EPILEPSY

1 bis



Motivazioni del monitoraggio continuo a distanza dell'epilessia

- Difficoltà nel riconoscere e riportare la reale frequenza delle crisi epilettiche
- Aumento del rischio di “Sudden Unexpected Death in Epilepsy” (SUDEP), specialmente in crisi tonico-cloniche generalizzate
- Disomogeneità dell'assistenza sanitaria globale.

2



Obiettivi del lavoro



1. Analisi dei dispositivi *wearable* usati nel monitoraggio dell'epilessia
2. Elaborazione del segnale EEG al fine del monitoraggio remoto dell'epilessia
3. Sicurezza dei dati nel telemonitoraggio.

2 bis



Obiettivo 1: analisi dei dispositivi *wearable*

Considerare un solo segnale non è efficace per analizzare le varie tipologie di crisi epilettiche:

Tonico-cloniche

Focali



I sistemi **multimodali** uniscono segnali di natura diversa (es: EEG, EMG, PPG) con lo scopo di aumentare la sensibilità e ridurre il tasso di falsi allarmi.

- Nielsen, et al., *Clinical Neurophysiology*, (2022)

3



Segnali utilizzati nei dispositivi *wearable*

Segnali **cerebrali**:

EEG nelle sue varie forme



Segnali **periferici**:



- Accelerometria (ACM)
- Elettromiografia di superficie (sEMG)
- Fotopletismografia (PPG)
- Attività elettrodermica (EDA)
- Elettrocardiografia (ECG).

4



Obiettivo 2: elaborazione del segnale EEG

Dispositivi indossabili
a **risorse limitate**:

- Batteria
- Memoria
- Banda



Pre-elaborazione del
segnale: **rimozione
di artefatti**
estrinseci ed
intrinseci



Compressione
del segnale



Jiang X., et al., *Sensors*, (2019) 5




Compressive Sensing: acquisire e comprimere in un solo passaggio

Il Compressive Sensing è un metodo che permette di risolvere il problema della grande quantità di dati proveniente dal segnale EEG.

Requisiti principali: **sparsità** del segnale e **incoerenza** tra matrici.

$$y = \Phi x = \Phi \Psi s = As$$



Curve D., et al., *Sensors*, (2020) 6



Esempio

Scenario (10-fold CV)	Kernel migliore	Valore accuratezza con CR 1/8	Valore accuratezza segnale grezzo
Ictale vs interictale (New Delhi)	Cubico	100%	100%
Ictale vs pre-ictale (New Delhi)	Cubico	95%	93%
Ictale vs non-ictale (New Delhi)	Lineare	96,7%	95,3%
Ictale vs non-ictale (Bonn)	Lineare	99%	95,3%

Wijayanto I., et al., *Biomedical Signal Processing and Control* (2023)


7



Obiettivo 3: sicurezza dei dati nei sistemi di monitoraggio

Nella trasmissione di dati a distanza sorge la necessità di garantire:

- **Privacy** dei dati
- **Integrità** dei dati
- **Disponibilità** dei sistemi.



8



Conclusioni

Vantaggi	Limiti
Tracciamento della frequenza delle crisi	Numero di falsi allarmi rilevati
Continuità del monitoraggio	Durata della batteria limitata
Autonomia e sicurezza del paziente	Mancanza di standard
Riduzione dei tempi e costi delle visite ordinarie	Tutela della sicurezza dei dati
Prevenzione della SUDEP	Responsabilità etica e legale

Il monitoraggio a distanza ha dimostrato un importante valore scientifico: i progressi tecnologici e le future sperimentazioni contribuiranno a renderlo uno strumento sempre più efficace nella gestione dell'epilessia.

9



Prospettive future

- **Validare** gli studi del monitoraggio da remoto (per tempi prolungati e in condizioni di vita reale)
- **Integrare** l'intero processo di monitoraggio e non i singoli step
- **Ascoltare** i giudizi e le richieste dei pazienti.



10

