

# Intelligenza Artificiale e decisione clinica

Un percorso attraverso evidenze e concetti chiave della letteratura recente.  
**Human in the Loop, Automation Bias ed Explainability**

**Dr. Erik Lagolio**

**Gruppo di coordinamento AI in Medicina Generale SIMG**

**Contributing Physicians Progetto Health Bench OpenAI**

*Tavola rotonda AI 25 novembre 2025*

## AI come supporto alle decisioni cliniche

- L'Intelligenza Artificiale entra in **diagnostica, triage, gestione delle cronicità, refertazione**.
- Gli editoriali di *Nature Medicine*, *NEJM* e *JAMA* invitano a valutare l'AI **nel contesto reale**, non solo su metriche di laboratorio: come vengono accettate, modificate o ignorate le raccomandazioni.
- Topol descrive una "**medicina ad alte prestazioni**" che nasce dalla **convergenza fra intelligenza umana e artificiale, umana e artificiale**, con l'AI in ruolo di potenziamento, non sostitutivo.

Rif. Topol EJ. Nat Med 2019; Kohane IS. N Engl J Med 2024; Nature Medicine 2025.

**5K+**

**Scenari clinici**

Scenari realistici costruiti su  
linee guida internazionali e  
casi clinici reali

**262**

**Medici coinvolti**

Professionisti sanitari  
distribuiti in 60 paesi per  
validazione cross-culturale

**48.5K**

**Rubriche valutative**

Metriche su accuratezza,  
sicurezza, empatia, chiarezza  
e gestione dell'incertezza

**Il progetto**  
**HealthBench:**  
**validazione su scala**  
**globale**

Benchmark open-access misura la *clinical alignment* dei Large Language Models, evidenziando gap di performance significativi tra diverse aree cliniche.



**Contributo personale:** sviluppo di rubriche specifiche per primary care  
(multimorbilità, incertezza, continuità assistenziale) e analisi comparativa per definire  
soglie minime di sicurezza in Medicina Generale.

## Human in, on, out of the loop

### Human in the loop (HITL)

- L'AI elabora dati e propone diagnosi, priorità, piani o testi.
- Il clinico **esamina, integra, modifica o rifiuta** la proposta.
- La **decisione finale** e la responsabilità restano umane.

### Human on the loop

L'AI agisce quasi in autonomia, mentre il clinico mantiene un ruolo di ruolo di **sorveglianza** e intervento in intervento in caso di anomalie.

### Human out of the loop

L'AI prende decisioni che vengono eseguite senza un controllo umano significativo.

Rif. Nature Medicine 2025 – "For trustworthy AI, keep the human in the loop".

## Perché il "human in the loop" è centrale

- Gli editoriali di *Nature Medicine* sottolineano che la **fiducia** nell'AI dipende dalla capacità di **integrare il giudizio clinico** e non di sostituirlo.
- La prospettiva HITL considera il **binomio clinico+AI** come unità di analisi e misura l'effetto sui pazienti, non solo sulla metrica del modello.

Rif. Nat Med 2025 – "For trustworthy AI, keep the human in the loop".  
loop".

## Automation Bias: definizione operativa

Revisione sistematica di Goddard et al. su *JAMIA*: l'automation bias è la tendenza a **sovrastimare l'accuratezza** del sistema del sistema automatizzato.

Si manifesta come:

### Errori di omissione

il clinico trascura informazioni cliniche non evidenziate evidenziate dall'AI.

### Errori di commissione

il clinico segue raccomandazioni errate, ignorando dati discordanti.

Fattori mediatori: **fiducia nell'automazione, carico di lavoro, tempo limitato, stile cognitivo** del medico.

Rif. Goddard K et al. J Am Med Inform Assoc. 2012;19(1):121–127.

## Automation Bias: dati da studi empirici

### Goddard et al., JAMIA 2012

- 74 studi inclusi su oltre 13.000 record iniziali.
- In alcuni contesti clinici, errori associati ad automation bias nel **6–11% delle consultazioni**.

### Studi recenti con assistenti AI in patologia computazionale

- L'integrazione di AI migliora la performance media.
- Si osserva comunque un tasso di circa **7%** di casi in cui un giudizio corretto viene modificato in uno errato per seguire il modello.

Rif. Goddard K et al., JAMIA 2012; Rosbach E et al., 2024 (computational pathology).

## Assistive AI: quando il “supporto” può creare danno

Khera et al. su *JAMA*: discussione di uno studio con centinaia di clinici che gestiscono un caso di dispnea con supporto AI.  
supporto AI.

Risultati chiave:



AI "corretta" migliora la probabilità di diagnosi corretta rispetto al gruppo senza AI.



AI "distorta" porta i clinici a **allontanarsi**  
**allontanarsi sistematicamente** dalla diagnosi appropriata.



Le spiegazioni attenuano ma non eliminano l'effetto negativo.

Conclusione: anche un sistema "assistivo" può introdurre **nuovi tipi di errore** se l'automation bias non viene gestito.

Rif. Khera R, Simon MA, Ross JS. *JAMA*. 2023;330(23):2255–2257.



Studio di Kwong et al. su modello AI per idronefrosi pediatrica.

Durante il "silent trial", senza modifica apparente del contesto:

- L'uso di scintigrafia renale scende da circa 80% a 58%.
- Non vengono rilevate variazioni di linee guida, team o casi.

**"When the model trains  
you" (NEJM AI 2024)**

Interpretazione:

- L'esposizione a dataset e predizioni del modello induce **revisione delle soglie decisionali** dei clinici.
- Il modello non solo supporta decisioni, ma **plasma il modo di decidere**.

Rif. Kwong JCC et al. NEJM AI. 2024;1(2):AIcs2300004.

## Studio Multicentrico in Colonscopia: evidenze concrete di deskilling percettivo

Un trial osservazionale multicentrico condotto in quattro centri endoscopici ha rilevato che l'utilizzo routinario di un sistema AI per la rilevazione dei polipi è stato associato a una **riduzione significativa dell'adenoma detection rate (ADR)** nelle procedure effettuate senza AI dopo il periodo di esposizione.

### Prima dell'esposizione all'AI

**ADR senza AI: 28,4%**

(226 su 795 pazienti)

### Dopo l'uso routinario dell'AI

**ADR senza AI: 22,4%**

(145 su 648 pazienti)

**-6%**

**Differenza assoluta**

IC 95% -10,5 a -1,6; p = 0,0089

**1,443**

**Pazienti coinvolti**

Studio multicentrico su 4 centri

I risultati sono compatibili con un effetto di **deskilling percettivo e cognitivo**, con endoscopisti meno abituati a un'esplorazione visiva attiva quando l'AI non è disponibile.

# Explainability (XAI): a cosa serve realmente

Amann et al. (BMC 2020) analizzano l'explainability da prospettive: **tecnologica, clinica, legale, del paziente.**

## Funzioni principali in sanità:

- Supportare la **valutazione critica** della raccomandazione da parte del clinico.
- Sostenere **responsabilità** e consenso informato.
- Favorire la **fiducia** nel sistema, se usata in modo credibile.

## Limiti:

- Spiegazioni post-hoc generiche possono risultare poco informative o fuorvianti.
- Un'eccessiva complessità rischia di aumentare, non ridurre, il ridurre, il carico cognitivo.

Rif. Amann J et al. BMC Med Inform Decis Mak. 2020;20:310.

## Explainability e "illusione di comprensione"

Hildt (Bioengineering 2025) discute come i bisogni di explainability varino con tipo di decisione (screening, diagnosi, triage, allocazione risorse).

Per decisioni ad alto impatto individuale:

- Serve una comprensione di massima di **perché** il sistema propone X.
- Occorre sapere quali **alternative** sono state considerate o escluse.

### Il rischio:

Spiegazioni poco trasparenti o troppo sofisticate possono generare una **falsa sensazione di capire**, rafforzando l'automation bias.

## XAI e progettazione centrata sull'utente

Studi recenti mostrano che le tecniche XAI risultano utili solo se:

1

si integrano nei **flussi di lavoro reali** dei clinici;

2

usano un **linguaggio e visualizzazioni** comprensibili;

3

vengono co-progettate con gli utilizzatori finali.

Gli autori raccomandano:

- approccio di **user-centered design** e iterazione continua;
- valutazione prospettica dell'impatto su errori, bias e tempi di decisione.

Rif. Prince EW et al. Front Radiol. 2025; altri lavori recenti su XAI e CDSS.

### **Favorire il giudizio attivo attivo del clinico**

- Richiedere una valutazione valutazione preliminare prima di mostrare il suggerimento.
- Evitare flussi che permettono di accettare tutto con un solo click.

### **Esporre incertezza e fattori fattori chiave**

- Mostrare probabilità, intervalli, feature principali che hanno guidato la previsione.

## **Principi di design per ridurre l'automation bias**

### **Monitorare l'uso nel tempo**

- Analizzare pattern di "approvazione automatica".
- Osservare eventuali cambiamenti nelle soglie decisionali dei clinici.