



INTELLIGENZA ARTIFICIALE E IMAGING MEDICO: VERSO UNA RADIOLOGIA DI PRECISIONE

L'intelligenza artificiale si rivela uno strumento chiave in radiologia per abilitare un cambio di paradigma verso una medicina sempre più personalizzata. Garantirne un'adozione efficace richiede il rispetto di principi quali trasparenza, equità e robustezza. Mitigare le correlazioni spurie e quantificare l'incertezza predittiva sono passi cruciali per realizzare sistemi affidabili e sicuri.

La medicina di precisione si fonda su un principio tanto semplice da enunciare quanto complesso da realizzare: offrire l'intervento giusto, al paziente giusto, al momento giusto [1]. In pratica, significa modulare le decisioni cliniche sulle caratteristiche specifiche di ciascun individuo e sulle modalità peculiari con cui la patologia si manifesta in questo. È il passaggio da un paradigma terapeutico generalista a “taglia unica” (in inglese *one-size-fits-all*) a un'assistenza adattiva, guidata dai dati e realmente personalizzata (Fig. 1).

L'imaging diagnostico occupa una posizione centrale in questa transizione. È ormai ben noto che gli esami radiologici non producano semplicemente immagini, ma generino dati ricchi di informazione. Quando analizzate con metodologie quantitative, le immagini possono svelare firme biologiche della malattia, i cosiddetti “fenotipi”, rilevanti traiettorie evolutive e pattern di risposta terapeutica invisibili all'occhio umano. Questa è l'intuizione fondamentale della *radiomica*: le immagini mediche sono molto più che rappresentazioni visive, sono informazione da usare in maniera strutturata [2].

L'imaging quantitativo in oncologia

In ambito oncologico, i fenotipi derivati dall'imaging possono integrare le informazioni genomiche e contribuire a modellare l'eterogeneità tumorale. I tumori variano non solo tra pazienti diversi, ma

anche all'interno della stessa lesione nel corso del tempo. Le caratteristiche quantitative estratte dalle immagini (forma, tessitura, perfusione, diffusione) catturano aspetti della biologia tumorale altrimenti inaccessibili. Integrate con dati clinici e molecolari, queste *feature* supportano la stratificazione del rischio, orientano la scelta terapeutica e permettono valutazioni oggettive della risposta al trattamento. Realizzare tutto ciò su larga scala può beneficiare largamente dei progressi dell'Intelligenza Artificiale (IA), soprattutto di quelli ottenuti nell'ambito di percezione e visione artificiale e, più recentemente, dei sistemi *agentici* capaci di fornire strumenti lungo l'intero workflow diagnostico. Lo scopo ultimo è quello di realizzare una sorta di “assistente digitale”: un altro membro del team in grado di affiancare i radiologi nel *continuum* dell'imaging diagnostico, nella



Fig. 1 - L'obiettivo della medicina personalizzata







Qualità delle immagini	Sintesi di immagini	Compiti ripetitivi	Scoperta di anomalie	Diagnosi e Prognosi
Recostruzione o eliminazione del rumore, miglioramento qualità → utile in ambienti con risorse limitate 	Sintesi di casi per bilanciare la rappresentatività e rispettare la privacy 	Segmentazione e countouring automatic di zone di interesse 	Individuazione di casi sospetti → molto utile in attività di screening 	Refertazione assistita → biopsia virtuale 

Fig. 2 - Alcuni esempi di come l'intelligenza artificiale può intervenire nel *continuum* diagnostico

lettura, interpretazione di immagini e sintesi referti. I punti di intervento dell'IA sono diversi e si collocano in vari punti del percorso che va dall'acquisizione dell'immagine alla decisione clinica. Li possiamo riassumere come segue (Fig. 2):

- Ricostruzione e qualità dell'immagine: i modelli generativi possono migliorare la ricostruzione delle immagini, ridurre il rumore e aumentare la risoluzione. Diversi strumenti con queste funzionalità hanno già ottenuto l'autorizzazione FDA e sono in uso clinico [3];
- Generazione di dati sintetici: la sintesi di immagini artificiali può ampliare scenari clinici rari, supportare l'assicurazione di qualità e proteggere la privacy dei pazienti. Gli approcci *physics-informed* risultano particolarmente promettenti: ne è esempio la sintesi di risonanza magnetica cardiaca 4D guidata da modelli computazionali del cuore [4];
- Segmentazione automatica: gli algoritmi di segmentazione possono automatizzare compiti estremamente dispendiosi, come nel caso della delineazione di centinaia di sezioni nelle malattie interstiziali polmonari necessaria per stabilire la severità della patologia [5];
- Rilevazione di anomalie: modelli di *detection* possono segnalare aree sospette, come nel caso dell'analisi dei dati di tomosintesi mammaria per l'individuazione di lesioni cancerose, assistendo il radiologo nella lettura e riducendo il rischio di omissioni [6];
- Biopsia virtuale: più a valle nel percorso decisionale, i modelli predittivi possono supportare la sti-

ma non invasiva della probabilità che una lesione sia clinicamente significativa, come ad esempio nel caso del tumore alla prostata individuato in dati di risonanza multiparametrica [7].

Lo stato di adozione

Effettivamente, l'utilizzo di strumenti di IA in radiologia è in crescita. Indagini condotte tra radiologi europei [8] hanno documentato un incremento a doppia cifra nell'uso dichiarato tra il 2023 e il 2024, accompagnato da una marcata riduzione della quota di professionisti che non ne utilizza alcuno. Negli Stati Uniti, dati recenti mostrano una netta espansione dell'IA per documentazione e refertazione, spesso alimentata da grandi modelli linguistici. Da notare, tuttavia, che l'aumento nel supporto decisionale diagnostico procede con maggiore cautela [9].

Il messaggio è coerente: l'interesse è elevato, ma i clinici richiedono solide prove di affidabilità prima di integrare questi strumenti nella pratica quotidiana. La parola chiave è affidabilità, in inglese *trustworthiness*. Gli strumenti di supporto diagnostico devono essere affidabili, trasparenti e sicuri per incidere realmente sulla qualità delle cure.

Perché i sistemi di IA possono fallire

Le ragioni del fallimento dei sistemi di IA in radiologia abbracciano persone, processi e tecnologia. Sul piano tecnico, i modelli possono generalizzare male quando addestrati su dataset monocentrici, esposti a un numero limitato di scanner o proto-




Fig. 3 - I sei principi promossi dalle FUTURE-AI guidelines

colli, oppure sviluppati senza valutazioni standardizzate. Il cosiddetto *data shift*, dovuto a cambiamenti nelle pratiche cliniche, nel mix dei pazienti o negli aggiornamenti dei dispositivi, può degradare le prestazioni nel tempo. L'apprendimento di scorciatoie (in termine tecnico *shortcut learning*) e le correlazioni spurie possono generare successi apparenti in fase di training che crollano in contesti nuovi.

Un framework per l'affidabilità: le linee guida FUTURE-AI

Costruire una IA affidabile richiede un approccio multifattoriale coordinato. Nell'ambito della rete europea AI4Health Imaging, che riunisce diversi progetti di eccellenza, abbiamo sviluppato le linee guida FUTURE-AI [10]: un framework articolato su sei principi fondamentali per garantire l'affidabilità dell'IA in ambito medico. Questi sei principi sono (Fig. 3):

- Fairness (Equità): garantire prestazioni uniformi tra sottogruppi demografici e clinici;
- Universality (Universalità): assicurare applicabilità in contesti clinici eterogenei, anche grazie all'uso di standard;
- Traceability (Tracciabilità): documentare l'intera pipeline di sviluppo, validazione e rilascio;
- Usability (Usabilità): assicurare un'integrazione

naturale ed ergonomica del sistema nei workflow clinici reali;

- Robustness (Robustezza): mantenere prestazioni stabili nonostante variazioni dei dati;
- Explainability (Esplicabilità): fornire per ogni suggerimento, conclusione o predizione un razionale clinicamente significativo e interpretabile.

Per ciascun principio abbiamo formulato raccomandazioni operative concrete, corredate da casi d'uso esemplificativi. A supporto della tracciabilità, abbiamo implementato una libreria open-source in Python per la generazione automatizzata dei cosiddetti *data passport* e *model passport* [11], documenti strutturati che registrano provenienza dei dati, pipeline di preparazione e pre-elaborazione dei dati, strategie di annotazione, architettura del modello, protocolli di training, metriche di valutazione e limitazioni note. Questa documentazione facilita la riproducibilità scientifica, abilita audit tecnici indipendenti e supporta decisioni informate durante il deployment.

Due sfide tecniche prioritarie sul fronte della robustezza

Due filoni tecnici meritano enfasi: la riduzione degli errori dovuti alle cosiddette correlazioni spurie e garantire una maggiore consapevolezza del possibile fallimento dei modelli a causa di diverse fonti di incertezza.




Fig. 4 - Un'illustrazione dell'intuizione dietro l'inferenza causale spaziale. Nella scena, è la presenza del ponte a causare la presenza della macchina in quella posizione e questa relazione causale si verifica con due esempi controfattuali, di fatto considerare esempi controfattuali è il procedimento tipico per la scoperta di relazioni causali, se infatti rimuoviamo la macchina, la scena continua ad avere senso, quindi è possibile trovare immagini che abbiano un ponte in quella posizione senza una macchina, mentre se rimuoviamo il ponte, la scena non ha più senso quindi è difficile trovare immagini che abbiamo la macchina in quella posizione senza il ponte

Mitigazione delle correlazioni spurie

I sistemi di AI basati sull'apprendimento identificano pattern statistici predittivi degli esiti clinici. Tuttavia, non tutte le associazioni riflettono relazioni causali genuine: molte costituiscono “scorciatoie” che funzionano esclusivamente nel contesto del dataset di training. Un esempio paradigmatico è la correlazione tra vendite di gelati e attacchi di squali: entrambe le variabili aumentano in estate, ma sono mediate da un confondente comune (la temperatura) senza alcun nesso causale diretto. Nell'imaging medico, le scorciatoie emergono quando caratteristiche tecniche - modello di scanner, protocolli di acquisizione, artefatti istituzionali - correlano artificialmente con le etichette diagnostiche. Un modello può “aggrapparsi” a questi indizi superficiali anziché apprendere le vere caratteristiche meccanicistiche della patologia, compromettendo così la generalizzabilità della soluzione finale.

In questo contesto, abbiamo sviluppato un approccio che rende i modelli profondi più sensibili ai segnali causali, attingendo a tecniche di inferenza causale osservazionale. Le reti neurali convolutive (CNN) apprendono mappe di feature che eviden-

ziano strutture rilevanti per il compito specifico. Se queste mappe sono non negative e normalizzate, possono essere interpretate come probabilità spaziali della presenza di una caratteristica. Stimando relazioni condizionali tra coppie di mappe, deriviamo una “mappa di causalità” che cattura influenze disposizionali tra pattern. L'intuizione è semplice: se rimuovere il pattern A tende a eliminare il pattern B (ma non viceversa), A è più probabilmente causa di B nel contesto osservato [12].

Integrando queste mappe di causalità in architetture CNN standard, la rete considera non solo quali *feature* sono presenti, ma anche come tendono a influenzarsi reciprocamente, orientando l'apprendimento verso relazioni stabili anziché scorciatoie fragili. Nei nostri esperimenti su *grading* istologico mammario e valutazione della significatività clinica in risonanza magnetica prostatica, questo approccio ha migliorato consistentemente le prestazioni rispetto ai modelli di base (Fig. 4) [13].

Quantificazione dell'incertezza predittiva

Il secondo pilastro tecnico riguarda lo sviluppo di modelli “consapevoli del proprio fallimento” at-

traverso metodi robusti di stima dell'incertezza [14]. Tutti i sistemi predittivi commettono errori. Distinguiamo due tipologie principali: (i) incertezza aleatoria, che riflette la stocasticità intrinseca delle osservazioni sul fenomeno che stiamo considerando, giacché i dati campionati non costituiscono una perfetta rappresentazione della realtà, ma sono contaminati da rumore e casualità, e (ii) incertezza epistemica, che riflette la variabilità dovuta alla mancanza di una conoscenza completa del problema, il che consiste nel non avere abbastanza dati che raccontino al meglio la variabilità del fenomeno che siamo analizzando. Purtroppo solo la seconda è riducibile con più dati. In ambito medico è cruciale comunicare quando e perché il modello può sbagliare. Esistono diversi approcci per modellare i vari tipi di incertezza e renderli evidenti. Si possono raggruppare in metodi intrusivi, molto accurati ma complessi, integrano il quadro probabilistico nell'architettura; semi-intrusivi, come gli ensemble che assicurano un buon equilibrio tra precisione ed efficienza, e non-intrusivi o post-hoc, come il Monte Carlo Dropout, più semplici, meno accurati, ma applicabili a modelli già addestrati [15].

A livello del risultato prodotto, l'incertezza dovrebbe affiancare i suggerimenti forniti da un modello di IA, ad esempio, un punteggio di malignità con confidenza calibrata o un flag "segnala all'umano", quando l'incertezza supera una soglia critica. A livello di sistema, l'incertezza può attivare salvaguardie automatiche: utilizzo sempre come "second read", acquisizione di sequenze aggiuntive o protocolli alternativi.

Prospettive

L'intelligenza artificiale sta ridefinendo i confini della radiologia, trasformando le immagini da rappresentazioni visive a sorgenti di dati quantitativi ad alta dimensionalità. Perché questa trasformazione si traduca in benefici clinici tangibili, l'affidabilità deve essere costruita sistematicamente, dalla progettazione del modello alla documentazione, dalla validazione al monitoraggio post-deployment. I principi FUTURE-AI e gli avanzamenti nella mitigazione delle correlazioni spurie e nella quantificazione dell'incertezza rappresentano passi concreti verso una radiologia aumentata dall'IA che sia al contempo potente e degna di fiducia.

BIBLIOGRAFIA

- [1] L.H. Goetz, N.J. Schork, *Fertil Steril.*, 2018, **109** (6), 952.
- [2] R.J. Gillies, P.E. Kinahan *et al.*, *Radiology*, 2016, **278**(2), 563.
- [3] G. Bonardel, A. Dupont *et al.* *EJNMMI Phys.*, 2022, **9**, 36.
- [4] G. Del Corso, C. Caudai, *et al.*, *International Conference on Image Analysis and Processing*, 2025, 381.
- [5] R. Buongiorno, G. Del Corso *et al.*, *Journal of Imaging*, 2023, **9**(12), 283.
- [6] A. Berti, C. Scapicchio *et al.*, *Computational and Structural Biotechnology Journal*, 2025, **27**, 2649.
- [7] E. Pachetti, S. Colantonio, *Bioengineering*, 2023, **10**(9), 1015.
- [8] M. Zanardo, J.J. Visser *et al.*, *Insights Imaging*, 2024, **15**, 240.
- [9] American Medical Association's, Physician Survey on Augmented Intelligence, 2026, <https://www.ama-assn.org/system/files/physician-ai-sentiment-report.pdf>
- [10] K. Lekadir, A. Frangi *et al.*, *bmj*, 2025, 388.
- [11] V. Kalokyri, N. Tachos *et al.*, *Computational and Structural Biotechnology Journal*, 2025, **28**, 386.
- [12] D. Lopez-Paz, R. Nishihara *et al.*, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017, 6979.
- [13] G. Carloni, S. Colantonio, *Expert Systems with Applications*, 2024, **249**, 123433.
- [14] G. Del Corso, S. Colantonio *et al.*, *Journal of the Franklin Institute*, 2025, **362**(3), 107548.
- [15] G. Del Corso, M.A. Pascali *et al.*, *Computational and Structural Biotechnology Journal*, 2024, **24**, 603.

Artificial Intelligence and Medical Imaging: a Powerful Combination for Precision Medicine

Artificial Intelligence is a key tool in radiology for enabling the transition toward precision medicine. Ensuring its effective adoption requires adherence to principles such as transparency, fairness, and robustness. Mitigating shortcut learning (spurious correlations) and quantifying predictive uncertainty are crucial steps in developing reliable and secure systems.