



OSPEDALE POLICLINICO SAN MARTINO
Sistema Sanitario Regione Liguria
Istituto di Ricovero e Cura a Carattere Scientifico

open data in biomedicina: opportunità e rischi nell'era dell'intelligenza artificiale

michele piana

dipartimento di matematica, università di genova

osservatorio astrofisico di torino, istituto nazionale di astrofisica

ospedale policlinico san martino IRCCS genova

genOAweek 2025 - etica e governance dei dati biomedicali nell'era dell'AI

18 novembre 2025

introduzione

chi sono

- laurea e dottorato in fisica a UNIGE
- post-doc, department of mathematical sciences, university of delaware
- professore associato, università di verona
- professore ordinario @UNIGE
- co-fondatore e coordinatore di MIDA @UNIGE (<https://mida.unige.it>)
- co-fondatore di LISCOMP @UNIGE e @HSM
- temi di ricerca: metodi computazionali per l'analisi dati in biomedicina e fisica solare

MIDA in un guscio di noce

anna maria massone

HELCOMP



centro eliofisico
altec, OATo, POLITO

federico benvenuto

M3

cristina campi

LISCOMP



federico benvenuto

LISCOMPTECH
gaslini

MIDA
methods for image
and data analysis



andrea tacchino



life science computational lab (LISCOMP)

- iniziativa congiunta tra università di genova e il policlinico san martino (2021)
- laboratorio di ricerca e innovazione per la modellizzazione matematica e l'analisi computazionale di dati biomedicali
- facility di scienziati computazionali e di risorse di calcolo a disposizione di medici e biologi all'interno dell'ospedale


DATAunit

- T1: data collection
- T2: data infrastructure
- T3: data protection



M2unit

- T1: computational imaging
- T2: systems biology and medicine
- T3: computational genomics
- T4: biostatistics

SOFTunit



metodi e scale @LISCOMP

attività	scala	matematica
pipeline genomiche		machine learning ottimizzazione
modelli in-silico di proteomica		sistemi dinamici optimization
serie temporali in neurofisiologia		problemi inversi statistica avanzata
organoidi per malattie degenerative		machine learning pattern recognition
biomarkers in imaging medico		machine learning problemi inversi elaborazione di immagini
radiomic/radiogenomica		elaborazione di immagini pattern recognition machine learning

analisi dati: molte scale, molti modi

scala DNA: aberrazioni della struttura genomica


le aberrazioni di copy number sono variazioni strutturali del genoma dove pezzi di DNA sono acquisiti oppure cancellati

Article | Published: 24 March 2021

Breast tumours maintain diversity during expansion

Darlan C. Minussi, Michael D. Nicholson, Tarabichi, Emi Sei, Haowei Du, Mashiat R Schalck, Asha Multani, Jin Ma, Thomas C Lim, Banu Arun, Funda Meric-Bernstam,



Nature 592, 302–308 (2021) | Cite this




Signatures of copy number variation in cancer

Christopher D. Steele, Ammal Abbasi, S. M. Ashiqul Haase, Shadi Hames-Fathi, Dolapo Ajayi, Annelien Lechner, Nicholas Light, Adam Shlien, David Malki Fredrik Mertens, Adrienne M. Flanagan, Maxime T Nischal Pillay

Nature 606, 984–991 (2022) | Cite this article



scala proteine: network di reazioni chimiche nel cancro



$$\begin{cases} \dot{\mathbf{x}}(\tau) = \mathbf{S} \mathbf{v}(\mathbf{x}(\tau), \mathbf{k}) \\ \mathbf{x}(0) = \mathbf{x}_0 \end{cases}$$





1. LLM per la generazione delle reti di reazioni

2. algoritmo per la generazione di sistemi dinamici

3. metodo di ottimizzazione per il calcolo degli equilibri

4. validazione con dati sperimentali

scala cellula: connettività





$$j = j_p + j_s \quad j_s = \sigma e$$

$$\nabla \times e = 0 \Rightarrow j_s = -\sigma \nabla v$$


$$\nabla \cdot j = 0 \Rightarrow \nabla \cdot j_p = \nabla \cdot (\sigma \nabla V)$$

$$\frac{\partial e}{\partial t} = 0, \frac{\partial b}{\partial t} = 0$$

$$b(r, t) = \frac{\mu_0}{4\pi} \int_{\Omega} j(r', t) \times \frac{r - r'}{|r - r'|^3} dr'$$








(a) Network Segregation





(b) Network Integration




scala organidi: gemelli bio-digitali



scala organi: biomarker da immagini





dalla scala organi alla scala DNA: modelli murini di glioblastoma



4 gruppi:

- controlli
- tre approcci terapeutici



l'obiettivo è quello di individuare possibili correlazioni tra le proprietà delle immagini, le caratteristiche genetiche del tumore e l'efficacia della terapia

alcune questioni delicate (secondo me)

la questione dei big data

*"information consumes the attention of its recipients.
hence a wealth of information creates a poverty of attention
and a need to allocate that attention efficiently
among the overabundance of information sources that might consume it"
(herbert simon, premio nobel per l'economia)*

la questione dei big data è a volte fuorviante

a contare davvero sono

- la qualità
- la comprensione
- l'interpretazione
- lo sfruttamento dei dati



la scienza dei dati è multi-forme e comprende

- simulazione
- teoria dei problemi inversi
- pattern recognition
- machine/deep learning

dati: quantità e qualità

- chat-GPT funziona benissimo perché internet è un archivio letteralmente impareggiabile di pdf
- chat-GPT riesce a generare immagini perché internet è un archivio letteralmente impareggiabile di immagini di buona qualità
- ma non è così in tutte le applicazioni:
 - ✓ i dati possono essere intrinsecamente pochi
 - ✓ i dati possono essere di scarsa qualità


la questione dei dati: due esempi




radiomica per la prognosi del mieloma multiplo

analisi di copy number

la questione energetica: cosa è una rete neurale



$$y=ax+b$$



$$y=mx^2+bx+c$$

una rete neurale è una funzione con molti parametri

nella fase di addestramento i parametri vanno calcolati in modo da

- descrivere un archivio storico molto grande di cui si possiede un'informazione completa
- stimare probabilisticamente l'informazione mancante in corrispondenza di nuovi dati


però:

- se ogni dato dell'archivio ha molte dimensioni (per esempio: immagini) i parametri da ottimizzare sono molti: reti profonde
- l'addestramento richiede la soluzione di un problema di minimo complesso

$$\min_w L(\theta(w, x), y) + R(w)$$

- il costo computazionale della fase di addestramento è grande

la questione energetica: high performance computing (HPC)



- la parola è uno strumento che trasmette il pensiero e la conoscenza
- la penna è uno strumento che infrange i limiti locali e temporali della comunicazione e permette l'accumulazione della conoscenza
- il computer è uno strumento che ci permette di risolvere problemi prima irrisolvibili
- non confondiamo l'aumentare della capacità di calcolo con l'aumentare della conoscenza matematica: l'AI si basa su matematica classica

**“Considerate la vostra semenza:
fatti non foste a viver come bruti,
ma per seguir virtute e canoscenza”**
(Dante, XXVI - 118-120)

e comunque non va dimenticato l'enorme consumo di corrente...

la questione del software

linguaggi di programmazione:

- python
- R
- matlab
- C (e derivati)


frameworks per deep learning:

- scikit_learn
- PyTorch
- TensorFlow
- Keras
- Theano
- Caffe
- DL4J
- CHAINER
- CNTK

anche l'open source pone domande difficili:

- chi è il padrone del software che realizza una soluzione AI?
- come si brevetta un software AI?
- è una buona idea brevettare un software AI?
- come si affronta la questione 'medical device'?

dati e software: nuove tendenze




transfer learning:

- una rete neurale è addestrata per un certo compito utilizzando un archivio storico adeguato
- la rete neurale ottimizzata viene messa in rete
- nel caso di un compito simile a quello per cui è stata addestrata, la rete neurale viene scaricata e addestrata con i dati relativi al nuovo compito
- modelli fondazionali: transfer learning estremizzato

federated learning:

- ogni nodo periferico ha a disposizione una copia pre-addestrata di una rete neurale, messa a disposizione dal noto centrale
- ogni nodo periferico addestra la propria copia con i propri dati
- i parametri ottimizzati da ogni nodo periferico sono trasferiti al nodo centrale che li utilizza per migliorare l'ottimizzazione della prima copia
- la rete neurale aggiornata è messa a disposizione dei nodi periferici

la questione giuridica: europa vs USA



- 1-2/10/2020: il consiglio europeo approva la strategia sull'intelligenza artificiale
- 21/04/2021: la commissione europea propone un regolamento sull'AI
- 6/12/2022: il consiglio europeo approva la propria posizione sul progetto di regolamento
- 9/12/2023: consiglio e parlamento europeo raggiungono un accordo
- 21/5/2024: il consiglio europeo approva definitivamente al regolamento
- 1/8/2024: entra in vigore il regolamento sull'AI (ma con due anni di embargo)



nel frattempo, in USA:

- 2018: prima release di alphaphold
 - 2020: seconda release di alphaphold
- 2022: pubblicazione di un database di 200 milioni di proteine prodotte da alphaphold
Settembre 2022: prima release di chat-GPT
2023: chat-GPT plus
2024: versione di alphaphold che comprende proteine, DNA, RNA, e ligandi
Settembre 2024: chat-GPT omni
Dicembre 2024: i premi nobel per la fisica a due americani “per scoperte rivoluzionarie nell’ambito” dell’AI
Dicembre 2024: i premi nobel per la fisica a tre americani per alphaphold

gli USA non hanno un AI-act

la questione della conoscenza



- 1450: invenzione della stampa
- 1500: almeno 9 milioni di libri in europa

- la stampa trasmette nuova conoscenza
- la stampa ispira nuova conoscenza che verrà generata dall'intelligenza naturale
- l'AI al momento connette vecchia conoscenza con un'originalità mai vista prima

ma la domanda è:

I'AI è in grado di generare nuova conoscenza in modo autonomo?

nota bene:

- alphazero gioca a scacchi in modo completamente eccentrico rispetto all'umano e con risultati migliori. **ma alphazero non inventa un nuovo gioco con nuove regole**
- alphafold genera nuove proteine la cui struttura l'umano non è stato in grado di scoprire. **ma alphafold non genera un modello generale che spiega perché le mutazioni generano proteine in modo sbagliato**

conclusioni (sempre secondo me)

una questione culturale...

- la scienza dei dati non è solo chat-GPT
- l'AI non è solo chat-GPT
- machine learning, problemi inversi, simulazione, pattern recognition sono solo cacciaviti: l'obiettivo rimane capire e riparare il motore
- c'è un bisogno urgente di laboratori interdisciplinari dove studiare tutti gli aspetti relativi alla scienza dei dati
- c'è un bisogno ancora più urgente di programmi formativi completamente nuovi, genuinamente interdisciplinari, e orientati ai problemi

“non esistono le discipline; esistono solo i problemi e i metodi per risolverli”
(k. popper)



il cervello di churchill
funzionava come il
machine learning



il cervello di un
bimbo funziona con
la simulazione



il cervello di un esploratore
funziona con il
pattern recognition




il cervello di sherlock
holmes risolve
problemi inversi

...e un po' di ansietà

<i>Breast cancer stage</i>	<i>Localized</i>	<i>Regional</i>	<i>Distant</i>
% of people with this stage of cancer at diagnosis	61%	32%	6%
5-year relative survival rate	99%	85%	26%
<i>Colorectal cancer stage</i>	<i>Localized</i>	<i>Regional</i>	<i>Distant</i>
% of people with this stage of cancer at diagnosis	39%	36%	20%
5-year relative survival rate	90%	71%	13%

miglioramento della sopravvivenza
grazie alla chemoterapia



miglioramento della sopravvivenza
grazie alle terapie cellulari

a quando un miglioramento
della sopravvivenza
guidato dalla matematica?