

Progetto Background DeepTech

COS'È L'INTELLIGENZA ARTIFICIALE

L'evoluzione dell'Intelligenza Artificiale dalle origini ai giorni nostri

Cassino 17 Febbraio 2026



Claudio De Stefano

Cos' l'intelligenza? Come posso definirla?

La definizione di intelligenza umana è un tema molto dibattuto tra gli studiosi e non esiste una definizione univoca e universalmente accettata. Le definizioni più comunemente utilizzate:

- Complesso di facoltà psichiche e mentali che consentono all'uomo di pensare, comprendere o spiegare i fatti o le azioni, elaborare modelli astratti della realtà, intendere e farsi intendere dagli altri, giudicare, e lo rendono insieme capace di adattarsi a situazioni nuove e di modificare la situazione stessa quando questa presenta ostacoli all'adattamento;
- Propria dell'uomo, in cui si sviluppa gradualmente a partire dall'infanzia e in cui è accompagnata dalla consapevolezza e dall'autoconsapevolezza, è riconosciuta anche, entro certi limiti (memoria associativa, capacità di reagire a stimoli interni ed esterni, di comunicare in modo anche complesso, ecc.), agli animali.

(Da: "Enciclopedia Treccani, voce Intelligenza")

- Il neuroscienziato Daniel Goleman afferma che l'intelligenza umana è "la capacità di comprendere se stessi e gli altri, e di utilizzare questa comprensione per prendere decisioni efficaci".

Ma cos'è l'intelligenza artificiale?

L'intelligenza artificiale è "un settore di ricerca dedicato al sviluppo di sistemi in grado di generare output quali contenuti, previsioni, raccomandazioni o decisioni per un dato insieme di obiettivi definiti dall'uomo.

L'intelligenza artificiale è una disciplina appartenente all'informatica che studia i fondamenti teorici, le metodologie e le tecniche che consentono la progettazione di sistemi hardware/software capaci di fornire prestazioni tipiche dell'intelligenza umana.

In particolare l'Intelligenza Artificiale generativa:



- a. riceve un "input" che non comprende;
- b. lo confronta con una base di dati di addestramento che non capisce;
- c. produce un "output" che ritiene essere coerente con l'input e con quanto trova nella base di addestramento, ma senza comprenderlo

In altre parole...l'intelligenza artificiale non è intelligente, è "plausibile"

Alan Turing e il "Gioco dell'Imitazione".

Nel 1950, Alan Turing si pose la seguente domanda:
"le macchine possono pensare?" e "comportarsi come un essere umano?"
Per rispondere a questo quesito propose un **test**

Abbiamo tre protagonisti: un uomo, una macchina e un interrogante che, in una stanza separata, deve determinare quale sia l'uomo e quale la macchina.



Test di Turing e AI

Il computer dovrebbe avere le seguenti capacità:

- Elaborazione del linguaggio naturale;
- Rappresentazione della conoscenza;
- Ragionamento automatico;
- Apprendimento automatico;

Oltre il Test di Turing: Total Turing Test - Interazioni fisiche: Robotica, Visione artificiale, Parlato, Movimento, ecc.

Nel 2014, un chatbot (Eugene Goostman), imitando le risposte di un tredicenne, pare abbia superato il test.

Programmi derivati di Eliza, programma scritto nel 1966 da Joseph Weizenbaum.

Altribot/assistenti vocali: Cleverbot (Machine Intelligence Prize 2010), SIRI (Apple), Cortana (Microsoft), Alexa (Amazon) ecc.

Spesso costruiti indicizzando conversazioni già memorizzate in altri colloqui. Hanno una valenza metodologica. Emulazione più che simulazione dell'intelligenza in domini limitati.

Intelligenza Artificiale: Tesi Debole e Tesi Forte

AI debole:

- E' possibile costruire macchine in modo che agiscano come se fossero intelligenti?
- Si : è l'attuale intelligenza artificiale, capace di simulare specifiche funzionalità umane

AI forte:

- E` possibile costruire macchine che pensino intelligentemente? (che abbiano menti coscienti reali?, che abbiano volontà, sentimenti?)
- Solleva alcuni tra i problemi concettuali più difficili di tutta la filosofia e connessi alla capacità di essere consapevoli e responsabili.
- Ancora NO. La comunità scientifica attualmente non ha una posizione chiara e univoca sul SE e QUANDO l'AI Forte sarà realizzata

La previsione di Turing

I believe that in about fifty years' time it will be possible to programme computers, with a storage capacity of about 10^9 , to make them play the imitation game so well that an average interrogator will not have more than 70 percent chance of making the right identification after five minutes of questioning. ... I believe that at the end of the century the use of words and general educated opinion will have altered so much that one will be able to speak of machines thinking without expecting to be contradicted.

Da: A. Turing, "A Computing machinery and intelligence", Mind, vol. 59, n. 236, pp. 433-460, 1950.

E' così oggi? ... Oppure Turing rimarrebbe deluso?

Perché l'intelligenza artificiale si chiama così?

Per caso in una conferenza:

Il termine *intelligenza artificiale* è stato coniato per la prima volta nel 1956 dal computer scientist John McCarthy, durante una conferenza alla Dartmouth University.

McCarthy voleva creare un campo di ricerca che si concentrasse sullo sviluppo di macchine in grado di simulare l'intelligenza umana.

Alcuni colleghi di McCarthy ritenevano abnorme il nome:


John McCarthy però ebbe la meglio in quanto il nome “intelligenza artificiale” per questo nuovo ambito della ricerca informatica venne ritenuto più “attraente” e più adatto ad attrarre i fondi per la ricerca.



1943



First mathematical model of a neuron.




$$\Phi(x) = \begin{cases} 1 & \text{if } x \geq \theta \\ -1 & \text{otherwise} \end{cases}$$

Electronic Brain by McCulloch & Pitts

1950



Turing test is proposed.



Turing Test by Alan Turing

1956

The conference that started it all.




Dartmouth Summer Research Project organized by John McCarthy

1957



Weights automatically learned.



$$y = \sum_{j=1}^d w_j x_j + w_0 = \mathbf{w}^T \mathbf{x}$$

Perceptron by Frank Rosenblatt

1965



The term Fuzzy Logic is introduced.




Fuzzy Logic by Lotfi Zadeh

1969



Perceptron cannot learn XOR.



XOR Problem by Minsky & Papert

1972



One of the first logic programming languages.


```
animal(X) :- cat(X).
```

PROLOG by Colmerauer & Kowalski

1979




The first convolutional neural network (CNN).



Neocognitron by Kunihiko Fukushima

1986




Backpropagation is popularized.

Backpropagation in MLP by Rumelhart, Hinton, Williams

1989



Convolutional neural networks (CNN) used for recognizing handwriting.



LeNet by Yann LeCun

1995

NIST

MNIST is born.



MNIST by NIST

2009



ImageNet, a large-scale image dataset is introduced.


IMAGENET

ImageNet by Fei-Fei Li

2012



First significant results in deep learning.



AlexNet by Krizhevsky & Hinton

2014



Generative Adversarial Network (GAN) introduced.




GAN by Ian Goodfellow

2013



Word embeddings become popular.



Word2Vec by Tomas Mikolov

2017

Google

Transformer network is introduced, paving the way for pretrained language models.

Attention Is All You Need

Transformer by Google Brain, Research



21 Aprile 2021

Proposal for a Regulation laying down harmonised rules on artificial intelligence

The Commission is proposing the first ever legal framework on AI, which addresses the risks of AI and positions Europe to play a leading role globally.

<https://digital-strategy.ec.europa.eu/en/library/proposal-regulation-laying-down-harmonised-rules-artificial-intelligence>

21 Maggio 2024

Il Parlamento Europeo approva definitivamente l'AI Act

Classificazione dei sistemi di AI in base al livello di rischio che presentano per le persone e per la società:

- Unacceptable risk
- High risk
- Limited risk
- Minimal Risk

<https://www.agendadigitale.eu/cultura-digitale/ai-act-ci-siamo-ecco-come-plasmera-il-futuro-dellintelligenza-artificiale-in-europa/>

AI: due approcci

Approccio top-down, o simbolico: ad alto livello, indipendente dal livello sottostante (computer o cervello), funzionale o comportamentista.

- Stati mentali identificati con rappresentazioni di tipo simbolico;
- Un sistema simbolico fisico, secondo Newell e Simon (1976), è un insieme di simboli che possono essere combinati in strutture simboliche complesse e trasformabili.
- Sistemi di logica, ontologie, sistemi a regole, architetture dichiarative.
- Esempio: una circonferenza è descritta in base alle sue proprietà matematiche (dichiarativa), oppure mediante un metodo per disegnarla col compasso (procedurale)

Approccio bottom up, o connessionista, di più basso livello, strutturale o costruttivista. Ci sono cose che il ragionamento formale non è in grado di cogliere (percezione, immagini, pixel, sensi, ambiente).


- Reti di neuroni artificiali. La conoscenza si accumula implicitamente nelle connessioni fra i neuroni.
- Concetto di circonferenza appreso in modo implicito a partire da esempi.
- Algoritmi genetici

Approccio top-down - Il ragionamento e la Logica:

- **Ragionamento deduttivo** (sillogismo aristotelico – logica deduttiva):
 - Da: *Tutti gli uomini sono mortali* e *Socrate è un uomo* allora: *Socrate è mortale*
 - Corretto, ma non ci consente di “imparare” nuova conoscenza.
- **Ragionamento induttivo** (apprendimento, deduzione inversa)
 - Dall’osservazione di *svariati uccelli che volano* allora *Tutti gli uccelli volano* (e i pinguini?).
 - Produzione di conoscenza “nuova”, a scapito della correttezza.
- **Ragionamento ipotetico o abduttivo** (duale del deduttivo):
 - Dall’osservazione della *morte di Socrate* e sapendo che *Tutti gli uomini sono mortali* ipotizza che *Socrate è un uomo*. (e se fosse un gatto?).
 - Risale alle cause mediante l’osservazione degli effetti a scapito della correttezza.
- **Ragionamento per analogia** (metaforico, case-based)
 - Non richiede un modello o molti dati, ma utilizza il principio di somiglianza. *Socrate e Giovanni si “assomigliano”* e *Socrate ama la filosofia* allora: *Giovanni ama la filosofia*.
 - K-Nearest-Neighbor e Support Vector Machine (SVM).
- Utilizzo di vincoli, probabilità, statistica (teorema di Bayes)

Sistemi a regole e di supporto alle decisioni (Sistemi Esperti -1980)

- Un sistema basato sulla conoscenza (o sistema esperto) è un sistema in grado di risolvere problemi in un dominio limitato ma con prestazioni simili a quelle di un esperto umano del dominio stesso.
- Esamina un gran numero di possibilità e costruisce dinamicamente una soluzione, opportunamente valutata e poi scelta o scartata.
- La ricerca e/o generazione delle soluzioni e' guidata da Regole.



Esempio di Sistema basato su regole

Semplicissimo problema di diagnostica.

OBIETTIVO: prescrivere una medicina adeguata per un determinato paziente in base ai risultati di alcuni esami di laboratorio: **prescribe (Drug)** .

BASE di CONOSCENZA

Fatti:

gram (neg) .

not (allergic (antb)) .

Regole:

R1: gram (neg) → id (ecoli) .

Se il risultato dell'esame è *gram-negativo* allora l'identità è *enterium-coli*

R2: gram (pos) → id (strep) .

Se il risultato dell'esame è *gram-positivo* allora l'identità è *streptococco*

R3: id (strep) OR id (bact) → ind (pen) .

Se l'identità è streptococco o bactero allora è bene indicare penicillina

R4: ind (X) AND not (allergic (X)) → prescribe (X)

Se è bene indicare una certa medicina e il paziente non è allergico a tale medicina, allora si può prescrivere tale medicina al paziente

R5: id (ecoli) → ind (antb) .

Se l'identità è *enterium-coli* allora è bene indicare antibiotici

Un esempio molto noto di sistema a regole : Mycin

Creato a metà degli anni 70, Maycin è stato uno dei primi Sistemi Esperti in campo medico, applicato nell'aiutare i dottori nella prescrizione di terapie antibiotiche nel caso di infezioni.



RULE037

IF the organism

- 1) stains grampos**
- 2) has coccus shape**
- 3) grows in chains**

THEN

**There is suggestive evidence
(.7) that the identity of the organism is
streptococcus.**

Towards Explicit Integration of Knowledge in Expert Systems: An Analysis of MYCIN's
Therapy Selection Algorithm, Bill Swartout, Jack Mostow, AAAI-86 ,1986.


Il modello ad Agente Artificiale Intelligente

Risoluzione di Problemi Mediante Ricerca nello spazio degli stati

Elementi di un problema semplice:


- Insieme di **stati** del mondo (ambiente) semplificato
- Insieme di **operatori** (o azioni) possibili
- Uno **stato iniziale**
- Uno o più **stati obiettivo** (goal)

*Trovare una sequenza di azioni che trasforma lo stato iniziale in uno stato obiettivo
(algoritmo o motore di ricerca)*



Un esempio


Esempio: “Rompicapo dell’8”



Stati = configurazione delle caselle

Operatori = muovere caselle in alto,basso,sinistra,destra
(oppure muovere casella vuota)

Esempio Albero di Ricerca



Il problema della Conoscenza

“La potenza di un programma intelligente nel risolvere un problema dipende primariamente dalla quantità e qualità di conoscenza che possiede su tale problema”. (Feigenbaum)

Varie applicazioni: Pianificazione, Previsione, Diagnosi, Progetto.

Acquisizione della Conoscenza (collo di Bottiglia dei Sistemi Esperti)

Problemi

- L'esperto nella sua “creatività” e “competenza” non può essere sostituito, ma coadiuvato (soprattutto nelle parti più lunghe e ripetitive).
- Fonti diverse, parziali e non sempre concordi (diversi punti di vista)
- La conoscenza evolve (nuove versioni dei documenti di riferimento)
- La conoscenza non è sempre manifesta ed esplicita (discovery)
- La conoscenza è spesso legata alla singola realtà, non ha solo regole generali ma lavora per analogia e casi simili (spesso nel caso di sistemi legali)

Soluzione



Tecniche di apprendimento automatico e data-mining (approccio *bottom up*)

Approccio bottom up: Apprendimento e data-mining

Imparare dall'esperienza, dai propri sbagli, dagli insegnanti, da altri esseri umani, dall'ambiente è una capacità peculiare e sostanziale dell'intelligenza.

- Approccio empirista (che si oppone all'approccio razionalista).
- Sviluppo di *algoritmi di apprendimento* ("*machine learning*"): una delle aree di ricerca più feconde della moderna IA.
- Nell'epoca dei *big data* e grazie all'enorme potenza di calcolo, gli algoritmi di apprendimento sono diventati sempre più importanti per cercare di dominare la complessità dell'informazione ed "estrarre" conoscenza.
- Apprendimento basato sul metodo induttivo, compromesso fra generalizzazione (non correttezza) e eccessiva specializzazione (*overfitting*).
- Sviluppo di algoritmi di apprendimento che si basano sull'emulazione dei sistemi biologici:
 - Intelligenza collettiva (*ant colonies, swarm intelligence, ecc.*)
 - Algoritmi genetici/evolutivi;
 - Reti neurali;

Approccio bottom up: Intelligenza Collettiva

La natura ha sviluppato tecniche intelligenti per:

- la difesa dell'organismo, la selezione della specie per adattarsi all'ambiente (*Algoritmi Genetici*)
- la coordinazione tra animali sociali (le termiti costruiscono termitai senza un progetto, le formiche muovono oggetti grandi senza un coordinatore, ecc.) (*Swarm Intelligence*)

Chi è a governare? Chi è che dà ordini, che immagina cosa accadrà in futuro, elabora piani e mantiene l'equilibrio?

- Questi comportamenti emergono autonomamente, senza la presenza di un coordinatore/supervisore.
- Lo studio (interdisciplinare) di questi fenomeni ha permesso di sviluppare sistemi intelligenti basati su modelli robusti e adattativi di fenomeni e processi naturali.



Approccio bottom up: Algoritmi Genetici/Evolutivi

Gli algoritmi genetici (e la computazione evolutiva in generale) traggono ispirazione dalla teoria dell'evoluzione naturale e sono stati sviluppati da John Holland negli anni '70.

- Una nuova “creazione” può essere generata partendo da una configurazione iniziale random, evolvendosi in base a leggi “naturalì”.
- Fitness: assicura che vengano scelte per la riduzione le soluzioni “migliori” (fa le veci di un “critico” d’arte).
- Mutazione: assicura l’introduzione di elementi di novità.
- La riproduzione garantisce la combinazione di buone soluzioni genitrici.
- Problema: non sempre la fitness è chiaramente definibile. Può essere interattiva e chiesta all’utente in alcuni casi.
- Utili quando non è possibile o non è semplice la modellazione del problema da risolvere.





Approccio bottom up: Reti neurali

L'idea di base è quella di simulare il funzionamento del cervello, ovvero costruire una macchina intelligente a partire da neuroni artificiali.

Il primo modello matematico di neurone artificiale ispirato ai neuroni biologici fu proposto nel 1943 da McCulloch e Pitts. Un neurone riceve un insieme di ingressi, ne fa una somma pesata ed applica poi una funzione di attivazione a soglia binaria per calcolare l'uscita: ogni neurone si attiva soltanto quando il proprio ingresso supera una certa soglia.

Nel 1958, Rosenblatt propose il “percettrone”, un neurone artificiale a soglia a singola uscita. I pesi delle connessioni potevano essere modificati iterativamente da un algoritmo di apprendimento per minimizzare l'errore.




Approccio bottom up: Reti neurali

Questi modelli sono molto limitati potendo rappresentare solo concetti nei quali gli esempi sono linearmente separabili.

Per rappresentare concetti più complessi si costruirono allora reti di neuroni, architetture multistrato (ad esempio le reti “in avanti” o “feed-forward”) e furono sviluppati nuovi algoritmi di apprendimento.

Questo approccio è significativamente diverso da quello simbolico: la conoscenza non è esplicita ma insita nella struttura della rete e nei pesi delle connessioni.



Reti neurali: potenza e limiti

- Il perceptrone può rappresentare solo funzioni lineari. Se però si considerano reti multi-strato, il potere espressivo aumenta notevolmente.
- Teorema di approssimazione universale: *Una rete feed-forward con uno strato nascosto e un finito numero di neuroni può approssimare con la desiderata precisione qualsiasi funzione continua.*
- Teoricamente interessante, ma non dice nulla sulle modalità di configurazione della rete neurale né su come applicare gli algoritmi di apprendimento per ottenere una buona approssimazione. Quali funzioni di uscita? Quanti neuroni? Quanti strati?
- Dagli anni 80 ad oggi sono stati sviluppati modelli sempre più dettagliati e complessi per i neuroni artificiali, sono state utilizzate funzioni, non lineari, diverse da quella a soglia (esempio la sigmoide), sono state identificate svariate architetture e modalità di connessione in rete, e sono stati sviluppati algoritmi di apprendimento sempre più sofisticati per modificare i pesi delle connessioni

Intelligenza Artificiale: Machine Learning

Apprendimento supervisionato:


- Si parte da un insieme di esempi (“training set”).
- Risolve principalmente problemi di classificazione (pattern recognition).

Apprendimento non supervisionato (Clustering) :

- Mediante osservazione e scoperta.
- Dall'esterno non arriva alcun aiuto, ma è il sistema stesso che si incarica di analizzare le informazioni di cui dispone, di classificarle e strutturarle e di formare autonomamente delle teorie

Apprendimento mediante rinforzo:

- Apprendere un comportamento ottimale a partire da esperienze passate.
- Osservo in modo critico il risultato buono o cattivo delle scelte fatte (anche mediante premi e punizioni) e modifico il comportamento di conseguenza



Scenario tipico del reinforcement learning

Machine Learning: apprendimento supervisionato

- Al sistema viene fornito un training set: insieme di coppie input/output (x_i, y_i) con $i=1, \dots, n_{\text{train}}$
- per ogni esempio x_i , viene fornita la label (etichetta) y_i
- Se il processo ha successo, il modello appreso è in grado di mappare gli esempi di input ad i rispettivi output
- Gli esempi sono misurazioni di un'osservazione reale
- Le label (o ground truth) vengono utilizzate per verificare la correttezza dell'algoritmo durante la fase di addestramento
- La procedura di labeling dell'esempio di input di solito coinvolge un esperto di dominio che associa ogni esempio all'etichetta corrispondente (attività tipicamente “costosa”)

Machine Learning: apprendimento supervisionato


I dati di training sono usati per supervisionare il modello durante la fase di training

Fase di training:

I dati sono usati per aggiornare i parametri del modello in maniera tale che il suo output si avvicini quanto più è possibile all'output desiderato

Fase di test:

al modello appreso (learned) vengono forniti dati nuovi (no training set) e si valutano le sue performance in base all'uscite generate (predette)



Un esempio: classificare immagini che rappresentano le cifre decimali

Ingressi:

- $M \times N$ pixel dell'immagine con valori binari 0/1

Uscite:

- possibili cifre da riconoscere: le cifre da 0 a 9;
- il vettore $[0,0,0,1,0,0,0,0,0,0]$ indica la cifra 3

Training set:


- insieme di coppie (ingressi,uscite) (MNIST dataset).

Algoritmo di apprendimento: *Back-Propagation*.

Modalità di apprendimento supervisionata, le classi di uscita sono note, per ciascun esempio, nel corso dell'apprendimento.

Valutazione dell'errore:



- esempi classificati correttamente
- utile per fermare l'addestramento



Machine Learning: la selezione delle *features*

Esempio:

Distinguere mele da pere





Machine Learning: apprendimento supervisionato

Gli algoritmi di classificazione costruiscono modelli predittivi a partire dai dati di training che hanno caratteristiche (features) e etichette di classe (class label)

i valori di output sono categorie

- Classificazione binaria: assegnazione tra due label (mele/pere, benigno, maligno, ecc,)
- Classificazione multiclasse: assegnazione di una tra N label, es. classificazione delle immagini
- classificazione multi-label: comporta l'assegnazione di più label (≥ 1) tra N labels (es. classificazione dei film per genere)



Machine Learning: apprendimento supervisionato

Gli algoritmi di **regressione** si basano sugli stessi meccanismi di quelli di classificazione, ma in questo caso i valori di output sono continui.

Vengono tipicamente applicati a problemi di previsione e ottimizzazione (forecasting and optimization), quali: Es. previsione del consumo di energia elettrica, previsioni meteo, ottimizzazione di processi aziendali


Esempio: Equazione della retta: $y = a + bx$

Parametri del modello: a e b

Formulazione del problema:

$$\text{minimizzare } S = \sum_{i=1}^n (y_i - f(x_i))^2$$

Algoritmo: metodo dei minimi quadrati



Machine Learning: apprendimento non supervisionato

L'obiettivo è raggruppare i punti (esempi) di training in gruppi omogenei secondo la loro somiglianza (es: distanza euclidea)


Esistono diversi approcci per costruire il clustering, basati su medie (K-means), gerarchie, ecc.

Applicazioni:

client segmentation nel marketing, analisi dei social network, climatologia, ecc.

Esempio:

<https://www.youtube.com/watch?v=5I3Ei69I40s>



Machine Learning: apprendimento mediante rinforzo

All'algoritmo vengono forniti:

un insieme di possibili stati


Per ogni stato un insieme di mosse

Ad ogni azione è associato un reward/penalty

Non ci sono label. L'algoritmo deve apprendere una politica che gli consenta di scegliere, per ogni stato, l'azione che massimizza la ricompensa complessiva


Applicazioni:

Robots moving policies, sequential scheduling problems, game playing (es. DeepMind)




Riassumendo ...


Il **Machine Learning** è lo studio di algoritmi che apprendono da esempi ed esperienza invece di fare affidamento su regole codificate, e sono capaci di fare previsioni su nuovi dati.



Classificazione




Regressione



Clustering

Intelligenza Artificiale: Machine Learning



Since an early flush of optimism in the 1950s, smaller subsets of artificial intelligence – first machine learning, then deep learning, a subset of machine learning – have created ever larger disruptions.


Image from <https://blogs.nyjdja.com/blog/2016/07129/whats-the-difference-artificial-intelligence-machine-learning-deep-learning-ai/>

Deep Learning

Il Deep Learning è un'area del Machine Learning che si basa su un modello di apprendimento automatico a vari livelli di rappresentazione in modo incrementale

Strati completamente connessi (densi)

Ogni neurone è connesso a tutti neuroni dello strato successivo



Deep Learning

Masse di informazioni non strutturate (big data) e grande capacità di memoria e potenza di calcolo (GPU, multi-core).

Deep Learning: modelli e algoritmi che utilizzano reti neurali con molti neuroni e molti strati, capaci di apprendere funzioni complesse, cercando di individuare caratteristiche “importanti” dei dati (grezzi).

Le DNN oggi maggiormente utilizzate consistono di un numero di livelli tra 7 e 50 (AlexNet, per il riconoscimento di immagini, 8 livelli e 650K neuroni).

Gli algoritmi supervisionati attualmente ottengono buone prestazioni con circa 5000 esempi per ciascuna categoria e superano gli umani con 10 milioni di esempi.


Non sono una “simulazione” del cervello che ha più neuroni e una struttura molto più complessa. Con uno sviluppo ulteriore della potenza di calcolo, potranno avere un numero di neuroni paragonabile a quello umano non prima del 2050. Per ora minore di quelli di una rana!.

Da: I. Goodfellow, Y. Bengio, A. Courville: “Deep Learning”, MIT Press,
<http://www.deeplearningbook.org>, 2016



Deep Learning

Nel Deep Learning, il mondo può essere rappresentato come una gerarchia di “concetti”, dai più semplici ai più astratti e complessi, sfruttando la struttura gerarchica della rete. La rappresentazione è “distribuita” in modo implicito a livelli.

Input image pixels → Edges → Textures → Parts → Objects



Confronto tra Machine Learning e Deep Learning



Deep Learning

Descrivere/riconoscere il contenuto di un'immagine: non sempre semplice...(Fonte Google).




Deep Learning: ImageNet Challenge

Sfida: classificatore di immagini universale da un dataset di 14M di immagini e 20k categorie, taggate via crowdsourcing e indicizzate con WordNet.


Nel 2011 il margine di errore delle macchine nel riconoscimento e nella classificazione delle immagini era del 26 per cento, oggi è sceso al 3 per cento. (gli umani sono meno efficienti e fanno più errori: in media il 5 per cento).

Da: Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... & Fei-Fei, L. (2015).

Imagenet large scale visual recognition challenge. arXiv preprint arXiv:1409.0575.



[Figure from vision.stanford.edu]



[Figure from Krizhevsky et al., 2012]

Deep Learning: ImageNet Challenge

A metà degli anni 2000 Fei-Fei Li, allora giovane professoressa a Princeton (poi passata a Stanford), ebbe un'intuizione controcorrente: il problema non erano i modelli, ma i dati. Se un bambino impara a vedere attraverso milioni di esempi nel mondo reale, perché l'IA dovrebbe farcela con poche migliaia di foto sgranate?

Il risultato: Nel 2009 è nato ImageNet, un dataset di oltre 14 milioni di immagini organizzate in più di 20.000 categorie.

Per stimolare la ricerca, Fei-Fei Li lanciò l'ILSVRC (ImageNet Large Scale Visual Recognition Challenge), una competizione annuale dove i ricercatori si sfidavano a creare l'algoritmo con il minor tasso di errore.

Il momento cruciale avvenne nel 2012: un team dell'Università di Toronto (guidato da Geoffrey Hinton) presentò AlexNet. A differenza degli approcci tradizionali, usarono le Reti Neurali Convoluzionali (CNN) alimentate dalla potenza di calcolo delle GPU. AlexNet distrusse la concorrenza, riducendo l'errore dal 26% al 16%.

È stato il momento in cui il mondo ha capito che il Deep Learning (apprendimento profondo) era il futuro.

Dai modelli Discriminativi a quelli Generativi



Monet ↔ Photos



Monet → photo




photo → Monet

Fonte delle immagini: <https://junyanz.github.io/CycleGAN/>

Dalle immagini al testo: i modelli linguistici

- I modelli linguistici sono modelli di intelligenza artificiale in grado di elaborare e comprendere il linguaggio umano
- Sono spesso utilizzati in compiti di elaborazione del linguaggio naturale come la generazione di testi, la traduzione linguistica e il riconoscimento vocale



Come funziona un modello linguistico?


- I modelli linguistici utilizzano tecniche di machine e deep learning, tra cui le reti neurali artificiali, per analizzare e apprendere da grandi quantità di dati testuali
- Scompongono le frasi in unità più piccole, come parole o caratteri, e analizzano le relazioni tra di esse
- Il modello utilizza quindi questa conoscenza per prevedere la probabilità che una parola o una frase si verifichi in un determinato contesto

Language Models

Trained to predict the next word in a sentence:

The cat is chasing the _____

dog 5%
mouse 70%
squirrel 20%
boy 5%
house 0%



LARGE LANGUAGE MODELS

I modelli linguistici (Large Language Models, LLM) hanno dato luce all'era dell'IA generativa (chiamata anche GenAI). Il focus di questi modelli è rappresentato dalla «*comprensione*» e creazione di testi, linguaggio, immagini e sempre più contenuti multimediali.


La grande differenza tra gli LLM come GPT di Open AI, Google Gemini o Claude di Anthropic rispetto a modelli di IA classica? Gli LLM sono già addestrati e sono quindi più fruibili, in quanto prodotti considerati «di serie».

I modelli linguistici di grandi dimensioni (LLM) vengono addestrati su vasti volumi di dati e utilizzano miliardi di parametri per generare output originali per attività come rispondere a domande, tradurre lingue e completare frasi.

ADDESTRARE E GESTIRE MODELLI CON I PROPRI DATI

La Retrieval-Augmented Generation (RAG) è il processo di ottimizzazione dell'output di un modello linguistico di grandi dimensioni, in modo che faccia riferimento a una base di conoscenza autorevole al di fuori delle sue fonti di dati di addestramento prima di generare una risposta.

La RAG estende le capacità già avanzate degli LLM a domini specifici o alla knowledge base interna di un'organizzazione, il tutto senza la necessità di riaddestrare il modello. È un approccio conveniente per migliorare l'output LLM in modo che rimanga pertinente, accurato e utile in vari contesti.



GPT-3

GPT-3, o Generative Pre-trained Transformer 3, è un modello linguistico sviluppato da OpenAI

È stato uno dei primi grandi modelli linguistici disponibili, con 175 miliardi di parametri

I parametri sono variabili che il modello utilizza per fare previsioni e apprendere dai dati: un numero maggiore di parametri significa generalmente prestazioni migliori.

GPT-3 è in grado di generare testo simile a quello umano, di completare richieste e di rispondere a domande



ChatGPT

ChatGPT è una versione di GPT-3 che è stata messa a punto specificamente per le interazioni conversazionali

È stato addestrato su una grande quantità di dati conversazionali e può generare risposte più naturali e contestuali



Da GPT-3 a GPT-4...

GPT-4 è in grado di generare testi che emulano ancora meglio un sistema umano

Quando è stato lanciato era uno dei più grandi modelli linguistici esistenti (triliardi di parametri)

La principale caratteristica è l'essere multimodale

È disponibile ora nella versione turbo

The Biggest **GPT-4** Improvements



iDenfy

... e siamo alla versione GPT-5

L'ETICA DELL' IA

Rispetto dell'autonomia umana

Gli esseri umani che interagiscono con i sistemi di IA devono poter mantenere la propria piena ed effettiva autodeterminazione.

I sistemi di IA non devono subordinare, costringere, ingannare, manipolare, condizionare o aggregare in modo ingiustificato gli esseri umani.

Il principio della prevenzione dei danni

I sistemi di IA non devono causare danni né aggravarli e neppure influenzare negativamente gli esseri umani.

Il principio di equità

Lo sviluppo, la distribuzione e l'utilizzo dei sistemi di IA devono essere equi.

Il principio dell'esplicabilità (Trasparenza)

I processi devono essere trasparenti, le capacità e lo scopo dei sistemi di IA devono essere comunicati apertamente e le decisioni, per quanto possibile, devono poter essere spiegate a coloro che ne sono direttamente o indirettamente interessati.

L'ETICA DELL' IA

Fairness: Le decisioni non devono essere discriminatorie. Posso provare che, ad esempio, la razza o il genere non è stato utilizzato, esplicitamente o implicitamente, nella decisione di concedere un prestito?

La nostra società e i dati che ne derivano possono contenere già decisioni discriminatorie che vengono quindi apprese. Si pensi Microsoft chatbot Tay che ha appreso dai Twitter chats ad essere nazista o a Amazon che prediligeva profili (tecnologici) di uomini per l'assunzione (chiuso nel 2017).

Verifyability: Posso dimostrare formalmente che il sistema è corretto rispetto ad alcune proprietà (difficile formalizzare i sistemi di AI e l'ambiente altamente dinamico in cui lavorano).

Accountability: responsabilità per le decisioni prese.

Il problema dell'esattezza

- Si tratta di macchine probabilistiche non deterministiche
- I sistemi di **IA generativa** funzionano con le reti neurali e forniscono risultati di tipo probabilistico.
- Il concetto di “esattezza” non è definito e non esiste.
- Le IA producono risultati “plausibili” o “verosimili”.
- Quelle che chiamiamo “allucinazioni” sono, semplicemente, un “risultato”.
- Anche le allucinazioni sono un prodotto delle IA che può essere utile; pensiamole per esempio come spunti di creatività per generare testi fantastici o poesie.
- Spesso però i risultati vengono accettati senza prima essere verificati: sia l'output che l'input devono essere controllati ed esaminati criticamente per evitare di considerare validi risultati errati.
- Mancanza di benchmark e tracciabilità: con l'IA generativa non è possibile definire e valutare l'accuratezza statistica dei risultati come, ad esempio, “80% corretto”. E la tracciabilità di un risultato è difficile perché varia anche se l'input è lo stesso.

01 — Handwriting analysis for Alzheimer's disease



Introduction

- *Neurodegenerative Disease (ND)* refers to a group of pathologies characterized by an irreversible and progressive loss of neuronal cells.
- *Alzheimer's disease (AD)* is one of the most common ND.
- Improve quality of life of affected individuals.
- Early detection and intervention is crucial.





Current AD diagnosis: imaging, blood tests, and lumbar punctures



The assessment of **handwriting** holds significant potential in diagnosing AD.




Handwriting analysis is relatively cost-effective




Handwriting data allow the monitoring of cognitive decline and the progression of AD

Protocol and Data Acquisition



Acquisition Workflow



Acquisition Workflow



Online Data





- ❖ x,y coordinates, pressure and timestamp
- ❖ Features (velocity, acceleration, jerk, etc.)

Offline Data

- ❖ Images of the tasks performed
- ❖ Features extracted using CNNs

Task Images Available

Setup



x,y,z,timestamp



Handwriting Tasks

#	Description
2	Join two points with a horizontal line, continuously for four times
3	Join two points with a vertical line, continuously for four times
4	Retrace a circle (6 cm of diameter) continuously for four times
5	Retrace a circle (3 cm of diameter) continuously for four times
22	Retrace a complex form
25	Draw a clock, with all hours and put hands at 11:05 (Clock Drawing Test)

- Graphic Tasks

#	Description
1	Signature drawing
15	Memorize the words "telefono", "cane" and "negozio" and rewrite them
19	Write the name of the object shown in a picture (a chair)
21	Write a simple sentence under dictation
24	Write a telephone number under dictation


- Memory Tasks
- Dictation Tasks

Handwriting Tasks

#	Description
6	Copy the letters 'l', 'm' and 'p'
7	Copy the letters on the adjacent rows
8	Write exactly four joined lowercase cursive letter 'l', in a single smooth movement
9	Write exactly four joined lowercase cursive bigram 'le', in a single smooth movement
10	Copy the word "foglio"
11	Copy the word "foglio" above a line
12	Copy the word "mamma"
13	Copy the word "mamma" above a line
18	Copy six words (regular, non regular, non words) in the appropriate box
20	Copy the completed fields of a postal order
23	Copy a telephone number
26	Copy a paragraph
16	Copy in reverse the word "bottiglia"
17	Copy in reverse the word "casa"

- Copy Tasks
- Reverse Copy Tasks


Task Images Available




Handcrafted features

#	Name	Description	Type
1	Duration	Time interval between the first and the last points in a stroke	D
2	Start Vertical Position	Vertical start position relative to the lower edge of the active digitizer area	S
3	Vertical Size	Difference between the highest and lowest y coordinates of the stroke	S
4	Peak vertical velocity	Maximum value of vertical velocity among the points of the stroke	D
5	Peak vertical acceleration	Maximum value of vertical acceleration among the points of the stroke	D
6	Start horizontal position	Horizontal start position relative to the lower edge of the active tablet area	S
7	Horizontal size	Difference between the highest (right most) and lowest (left most) x coordinates of the stroke	S
8	Straightness error	It is calculated estimating the length of the straight line, fitting the straight line, estimating the (perpendicular) distances of each point to the fitted line, estimating the standard deviation of the distances and dividing it by the length of the line between begin and end	D
9	Slant	Direction from beginning point to endpoint of the stroke, in radiant	S
10	Loop Surface	Area of the loop enclosed by the previous and the present stroke	S
11	Relative initial slant	Departure of the direction during the first 80 ms to the slant of the entire stroke.	D
12	Relative time to peak vertical velocity	Ratio of the time duration at which the maximum peak velocity occurs (from the start time) to the total duration	D
13	Absolute size	Calculated from the vertical and horizontal sizes	S
14	Average absolute velocity	Average absolute velocity computed across all the samples of the stroke	D
15	Road length	length of a stroke from begin to end, dimensionless	S
16	Absolute y jerk	The root mean square (RMS) value of the absolute jerk along the vertical direction, across all points of the stroke	D
17	Normalized y jerk	Dimensionless as it is normalized for stroke duration and size	D
18	Absolute jerk	The Root Mean Square (RMS) value of the absolute jerk across all points of the stroke	D
19	Normalized jerk	Dimensionless as it is normalized for stroke duration and size	D
20	Number of peak acceleration points	Number of acceleration peaks both up-going and down-going in the stroke	S
21	Pen pressure	Average pen pressure computed over the points of the stroke	D
22	#strokes	Total number of strokes of the task	S
23	Sex	Subject's gender	P
24	Age	Subject's age	P
25	Work	Type of work of the subject (intellectual or manual)	P
26	Instruction	Subject's education level, expressed in years	P

Approach ML – Stroke-based



Approach ML – Stroke-based




Combining Rules:

- Majority Vote
- Weighted Majority Vote
- Ranking Diversity
- Stacking


Approach ML – Stroke-based

Method	AL						OP						IA					
	Model	Acc (Std)	Sens (Std)	Spec (Std)	F1 (Std)	FS	Model	Acc (Std)	Sens (Std)	Spec (Std)	F1 (Std)	FS	Model	Acc (Std)	Sens (Std)	Spec (Std)	F1 (Std)	FS
MV	CB	77.90 (5.26)	78.55 (5.45)	77.25 (5.38)	77.65 (5.32)	RFE	KNN	75.27 (5.10)	75.92 (5.28)	74.62 (5.22)	75.05 (5.15)	KB	GNB	67.60 (6.78)	68.25 (6.95)	66.95 (6.88)	67.38 (6.82)	KB
WMV	CB	74.81 (9.15)	75.48 (9.35)	74.15 (9.28)	74.58 (9.22)	KB	SVC	73.90 (5.92)	74.55 (6.12)	73.25 (6.05)	73.68 (5.98)	KB	DT	61.78 (5.61)	62.45 (5.78)	61.12 (5.72)	61.55 (5.65)	RFE
Ranking	CB	80.18 (6.22)	80.85 (6.42)	79.52 (6.35)	79.95 (6.28)	KB	CB	74.32 (10.96)	74.98 (11.15)	73.65 (11.08)	74.08 (11.02)	KB	CB	67.69 (13.40)	68.35 (13.58)	67.02 (13.52)	67.45 (13.45)	KB
Stacking	CB	77.30 (9.50)	77.95 (9.68)	76.65 (9.62)	77.08 (9.55)	RFE	CB	77.62 (9.54)	78.28 (9.72)	76.95 (9.65)	77.42 (9.58)	KB	CB	76.67 (9.13)	77.32 (9.32)	76.02 (9.25)	76.45 (9.18)	RFE

Approach DL – Handwriting Images Analysis




Deep Learning Stage



CNN models:

- VGG19
- ResNet50
- InceptionV3
- InceptionResNetV2

Combining



Combining Rules:


- Majority Vote
- Weighted Majority Vote
- Ranking Diversity
- Hill Climbing
- Simulated Annealing
- Tabu Search

Results


Accuracy mean achieved using different image sets

Offline				
Method	VGG19	ResNet50	IncV3	IncResNetV2
CNN (Best Task)	72.3 (T11)	71.7 (T05)	71.1 (T09)	68.9 (T08)
MV	74.2 ± 2.4	62.3 ± 2.7	68.2 ± 2.0	63.3 ± 2.1
WMV	74.3 ± 2.5	60.9 ± 2.6	66.9 ± 2.0	63.9 ± 2.3
RD	76.1 ± 3.3	68.1 ± 2.8	74.8 ± 3.6	72.6 ± 2.5
HC	70.9 ± 8.6	73.0 ± 6.9	69.7 ± 7.0	64.8 ± 10.5
SA	72.2 ± 7.4	64.4 ± 6.4	68.4 ± 6.8	68.2 ± 7.7
TS	70.0 ± 8.1	65.6 ± 5.8	60.3 ± 7.1	62.4 ± 7.5
RGB OnPaper				
CNN (Best Task)	72.7 (T19)	70.4 (T04)	72.9 (T04)	68.8 (T09)
MV	71.7 ± 2.1	72.0 ± 2.2	74.0 ± 2.1	69.6 ± 2.1
WMV	72.8 ± 2.0	73.6 ± 2.5	74.3 ± 2.5	71.5 ± 2.1
RD	76.4 ± 3.8	74.2 ± 3.6	76.2 ± 4.0	76.2 ± 3.9
HC	55.8 ± 8.0	63.1 ± 8.3	63.0 ± 7.8	65.1 ± 7.4
SA	74.4 ± 6.4	70.9 ± 6.4	73.2 ± 6.5	71.6 ± 6.6
TS	74.2 ± 7.8	71.6 ± 5.7	72.2 ± 6.2	72.3 ± 5.8
RGB InAir OnPaper				
CNN (Best Task)	72.8 (T22)	71.6 (T08)	70.3 (T23)	70.6 (T02)
MV	74.1 ± 2.6	75.9 ± 1.8	78.4 ± 2.4	75.3 ± 2.5
WMV	74.6 ± 2.7	74.7 ± 1.9	79.1 ± 2.1	75.8 ± 2.4
RD	78.5 ± 2.9	77.2 ± 2.8	80.6 ± 2.6	76.8 ± 2.7
HC	66.1 ± 7.3	71.2 ± 7.8	68.2 ± 7.6	72.6 ± 8.5
SA	71.4 ± 6.4	75.3 ± 7.6	76.9 ± 6.1	73.0 ± 6.7
TS	71.2 ± 7.2	74.4 ± 7.5	76.0 ± 6.9	73.6 ± 6.6


Task Occurrences for RGB InAir OnPaper image set



Approach DL 2 – Unified Handwriting Images Analysis



Method Scheme



Results

CNN & Transformer models performance on first stage

Model	Accuracy	Specificity	Sensitivity	MCC
VGG16	74.56 (4.35)	74.61 (9.34)	73.78 (5.76)	48.59 (9.70)
VGG19	75.48 (3.41)	78.84 (7.18)	71.83 (6.14)	50.90 (7.34)
ResNet50	70.74 (2.29)	78.04 (8.35)	64.08 (6.18)	42.72 (5.61)
ResNet101	71.45 (3.39)	77.46 (6.80)	65.35 (5.99)	43.19 (7.35)
EfficientNetV2M	72.50 (4.69)	74.35 (9.01)	70.28 (6.88)	44.86 (10.00)
EfficientNetV2S	73.05 (3.22)	77.41 (9.46)	68.52 (6.45)	46.43 (7.62)
ConvNextTiny	78.83 (2.65)	77.96 (7.18)	79.41 (8.57)	57.88 (5.32)
ConvNextSmall	79.21 (3.39)	74.66 (8.38)	82.32 (7.47)	57.82 (7.64)
ConvNextBase	78.03 (4.55)	76.80 (10.88)	78.01 (8.00)	55.42 (10.12)
VitB16	70.10 (3.82)	73.85 (9.60)	66.47 (9.53)	40.88 (7.95)
SwinV2B	77.61 (2.75)	79.62 (5.99)	75.70 (8.85)	55.69 (5.23)
SwinV2S	76.86 (2.95)	74.66 (11.44)	78.68 (9.18)	54.36 (5.34)
SwinV2T	77.13 (2.31)	74.92 (5.61)	78.44 (6.95)	53.82 (5.00)
TrOCR-Small-Hand	67.53 (2.73)	76.29 (6.01)	59.57 (5.22)	36.36 (5.20)
TrOCR-Base-Hand	66.02 (3.04)	77.98 (10.85)	55.47 (12.62)	35.10 (5.32)

CNN & Transformer models performance using Majority Vote


Model	Accuracy	Specificity	Sensitivity	MCC
VGG16	82.57 (8.11)	85.02 (11.98)	79.69 (8.94)	65.01 (17.04)
VGG19	84.37 (3.35)	91.99 (5.24)	77.15 (9.23)	70.09 (5.56)
ResNet50	79.50 (2.39)	92.06 (7.45)	67.97 (8.41)	62.09 (4.64)
ResNet101	78.93 (7.61)	90.16 (10.74)	67.73 (11.99)	59.84 (15.39)
EfficientNetV2M	80.73 (8.89)	86.63 (13.87)	74.76 (10.46)	62.56 (18.45)
EfficientNetV2S	78.31 (5.89)	87.73 (10.86)	69.20 (9.48)	58.55 (12.37)
ConvNextTiny	87.38 (5.78)	88.46 (10.19)	86.59 (13.30)	76.38 (10.70)
ConvNextSmall	87.99 (5.30)	85.15 (9.90)	89.69 (13.06)	76.75 (10.63)
ConvNextBase	86.17 (8.65)	87.37 (13.44)	84.01 (12.28)	72.60 (18.09)
VitB16	77.70 (9.72)	86.63 (10.46)	69.42 (21.85)	58.40 (16.42)
SwinV2B	84.94 (5.07)	89.63 (8.20)	80.70 (11.98)	71.36 (9.51)
SwinV2S	83.74 (3.59)	83.08 (12.53)	84.30 (12.29)	69.26 (7.26)
SwinV2T	85.54 (1.18)	86.89 (7.01)	84.04 (6.86)	71.53 (2.75)
TrOCR-Small-Hand	71.66 (6.63)	87.95 (8.26)	57.23 (11.58)	47.86 (11.38)
TrOCR-Base-Hand	71.00 (11.54)	90.16 (11.36)	53.85 (20.86)	48.17 (19.91)

02 — Specific Learning Disorders

Introduction

- ❖ **Learning Disorders (LD):** Differences in brain function affecting learning processes.
- ❖ **Common LD Types:** Dyslexia, Dysgraphia, Dyscalculia
- ❖ **The Importance of Early Detection:** How timely intervention can reshape a child's academic and emotional journey.
- ❖ **Impact Beyond Academics:** Emotional turmoil, self-esteem issues, social isolation, and more.

% STUDENTS WITH LD ITALY



Introduction



Learning Disorders

Inherent brain differences leading to varied learning processes.



Handwriting's Role in LD

Identifying patterns, speed, and pressure anomalies.



Dysgraphia

Challenges with handwriting consistency, motor skills, and expression.




AI's Contribution

Using machine learning to provide insights and recommendations based on handwriting analysis.



AI Workflow



Acquisition App

- Developed in C#
- CDL Wacom library
- Bluetooth, USB protocols supported
- Save .csv and .png file




Wacom ONE



20 Handwriting tasks




Name Task



Tracking Task



Sequence Task



Movement Task

Specific Learning Disorders (SLD)



CRC
Rome




3rd year acquisition



Second year
primary school
pupils

03 — Parkinson's Disease



Markerless Gait Analysis




Keypoint Extraction

❖ What are the key points?

In computer vision tasks, keypoints represent human body joints, facial landmarks, or salient points on objects.

❖ VitPose-base:

- ❖ Pretrained on COCO
- ❖ Top-down approach
- ❖ Return 17-point keypoint



Spatio-temporal Feature

❖ Spatio-temporal Feature:

- ❖ Gait velocity as the average speed of each keypoints.
- ❖ Step/stride length
- ❖ Cadence
- ❖ Stance/swing duration



Kinematic Feature



- ❖ Kinematic Feature:
 - ❖ Joint angles using Carnot's theorem



04 — Biomechanical Landmarks Enhancement: Transforming 3D Pose Keypoints into Anatomical Landmarks


Why we need to estimate Anatomical Landmarks?

- ❖ **Pose estimation models provide only joint centres,** which are insufficient for full 3D joint angle computation.
- ❖ **Pose estimation keypoints lack biomechanical significance,** making it difficult to capture true segment orientation and joint movement across anatomical planes.
- ❖ **To overcome this,** we need methods that **transform sparse pose keypoints into complete anatomical coordinates.**




So, what do we want to do?


3D Keypoint



3D Anatomical Landmarks




And How?




Visual Results

Prediction



Ground Truth



05 — Alzheimer's Disease Prediction from brain MRI: Foundation Diffusion Models for Unsupervised Learning





Why a “Foundation Model” for Brain MRI?

- ❖ **Label-free training unlocks data** >80 % of brain MRIs stored in a typical hospital PACS come with no structured diagnosis or voxel-level labels. Our Latent Diffusion Auto-Encoder (LDAE) turns this vast, unlabeled archive into usable knowledge—every new scan strengthens the model with zero extra clerical work.
- ❖ **Scalable & less biased** Training on >10,000 routine scans captures subtle, early Alzheimer’s patterns that small, hand-labeled datasets miss and avoids the selection bias of expert-curated cohorts
- ❖ **Compact & fast** LDAE shrinks each 3-D scan 170 ×, then runs diffusion in that tiny space, reconstructing images ≈ 6 s per scan on a clinical GPU—20 × quicker than earlier diffusion methods.
- ❖ **Clinically relevant accuracy** A simple linear classifier reaches 84 % diagnostic accuracy (AUROC ≈ 0.90) and predicts chronological age within ± 4 years.

Clinical Value Today

- ❖ **Decision support** Identify AD from just one T1w MRI; no extra information needed
- ❖ **Explainable imaging** We can dial disease severity up or down in the image; hippocampi shrink or recover in real time, showing clinicians exactly what drives the algorithm's judgement (counter-factual manipulation).
- ❖ **Follow-up made visible** Predicts missing or future MRI: reconstructs 6-month intermediate scans with SSIM 0.97 and stays > 0.93 even 24 months out—helpful when a visit is skipped or for trial planning.
- ❖ **One model, many tasks** The same unsupervised backbone feeds diagnosis, progression modelling, and research exploration without re-training.

Results



Grazie per l'attenzione

