



XI CONSILIATURA 2023 - 2028

INTELLIGENZA ARTIFICIALE, PROCESSI PRODUTTIVI, SERVIZI PUBBLICI

*PRIMA RASSEGNA RAGIONATA DELLA LETTERATURA
SUI MODELLI COMPUTAZIONALI
PER L'INTELLIGENZA ARTIFICIALE GENERATIVA*

**CASI E MATERIALI DI DISCUSSIONE:
MERCATO DEL LAVORO E CONTRATTAZIONE COLLETTIVA**

N. 6 | 2024

**INTELLIGENZA ARTIFICIALE, PROCESSI PRODUTTIVI,
SERVIZI PUBBLICI**

**PRIMA RASSEGNA RAGIONATA DELLA LETTERATURA
SUI MODELLI COMPUTAZIONALI PER L'INTELLIGENZA ARTIFICIALE
GENERATIVA**

di Alessio Del Bue

membro del gruppo di lavoro su IA istituito dal Presidente del CNEL

in collaborazione con CNR, IIT e Centro Ricerche Enrico Fermi

*Le opinioni espresse nel presente documento sono personali e non impegnano
la responsabilità del CNEL.*

CASI E MATERIALI DI DISCUSSIONE:

INTELLIGENZA ARTIFICIALE, PROCESSI PRODUTTIVI,
SERVIZI PUBBLICI

N. 6 | 2024

Aprile 2024

ABSTRACT

L'impatto trasformativo dell'intelligenza artificiale (IA) nei processi produttivi e servizi pubblici è il risultato del continuo e inarrestabile progresso scientifico nelle discipline dell'apprendimento automatico, dell'elaborazione del linguaggio, della visione artificiale e della robotica. Più che mai in questa epoca storica si delinea un panorama in rapido cambiamento caratterizzato da sistemi computazionali che riescono a padroneggiare capacità lavorative che fino a pochi anni fa si ritenevano difficili, se non impossibili, da attuare.

In questo scenario l'IA si rivela un motore di trasformazione nei diversi settori produttivi. La sua capacità di analizzare enormi volumi di dati in tempo reale consente di ottimizzare processi in ambiti quali: l'industria manifatturiera, dove l'IA predice malfunzionamenti e pianifica la manutenzione preventiva, riducendo i tempi di inattività; nel commercio al dettaglio, in cui algoritmi predittivi migliorano la gestione delle scorte e personalizzano l'esperienza di acquisto; nel settore sanitario, dove l'IA assiste nella diagnosi precoce e nella personalizzazione dei trattamenti; nella finanza che può avvalersi di modelli avanzati di apprendimento automatico per rivelare frodi in tempo reale e automatizzare il trading. Importante è anche il contributo nel contesto legale, dove l'IA facilita l'analisi di grandi volumi di documentazione e accelera la ricerca di precedenti e l'elaborazione di contratti. Risulta evidente come l'adozione dell'IA nei processi aziendali e nei servizi pubblici sia ormai diventata una necessità per mantenere la competitività ed essere in grado di innovare. Tale trasformazione verrà delineata attraverso la seguente relazione in tre distinte fasi.

Nella sezione introduttiva, l'articolo posiziona l'IA nel contesto storico e tecnologico attuale, evidenziando come le sue radici affondino nelle ambizioni e nelle ricerche scientifiche della metà del ventesimo secolo, per poi espandersi in un campo di studi che oggi influisce profondamente su quasi ogni aspetto della vita quotidiana e professionale. Si esamina l'evoluzione dell'IA, da algoritmi per la risoluzione di problemi in contesti molto specifici fino a sistemi complessi capaci di apprendimento profondo e di decisioni autonome, sottolineando il ruolo cruciale dei grandi dati e dell'incremento della capacità di calcolo.

La seconda sezione si addentra nei modelli generativi, una frontiera avanzata dell'IA che comprende diversi modelli computazionali addestrati e ottimizzati mediante l'utilizzo di grandi quantità di dati e parametri che caratterizzano la

complessità del modello. I modelli si distinguono, ciascuno con le proprie caratteristiche realizzative, per le capacità di gestire dati sequenziali, come il testo, immagini o informazioni provenienti da diverse modalità di dati. Questi modelli hanno la capacità unica di creare dati nuovi, modellando le distribuzioni di dati reali, aprendo così nuove prospettive in termini di creazione di contenuti digitali, simulazioni e soluzioni personalizzate.

Infine, la terza sezione dell'articolo si concentra sulle applicazioni dell'IA nel mondo del lavoro, esaminando in quali contesti i vari modelli di IA generativa vengono applicati e analizzando come l'introduzione di sistemi intelligenti stia modificando alcune dinamiche lavorative, dall'assistenza nelle attività manuali e ripetitive, fino all'introduzione di nuove competenze e ruoli lavorativi. Partendo dall'applicazione di sistemi IA per l'amministrazione fino a strumenti per il supporto legale, l'analisi presenta chiari casi di integrazione della tecnologia in contesti lavorativi sia nazionali che internazionali.

INDICE

1. CONTESTO STORICO E INTRODUZIONE SUI MODELLI COMPUTAZIONALI PER L'INTELLIGENZA ARTIFICIALE.....	6
2. I MODELLI DELL'IA GENERATIVA	9
3. APPLICAZIONE DELL'IA GENERATIVA NEL MONDO DEL LAVORO.....	20
4. BIBLIOGRAFIA	35

1. CONTESTO STORICO E INTRODUZIONE SUI MODELLI COMPUTAZIONALI PER L'INTELLIGENZA ARTIFICIALE

L'Intelligenza Artificiale (IA) è emersa globalmente come una forza trasformativa nell'economia e nel tessuto produttivo promettendo un aumento dell'efficienza, nuovi modelli di business e innovazione in vari settori. La seguente rassegna si focalizzerà sugli aspetti scientifici alla base di questa nuova tecnologia, indicando gli elementi fondamentali alla base del successo dei moderni sistemi di IA e delineando successivamente l'impatto tecnologico dei nuovi modelli computazionali generativi.

Il risalto che viene dato oggi all'IA non è certamente frutto di pochi salti quantici avvenuti nel progresso scientifico della tecnologia. Il concetto di modello generativo, in una sua definizione più specifica, era stato introdotto nella seconda metà degli anni '60 nei *Hidden Markov models* (Baum & Petrie, 1966) che, data una distribuzione statistica dei dati cercavano di predire, e quindi di generare, serie temporali che erano condizionate statisticamente dai dati in input. Queste iniziali capacità di predizione erano estremamente limitate, ma trovavano comunque applicazione in una miriade di problemi computazionali nei campi della bioinformatica, finanza, riconoscimento vocale, telecomunicazioni e altre (Mor, Garhwal, & Kumar, 2021). Un aspetto affascinante riguarda una metodologia affine, le *Markov Chains*, un metodo risalente anch'esso alla metà del secolo scorso, il cui concetto di base ha ispirato gli odierni *Diffusion Models*, i modelli generativi per immagini alla base di software come GLIDE (Nichol, et al., 2022), DALL-E 2 (Ramesh, Dhariwal, Nichol, Chu, & Chen, 2022), Midjourney e Stable Diffusion (Rombach, Blattmann, Lorenz, Esser, & Ommer, 2022). L'elemento che ha permesso all'IA di essere applicata in modo eterogeneo e rilevante sta nella capacità di generalizzazione dei modelli che sono in grado di risolvere e affrontare una moltitudine di compiti senza essere stati esplicitamente programmati per gli stessi. In questo senso, c'è una distinzione sempre più marcata tra le metodologie di IA di inizio secolo, definite come *narrow AI*, e quelle odierne che risultano più efficienti nel risolvere i compiti più disparati.

Il primo elemento temporale di distinzione che viene considerato dalla comunità scientifica corrisponde alla prima applicazione del *Deep Learning* a diversi problemi computazionali (LeCun, Bengio, & Hinton, 2015). Tali modelli computazionali basati su reti neurali hanno dimostrato la loro peculiare abilità nel risolvere problemi classici di visione artificiale, superando con ampio

marginale i modelli convenzionali dell'epoca (Krizhevsky, Sutskever, & Hinton, 2012). La particolarità dei modelli di *Deep Learning* risiedeva nel realizzare architetture neurali di complessità crescente in grado di processare quantità di dati di ordini di grandezza superiori rispetto a prima. In aggiunta allo sviluppo scientifico dei modelli, anche la disponibilità di risorse computazionali ha consentito di addestrare le reti neurali mediante un processo di apprendimento stocastico (Rosenblatt, 1958), anche in presenza di quantità di dati molto elevata (Deng, et al., 2009). I primi modelli di *Deep Learning* erano approcci con metodi di apprendimento supervisionati che necessitavano l'annotazione manuale dei dati mediante "meta-dati" o etichette con un consistente impegno di ore-uomo e con l'inevitabile introduzione di errori e ambiguità sulle annotazioni. Di fronte alle evidenti capacità dei modelli di aumentare le prestazioni con l'aumentare dei dati e del numero dei parametri delle reti (Hestness, et al., 2017) (Kaplan, et al., 2020), lo sviluppo tecnologico ha fatto emergere architetture computazionali scalabili e tecniche in grado di aumentare la dimensione dei dataset a disposizione.

Per superare l'ostacolo dell'annotazione dei dati, il ricorso a tecniche *self-supervised* o semi-supervisionate ha contribuito grandemente allo sviluppo dei "foundation models" (Bommasani, et al., 2021), alla base degli odierni modelli del linguaggio come GPT (Brown, et al., 2020). Tali metodologie *self-supervised* prevedono strategie di apprendimento dove non è necessario l'utilizzo della supervisione umana in termini di annotazione, utilizzando il dato stesso come sorgente di annotazioni (Noroozi & Favaro, 2016). Un esempio di strategia elementare ma allo stesso tempo efficace e generalizzabile è quella che viene utilizzata per l'addestramento di modelli del linguaggio. Alla rete in fase di addestramento viene richiesto di risolvere un compito surrogato che consiste nel completare una frase di testo dove mancano una o più parole. Questo semplice compito permette di creare una quantità massiva di dati annotati (eliminando causalmente delle parole) e quindi aumentare di diversi ordini di grandezza i dataset per l'addestramento, spesso usando grandi moli di testo estratte da *Internet* o da altri database accessibili pubblicamente.

L'enorme quantità di dati annotati disponibili, abbinata a nuove architetture per l'elaborazione di dati sequenziali come i *Transformers* (Vaswani, et al., 2017), ha permesso di ottenere modelli con la capacità di generalizzare facilmente nuovi compiti, come la risposta automatica a domande mediante *prompt* testuali, la traduzione tra diverse lingue e altri nuovi task che possono essere risolti con limitata supervisione umana. Questa elevata disponibilità di dati ha permesso di incrementare sostanzialmente la dimensione dei modelli, migliorando

notevolmente le capacità di risoluzione di diversi compiti o *task*. Questa crescita ha reso necessario un incremento delle capacità computazionali rendendo complesso, se non impossibile, l'addestramento di tali modelli in contesti accademici, limitando lo sviluppo dei modelli a larga scala a poche aziende e istituzioni.

2. I MODELLI DELL'IA GENERATIVA

I modelli IA generativi hanno una struttura e un funzionamento simile tra di loro ma, prima di entrare nel dettaglio dei modelli utilizzati nello stato dell'arte della ricerca scientifica e applicativa, vogliamo esaminare gli elementi che li compongono e i processi sottostanti. I modelli generativi si basano sulla capacità di apprendere e modellare complesse distribuzioni di dati in un modo tale da consentire la generazione di nuovi esempi che mantengono le proprietà statistiche dei dati originari (Tomczak, 2022).

La fase iniziale del processo di addestramento è la preparazione dei dati, che nei modelli generativi dell'IA è fondamentale e complessa, dovendo superare difficoltà significative per sviluppare metodologie per la pulizia dei dati, la loro organizzazione, la gestione di *bias* e dei problemi di privacy e copyright. Prima di addestrare un modello, i dati devono essere accuratamente selezionati, puliti e organizzati, per essere certi che siano rappresentativi e privi di errori o distorsioni. Questo processo può includere l'eliminazione di dati irrilevanti e di informazioni erronee, la gestione di elementi mancanti e la normalizzazione dei dati. Questa può essere una delle fasi più complesse, soprattutto a causa della necessità di recuperare grandi moli di dati, di solito estratte mediante algoritmi che setacciano indiscriminatamente le informazioni disponibili online (*web scraping*).

Un aspetto critico in questa fase è il possibile *bias* nei dati, che può generare modelli che perpetuano o amplificano stereotipi esistenti, o che semplicemente tendono statisticamente a favorire un risultato rispetto ad un altro (Ali, et al., 2023). Per questa ragione è essenziale identificare e correggere il *bias* nei dati di addestramento (Li & Vasconcelos, 2019) per evitare che i modelli generativi producano risultati ingiusti o discriminatori: parliamo del cosiddetto principio della *fairness* del modello generativo (Mehrabi, Morstatter, Saxena, Lerman, & Galstyan, 2021) o di qualsiasi altro modello estratto dai dati. Come includere questi principi all'interno di un algoritmo computazionale è un aspetto di interesse non solo scientifico ma anche socio-economico, dato che non sempre l'ingegnerizzazione di un modello di questo tipo apporta dei benefici alla società (Mittelstadt, Wachter, & Russell, 2023).

La privacy e il diritto d'autore rappresentano problematiche rilevanti, poiché l'automatizzazione della raccolta dati può inserire campioni di informazioni sensibili o protetti da copyright. È quindi necessario implementare misure e strumenti per l'anonimizzazione dei dati o l'inclusione di dati liberamente

disponibili. La scelta dei dati ha un impatto diretto sulla qualità e sull'applicabilità dei modelli generativi. Dati non rappresentativi o di bassa qualità possono generare modelli inefficienti o inadeguati. Pertanto, la preparazione dei dati richiede un'attenzione meticolosa e una profonda comprensione dei dati stessi, oltre alla consapevolezza delle implicazioni etiche e giuridiche associate al loro utilizzo. Per questa ragione, questi aspetti sono attualmente oggetto di una intensa attività di regolamentazione a livello internazionale ed europeo (§ 3 della rassegna a cura di E. Dagnino, 3 | 2024 “Casi e materiali di discussione: mercato del lavoro e contrattazione collettiva”).

Dopo la preparazione dei dati, la fase di addestramento ottimizza il modello e assimila le caratteristiche chiave dei dati di input, apprendendo a riconoscere schemi, correlazioni, e in generale una rappresentazione implicita dei dati (chiamato *embedding* o spazio delle *features*). Questa fase richiede un'ingente quantità di dati e una significativa potenza di calcolo per iterare attraverso i cicli di apprendimento, dove il modello aggiusta continuamente i suoi parametri interni per minimizzare la differenza tra i dati generati e quelli reali. L'obiettivo è affinare il modello fino a quando non è in grado di produrre dati di *output* che siano statisticamente indistinguibili dai dati originari, utilizzando metodi e tecniche di ottimizzazione come lo *stochastic gradient descent*. Questo processo richiede un'attenzione meticolosa per evitare il sovradattamento, in modo che il modello mantenga la capacità di generalizzare ad esempi non visti durante l'addestramento: in pratica assicurando che il modello eviti di memorizzare il dataset ma ne impari le caratteristiche salienti. Questo aspetto è fondamentale nei modelli generativi considerato che una delle loro capacità implicite più importanti è quella di generare dati nuovi a seconda del compito che devono risolvere. Per migliorare la robustezza dei modelli si utilizzano spesso tecniche come il *dropout* (Srivastava, Hinton, Krizhevsky, Sutskever, & Salakhutdinov, 2014) (Morero, Cavazza, Volpi, Vidal, & Murino, 2017) (Zunino, et al., 2021), e l'*augmentation* dei dati (Moradi, Berangi, & Minaei, 2020).

Un'ulteriore distinzione rilevante sui metodi di apprendimento è relazionata alla supervisione umana necessaria per ottimizzare il modello, come illustrato al precedente §1. Questo aspetto generalmente si trasla nuovamente sulla struttura dei dati e sulla presenza di annotazioni o etichettature sul contenuto dei dati da parte di un umano (i meta-dati). Nell'approccio supervisionato i meta-dati forniscono contesto e informazioni aggiuntive che descrivono le caratteristiche o gli attributi degli input, permettendo al modello di apprendere relazioni complesse tra input e *output* in modo più definito. Questo metodo si basa sulla correlazione tra i dati di ingresso e le informazioni di contesto per

generare *output* che non solo imitano la distribuzione dei dati originari ma che sono anche coerenti con specifiche caratteristiche o attributi definiti dalle etichette o meta-dati. L'apprendimento non supervisionato, invece, non si avvale di dati etichettati cercando piuttosto di identificare autonomamente nei dati le strutture e i *pattern* non evidenti. In questo contesto i modelli generativi sono addestrati per imparare la distribuzione dei dati di input senza alcuna indicazione specifica su cosa rappresentano. In questo modo possono generare nuovi dati che imitano esclusivamente la distribuzione appresa, senza nessuna indicazione da un operatore esterno. Questo approccio è particolarmente potente per generare dati nuovi in contesti dove le etichette specifiche non sono disponibili o sono difficili da ottenere.

Nel seguito definiremo le varie strategie e i modelli di apprendimento esemplificativi dello stato dell'arte nella ricerca scientifica e le loro potenziali applicazioni nel mondo del lavoro (§ 3).

2.1 I modelli computazionali deep learning

Nell'ultimo decennio vi è stato un significativo consolidamento e progresso del *deep learning*, con l'adozione e l'ottimizzazione di reti neurali che hanno segnato il progresso nel campo dell'intelligenza artificiale. Questa fase è stata caratterizzata dallo sviluppo di modelli che hanno permesso di ottenere prestazioni notevoli in diversi domini applicativi, come la visione artificiale e l'elaborazione del linguaggio naturale, grazie alla loro capacità di apprendere rappresentazioni complesse dei dati. Nel seguito verrà esposta una breve descrizione delle architetture di apprendimento automatico più rilevanti nel nostro contesto scientifico e applicativo.

Percettrone multistrato (MLPs). I percettroni multistrato (MLPs) (Van Der Malsburg, 1986) hanno trovato applicazione in compiti di classificazione e regressione su dati strutturati. Sebbene i MLP non possiedano la stessa capacità delle CNN nell'elaborazione di dati visivi o sequenziali, la loro semplicità e flessibilità ne fanno una soluzione valida per apprendere relazioni complesse in dataset dove la struttura spaziale o temporale non è predominante. I MLP sono stati fondamentali per esplorare le dinamiche dell'addestramento (Rumelhart, Hinton, & Williams, 1986), e l'uso di funzioni di attivazione non lineari, tecniche di regolarizzazione come il *dropout* (Srivastava, Hinton, Krizhevsky, Sutskever, & Salakhutdinov, 2014), e ottimizzatori avanzati (Kingma & Ba, Adam: A Method for Stochastic Optimization, 2014).

Reti Neurali Convoluzionali (CNNs). Le Reti Neurali Convoluzionali (CNNs) sono uno dei modelli computazionali per lo sviluppo di molti metodi che analizzano immagini, e in particolare per il riconoscimento di oggetti e altri elementi semantici delle scene. La struttura delle CNN, con strati convoluzionali che elaborano i dati visivi in maniera gerarchica, ha permesso di estrarre *feature* visive con un livello crescente di dettaglio e astrazione. Il modello AlexNet (Krizhevsky, Sutskever, & Hinton, 2012), introdotto nel 2012, ha rappresentato un punto di svolta, dimostrando l'efficacia delle CNN su dataset di grandi dimensioni come ImageNet. Successivamente, modelli come VGG (Simonyan & Zisserman, 2015), Inception (Szegedy, et al., 2015) e ResNet (He, Zhang, Ren, & Sun, 2016) hanno introdotto miglioramenti significativi come l'incremento della profondità delle reti e l'introduzione di connessioni residuali per gestire i problemi di ottimizzazione legati ai limiti intrinseci degli algoritmi di discesa del gradiente e migliorare l'addestramento di reti profonde.

Reti Neurali Ricorrenti (RNNs) e Long Short-Term Memory (LSTM). Le Reti Neurali Ricorrenti (RNNs) sono un'architettura chiave per l'elaborazione di dati sequenziali, come testo e serie temporali. La loro capacità di mantenere uno stato interno permette di considerare le dipendenze temporali nei dati. Tuttavia, le RNN tradizionali soffrono di problemi legati alla scomparsa ed esplosione del gradiente quando si lavora con sequenze lunghe. L'introduzione delle unità *Long Short-Term Memory* (LSTM) (Hochreiter & Schmidhuber, 1997) ha mitigato questi problemi, introducendo meccanismi di *gate* che regolano il flusso di informazioni, permettendo al modello di mantenere dipendenze a lungo termine. Questo ha significativamente migliorato le prestazioni in compiti di NLP e nella generazione di sequenze (Sutskever, Vinyals, & Le, 2014), rendendo le LSTM uno strumento standard per applicazioni che richiedono la modellazione di dipendenze temporali complesse.

U-Net per l'elaborazione delle immagini. Parallelamente agli sviluppi nelle CNN e nelle RNN, il modello *U-Net* ha rappresentato un progresso significativo nell'elaborazione delle immagini. Inizialmente proposta per applicazioni nel campo della segmentazione di immagini biomedicali, *U-Net* (Ronneberger, Fischer, & Brox, 2015) si distingue per la sua architettura simmetrica, che facilita l'apprendimento di rappresentazioni ad alta risoluzione. Questo modello utilizza un percorso di contrazione per catturare il contesto e un percorso di espansione simmetrico che consente una localizzazione precisa. La caratteristica distintiva di *U-Net* è la sua capacità di lavorare con un numero limitato di campioni di addestramento, rendendolo particolarmente adatto per applicazioni mediche dove i dati annotati sono spesso scarsi. L'applicazione di

U-Net si estende ben oltre il campo medico. L'efficienza dell'architettura e la capacità di produrre mappe di segmentazione di alta qualità hanno reso *U-Net* e tutte le sue varianti una scelta popolare anche in altri campi dell'elaborazione delle immagini, come la segmentazione di oggetti in immagini satellitari e in applicazioni di visione artificiale per veicoli a guida autonoma. L'approccio di *U-Net* alla segmentazione delle immagini ha ispirato numerosi miglioramenti e varianti nel tentativo di ottimizzare ulteriormente la precisione della segmentazione e l'efficienza computazionale per applicazioni specifiche. Il successo di *U-Net* dimostra l'importanza di architetture neurali specializzate per affrontare sfide specifiche nel campo del *deep learning*, evidenziando come soluzioni mirate possano superare le limitazioni dei modelli più generalisti in contesti applicativi particolari.

2.2 I modelli generativi basati su Generative Adversarial Networks (GANs)

Le GANs sono una classe di modelli di apprendimento automatico introdotti da (Goodfellow, et al., 2014). Hanno guadagnato una grande popolarità per la loro capacità di generare dati estremamente realistici, in particolare immagini, ma anche testi, audio e dati in altri domini. Le GANs si basano su un approccio di apprendimento competitivo tra due reti neurali: il generatore, che impara a produrre dati simili a quelli reali, e il discriminatore, che impara a distinguere tra dati reali e dati generati dal generatore. Il modello generatore e quello discriminatore vengono addestrati simultaneamente in un gioco a somma zero, dove l'obiettivo del generatore è ingannare il discriminatore producendo dati sempre più simili ai dati reali, mentre il discriminatore cerca di diventare sempre migliore nel distinguere i dati reali da quelli generati. Questo processo di addestramento competitivo porta il generatore a produrre dati estremamente realistici e dettagliati.

Varianti delle GANs. Le *Conditional GANs* (cGANs) (Mirza & Osindero, 2014) generano dati condizionati da informazioni aggiuntive, come etichette di classe o dati di input. Questo consente loro di guidare il processo di generazione per produrre risultati più precisi e specifici. Le *Deep Convolutional GANs* (DCGANs) (Radford, Metz, & Chintala, 2015) sono una delle prime varianti ad utilizzare architetture convoluzionali sia nel generatore che nel discriminatore, migliorando significativamente la qualità delle immagini generate e fissando lo stato dell'arte per molti sviluppi futuri (Yu, Gong, Zhong, & Shan, 2017). La metodologia *Progressive Growing of GANs* (PGGANs) introdotta da (Karras, Aila, Laine, & Lehtinen, 2018) aumenta progressivamente la risoluzione delle immagini generate durante l'addestramento, permettendo la generazione di immagini ad alta risoluzione con dettagli notevolmente migliorati. Le

StyleGAN e StyleGAN2, anch'esse sviluppate da (Karras, Laine, & Aila, 2019) in due lavori successivi, introducono modifiche nell'architettura del generatore che permettono un controllo fine su vari aspetti stilistici delle immagini generate, producendo risultati di qualità elevata con la possibilità di manipolare lo stile delle immagini (Karras, et al., 2020).

Oltre che nella generazione di immagini, le GANs hanno trovato applicazione in numerosi altri campi, tra cui il miglioramento della risoluzione delle immagini, la traduzione tra domini di immagini (ad esempio, da schizzi a immagini fotorealistiche), la generazione di testo e la sintesi vocale. L'approccio GAN ha ispirato anche ricerche in ambiti come la privacy dei dati, dove possono essere utilizzate per generare dati sintetici che preservano le statistiche dei dataset originari senza condividere dati reali.

2.3 I modelli generativi auto-encoders

I modelli generativi *auto-encoders* rappresentano una famiglia di reti neurali utilizzate per apprendere rappresentazioni efficienti dei dati in uno spazio latente ridotto da cui è possibile ricostruire i dati originari. Questi modelli si basano su una struttura composta da due parti principali: l'*encoder*, che trasforma i dati in una rappresentazione latente, e il *decoder*, che ricrea l'input a partire da questa rappresentazione. L'obiettivo è quello di catturare le caratteristiche essenziali dei dati nel vettore latente, permettendo non solo una compressione dei dati ma anche la generazione di nuovi esempi simili a quelli osservati durante l'addestramento.

Variational Auto-Encoders (VAEs). I VAEs (Kingma & Welling, 2014) (Rezende, Mohamed, & Wierstra, 2014) sono una variante degli *auto-encoders* che apprendono la distribuzione dei dati in uno spazio latente. A differenza degli *auto-encoders* tradizionali, che attuano un semplice meccanismo di codifica e decodifica, i VAEs sono progettati per codificare un dato input in una distribuzione di possibili valori nello spazio latente anziché un singolo vettore. Questo risultato è ottenuto forzando, durante l'addestramento, una distribuzione a priori, tipicamente gaussiana, sullo spazio latente. Il processo di decodifica non è deterministico e viene attuato a partire da un campionamento della distribuzione gaussiana. I VAEs sono noti in particolare per la capacità di generare nuovi dati che mantengono le caratteristiche statistiche del set di addestramento. Analogamente alle *cGANs* (Mirza & Osindero, 2014), vengono utilizzati per generare immagini o generici *output* a partire da un qualsiasi condizionamento (Sohn, Lee, & Yan, 2015).

Denoising Auto-encoders (DAEs). I *DAEs* (Vincent, Larochelle, Bengio, & Manzagol, 2008) sono un'altra importante variante degli *auto-encoders* che punta a migliorare la robustezza e la capacità di generalizzazione del modello introducendo rumore nell'input durante l'addestramento. L'obiettivo è ricostruire l'input originario a partire dall'input corrotto, costringendo l'*encoder* ad apprendere rappresentazioni più stabili e significative. Questa tecnica migliora la capacità del modello di catturare le strutture sottostanti dei dati rendendolo utile non solo per la generazione di dati ma anche per applicazioni di *denoising* e recupero di informazioni.

Sparse Autoencoders. Gli *Sparse Autoencoders* (Cunningham, Ewart, Riggs, Huben, & Sharkey, 2023) sono una variante che introduce un vincolo di sparsità sulle attivazioni dello strato latente. Questo significa che, durante l'addestramento, nello strato latente sarà attivo solo un limitato numero di neuroni per un dato input. Questo approccio incoraggia il modello a scoprire rappresentazioni latenti più informative e meno ridondanti, migliorando l'efficienza della rappresentazione e facilitando l'interpretazione dei fattori latenti. Gli *Sparse Autoencoders* trovano applicazione non solo nella generazione di dati ma anche in compiti di selezione delle *features* e di riduzione della dimensionalità.

Questi diversi approcci agli *autoencoders* hanno ampliato notevolmente il campo di applicazione dei modelli generativi, permettendo di affrontare una vasta gamma di compiti: dalla generazione di dati alla riduzione della dimensionalità, dal miglioramento della qualità dell'immagine alla generazione di rappresentazioni latenti per compiti di apprendimento non supervisionato e semi-supervisionato. L'evoluzione ancora in corso di queste architetture, ad esempio mediante considerazione di modelli gerarchici (Vahdat & Kautz, 2020), testimonia l'importanza degli *autoencoders* nel panorama dell'intelligenza artificiale generativa, dove offre strumenti potenti e flessibili.

2.4 I modelli generativi basati su Transformers

I modelli generativi *Transformers* (Vaswani, et al., 2017) sono basati sull'elaborazione di dati sequenziali, come per le RNN e LSTM, ma utilizzano prevalentemente meccanismi di attenzione per elaborare dipendenze tra i dati a più lungo termine rispetto alle precedenti soluzioni. L'innovazione al centro dei *Transformers* è proprio il meccanismo di attenzione, che permette al modello di ponderare l'importanza relativa di diversi elementi in una sequenza. Un input viene trasformato in una serie di *token* (unità atomica del dato), che possono rappresentare parole (se si tratta di testo) o parti di un'immagine (come

una *patch* in Vision Transformer (Dosovitskiy, et al., 2021)). Ogni *token* viene elaborato in parallelo, consentendo ai *Transformers* di analizzare l'intera sequenza di input in una volta sola, a differenza delle *RNN* che eseguono un'elaborazione sequenziale. Questa elaborazione parallela permette non solo una maggiore efficienza computazionale, ma anche la capacità di catturare relazioni complesse e a lungo raggio tra i diversi *token*, sfruttando appunto il meccanismo di attenzione, che mette in relazione ciascun token della sequenza con ogni altro token. Essendo capaci di modellare sequenze, i *Transformers* sono anche in grado di generare sequenze intere a partire da sequenze parziali, tramite un meccanismo di decodifica (*Transformer Decoder*) e possono quindi essere utilizzati per generare dati in maniera autoregressiva.

Applicazioni dei Transformers. Nel campo dell'elaborazione del linguaggio naturale (NLP), i *Transformers* (Vaswani, et al., 2017) hanno dato origine a modelli linguistici di grande successo come GPT (*Generative Pre-trained Transformer*) (Radford & Narasimhan, 2018), che ha mostrato notevoli capacità di generazione di testo, comprensione del linguaggio, traduzione automatica e altro ancora. Grazie alla loro architettura, i *Transformers* possono considerare il contesto di ogni parola all'interno di un testo, migliorando significativamente la qualità della generazione e della comprensione del linguaggio rispetto ai modelli precedenti. I *Transformers* hanno trovato applicazioni anche nella visione artificiale, con l'introduzione di modelli come *Vision Transformer (ViT)* (Dosovitskiy, et al., 2021). In questo contesto, le immagini vengono suddivise in *patch* che vengono trattate come token equivalenti a parole. Il modello può quindi apprendere relazioni complesse tra differenti parti di un'immagine, superando in alcuni casi le prestazioni delle *CNN* per compiti come la classificazione e la segmentazione di immagini. Oltre che per NLP e *computer vision*, i *Transformers* sono stati impiegati in una varietà di altri ambiti, come il riconoscimento del parlato (Dong, Xu, & Xu, 2018), la generazione di musica (Shih, Wu, Zalkow, Müller, & Yang, 2022) e la bioinformatica (Zhang, et al., 2023). La flessibilità del loro meccanismo di attenzione li rende adatti a modellare complesse relazioni in dati di natura diversa, aprendo nuove possibilità in campi precedentemente dominati da modelli specifici per ciascun tipo di dati.

I Transformers rappresentano quindi una classe di modelli estremamente potente e versatile, il cui meccanismo di attenzione permette di catturare relazioni complesse nei dati, facilitando compiti di generazione e comprensione su una scala prima inimmaginabile. La loro continua evoluzione e il loro

adattamento a nuovi ambiti evidenziano l'importanza di questa architettura nel panorama attuale dell'Intelligenza Artificiale.

2.5 I modelli generativi basati su *Diffusion Models*

I *Diffusion Models* (Sohl-Dickstein, Weiss, Maheswaranathan, & Ganguli, 2015) rappresentano un approccio recente alla generazione di dati, che ha suscitato notevole interesse per la capacità di produrre risultati di alta qualità, specialmente nella generazione di immagini, audio e altri tipi di dati complessi. Questi modelli si basano su un processo di diffusione che trasforma gradualmente i dati in un rumore casuale, per poi apprendere a invertire questo processo per generare nuovi dati a partire dal rumore. Nello specifico, il funzionamento dei *Diffusion Models* può essere suddiviso in due fasi principali: la fase di diffusione (*forward process*) e la fase di *denoising* (*reverse process*). Nella fase di diffusione, si parte da un'immagine (o altro tipo di dato) e si applica iterativamente un processo che aggiunge rumore, portando progressivamente i dati verso uno stato di puro rumore, seguendo una catena di Markov (§ 1). Nella fase di *denoising*, il modello apprende a invertire questo processo partendo dal rumore e ricostruendo passo dopo passo l'immagine originale (o un'immagine nuova ma coerente con il dataset di addestramento), imparando quindi effettivamente la distribuzione dei dati.

Varianti dei *Diffusion Models*. I *Conditional Diffusion Models* vengono addestrati per generare dati condizionati da qualche input specifico, come una frase descrittiva per la generazione di immagini o una melodia base per la creazione di accompagnamenti musicali. Questa variante permette la generazione di dati mirati e personalizzati a seconda della descrizione del *prompt* testuale utilizzato.

Gli *Score-Based Generative Models* di (Song & Ermon, 2019) utilizzano una funzione di ottimizzazione che stima il gradiente del logaritmo della probabilità dei dati rispetto al rumore ad ogni iterazione del processo di diffusione. Questo approccio permette di guidare più efficacemente il processo di *denoising* verso la generazione di dati realistici. I *Denoising Diffusion Probabilistic Models* (*DDPMs*), proposti da (Ho, Jain, & Abbeel, 2020), rappresentano una significativa evoluzione dei *diffusion models*, introducendo un *framework* probabilistico rigoroso per il processo di *denoising* e migliorando notevolmente la qualità e l'efficienza della generazione dei dati.

I modelli generativi basati su *Diffusion Models* rappresentano una delle aree più promettenti e in rapida evoluzione nell'intelligenza artificiale generativa. La loro combinazione unica di potenza generativa e versatilità li rende strumenti

preziosi per esplorare nuove frontiere nella creazione di contenuti sintetici, aprendo nuove possibilità per applicazioni creative e tecniche.

2.6 Le Graph Neural Networks (GNNs) e il loro utilizzo con dati strutturati

Le *Graph Neural Networks* (GNNs) (Scarselli, Gori, Tsoi, Hagenbuchner, & Monfardini, 2008) sono emerse come una potente classe di modelli per l'elaborazione di dati strutturati sotto forma di grafi. Questi modelli sono particolarmente adatti a catturare le relazioni complesse e le dipendenze strutturali presenti nei grafi relazionali, che sono comuni in numerosi ambiti applicativi, come le reti sociali, i sistemi di raccomandazione, la chimica computazionale e la bioinformatica. Il principio di base delle GNN si fonda sull'aggregazione di informazioni dai vicini di un nodo all'interno di un grafo. Ogni nodo del grafo riceve informazione dai suoi vicini e, attraverso una funzione di aggregazione, combina queste informazioni per aggiornare il proprio stato. Questo processo iterativo consente ai nodi di catturare informazioni locali e globali dal grafo. Il risultato finale può essere un vettore di caratteristiche per ogni nodo o per l'intero grafo, a seconda del compito specifico (ad esempio, classificazione dei nodi, classificazione dei grafi, previsione dei collegamenti tra nodi). Le GNN sono state applicate con successo in una vasta gamma di compiti, dalla previsione delle proprietà dei composti chimici (Zang, Zhao, & Tang, 2023) alla generazione di nuove molecole, dalla classificazione dei nodi e dei grafi alla previsione di interazioni in reti complesse (Khemani, Patil, Kotecha, & Tanwar, 2024). La loro capacità di modellare direttamente le relazioni e le dipendenze tra gli elementi in un dataset le rende particolarmente preziose in contesti dove è fondamentale preservare la struttura dei dati.

Varianti delle GNN. Le *Graph Convolutional Networks* (GCNs) proposte da (Kipf & Welling, 2017) generalizzano le reti convoluzionali ai grafi, utilizzando un'operazione di convoluzione sui grafi che permette di apprendere rappresentazioni dei nodi efficaci basate sui vicini. Le *Graph Attention Networks* (GATs) introdotte da (Veličković, et al., 2018) implementano meccanismi di attenzione nei grafi, permettendo al modello di attribuire importanze diverse ai vicini di un nodo durante l'aggregazione delle informazioni, migliorando la flessibilità e la capacità di adattamento del modello. Le *Generative Graph Neural Networks* estendono l'applicazione delle GNN alla generazione di grafi. Ad esempio, il modello *GraphRNN* (You, Ying, Ren, Hamilton, & Leskovec, 2018) genera grafi sequenzialmente, nodo per nodo e connessione per connessione, apprendendo la distribuzione di grafi complessi e la loro struttura.

Le GNN rappresentano un campo di ricerca dinamico e in rapida evoluzione, con possibili applicazioni in numerosi domini scientifici e tecnologici. La loro capacità unica di catturare e modellare le relazioni complesse nei dati grafici le rende uno strumento prezioso per l'analisi e la generazione di dati strutturati. Rispetto alle altre architetture, al momento le GNN non riescono a scalare la loro complessità in relazione alle precedenti architetture, come fanno invece i *Transformers* e i *Diffusion Models*. Si sta cercando di affrontare questo particolare problema con nuove metodologie che propongono di semplificare in maniera stocastica la struttura del grafo, in modo da ridurre il numero di connessioni da considerare, e introducendo il concetto di ipernodo – un nodo del grafo connesso a tutti gli altri – che possa servire da tramite per il passaggio dell'informazione (Shirzad, Velingker, Venkatachalam, Sutherland, & Sinop, 2023). Questo permette di risolvere problemi di complessità quadratica, come la risoluzione di puzzle, che necessita di confrontare ciascun pezzo con ogni altro (Scarpellini, Fiorini, Giuliari, Morerio, & Del Bue, 2024).

3. APPLICAZIONE DELL'IA GENERATIVA NEL MONDO DEL LAVORO

Lo sviluppo di nuovi modelli per l'Intelligenza Artificiale generativa ha gettato le basi per la creazione di nuove tecnologie che possono supportare il lavoratore nelle sue attività, aumentandone l'efficienza e riducendo il suo impegno in attività ripetitive. L'avvento e la progressiva diffusione dell'Intelligenza Artificiale rappresenta un fenomeno complesso in grado di avere un impatto determinante su numerosi aspetti della società, tra i quali sicuramente rientra il mercato del lavoro. L'importanza dell'IA risiede nel fatto che le sue ricadute si estendono a un ampio ventaglio di contesti del mercato del lavoro: dal lavoro amministrativo ai servizi per il cliente, dalla robotica alla logistica, per arrivare alle applicazioni nel campo della giustizia e della medicina. Nel seguito presentiamo come l'IA è applicata e potrebbe essere applicata in diversi settori nel mondo del lavoro, esaminando casi di studio precisi.

3.1 Amministrazione

L'adozione dell'Intelligenza Artificiale nelle pubbliche amministrazioni rappresenta un chiaro caso di studio per l'efficientamento dei servizi pubblici e l'ottimizzazione delle risorse. Al momento sono in corso di sviluppo diverse soluzioni: modelli generativi avanzati come GANs, *Diffusion Models*, *Transformers* e *Graph Neural Networks* (GNNs) vengono implementati in software che interessano vari aspetti dell'amministrazione pubblica, dalla semplificazione delle procedure burocratiche alla personalizzazione dei servizi per i cittadini. Nel seguito presentiamo alcuni casi specifici di implementazione.

Automazione documentale e assistenza virtuale. I *Transformers*, con la loro capacità di comprendere e generare linguaggio naturale, sono utilizzati per automatizzare la gestione documentale, analizzare in tempo reale le richieste dei cittadini e fornire risposte e documenti personalizzati. In particolare, i modelli generativi permetteranno un'ottimizzazione dei processi di compilazione ed estrazione automatica di informazioni dai documenti, riducendo la necessità di attività manuale nella compilazione, riducendo i margini di errore e permettendo al contempo una maggior attenzione alle situazioni che richiedono l'intervento di operatori umani. Inoltre, modelli di comprensione del testo alimentano assistenti virtuali capaci di aiutare i cittadini a orientarsi in procedure complesse, migliorando l'accessibilità e riducendo i tempi di attesa. Per esempio, l'Estonia, in prima fila nel campo dell'*e-Government*, ha introdotto il programma *e-Residency* che permette a imprenditori stranieri di avviare e gestire un'attività basata nell'UE, seguendo una procedura

digitale (Kerikmäe & Pärn-Lee, 2021). Questo sistema si appoggia su tecnologie avanzate di IA per semplificare i processi burocratici e garantire la sicurezza digitale.

Ottimizzazione logistica e pianificazione urbana. Grazie alla loro abilità nel modellare relazioni complesse tra dati strutturati, le GNNs vengono impiegate per ottimizzare la logistica urbana (Li, Zhou, & Pan, 2022), dalla gestione del traffico alla pianificazione delle infrastrutture. Analizzando i dati provenienti da sensori e sistemi IoT, modelli computazionali opportunamente addestrati possono prevedere flussi di traffico e suggerire modifiche alla viabilità per ridurre ingorghi e migliorare la qualità dell'aria. La pianificazione urbana è nelle prime fasi di adozione dell'innovazione portata dall'IA (Thomas W. Sanchez & Lim, 2023). Un problema molto complesso che le città devono affrontare è la gestione dell'uso del suolo e dei trasporti. Il cambiamento dell'ambiente urbano delle città influisce sulla gestione, organizzazione e pianificazione e delle relative infrastrutture di trasporto. In sintesi, alcune analisi preliminari mostrano che l'IA è in grado di apprendere, prevedere, stimare, archiviare, gestire e analizzare in modo efficace i dati relativi al traffico e agli insediamenti residenziali. Volendo fare riferimento a una applicazione concreta, a Singapore sono utilizzati dei modelli computazionali per ottimizzare i percorsi dei trasporti pubblici in base alla domanda prevista, migliorando l'efficienza del servizio e riducendo l'impatto ambientale (Huiling, Goh, & Ai, 2017).

Previsione e decisione nella pubblica sicurezza. Nel campo della pubblica sicurezza, i modelli di IA vengono utilizzati per analizzare grandi volumi di dati provenienti da telecamere di sorveglianza e sensori urbani, allo scopo di individuare in tempo reale possibili minacce alla sicurezza o situazioni di emergenza. L'impiego di *LSTM* e *Transformers* per la simulazione e previsione del flusso delle persone (Hasan, et al., 2021) (Yu, Ma, Ren, Zhao, & Yi, 2020) può anche aiutare i decisori a pianificare risposte più efficaci. In Giappone, sistemi basati su IA analizzano in tempo reale i flussi di persone in occasione di grandi eventi pubblici, per individuare e prevenire situazioni di rischio (Nishida, Onishi, & Hashimoto, 2023). I sistemi sono basati su simulatori del movimento delle folle in grado di generare grandi quantità di dati da utilizzare per addestrare algoritmi di previsione del rischio.

L'impiego dell'IA nelle pubbliche amministrazioni migliora non solo l'efficienza e la qualità dei servizi offerti ai cittadini, ma apre anche la strada a una maggiore trasparenza e partecipazione civica, dimostrando come la tecnologia possa essere un alleato prezioso nella gestione della cosa pubblica.

3.2 Servizi e assistenza clienti nel settore privato

Molte attività di assistenza al cliente potranno essere automatizzate o semi-automatizzate tramite la creazione di *chatbot* che risponderanno prontamente alle esigenze più comuni, lasciando all'operatore umano il compito di intervenire solo in caso di necessità, avendo così più tempo a disposizione e riducendo il carico di lavoro di una categoria già sottoposta ad intenso stress lavorativo. L'Intelligenza Artificiale ha rivoluzionato il campo dei servizi e dell'assistenza clienti nel settore privato, migliorando significativamente l'efficienza e la personalizzazione dei servizi offerti. Sistemi di IA come *chatbot* basati su modelli del linguaggio che usano *Transformers*, sistemi di raccomandazione avanzati e assistenti virtuali (Roller, et al., 2021) sono solo alcuni esempi di impiego di queste tecnologie per migliorare l'esperienza del cliente.

Chatbot e Assistenza Clienti Automatizzata. I *chatbot* basati su IA, alimentati da modelli linguistici avanzati come GPT di OpenAI, con un'opportuna integrazione, offrono 24/7 un'assistenza clienti immediata e personalizzata. Questi sistemi sono in grado di comprendere le richieste in linguaggio naturale, fornendo risposte accurate e assistenza in tempo reale. L'addestramento di un *bot* avviene attraverso l'inserimento di documentazione riguardante l'argomento di discussione oppure utilizzando lo storico di iterazioni operatore-cliente durante il servizio di assistenza online. Le problematiche sensibili riguardano come strutturare il modello conversazionale senza il complesso inserimento continuo di regole specifiche (Tyen, Brenchley, Caines, & Buttery, 2022). Un esempio concreto riguarda la banca online "Revolut", che utilizza *chatbot* avanzati per gestire le richieste dei clienti, riducendo i tempi di attesa e migliorando la soddisfazione del cliente. Il sistema è in grado di risolvere autonomamente una vasta gamma di problemi, dall'assistenza nelle transazioni alla segnalazione di operazioni sospette (Scotto Di Luzio, 2021).

Sistemi di raccomandazione personalizzati. I sistemi di raccomandazione basati su IA analizzano i dati degli utenti per fornire suggerimenti personalizzati, migliorando l'esperienza di acquisto e la fidelizzazione del cliente. Questi sistemi utilizzano vari modelli IA, con soluzioni in continua evoluzione di pari passo con i risultati scientifici. Storicamente sono stati creati molti dataset di apprendimento automatico per risolvere problemi di raccomandazione personalizzati, ben prima dell'avvento del *deep learning* e dei

modelli recenti esaminati sopra (Zhou, Wilkinson, Schreiber, & Pan, 2008). I sistemi di raccomandazione presentano molteplici possibilità di applicazioni, e grandi gruppi dell'e-Commerce (Amazon, Alibaba, etc.) stanno utilizzando sistemi avanzati di raccomandazione per suggerire prodotti ai propri clienti sulla base delle loro abitudini di acquisto pregresse, delle pagine visualizzate e del comportamento di ricerca. In questo caso è complesso ricondurre il problema a un particolare modello di IA, data anche la vastità delle applicazioni e del tipo di materiale elaborato (audio, immagini, video, testo e altri meta-dati) (Roy & Dutta, 2022).

Assistenza personale e virtuale. L'evoluzione degli assistenti virtuali ha visto l'impiego intensivo di modelli avanzati di apprendimento, in particolare di NLP, e meccanismi di attenzione per potenziare la capacità di questi sistemi nel comprendere, elaborare e reagire in modo più efficace al linguaggio naturale degli utenti. Questi sistemi si basano su architetture di *deep learning* come le reti neurali ricorrenti (RNN), LSTM e, più recentemente, i *Transformers*. Questi modelli sono addestrati su vasti dataset di linguaggio umano per apprendere le complessità e le sfumature della lingua, permettendo agli assistenti virtuali di interpretare le richieste degli utenti e di fornire risposte coerenti e appropriate in base al contesto. Un altro ambito in costante crescita è la creazione verosimigliante di *Avatar* virtuali, in modo tale da migliorare l'interazione con l'utente. Aziende come Meta e Microsoft investono attivamente in metodologie per creare *Avatar* fotorealistici (Ma, et al., 2021) e sistemi di teletrasporto in Realtà Virtuale o Mista (Orts-Escolano, et al., 2016). Un caso concreto di questo mercato riguarda la creazione di video mediante descrizione testuale di Synthesia.¹ Il software permette di animare e dare voce a un *Avatar* utilizzando solo un *prompt* testuale ottenendo un'animazione il più naturale possibile dal punto di vista visivo, creando effettivamente un'impersonificazione più coinvolgente rispetto a un assistente testuale.

L'adozione di modelli IA nel settore dei servizi e dell'assistenza clienti non solo ha migliorato l'efficienza e la qualità, ma ha anche aperto nuove possibilità di personalizzazione e innovazione nel settore privato, trasformando il modo in cui le aziende interagiscono con i propri clienti.

¹ <https://www.synthesia.io/>

3.3 Logistica

L'intelligenza artificiale è sempre più integrata nel settore della logistica, con miglioramenti significativi in termini di efficienza operativa, riduzione dei costi e miglioramento del servizio clienti. Le applicazioni dell'IA nel campo della logistica spaziano dall'automazione robotica alla previsione della domanda, dall'ottimizzazione dei percorsi di consegna all'analisi predittiva per la manutenzione degli impianti.

Robotica e automazione. La robotica guidata dall'IA sta assumendo un ruolo sempre più centrale nei magazzini e nei centri di distribuzione, per automatizzare compiti ripetitivi come il *picking* (Mahler & Goldberg, 2017), il *packing* e il trasporto di merci. Questi robot sono dotati di sensori avanzati e algoritmi di *machine learning* che consentono loro di spostarsi autonomamente negli spazi di lavoro, migliorando la precisione e riducendo i tempi di evasione degli ordini. Inoltre, i sistemi robotici sono in grado di afferrare i colli in maniera affidabile, grazie a nuovi modelli di *grasping* basati su *Transformer* (Mohammadi, et al., 2023), che permettono una percezione migliorata degli elementi da trasportare. Nella logistica esistono già esempi di ottimizzazione estrema, dove l'impiego di una flotta di robot guidati dall'IA è uno standard de facto per movimentazioni di grandi volumi di merci. Scaffali interi di prodotti vengono spostati automaticamente verso le stazioni di imballaggio, riducendo significativamente il tempo necessario per evadere gli ordini e migliorando l'efficienza del magazzino. La penetrazione di questa tecnologia in aziende e medie dimensioni è più contenuta, a causa dei notevoli investimenti iniziali necessari per creare una infrastruttura sensoristica e robotica ad hoc. Ma il costante progresso sul fronte delle piattaforme e degli algoritmi faciliterà l'inserimento di questi sistemi in magazzini meno strutturati rispetto a quelli già costruiti nell'ottica di ospitare robot autonomi.

Smistamento merci e ottimizzazione dei percorsi. L'IA è in grado di analizzare dati riguardanti la movimentazione delle merci, non solo nel contesto della logistica di magazzino ma soprattutto nella movimentazione delle merci per l'ottimizzazione dei percorsi di consegna, analizzando enormi volumi di dati dei tragitti giornalieri, e per la determinazione dei percorsi più efficienti, integrando questi elementi con il fattore umano (Klumpp, 2018). Questo non solo riduce i tempi di consegna, ma contribuisce anche a ridurre il consumo di carburante e le emissioni di CO₂. Nel 2020 UPS ha introdotto il sistema ORION (*On-Road Integrated Optimization and Navigation*), un algoritmo avanzato che

analizza le consegne giornaliere e determina il percorso ottimale per ogni autista. ORION ha permesso a UPS di ridurre ogni anno milioni di chilometri di percorrenza e di tagliare le emissioni di anidride carbonica.

Previsione della domanda e gestione delle scorte. I modelli predittivi basati sull'IA consentono alle aziende di prevedere con maggiore precisione la domanda dei consumatori, ottimizzando la gestione delle scorte e riducendo i costi legati all'eccesso o alla carenza di scorte. In particolare, nel settore *retail* e della grande distribuzione, l'automatizzazione di funzioni manuali, come l'individuazione della rottura di *stock* mediante analisi di immagini (Rosado, Gonçalves, Costa, Ribeiro, & Soares, 2016), può incrementare le vendite e aiutare ad organizzare il magazzino e gli ordini ai fornitori. In questa direzione, Walmart utilizza algoritmi di previsione della domanda per ottimizzare le scorte nei suoi negozi e magazzini, garantendo che i prodotti maggiormente richiesti siano sempre disponibili, minimizzando al contempo l'eccesso di scorte.

L'integrazione dell'IA nel settore logistico sta migliorando non solo l'efficienza operativa ma sta apportando anche cambiamenti radicali nei modelli di business, consentendo alle aziende di rispondere più rapidamente alle esigenze del mercato e di offrire al cliente un servizio più affidabile e personalizzato. Questi sviluppi dimostrano le potenzialità dell'IA nel trasformare radicalmente il settore logistico, promuovendo l'innovazione e sostenendo la crescita a lungo termine.

3.4 Manifattura

L'introduzione dell'IA generativa nel settore manifatturiero segna una svolta nell'automazione, nella progettazione di prodotti, nella manutenzione preventiva e nella personalizzazione di massa. Queste tecnologie non solo ottimizzano i processi produttivi ma rendono possibili anche nuovi modelli di business e nuove strategie di sviluppo prodotto.

Automazione avanzata e controllo di qualità. L'impiego di sistemi IA nella visione artificiale per il controllo qualità automatizzato permette di identificare i difetti con maggiore precisione (Martelli, et al., 2018), a velocità impensabili per l'occhio umano (Haleem, Bustreo, & Del Bue, 2021). Per questo motivo le attività di ispezione automatizzate hanno avuto un impatto rilevante nell'industria come sistema rilevante di automatizzazione di processo. Recenti soluzioni riescono a produrre risultati rilevanti anche in assenza di dati di addestramento (Roth, et al., 2022), rendendone possibile l'applicazione in contesti dove i prodotti presentano un alto tasso di ricambio in produzione.

Inoltre, l'integrazione con robotica avanzata guidata dall'IA consente automazioni complesse nella linea di produzione, aumentando l'efficienza e riducendo i tempi di fermo macchina. BMW utilizza soluzioni di IA per eseguire compiti ripetitivi come il controllo qualità e la pianificazione delle disposizioni logistiche, migliorando l'efficienza della produzione e riducendo gli errori. Toyota ha collaborato con Invisible AI per implementare la visione computerizzata nelle sue fabbriche nordamericane, migliorando così la sicurezza, la qualità e l'efficienza delle attività.

Design generativo. L'utilizzo di modelli generativi nel design di prodotti consente di esplorare soluzioni innovative che massimizzano le prestazioni mantenendo i vincoli di produzione (Oh, Jung, Kim, Lee, & Kang, 2019), tenendo anche conto delle caratteristiche dei materiali impiegati (Buonamici, Carfagni, Furferi, Volpe, & Governi, 2020). Questo approccio supporta la creazione di componenti ottimizzati per la stampa 3D, favorendo la personalizzazione e la riduzione dei costi. Il design generativo ha anche un impatto nella creazione di nuovi sistemi autonomi che devono adattare la propria morfologia agli specifici compiti da eseguire (Alattas, Patel, & Sobh, 2019) (Bergonti, et al., 2023). Rispetto al "design statico" presenta un livello di complessità maggiore, dovendo considerare i vincoli fisici strutturali e materiali nella progettazione del sistema soddisfacendo al contempo i vincoli per la risoluzione del compito assegnato. Nel campo dell'energia, General Electric ha sviluppato modelli IA per analizzare milioni di variazioni di design in soli 15 minuti, accelerando significativamente la progettazione di turbine a gas e motori a reazione.

Manutenzione predittiva. L'analisi predittiva attraverso l'IA (Zonta, et al., 2020) genera modelli capaci di prevedere guasti prima che si verifichino basandosi sull'analisi continua dei dati raccolti dai sensori di macchinari. Questa metodologia utilizza strumenti computazionali per determinare quando sono necessari degli interventi di manutenzione. Basandosi sul monitoraggio continuo dell'integrità di una macchina o di un processo, consente di eseguire la manutenzione solo quando è effettivamente necessaria. Inoltre, consente di rilevare precocemente i guasti basandosi su dati storici, per mezzo di modelli generativi (Serradilla, Zugasti, Rodriguez, & Zurutuza, 2022) e fattori di integrità, utilizzando sensori come telecamere che rilevano automaticamente l'usura (Padalkar, Beltrán-González, Bustreo, Del Bue, & Murino, 2021), metodi di inferenza statistica e approcci ingegneristici (Carvalho, et al., 2019). La manutenzione predittiva migliora significativamente l'affidabilità degli impianti e riduce i costi associati a interruzioni non programmate.

Uno strumento di questo genere è vitale nelle centrali di produzione e trasformazione dell'energia, dove la manutenzione e l'arresto degli impianti hanno un impatto rilevante. La capacità di definire mediante modelli predittivi la possibilità di un danno (Costamagna, Giorgi, Moser, Serpico, & Trucco, 2019) è essenziale per ridurre i costi e per migliorare la vita utile degli impianti.

Robotica assistiva e collaborativa. I Robot collaborativi lavorano sinergicamente con il personale riducendo lo sforzo e il numero degli operatori per eseguire le attività quotidiane, specialmente quelle ripetitive e che pesano sull'apparato muscolo-scheletrico (Tirupachuri, Nava, Rapetti, Latella, & Pucci, 2019). Grazie all'IA, sistemi di questo genere potranno comprendere quando intervenire grazie a sensori e tecnologie che forniscono dati sul grado di rischio di una specifica attività lavorativa. Dove non sia possibile l'implementazione di sistemi automatizzati, si potrà intervenire per supportare gli esseri umani mediante l'ausilio di esoscheletri indossabili (Huysamen, et al., 2018) (Lorenzini, Lagomarsino, Fortini, Gholami, & Ajoudani, 2023) che si adattano alle attività dei lavoratori. Sarà così possibile ridurre il carico dei lavori gravosi, riducendo l'impatto sulla salute del personale e diminuendo i costi per il trattamento di patologie con tendenza alla cronicizzazione, con conseguente calo del carico sul Sistema Sanitario Nazionale (SSN). In questo contesto IIT ha sviluppato in collaborazione con INAIL esoscheletri robotici indossabili in grado di mitigare i fattori di rischio da sovraccarico biomeccanico degli operatori. L'obiettivo è giungere a una commercializzazione in tempi rapidi, in modo da fornire un ausilio agli operatori e alle operatrici in ambito industriale, manifatturiero, logistico e dell'edilizia civile.

L'introduzione dell'IA generativa nella manifattura promette non solo di migliorare l'efficienza e ridurre i costi, ma apre anche la strada a nuovi paradigmi di produzione, dove hanno un ruolo centrale la personalizzazione, l'innovazione e la sostenibilità. Le implicazioni di queste tecnologie non si limitano all'ottimizzazione operativa, facendo intravedere una manifattura in futuro più agile, resiliente e in linea con le esigenze di un mercato in rapida evoluzione.

3.5 Sanità e Farmaceutica

L'integrazione dell'intelligenza artificiale nel settore sanitario e farmaceutico sta migliorando significativamente la scoperta di nuovi farmaci, la gestione dei dati sanitari, l'assistenza ai medici nelle decisioni terapeutiche, e l'assistenza chirurgica tramite robot. Nuovi strumenti di IA permetteranno di gestire al meglio un maggior numero di persone nelle strutture sanitarie, anche a fronte

di una potenziale riduzione del personale ospedaliero. L'IA velocizzerà le diagnosi e aumenterà l'accuratezza delle terapie permettendo la realizzazione di cure personalizzate e la correlazione di grandi masse di dati. Inoltre, in questo campo l'IA sarà funzionale all'efficientamento di tutti quei dispositivi per l'acquisizione di dati clinici volti alla cura degli esseri umani o alla cura a distanza anche di pazienti che si trovano in zona svantaggiate e/o remote.

Supporto alle analisi di dati biomedicali. I nuovi modelli di IA sono uno strumento che trova sempre maggiore impiego nell'analisi di immagini medicali, come le radiografie e le immagini a risonanza magnetica (MRI). In particolare, il modello *U-Net* consente una segmentazione precisa delle strutture anatomiche complesse, migliorando significativamente la precisione diagnostica e la pianificazione del trattamento. Questi sistemi hanno la capacità di supportare il personale medico nella definizione della prognosi di un paziente. Ad esempio, durante la pandemia COVID-19, un'iniziativa italiana multi-centrica di ospedali, cliniche, istituti di ricerca e aziende ha permesso la realizzazione di un sistema assistivo per la prognosi del virus che utilizzava sia i dati delle radiografie, quindi immagini, sia il testo ricavato dalla cartella clinica dei pazienti (Soda, et al., 2021).

Genomica computazionale. Le tecniche di *deep learning* come i *Diffusion Models* e le reti neurali convoluzionali (*CNN*) sono fondamentali per gestire la grandissima mole di dati che normalmente entra in gioco nell'analisi genetica e nella medicina personalizzata. Queste tecniche permettono di interpretare sequenze genetiche complesse, identificare varianti genetiche associate a malattie e definire terapie personalizzate. Un esempio specifico nel settore è l'uso di algoritmi di *deep learning* per analizzare i dati di sequenziamento del DNA, facilitando la scoperta di biomarcatori per malattie come il cancro e le malattie cardiovascolari. Questo campo sta vivendo una rapida evoluzione con aziende biotecnologiche e farmaceutiche che integrano queste tecnologie per accelerare la ricerca e lo sviluppo di nuovi farmaci. Questa tecnologia è in via di integrazione nel Sistema Sanitario Nazionale tramite uno studio pilota del Centro di medicina personalizzata, preventiva e predittiva in Valle d'Aosta (CMP³VdA).² L'infrastruttura di laboratori per la genomica e l'IA cercheranno di migliorare l'accesso alla diagnosi e alle terapie personalizzate attraverso lo studio approfondito del DNA di ogni paziente, abbinato allo studio dei dati

² <https://5000genomivda.it/it/>

relativi alla storia clinica e dello stile di vita, grazie a specifici software analitici e predittivi.

Elaborazione delle cartelle cliniche. I modelli *Transformers* stanno cambiando la gestione delle cartelle cliniche, estraendo informazioni vitali da grandi volumi di testo non strutturato. Questo permette non solo un miglioramento nella precisione delle diagnosi, ma anche una maggiore efficienza nella ricerca clinica, facilitando l'identificazione di *pattern* e correlazioni non evidenti nell'ambito dei dati sanitari. Grandi quantità di informazioni e dati clinici possono essere utilizzate per diagnosticare una malattia, ma non è possibile garantire l'accuratezza della diagnosi ed è impossibile escludere diagnosi errate, sia da parte di un operatore umano che di un operatore artificiale. Tuttavia, i modelli di intelligenza artificiale sono estremamente abili nel gestire grandi quantità di dati. L'elaborazione e l'estrazione integrative possono consentire una diagnosi della malattia più accurata grazie all'efficienza e all'efficacia dell'apprendimento e dell'addestramento di campioni di grandi dimensioni (Huang, Yang, Fong, & Zhao, 2020). Uno scenario di rilevante importanza è la creazione di modelli a larga scala (Moor, et al., 2023), avendo a disposizione i dati dai servizi sanitari nazionali, integrando informazioni provenienti da diverse sorgenti (multimodali) e includendo informazione di contesto in ambito medico.

Scoperta di nuovi materiali e farmaci. L'adozione di *GNNs* e *Diffusion Models* nel processo di scoperta dei farmaci sta accelerando significativamente la ricerca farmaceutica, riducendo il tempo e i costi associati allo sviluppo di nuovi farmaci, promettendo di portare sul mercato terapie innovative in tempi più rapidi rispetto al passato. Questi modelli si dividono in due categorie principali: la prima categoria include i modelli puramente generativi, ovvero in grado di generare direttamente nuove molecole, con le proprietà desiderate. Fanno parte di questa categoria i recenti modelli basati su *Diffusion Models* (Hoogeboom, Satorras, Vignac, & Welling, 2022) (Weiss, et al., 2023) per la sintesi di piccole molecole, per la generazione delle strutture cristalline di nuovi materiali (Yang, et al., 2023). La seconda categoria include invece tutti quei metodi che sono in grado di valutare rapidamente la plausibilità di un gran numero di molecole, materiali o complessi sintetizzati virtualmente (Corso, Stärk, Jing, Barzilay, & Jaakkola, 2023).

In conclusione, l'integrazione dell'IA nel settore sanitario e farmaceutico non solo sta migliorando l'efficacia delle diagnosi e dei trattamenti ma sta anche rivoluzionando la ricerca farmaceutica. L'impiego di metodologie avanzate come *U-Net*, *Transformers*, *CNN*, e modelli di diffusione promette di giungere a

una medicina più personalizzata, accurata e accessibile, segnando un'era di trasformazione digitale nella cura della salute.

3.6 Settore finanziario e bancario

I modelli di IA generativa, in particolare, hanno mostrato potenzialità significative in diverse aree applicative nel settore finanziario e bancario, sfruttando la capacità di elaborare e interpretare grandi volumi di dati con precisione e velocità superiori rispetto ai metodi tradizionali. Rispetto ad altri campi di applicazione, spesso i dati finanziari sono già disponibili in formato digitale e sono ragionevolmente strutturati, e possono quindi essere usati come sorgente per ottimizzare modelli per l'analisi e il *forecasting*.

Analisi predittiva per il trading algoritmico. L'impiego di reti neurali ricorrenti (RNN) e *transformers* nel trading algoritmico ha permesso di prevedere con maggiore accuratezza le fluttuazioni dei prezzi dei mercati finanziari. Questi modelli analizzano le serie storiche dei prezzi, identificando schemi e tendenze che potrebbero sfuggire all'analisi di una singola persona od organizzazione, per automatizzare le decisioni di trading. La ricerca ha dimostrato che l'integrazione dell'IA nel trading algoritmico migliora la redditività, riducendo contemporaneamente il rischio di perdite significative, segnalando fattori di rischio difficilmente computabili con altre tecniche. Aladdin è un sistema elettronico realizzato da *BlackRock Solutions*, la divisione di gestione del rischio di una delle più grandi società di gestione degli investimenti al mondo. Si basa su una tecnologia open source e utilizza NLP per analizzare grandi volumi di dati provenienti da documenti, come notizie e rapporti dei broker. Un'applicazione di questo sistema è l'analisi di dati sull'attività di trading al fine di rilevare modelli complessi e prevedere le transazioni che hanno maggiori probabilità di non avere un esito positivo.

Automazione del servizio clienti con *chatbot* intelligenti. L'automazione del servizio clienti nel settore bancario e finanziario attraverso l'uso di *chatbot* intelligenti (§ 3.2) si sta rivelando una svolta significativa che consente alle banche di offrire un servizio clienti efficiente e personalizzato su larga scala. Questi *chatbot*, alimentati da tecnologie di intelligenza artificiale (IA) come il *Natural Language Processing* (NLP) e il *machine learning*, sono capaci di comprendere ed elaborare le richieste dei clienti in linguaggio naturale, offrendo risposte immediate e accurate. Questi *chatbot* non solo rispondono a domande frequenti, ma sono anche in grado di eseguire operazioni bancarie come trasferimenti di fondi, pagamento di bollette e gestione di carte di credito, il tutto con un intervento umano diretto ridotto al minimo.

La capacità di apprendere dalle interazioni passate permette a questi assistenti virtuali di migliorare continuamente la qualità del servizio offerto, personalizzando l'esperienza in base alle preferenze e alle esigenze specifiche di ciascun cliente.

Prevenzione delle frodi finanziarie. L'adozione di modelli GAN per il rilevamento di anomalie ha segnato un progresso significativo nella lotta contro le frodi finanziarie. Il modello viene addestrato per generare frodi sintetiche che il discriminatore cerca di analizzare per capire se siano vere o false (Cheah, Yang, & Lee, 2023). In questo modo è possibile risolvere il problema del bilanciamento dei dati, dove le transazioni corrette sono in numero maggiore rispetto a quelle attribuibili a frodi. Questo permette di utilizzare il discriminatore per analizzare le transazioni in tempo reale, identificando comportamenti sospetti potenzialmente indicativi di tentativi di frode, permettendo alle banche di intervenire prontamente per prevenire perdite economiche. Per esempio, i servizi finanziari CO-OP in collaborazione con Feedzai includono un sistema per la valutazione del rischio della transazione basato sull'apprendimento automatico. Il sistema funziona con tutti i tipi di pagamento, comprese carte, voucher, *token* di carte prepagate o bitcoin. Inoltre, i maggiori circuiti di carte di credito hanno dichiarato di far uso massicciamente di strumenti di IA per l'approvazione delle transazioni in base allo storico dell'utente e alle informazioni di contesto (Roy, et al., 2018).

Automazione del processo di esame documentale. Questa tecnologia è particolarmente importante per gli istituti finanziari, dove la necessità di esaminare accuratamente contratti e documenti legali è fondamentale per la gestione del rischio, la conformità normativa e l'efficienza operativa. I modelli di *machine learning* hanno rivoluzionato la valutazione del rischio di credito, fornendo previsioni più accurate sulla solvibilità dei richiedenti. Analizzando un vasto insieme di dati, anche non strutturati, questi modelli offrono una valutazione del rischio più granulare, permettendo decisioni più rapide e informate sull'erogazione di credito. La ricerca in questo campo ha mostrato che l'IA può ridurre significativamente i tassi di inadempienza, migliorando la stabilità finanziaria delle banche. Inoltre, l'esame manuale di documenti legali e contratti è un processo che richiede molto tempo, è soggetto a errori umani e rappresenta un costo significativo per le banche e le istituzioni finanziarie. L'introduzione di sistemi IA in questo contesto può trasformare radicalmente l'efficienza e l'accuratezza della gestione di questi documenti (Hassani, Huang, Silva, & Ghodsi, 2020). Un esempio emblematico di questa applicazione è il sistema COiN (Contract Intelligence) implementato da JP Morgan. Questo

sistema utilizza tecnologie di *machine learning* per automatizzare l'analisi e la revisione di contratti commerciali. La piattaforma è capace di estrarre in pochi secondi dati rilevanti, identificare clausole, obblighi e diritti, un compito che tradizionalmente richiederebbe centinaia di ore di lavoro umano.

3.7 Professione legale e sviluppo di modelli IA ottimizzati

Nel contesto legale, l'intelligenza artificiale sta emergendo come uno strumento che offre ai professionisti la possibilità di semplificare l'accesso alla grande vastità di documenti legali (Rodgers, Armour, & Sako, 2023), mediante applicativi di ricerca giuridica che analizzano vasti archivi di leggi, precedenti, articoli e altri documenti legali, identificando il materiale rilevante. L'impiego di tecnologie di IA riguarda prevalentemente motori di *Natural Language Processing* (NLP), che grazie alla capacità di elaborare dati testuali possono migliorare l'efficienza con cui gli avvocati e gli studi legali accedono alle informazioni, in modalità similari a quanto illustrato nella sezione § 3.6 per il settore finanziario.

Modelli di NLP come BERT e GPT-3 possono essere ottimizzati e addestrati nuovamente per comprendere la struttura del linguaggio giuridico (Yue, et al., 2023). Un primo caso di applicazione a questo dominio è LEGAL-BERT (Chalkidis, Fergadiotis, Malakasiotis, Aletras, & Androutsopoulos, 2020), una specializzazione di un modello del linguaggio BERT (Devlin, Chang, Lee, & Toutanova, 2019) all'ambito legale, in seguito testato su diversi compiti o *task* legali con un dataset in lingua inglese estratto da diversi contesti giuridici internazionali (europeo, inglese e USA). Come già indicato nella sezione § 2, la raccolta di dati di qualità gioca un ruolo fondamentale per l'addestramento di un modello. Mediante tecniche di *web scraping* da database disponibili online come EURLEX, HUDOC, SEC-EDGAR, è stato raccolto un corpus di dati di 12 Gigabyte, per un totale di più di 360 mila documenti. L'addestramento del modello segue sia tecniche standard di *fine-tuning*, ossia utilizza i parametri di un modello standard BERT, ottimizzato in seguito utilizzando i dati di testi legali, sia un addestramento da zero, che apprende il modello esclusivamente dal linguaggio legale. I compiti possono essere considerati comuni nella comunità NLP e riguardano la classificazione dei documenti legali, il riconoscimento delle persone giuridiche, e la risposta a domande di natura giuridica. La tecnica di *fine-tuning* risulta la più promettente per i compiti valutati, in concordanza con diversi esperimenti di adattamento e specializzazione del modello del linguaggio in diversi ambiti scientifici (per esempio biologia, fisica e medicina).

Nel contesto italiano, il modello del linguaggio LamBERTa (Tagarelli & Simeri, 2022) utilizza una procedura simile a LEGAL-BERT, con la differenza che il modello è addestrato e ottimizzato sull'intero Codice civile italiano. Il problema affrontato nello specifico è il recupero di articoli di legge, ossia identificare articoli di interesse che possono essere d'aiuto per dare una risposta adeguata a una domanda che esprime un quesito giuridico. Il problema viene affrontato con una modalità supervisionata, avendo a disposizione durante l'addestramento sia il quesito giuridico sia l'indicazione degli articoli afferenti allo stesso. Le complessità specifiche riguardano l'elevato numero di variabilità delle domande e il loro contesto, unitamente alla scarsità di dati per l'addestramento. Il modello utilizza un modello BERT pre-addestrato in italiano, con un corpus di dati di 81 Gigabyte, successivamente specializzato su una sequenza di *task* di classificazione basati sul Codice civile italiano. Il problema principale sorge durante l'addestramento sul testo del Codice civile, data l'assenza di un dataset annotato. Questo problema è risolto utilizzando una tecnica di NLP non-supervisionata per etichettare i vari articoli nel testo, per associare una particolare categoria ad uno specifico articolo senza ricorrere all'intervento umano. Questa procedura ha il vantaggio di creare un alto numero di dati per l'addestramento, ma presenta difficoltà nella valutazione dell'accuratezza del processo non-supervisionato.

Il modello ITALIAN-LEGAL-BERT (Licari & Comandè, 2024) estende e adatta la procedura di LEGAL-BERT, utilizzando dati estratti dal sistema legislativo italiano per eseguire un ulteriore *fine-tuning*. L'addestramento di ITALIAN-LEGAL-BERT si avvale di un set di dati composto da 235 mila documenti che riguardano casi di diritto civile. Per rendere possibile l'addestramento da zero del modello italiano, si è resa necessaria un'ulteriore parte di testo, con circa 300.000 documenti relativi a casi di diritto penale. È importante osservare che i documenti legali utilizzati in questo studio non sono disponibili pubblicamente, al contrario sono stati forniti direttamente da diversi tribunali italiani. I compiti eseguiti per la valutazione del modello riguardano l'identificazione dei soggetti nominati nella sentenza, la classificazione delle parti di una sentenza, la similarità tra due sentenze, e la classificazione del tipo di documento. In questo caso, la scelta del miglior modello (con *fine-tuning* o da zero) dipende in particolare dal tipo di compito eseguito: si osservano risultati migliori nei modelli con *fine-tuning*, mentre i modelli addestrati da zero mostrano una migliore abilità in contesti più specifici. Le attuali limitazioni di questi modelli riguardano soprattutto l'esigenza di avere a disposizione ulteriore tempo di elaborazione, risorse di calcolo e capacità computazionali durante

l'addestramento. La dimensione dei dataset (Niklaus, et al., 2023) rappresenta un'altra condizione limitante che potrebbe migliorare avendo a disposizione informazioni su tutte le possibili sentenze, e non ristrette solo a taluni campi.

4 BIBLIOGRAFIA

- Alattas, R. J., Patel, S., & Sobh, T. M. (2019). Evolutionary Modular Robotics: Survey and Analysis. *Journal of Intelligent & Robotic Systems*, 95, 815–828.
- Ali, J., Kleindessner, M., Wenzel, F., Budhathoki, K., Cevher, V., & Russell, C. (2023). Evaluating the Fairness of Discriminative Foundation Models in Computer Vision. *Proceedings of the 2023 AAAI/ACM Conference on AI, Ethics, and Society* (p. 809–833). New York, NY, USA: Association for Computing Machinery.
- Baum, L. E., & Petrie, T. (1966). Statistical Inference for Probabilistic Functions of Finite State Markov Chains. *The Annals of Mathematical Statistics*, 37, 1554 – 1563.
- Bergonti, F., Nava, G., Wüest, V., Paolino, A., L’Erario, G., Pucci, D., & Floreano, D. (2023). Co-Design Optimisation of Morphing Topology and Control of Winged Drones. *ArXiv*, abs/2309.13948.
- Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., von Arx, S., et al. (2021). On the Opportunities and Risks of Foundation Models. *arXiv preprint arXiv:2108.07258*.
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., . . . Amodei, D. (2020). Language Models are Few-Shot Learners. In H. Larochelle, M. Ranzato, R. Hadsell, M. F. Balcan, & H. Lin (A cura di), *Advances in Neural Information Processing Systems*. 33, p. 1877–1901. Curran Associates, Inc.
- Buonamici, F., Carfagni, M., Furferi, R., Volpe, Y., & Governi, L. (2020). Generative design: An explorative study. *Computer-Aided Design and Applications*, 18, 144 – 155.
- Carvalho, T. P., Soares, F. A., Vita, R., da P. Francisco, R., Basto, J. P., & Alcalá, S. G. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024.
- Chalkidis, I., Fergadiotis, M., Malakasiotis, P., Aletras, N., & Androutsopoulos, I. (2020, November). LEGAL-BERT: The Muppets straight out of Law School. In T. Cohn, Y. He, & Y. Liu (A cura di), *Findings of the Association for Computational Linguistics: EMNLP 2020* (p. 2898–2904).

- Cheah, P. C., Yang, Y., & Lee, B. G. (2023). Enhancing Financial Fraud Detection through Addressing Class Imbalance Using Hybrid SMOTE-GAN Techniques. *International Journal of Financial Studies*, 11.
- Corso, G., Stärk, H., Jing, B., Barzilay, R., & Jaakkola, T. (2023). DiffDock: Diffusion Steps, Twists, and Turns for Molecular Docking. *International Conference on Learning Representations (ICLR)*.
- Costamagna, P., Giorgi, A. D., Moser, G., Serpico, S. B., & Trucco, A. (2019). Data-driven techniques for fault diagnosis in power generation plants based on solid oxide fuel cells. *Energy Conversion and Management*, 180, 281-291.
- Cunningham, H., Ewart, A., Riggs, L., Huben, R., & Sharkey, L. (2023). Sparse Autoencoders Find Highly Interpretable Features in Language Models. *ArXiv*, abs/2309.08600.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., & Fei-Fei, L. (2009). ImageNet: A large-scale hierarchical image database. *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 248-255.
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019, June). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. In J. Burstein, C. Doran, & T. Solorio (A cura di), *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)* (p. 4171–4186). Minneapolis: Association for Computational Linguistics.
- Dong, L., Xu, S., & Xu, B. (2018). Speech-Transformer: A No-Recurrence Sequence-to-Sequence Model for Speech Recognition. *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, (p. 5884-5888).
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Houselby, N. (2021). An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. *International Conference on Learning Representations*.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., . . . Bengio, Y. (2014). Generative Adversarial Nets. In Z. Ghahramani, M. Welling, C. Cortes, N. Lawrence, & K. Q. Weinberger (A cura di), *Advances in Neural Information Processing Systems*. 27. Curran Associates, Inc.
- Haleem, N., Bustreo, M., & Del Bue, A. (2021). A computer vision based online quality control system for textile yarns. *Computers in Industry*, 133, 103550.

- Hasan, I., Setti, F., Tsesmelis, T., Belagiannis, V., Amin, S., Del Bue, A., Galasso, F. (2021, April). Forecasting People Trajectories and Head Poses by Jointly Reasoning on Tracklets and Vislets. *IEEE transactions on pattern analysis and machine intelligence*, 43(4), 1267-1278.
- Hassani, H., Huang, X., Silva, E., & Ghodsi, M. (2020). Deep Learning and Implementations in Banking. *Annals of Data Science*, 7, 433–446.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016, June). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Hestness, J., Narang, S., Ardalani, N., Diamos, G., Jun, H., Kianinejad, H., . . . Zhou, Y. (2017). Deep learning scaling is predictable, empirically. *arXiv preprint arXiv:1712.00409*.
- Ho, J., Jain, A., & Abbeel, P. (2020). Denoising Diffusion Probabilistic Models. In H. Larochelle, M. Ranzato, R. Hadsell, M. F. Balcan, & H. Lin (A cura di), *Advances in Neural Information Processing Systems*. 33, p. 6840–6851. Curran Associates, Inc.
- Hochreiter, S., & Schmidhuber, J. (1997, November). Long Short-Term Memory. *Neural Comput.*, 9, 1735–1780.
- Hoogeboom, E., Satorras, V. G., Vignac, C., & Welling, M. (2022). Equivariant Diffusion for Molecule Generation in 3D. In K. Chaudhuri, S. Jegelka, L. Song, C. Szepesvari, G. Niu, & S. Sabato (A cura di), *Proceedings of the 39th International Conference on Machine Learning*. 162, p. 8867–8887. PMLR.
- Huang, S., Yang, J., Fong, S., & Zhao, Q. (2020). Artificial intelligence in cancer diagnosis and prognosis: Opportunities and challenges. *Cancer Letters*, 471, 61-71.
- Huiling, E., Goh, B., & Ai, “. (2017, February 26). Robotics and Mobility as a Service: the Case of Singapore. *Field Actions Science Reports. The journal of field actions* p. 26-29
- Huysamen, K., de Looze, M., Bosch, T., Ortiz, J., Toxiri, S., & O'Sullivan, L. W. (2018). Assessment of an active industrial exoskeleton to aid dynamic lifting and lowering manual handling tasks. *Applied Ergonomics*, 68, 125-131.
- Kaplan, J., McCandlish, S., Henighan, T., Brown, T. B., Chess, B., Child, R., . . . Amodei, D. (2020). Scaling laws for neural language models. *arXiv preprint arXiv:2001.08361*.

- Karras, T., Aila, T., Laine, S., & Lehtinen, J. (2018). Progressive Growing of GANs for Improved Quality, Stability, and Variation. *International Conference on Learning Representations*.
- Karras, T., Laine, S., & Aila, T. (2019, June). A Style-Based Generator Architecture for Generative Adversarial Networks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Karras, T., Laine, S., Aittala, M., Hellsten, J., Lehtinen, J., & Aila, T. (2020, June). Analyzing and Improving the Image Quality of StyleGAN. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Kerikmäe, T., & Pärn-Lee, E. (2021). Legal dilemmas of Estonian artificial intelligence strategy: in between of e-society and global race. *AI & SOCIETY*, 36, 561–572.
- Khemani, B., Patil, S., Kotecha, K., & Tanwar, S. (2024). A review of graph neural networks: concepts, architectures, techniques, challenges, datasets, applications, and future directions. *Journal of Big Data*, 11, 18
- Kingma, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. *CoRR*, abs/1412.6980.
- Kingma, D. P., & Welling, M. (2014). Autoencoding Variational Bayes. *International Conference on Learning Representations*.
- Kipf, T. N., & Welling, M. (2017). Semi-Supervised Classification with Graph Convolutional Networks. *International Conference on Learning Representations*.
- Klumpp, M. (2018). Automation and artificial intelligence in business logistics systems: human reactions and collaboration requirements. *International Journal of Logistics Research and Applications*, 21, 224-242.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. In F. Pereira, C. J. Burges, L. Bottou, & K. Q. Weinberger (A cura di), *Advances in Neural Information Processing Systems*. 25. Curran Associates, Inc.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436–444.
- Li, Y., & Vasconcelos, N. (2019, June). REPAIR: Removing Representation Bias by Dataset Resampling. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*.

- Li, Y., Zhou, X., & Pan, M. (2022). Graph Neural Networks in Urban Intelligence. In L. Wu, P. Cui, J. Pei, & L. Zhao (A cura di), *Graph Neural Networks: Foundations, Frontiers, and Applications* (p. 579–593). Singapore: Springer Nature Singapore.
- Licari, D., & Comandè, G. (2024). ITALIAN-LEGAL-BERT models for improving natural language processing tasks in the Italian legal domain. *Computer Law & Security Review*, 52, 105908.
- Lorenzini, M., Lagomarsino, M., Fortini, L., Gholami, S., & Ajoudani, A. (2023). Ergonomic human-robot collaboration in industry: A review. *Frontiers in Robotics and AI*, 9.
- Ma, S., Simon, T., Saragih, J., Wang, D., Li, Y., De la Torre, F., & Sheikh, Y. (2021, June). Pixel Codec Avatars. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, (p. 64-73).
- Mahler, J., & Goldberg, K. (2017). Learning Deep Policies for Robot Bin Picking by Simulating Robust Grasping Sequences. In S. Levine, V. Vanhoucke, & K. Goldberg (A cura di), *Proceedings of the 1st Annual Conference on Robot Learning*. 78, p. 515–524. PMLR.
- Martelli, S., Mazzei, L., Canali, C., Guardiani, P., Giunta, S., Ghiazza, A., . . . Del Bue, A. (2018). Deep Endoscope: Intelligent Duct Inspection for the Avionic Industry. *IEEE Transactions on Industrial Informatics*, 14, 1701-1711.
- Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2021, July). A Survey on Bias and Fairness in Machine Learning. *ACM Comput. Surv.*, 54.
- Mirza, M., & Osindero, S. (2014). Conditional Generative Adversarial Nets. *Conditional Generative Adversarial Nets*.
- Mittelstadt, B., Wachter, S., & Russell, C. (2023, January 20). The Unfairness of Fair Machine Learning: Levelling down and strict egalitarianism by default. In *Michigan Technology Law Review (forthcoming)*, Available at SSRN.
- Mohammadi, S. S., Duarte, N. F., Dimou, D., Wang, Y., Taiana, M., Morerio, P., . . . Santos-Victor, J. (2023). 3DSGrasp: 3D Shape-Completion for Robotic Grasp. *2023 IEEE International Conference on Robotics and Automation (ICRA)*, 3815-3822.
- Moor, M., Banerjee, O., Abad, Z. S., Krumholz, H. M., Leskovec, J., Topol, E. J., & Rajpurkar, P. (2023). Foundation models for generalist medical artificial intelligence. *Nature*, 616, 259–265.
- Mor, B., Garhwal, S., & Kumar, A. (2021). A Systematic Review of Hidden Markov Models and Their Applications. *Archives of Computational Methods in Engineering*, 28, 1429–1448.

- Moradi, R., Berangi, R., & Minaei, B. (2020). A survey of regularization strategies for deep models. *Artificial Intelligence Review*, 53, 3947–3986.
- Morerio, P., Cavazza, J., Volpi, R., Vidal, R., & Murino, V. (2017, October). Curriculum Dropout. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*.
- Nichol, A. Q., Dhariwal, P., Ramesh, A., Shyam, P., Mishkin, P., Mcgrew, B., . . . Chen, M. (2022). GLIDE: Towards Photorealistic Image Generation and Editing with Text-Guided Diffusion Models. In K. Chaudhuri, S. Jegelka, L. Song, C. Szepesvari, G. Niu, & S. Sabato (A cura di), *Proceedings of the 39th International Conference on Machine Learning*. 162, p. 16784–16804. PMLR.
- Niklaus, J., Matoshi, V., Rani, P., Galassi, A., Sturmer, M., & Chalkidis, I. (2023). LEXTREME: A Multi-Lingual and Multi-Task Benchmark for the Legal Domain. *ArXiv, abs/2301.13126*.
- Nishida, R., Onishi, M., & Hashimoto, K. (2023). Crowd Simulation Incorporating a Route Choice Model and Similarity Evaluation using Real Large-scale Data. *Proceedings of the 2023 International Conference on Autonomous Agents and Multiagent Systems* (p. 2751–2753). Richland: International Foundation for Autonomous Agents and Multiagent Systems.
- Noroozi, M., & Favaro, P. (2016). Unsupervised Learning of Visual Representations by Solving Jigsaw Puzzles. In B. Leibe, J. Matas, N. Sebe, & M. Welling (A cura di), *Computer Vision – ECCV 2016* (p. 69–84). Cham: Springer International Publishing.
- Oh, S., Jung, Y., Kim, S., Lee, I., & Kang, N. (2019, September). Deep Generative Design: Integration of Topology Optimization and Generative Models. *Journal of Mechanical Design*, 141, 111405.
- Orts-Escolano, S., Rhemann, C., Fanello, S., Chang, W., Kowdle, A., Degtyarev, Y., . . . Izadi, S. (2016). Holoportation: Virtual 3D Teleportation in Real-time. *Proceedings of the 29th Annual Symposium on User Interface Software and Technology* (p. 741–754). New York, NY, USA: Association for Computing Machinery.
- Padalkar, M. G., Beltrán-González, C., Bustreo, M., Del Bue, A., & Murino, V. (2021). A Versatile Crack Inspection Portable System based on Classifier Ensemble and Controlled Illumination. *2020 25th International Conference on Pattern Recognition (ICPR)*, (p. 4009-4016).
- Radford, A., & Narasimhan, K. (2018). Improving Language Understanding by Generative Pre-Training. *OpenAI blog*.

- Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. *CoRR*, *abs/1511.06434*.
- Ramesh, A., Dhariwal, P., Nichol, A., Chu, C., & Chen, M. (2022). Hierarchical Text-Conditional Image Generation with CLIP Latents. *arXiv preprint arXiv:2204.06125*.
- Rezende, D. J., Mohamed, S., & Wierstra, D. (2014). Stochastic backpropagation and approximate inference in deep generative models. *International conference on machine learning*, (p. 1278–1286).
- Rodgers, I., Armour, J., & Sako, M. (2023). How Technology Is (or Is Not) Transforming Law Firms. *Annual Review of Law and Social Science*, 19.
- Roller, S., Dinan, E., Goyal, N., Ju, D., Williamson, M., Liu, Y., . . . Weston, J. (2021, April). Recipes for Building an Open-Domain Chatbot. In P. Merlo, J. Tiedemann, & R. Tsarfaty (A cura di), *Proceedings of the 16th Conference of the European Chapter of the Association for Computational Linguistics: Main Volume* (p. 300–325).
- Rombach, R., Blattmann, A., Lorenz, D., Esser, P., & Ommer, B. (2022, June). High-Resolution Image Synthesis With Latent Diffusion Models. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, (p. 10684-10695).
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In N. Navab, J. Hornegger, W. M. Wells, & A. F. Frangi (A cura di), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (p. 234–241). Cham: Springer International Publishing.
- Rosado, L., Gonçalves, J., Costa, J., Ribeiro, D., & Soares, F. (2016). Supervised learning for Out-of-Stock detection in panoramas of retail shelves. *2016 IEEE International Conference on Imaging Systems and Techniques (IST)* (p. 406–411). Chania: IEEE Press.
- Rosenblatt, F. (1958, November). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386-408.
- Roth, K., Pemula, L., Zepeda, J., Schölkopf, B., Brox, T., & Gehler, P. (2022, June). Towards Total Recall in Industrial Anomaly Detection. *Proceedings of the*

- IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, (p. 14318-14328).
- Roy, A., Sun, J., Mahoney, R., Alonzi, L., Adams, S., & Beling, P. (2018). Deep learning detecting fraud in credit card transactions. *2018 Systems and Information Engineering Design Symposium (SIEDS)*, (p. 129-134).
- Roy, D., & Dutta, M. (2022). A systematic review and research perspective on recommender systems. *Journal of Big Data*, 9, 59.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323, 533–536.
- Scarpellini, G., Fiorini, S., Juliari, F., Morerio, P., & Del Bue, A. (2024). DiffAssemble: A Unified Graph-Diffusion Model for 2D and 3D Reassembly. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Scarselli, F., Gori, M., Tsoi, A. C., Hagenbuchner, M., & Monfardini, G. (2008). The graph neural network model. *IEEE transactions on neural networks*, 20, 61–80.
- Scotto Di Luzio, M. (2021). L'impatto dell'intelligenza artificiale nel settore bancario: Chatbot e customer experience. *Tesi*.
- Serradilla, O., Zugasti, E., Rodriguez, J., & Zurutuza, U. (2022). Deep learning models for predictive maintenance: a survey, comparison, challenges and prospects. *Applied Intelligence*, 52, 10934–10964.
- Shih, Y.-J., Wu, S.-L., Zalkow, F., Müller, M., & Yang, Y.-H. (2022). Theme Transformer: Symbolic Music Generation with Theme-Conditioned Transformer. *IEEE Transactions on Multimedia*.
- Shirzad, H., Vellingker, A., Venkatachalam, B., Sutherland, D. J., & Sinop, A. K. (2023). Exphormer: Sparse transformers for graphs. *International Conference on Machine Learning*.
- Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. In Y. Bengio, & Y. LeCun (A cura di), *3rd International Conference on Learning Representations, ICLR 2015, San Diego, CA, USA, May 7-9, 2015, Conference Track Proceedings*.
- Soda, P., D'Amico, N. C., Tessadori, J., Valbusa, G., Guarrasi, V., Bortolotto, C., . . . Papa, S. (2021, December). AIforCOVID: Predicting the clinical outcomes in patients with COVID-19 applying AI to chest-X-rays. An Italian multicentre study. *Medical image analysis*, 74, 102216.

- Sohl-Dickstein, J., Weiss, E. A., Maheswaranathan, N., & Ganguli, S. (2015). Deep unsupervised learning using nonequilibrium thermodynamics. *Proceedings of the 32nd International Conference on International Conference on Machine Learning - Volume 37* (p. 2256–2265).
- Sohn, K., Lee, H., & Yan, X. (2015). Learning Structured Output Representation using Deep Conditional Generative Models. *Neural Information Processing Systems*.
- Son, T. H., Weedon, Z., Yigitcanlar, T., Sanchez, T., Corchado, J. M., & Mehmood, R. (2023). Algorithmic urban planning for smart and sustainable development: Systematic review of the literature. *Sustainable Cities and Society*, 94, 104562.
- Song, Y., & Ermon, S. (2019). Generative Modeling by Estimating Gradients of the Data Distribution. In H. Wallach, H. Larochelle, A. Beygelzimer, F. d\textquotesingle Alché-Buc, E. Fox, & R. Garnett (A cura di), *Advances in Neural Information Processing Systems*. 32. Curran Associates, Inc
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014, June). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15, 1929-1958.
- Sutskever, I., Vinyals, O., & Le, Q. V. (2014). Sequence to sequence learning with neural networks. *Proceedings of the 27th International Conference on Neural Information Processing Systems - Volume 2* (p. 3104–3112). Cambridge: MIT Press.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., . . . Rabinovich, A. (2015, June). Going Deeper With Convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Tagarelli, A., & Simeri, A. (2022). Unsupervised law article mining based on deep pre-trained language representation models with application to the Italian civil code. *Artificial Intelligence and Law*, 30, 417–473.
- Thomas W. Sanchez, T. G., & Lim, T. (2023). The prospects of artificial intelligence in urban planning. *International Journal of Urban Sciences*, 27, 179-194.
- Tirupachuri, Y., Nava, G., Rapetti, L., Latella, C., & Pucci, D. (2019). Trajectory Advancement during Human-Robot Collaboration. *2019 28th IEEE International Conference on Robot and Human Interactive Communication (RO-MAN)*, (p. 1-8).
- Tomczak, J. M. (2022). Why Deep Generative Modeling? In *Deep Generative Modeling* (p. 1–12). Cham: Springer International Publishing.

- Tyen, G., Brenchley, M., Caines, A., & Buttery, P. (2022, July). Towards an open-domain chatbot for language practice. In E. Kochmar, J. Burstein, A. Horbach, R. Laarmann-Quante, N. Madnani, A. Tack, . . . T. Zesch (A cura di), *Proceedings of the 17th Workshop on Innovative Use of NLP for Building Educational Applications (BEA 2022)* (p. 234–249). Seattle: Association for Computational Linguistics.
- Vahdat, A., & Kautz, J. (2020). NVAE: A Deep Hierarchical Variational Autoencoder. *Neural Information Processing Systems (NeurIPS)*.
- Van Der Malsburg, C. (1986). Frank Rosenblatt: Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms. In G. Palm, & A. Aertsen (A cura di), *Brain Theory* (p. 245–248). Berlin: Springer Berlin Heidelberg.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., . . . Polosukhin, I. (2017). Attention is All you Need. In I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (A cura di), *Advances in Neural Information Processing Systems*. 30. Curran Associates, Inc.
- Veličković, P., Cucurull, G., Casanova, A., Romero, A., Liò, P., & Bengio, Y. (2018). Graph Attention Networks. *International Conference on Learning Representations*.
- Vincent, P., Larochelle, H., Bengio, Y., & Manzagol, P.-A. (2008). Extracting and composing robust features with denoising autoencoders. *Proceedings of the 25th International Conference on Machine Learning* (p. 1096–1103). New York, NY, USA: Association for Computing Machinery.
- Weiss, T., Mayo Yanes, E., Chakraborty, S., Cosmo, L., Bronstein, A. M., & Gershoni-Poranne, R. (2023). Guided diffusion for inverse molecular design. *Nature Computational Science*, 3, 873–882.
- Yang, M., Cho, K., Merchant, A., Abbeel, P., Schuurmans, D., Mordatch, I., & Cubuk, E. D. (2023). Scalable Diffusion for Materials Discovery. *arXiv e-prints*.
- You, J., Ying, R., Ren, X., Hamilton, W. L., & Leskovec, J. (2018). GraphRNN: Generating Realistic Graphs with Deep Auto-regressive Models. *International Conference on Machine Learning*.
- Yu, C., Ma, X., Ren, J., Zhao, H., & Yi, S. (2020). Spatio-Temporal Graph Transformer Networks for Pedestrian Trajectory Prediction. *Computer Vision – ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part XII* (p. 507–523). Berlin: Springer-Verlag.
- Yu, Y., Gong, Z., Zhong, P., & Shan, J. (2017). Unsupervised Representation Learning with Deep Convolutional Neural Network for Remote Sensing

- Images. In Y. Zhao, X. Kong, & D. Taubman (A cura di), *Image and Graphics* (p. 97–108). Cham: Springer International Publishing.
- Yue, S., Chen, W., Wang, S., Li, B., Shen, C., Liu, S., . . . Wei, Z. (2023). DISC-LawLLM: Fine-tuning Large Language Models for Intelligent Legal Services. *ArXiv, abs/2309.11325*.
- Zang, X., Zhao, X., & Tang, B. (2023). Hierarchical Molecular Graph Self-Supervised Learning for property prediction. *Communications Chemistry, 6*, 34.
- Zhang, S., Fan, R., Liu, Y., Chen, S., Liu, Q., & Zeng, W. (2023). Applications of transformer-based language models in bioinformatics: a survey. *Bioinformatics advances, 3*(1), vbad001.
- Zhou, Y., Wilkinson, D., Schreiber, R., & Pan, R. (2008). Large-Scale Parallel Collaborative Filtering for the Netflix Prize. *Proceedings of the 4th International Conference on Algorithmic Aspects in Information and Management* (p. 337–348). Berlin: Springer-Verlag.
- Zonta, T., da Costa, C. A., da Rosa Righi, R., de Lima, M. J., da Trindade, E. S., & Li, G. P. (2020). Predictive maintenance in the Industry 4.0: A systematic literature review. *Computers & Industrial Engineering, 150*, 106889.
- Zunino, A., Bargal, S. A., Morerio, P., Zhang, J., Sclaroff, S., & Murino, V. (2021). Excitation Dropout: Encouraging Plasticity in Deep Neural Networks. *International Journal of Computer Vision, 129*, 1139–1152.

Le altre pubblicazioni dei “Casi e materiali di discussione: mercato del lavoro e contrattazione collettiva”:

1 | 2024 “L'archivio nazionale dei contratti e degli accordi collettivi di lavoro (art. 17, comma 4, legge n. 936/186) - Prima edizione”

2 | 2024 “La banca dati sul mercato del lavoro. Articolo 17, comma 4, legge n. 936/186) - Prima edizione”

3 | 2024 “Intelligenza Artificiale e mercati del lavoro” – Prima rassegna ragionata della letteratura economica e giuridica”

4 | 2024 “Malattie professionali e infortuni sul lavoro: i dati INAIL 2003 – 2023”

5 | 2024 “Intelligenza Artificiale e mercati del lavoro - Evidenze e prospettive dall'indagine conoscitiva della XI Commissione della Camera (lavoro pubblico e privato)”

