# SAFE-AI: E' possibile misurare l'etica dell'intelligenza artificiale?

Paolo Giudici

Professore Ordinario di Statistica, Universitá di Pavia

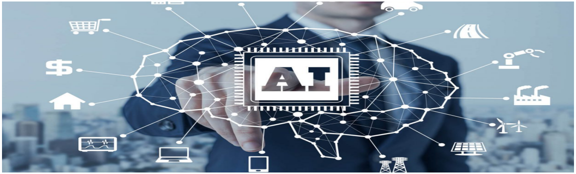

# Definizione di Intelligenza Artificiale (AI)

Sistema di intelligenza artificiale (D.D.L. 1146, Art. 2) :

- **Un sistema automatizzato** progettato per funzionare con livelli di autonomia variabile e che puó presentare adattabilitá dopo la diffusione
- che, per obiettivi espliciti o impliciti, **deduce dall'input che riceve come generare output** quali previsioni, contenuti, raccomandazioni o decisioni **che possono influenzare ambienti fisici o virtuali**.

# Esempio

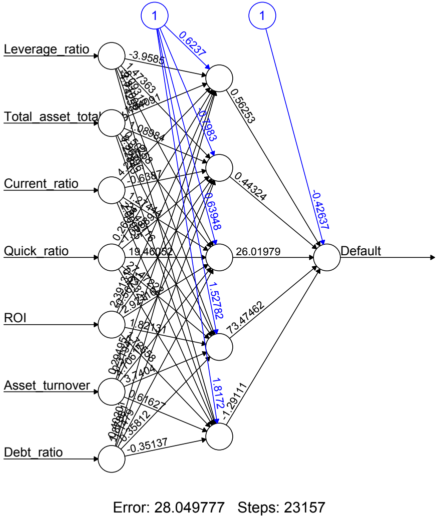

Figure: Rete neurale che apprende come classificare imprese affidate, sulla base dei relativi dati di bilancio.

# Evoluzione dell' AI

- Statistical learning: regressione lineare, logistica, modelli econometrici e loro regolarizzazioni (Stepwise/Ridge/Lasso)
- Machine learning: modelli ad albero, foreste casuali (random forests), ensemble models.
- Deep learning: reti neurali a piú strati. Inizialmente monodirezionali, quindi ricorsive, quindi dotate di attenzione in tutte le direzioni (transformers)
- General purpose AI (GPAI): modelli basati su pre-addestramento da grandi basi di dati (Large Language models), atti a risolvere diversi tipi di problemi
- Agentic AI: modelli AI e GPAI sviluppati da squadre di agenti digitali, ciascuno dotato di obiettivi da raggiungere, in continuo dialogo, e coordinati a diversi livelli.
- Edge AI, AGI, ASI.

# Impatti dell' AI: opportunitá

- **Efficienza**: miglioramento dei processi, dei prodotti e dei servizi
- **Personalizzazione**: prodotti e servizi su misura
- **Inclusione**: possibile raggiungere nuovi utenti
- **Prossimitá**: servizi maggiormente capillari e distribuiti

# Impatti dell'AI: rischi

- **Sicurezza**: una limitata robustezza puó condurre a rischi operativi, informatici e cibernetici.
- **Accuratezza**: una limitata accuratezza puó condurre a rischi di modello
- **Equitá**: una limitata equitá puó condurre a rischi legali e reputazionali
- **Interpretabilitá**: una limitata interpretabilitá puó condurre a rischi di controllo e di governance

# Esempi di danni da AI (aiaaic.org)

| Category | Subcategories |
|---|---|
| Autonomy | Autonomy/agency loss, Impersonation/identity theft, Personality loss ality rights loss |
| Emotional & psychological | Anxiety/distress/depression, Intimidation, Radicalisation, Dig tion/objectification, Sexualisation, Self-harm, Addiction, Over-rel Coercion/manipulation |
| Financial & business | Financial/earnings loss, Confidentiality loss, Loss of productivity, Oppo Business operations/infrastructure damage |
| Human rights & civil liberties | Discrimination, Benefits/entitlements loss, Loss of human rights a Loss/violation of human rights and freedoms, Loss of right to du liberty and security |
| Physical | Loss of life, Bodily injury, Property damage, Personal health deteriora |
| Political & economic | Political instability, Institutional trust loss, Critical infrastructure dam Economic instability, Electoral interference, Economic/political power |
| Psychological | Coercion/manipulation, Anxiety/distress, Sexualisation, Dehumanisat loss, Alienation/isolation, Over-reliance, Addiction, Harassment/abu Radicalisation |
| Reputational | Defamation/libel/slander, Loss of confidence/trust |
| Societal & cultural | Public service delivery deterioration, Stereotyping, Information ec lence/armed conflict, Damage to public health, Societal destabilisati loss/losses, Loss of creativity/critical thinking, Cheating/plagiarism |

Categories and their respective subcategories of harms caused by AI systems. Source: AIAAIC database.

# Normativa internazionale

- La regolamentazione Europea (**AI Act**) segue un approccio basato sul rischio, e distingue fra:
    - **Attivitá proibite,** (es. social scoring)
    - **Attivitá ad alto rischio,** per le quali serve un sistema di gestione dei rischi (es. crediti, premi vita)
    - **Attivitá a rischio limitato,** per le quali sussiste obbligo di trasparenza (es. chatbots)
- Il **D.D.L. 1146**, conforme alla normativa Europea, promuove un utilizzo corretto, trasparente e responsabile dell'AI, in una dimensione antropocentrica volta a coglierne le opportunitá e a garantire la vigilanza sui rischi economici e sociali e sullâimpatto sui diritti fondamentali.
- Il D.D.L. 1146 ha diversi aspetti in comune con le linee guida della Pontificia Commissione per lo Stato della Cittá del Vaticano in materia di intelligenza artificiale.

# AI responsabile

- Una **AI responsabile** dovrebbe esssere in grado di **misurare e controllare i propri rischi**, al fine di determinare un utilizzo etico e trasparente, in una dimensione antropocentrica e affidabile, nel rispetto della dignitá umana e del bene comune.
- **Occorre passare da AI a SAFE-AI: Sustainable, Accurate, Fair, Explainable AI**
- L'obiettivo delle ricerche del mio gruppo, e dei laboratori collegati, é lo sviluppo di **metodi di misurazione** SAFE-AI, in linea con l'approccio dell'associazione scientifica **iaseai.org**

# Metodologia

Si basa su 4 indicatori statistici, espressi in termini percentuali: RGA, RGR, RGE, RGF. Tutti ricavati dagli stessi concetti matematici: **la curva di Lorenz** e **l'indice di Gini** (utilizzato dal 1905 per lo studio della distribuzione dei redditi).

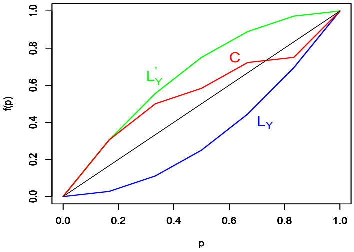

Figure: Curva di Lorenz ($L_y$), Curva di Lorenz duale ($L'_y$) e Curva di Concordanza (C) dove $p$ e $f(p)$ sono le percentuali di osservazioni e dei rispettivi valori cumulati.

# Software: safeaipackage

Tutte le metriche sono state tradotte in un "pacchetto" di comandi di software Python, facilmente riproducibili, liberamente disponibili a:

`https://github.com/GolnooshBabaei/safeaipackage`.

# Misurare l'accuratezza

Per un problema di credito al consumo abbiamo confrontato le previsioni di GPT, sia senza addestramento, che con addestramento (con dati di 80 clienti, "Informed GPT"), rispetto ad un classico modello di regressione logistica (con dati di 30000 clienti).

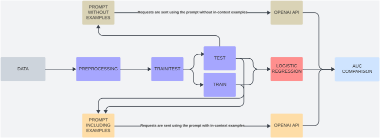

Figure: GPAI model

Table: Confronto fra modelli basato sulla **capacitá predittiva (AUC)**.

| **Metodo** | **Min** | **Max** | **Media** | **Dev. Std** |
|---|---|---|---|---|
| Informed GPT | 0.6260601915 | 0.6963064295 | 0.66655266764 | 0.0261630545 |
| GPT | 0.5895348837 | 0.6445964432 | 0.61264021887 | 0.0212562962 |
| LR | 0.7018467852 | 0.7950752394 | 0.7531874145 | 0.0314667993 |

# Misurare l' equitá

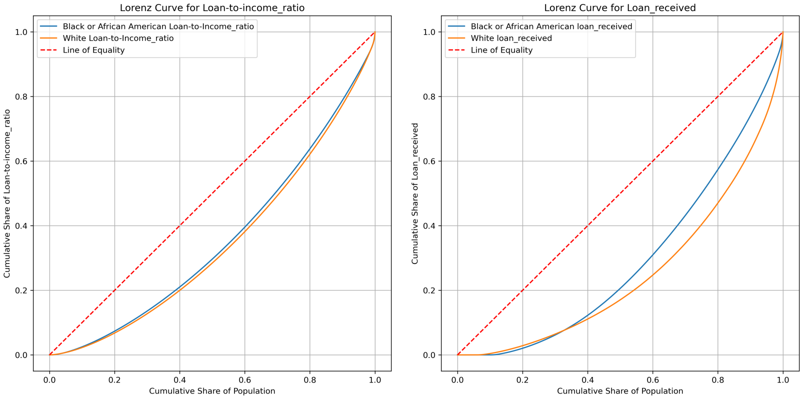

Figure: Confronto fra: prestito/reddito e prestito ricevuto per due diversi gruppi di popolazione (Stato di New York) mediante **curve di Lorenz ed indici di Gini.**

# Misurare l' interpretabilitá

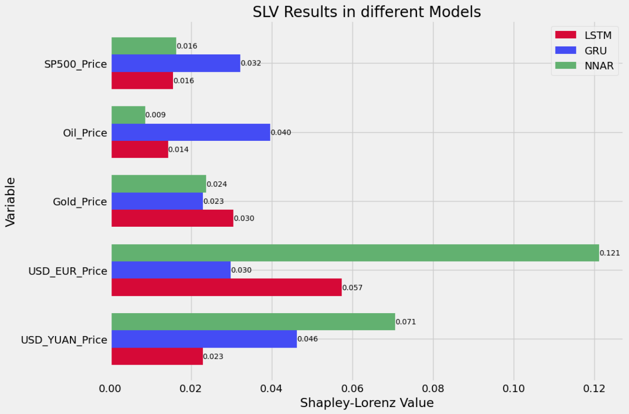

I moderni modelli di AI sono "black-box": non trasparenti. Possono essere resi tali, ad esempio con il **metodo Shapley Lorenz (SLV)**, che spiega il contributo percentuale di ciascun predittore (es. prezzi noti) alla capacitá predittiva complessiva del prezzo da prevedere.

# Misurare l'interpretabilitá - 2

```
from safeaipackage import check_explainability

explainability_obj = check_explainability.Explainability(xtrain, xtest,
    ytrain, ytest, RandomForestClassifier(random_state=1))

explainability_obj.rge()
```

```
                       RGE
jobtime           0.211268
age               0.190141
prevexp           0.119718
edu               0.105634
jobcat_Clerical   0.098592
jobcat_manager    0.098592
minority          0.091549
gender            0.063380
jobcat_Custodial  0.056338
```

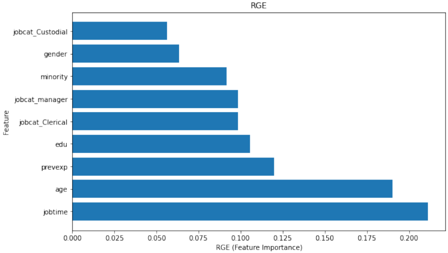

# Misurare la sostenibilitá

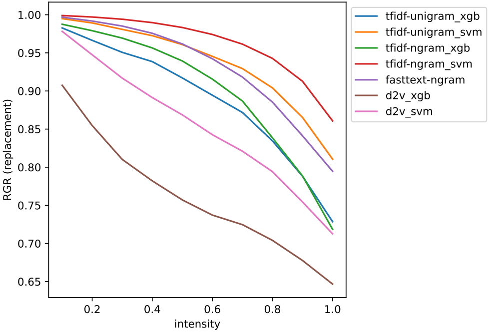

Figure: La figura mostra come cambiano le valutazioni sull'accoglienza di un reclamo bancario modificando le parole del relativo testo, **con intensitá crescente**, per diversi modelli di AI. I modelli piú stabili, con indice di robustezza (RGR) vicino a 1, sono i migliori.

# Come integrare le misure di rischio

| Modello | Sust. | Acc. | Exp. | Prob | RMSE |
|---|---|---|---|---|---|
| MLP | 0.9661 | 0.4518 | 0.5114 | 0.7768 | 0.1046 |
| RBF | 0.9538 | 0.4519 | 0.5443 | 0.75454 | 0.0982 |
| NNAR | 0.7157 | 0.3718 | 0.2405 | 0.9361 | 0.1358 |
| LSTM | 0.9607 | 0.8186 | 0.1122 | 0.9118 | 0.0561 |
| GRU | 0.9244 | 0.8865 | 0.1778 | 0.8543 | 0.0439 |

Table: Confronto fra reti neurali MLP, RBF, NNAR, LSTM e GRU models, nella previsione di prezzi finanziari, in termini di metriche SAFE vs il classico RMSE.

# Riferimenti bibliografici

- Lorenz MO. (1905). Methods of measuring the concentration of wealth. Publications of the American Statistical Association, 70.
- Gini C. (1921). Measurement of Inequality of Incomes. Economic Journal, 31, 124-126.
- Giudici P., Raffinetti E. (2021). Shapley-Lorenz eXplainable Artificial Intelligence *Expert Systems With Applications*, 167, 114104.
- Giudici P, Raffinetti E. (2023).SAFE Artificial Intelligence in Finance. *Finance Research Letters* , volume 56, 104088.
- Giudici P, Raffinetti E. (2024). RGA: a unified measure of predictive accuracy. *Advances in Data analysis and classification.*
- Babaei, G., Giudici P, Raffinetti E. (2025).A rank graduation Box for SAFE AI. *Expert Systems With Applications*

# Riferimenti- Appena pubblicato

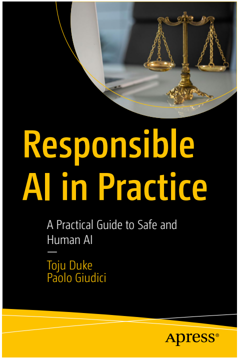

Responsible AI in Practice

A Practical Guide to Safe and Human AI

Toju Duke
Paolo Giudici

Apress®

# Riferimenti - Convegno Pavia 19-6-2025

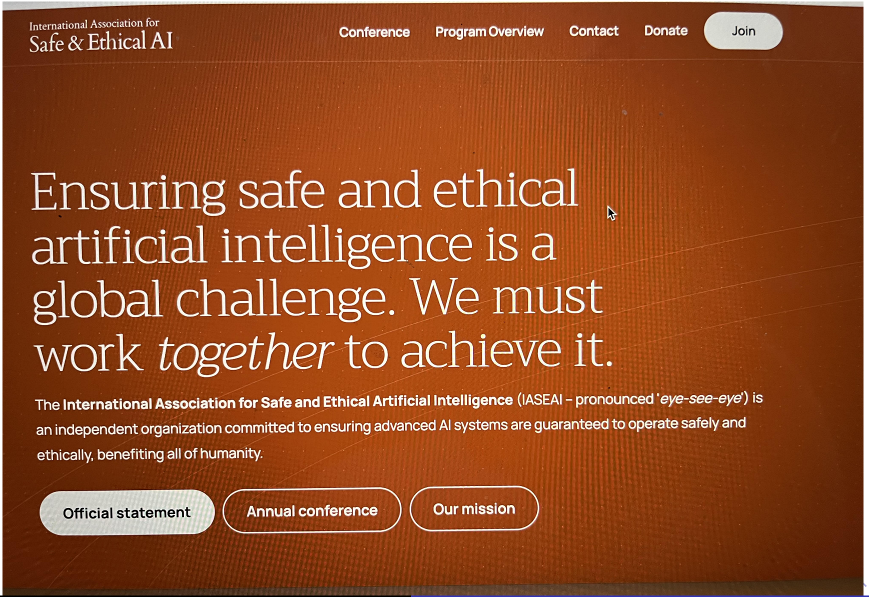

Ensuring safe and ethical artificial intelligence is a global challenge. We must work *together* to achieve it.

The **International Association for Safe and Ethical Artificial Intelligence** (IASEAI – pronounced '*eye-see-eye*') is an independent organization committed to ensuring advanced AI systems are guaranteed to operate safely and ethically, benefiting all of humanity.