

Finanza sostenibile

L'impatto del fattore ESG sulla performance industriale

Un'analisi con tecniche di *machine learning*

M. Palynska, F. Medda, V. Caivano, G. Di Stefano, F. Scalese

4

giugno 2024



La collana **Finanza sostenibile** raccoglie le analisi e gli approfondimenti effettuati nell'ambito dello Steering Committee sulla sostenibilità, istituito per valorizzare gli interventi negli ambiti di regolazione e vigilanza attribuiti all'Istituto, nonché favorire, anche a legislazione data, l'incontro fra domanda e offerta di prodotti finanziari sostenibili.

Comitato editoriale

Paola Deriu (coordinatrice)

Daniela Costa

Giovanna Di Stefano

Monica Gentile

Paola Soccorso

Segreteria di Redazione

Eugenia Della Libera

Tutti i diritti riservati.

È consentita la riproduzione a fini didattici e non commerciali, a condizione che venga citata la fonte.

CONSOB

00198 Roma - Via G.B. Martini, 3

t +39.06.84771 centralino

f +39.06.8477612

20121 Milano - Via Broletto, 7

t +39.02.724201 centralino

f +39.02.89010696

h www.consob.it

e studi_analisi@consob.it

L'impatto del fattore ESG sulla performance industriale

Un'analisi con tecniche di *machine learning*

F. Medda, M. Palynska, V. Caivano, G. Di Stefano, F. Scalese (*)

Sintesi del lavoro

La transizione verso un modello economico più sostenibile ha assunto, negli anni recenti, una rilevanza crescente sia per i soggetti che operano sui mercati finanziari sia per le autorità di vigilanza e regolamentazione. In un contesto in cui la normativa è in continua evoluzione e l'ecosistema delle informazioni si va progressivamente perfezionando, le analisi empiriche sulle tematiche ESG fanno sempre più ricorso a tecniche di intelligenza artificiale. Questo studio mostra come modelli di *machine learning* possano aiutare a comprendere quale relazione sussista tra performance ESG e performance reddituale delle imprese. Il lavoro si basa su dati riferiti a oltre 850 imprese europee e statunitensi nel periodo 2007- 2021 e analizza il legame tra lo score ESG (che sintetizza il profilo di sostenibilità dell'impresa) e l'EBIT (che sintetizza il profilo reddituale), verificando l'impatto dei tre pilastri E, S e G sulle performance reddituali delle imprese. I risultati mostrano che lo score riferito alla sostenibilità ambientale (pilastro E) risulta associato positivamente alle performance reddituali in maniera più netta rispetto agli score riferiti agli altri due pilastri (S e G). Il lavoro evidenzia, altresì, talune differenze nei risultati relativi alle imprese europee rispetto a quelle statunitensi, presumibilmente derivanti dal diverso assetto normativo che caratterizza le due giurisdizioni. La ricerca fornisce un contributo alla letteratura relativa all'utilizzo di modelli di *machine learning* per l'analisi di tematiche di finanza sostenibile mostrando come tali metodi possano rappresentare un valore aggiunto per l'attività di ricerca in questi ambiti. L'utilizzo di tecniche di *machine learning* consente, tuttavia, di superare solo in parte le criticità connesse alla qualità delle metriche ESG attualmente a disposizione. La progressiva definizione di standard e metriche di sostenibilità faciliterà la raccolta e l'analisi dei dati strutturati e l'evoluzione normativa in materia di rating ESG aumenterà la trasparenza circa le sottostanti metodologie.

(*) Marta Palynska (nel corso di un tirocinio presso la CONSOB al momento della ricerca); Francesca Medda (CONSOB al momento della ricerca); Valeria Caivano, Divisione Studi CONSOB (v.caivano@consob.it); Giovanna Di Stefano, Divisione Studi CONSOB (g.distefano@consob.it); Francesco Scalese, Divisione Studi CONSOB (f.scalese@consob.it).

Si ringrazia Nadia Linciano per gli utili commenti in fase di ideazione dello studio. Errori e imprecisioni sono imputabili esclusivamente agli autori. Le opinioni espresse nel lavoro sono attribuibili esclusivamente agli autori e non impegnano in alcun modo la responsabilità dell'Istituto. Nel citare il presente lavoro, pertanto, non è corretto attribuire le argomentazioni ivi espresse alla CONSOB o ai suoi Vertici.

The impact of the ESG factor on industrial performance

An analysis using machine learning techniques

M. Palynska, F. Medda, V. Caivano, G. Di Stefano, F. Scalese (*)

Abstract

In recent years, the transition towards a more sustainable economic model has become increasingly important for both financial market participants and supervisory and regulatory authorities. In a context in which regulations are constantly evolving and the information ecosystem is progressively being refined, empirical analyses on ESG issues increasingly make use of artificial intelligence techniques. The aim of this study is to show how machine learning methods can contribute to understand the relationship between ESG performance and corporate earnings performance. The study is based on data from over 850 European and US companies over the period 2007–2021. Its aim is to analyse the link between the ESG score (used as indicator of the company's sustainability profile) and EBIT (used as indicator of the earnings profile). The hypothesis tested in this study is that the three pillars E, S and G have a different impact on company earnings performance. The results indicate that the environmental score (pillar E) is more strongly associated with financial performance than those relative to the other two pillars (S and G). Additionally, the work reveals differences in the results for European versus US companies, which may be ascribed to the different regulatory frameworks in the two jurisdictions. The research contributes to the literature on the use of machine learning techniques for the analysis of sustainable finance issues, showing how such methods can enhance research activity on these topics. However, the use of machine learning techniques cannot fully address the critical issues related to the quality of ESG metrics currently available. The ongoing definition of sustainability standards and metrics will facilitate the collection and analysis of structured data. Furthermore, the evolution of ESG rating regulations will increase transparency about the underlying methodologies.

Keywords: ESG, firm's profitability, machine learning, interpretability tools, sustainable finance regulation.

(*) Marta Palynska (during an internship at CONSOB at the time of the study); Francesca Medda (CONSOB at the time of the study); Valeria Caivano, Research Department CONSOB (v.caivano@consob.it); Giovanna Di Stefano, Research Department CONSOB (g.distefano@consob.it); Francesco Scalese, Research Department CONSOB (f.scalese@consob.it).

The authors would like to thank Nadia Linciano for her insightful comments during the preliminary stages of the study design. It is the responsibility of the authors alone to account for any errors or imprecisions. The opinions expressed herein are those of the authors and do not necessarily represent the views of CONSOB. In citing this work, therefore, it is incorrect to attribute the arguments expressed therein to CONSOB.

Indice

1	Introduzione	7
2	La letteratura economica	9
3	L'approccio metodologico	13
3.1	I metodi di analisi	13
3.2	I modelli agnostici	15
4	La descrizione e la preparazione dei dati	16
4.1	La descrizione	16
4.2	La preparazione	20
4.3	La correlazione	21
5	La stima dei modelli	22
6	L'interpretazione dei risultati	26
7	Conclusioni	31
	Riferimenti bibliografici	33

1 Introduzione

La rilevanza dei temi connessi allo sviluppo economico sostenibile sta crescendo progressivamente tra cittadini e istituzioni. La comunità internazionale ha infatti preso atto, attraverso numerose iniziative che si sono susseguite nel tempo, della necessità di agire per trovare un equilibrio fra tre diversi tipi di sostenibilità, egualmente rilevanti, di natura ambientale, sociale ed economica¹.

La transizione verso un modello economico più sostenibile necessita, tuttavia, di un quadro di regole all'interno del quale possano svilupparsi forme di finanziamento utili a convogliare risorse verso progetti imprenditoriali che sposino questo modello di crescita. In tale ambito risulta particolarmente rilevante l'impegno dell'Unione Europea volto alla definizione di un impianto normativo che possa favorire il flusso finanziario verso attività economiche in grado di contribuire agli obiettivi di sostenibilità prefissati.

Con l'acronimo ESG (*environmental, social e governance*)², utilizzato in particolare modo nel mondo finanziario, si indica abitualmente il quadro di riferimento utile a valutare gli aspetti ambientali, sociali e di governance di un'azienda o di un investimento e la relativa capacità di generare rendimenti economici a lungo termine. Si tratta di un concetto distinto da quello più ampio di sostenibilità che invece include, oltre ai fattori ESG, anche considerazioni di carattere economico.

I profili ESG hanno assunto crescente rilevanza sui mercati finanziari dove si osserva, già da diversi anni, un aumento sia della domanda sia dell'offerta di prodotti sostenibili. Secondo le stime disponibili, a livello globale le masse gestite di fondi comuni di investimento sostenibili sono infatti cresciute progressivamente passando da 1.400 miliardi di dollari nel 2018 a 3.400 miliardi circa a fine 2023, di cui oltre l'80% riferibile a fondi europei³. In Europa, le emissioni di obbligazioni ESG sono passate da meno di 100 miliardi di euro nel 2018 a oltre 600 miliardi nel 2023⁴. In base a dati di

1 Al Rapporto del 1987 della World Commission on Environment and Development (Rapporto Brundtland) sono seguite numerose iniziative, culminate nel 2015 nell'approvazione dell'Agenda 2030 delle Nazioni Unite per lo sviluppo sostenibile e dei relativi 17 obiettivi (Sustainable Development Goals – SDGs), articolati in 169 Target da raggiungere entro il 2030. Nel dicembre dello stesso anno, la conferenza sul clima di Parigi (COP21) ha visto 195 paesi aderire al primo accordo universale e giuridicamente vincolante su un piano d'azione globale, con l'obiettivo di prevenire 'pericolosi cambiamenti climatici' e contenere il riscaldamento globale al di sotto dei 2°C rispetto ai livelli preindustriali. La COP21 è stata poi seguita da ulteriori accordi globali e regionali (Linciano et al. 2021).

2 Il termine ESG è stato utilizzato a partire dagli anni duemila. Nel 2004 viene citato dal Global Compact delle Nazioni Unite nel Rapporto '*Who Cares Wins*', in cui alcune importanti istituzioni finanziarie hanno fornito suggerimenti per integrare meglio le questioni ambientali, sociali e di governance nei campi dell'analisi, della gestione degli *asset* e dei servizi di intermediazione di titoli, al fine di aumentare l'attenzione verso questi fattori in ambito finanziario. Viene inoltre menzionato nel 2006 nel report delle Nazioni Unite dal titolo '*Principi per l'Investimento Responsabile*', in cui viene richiesto di considerare gli indicatori ambientali, sociali e di governance come parametri della valutazione finanziaria di un'azienda. A livello europeo, l'acronimo viene usato nella definizione di finanza sostenibile della Commissione europea (https://finance.ec.europa.eu/sustainable-finance/overview-sustainable-finance_en): «Sustainable finance refers to the process of taking environmental, social and governance (ESG) considerations into account when making investment decisions in the financial sector, leading to more long-term investments in sustainable economic activities and projects.» In relazione alla normativa europea sull'informativa di sostenibilità delle imprese (Corporate Sustainability Reporting Directive o CSRD, di prossima applicazione), gli standard di rendicontazione europei prevedono che il reporting faccia riferimento alle tre tematiche *environmental, social e governance*.

3 Si veda Morgan Stanley (2024).

4 Si veda AFME (2023).

survey, inoltre, la grande maggioranza degli investitori istituzionali indica un incremento nella domanda di opportunità di investimento connesse a tematiche ESG nel 2023. Inoltre, le considerazioni ESG stanno assumendo un ruolo sempre più prominente nei mandati degli investitori ai gestori⁵. Anche alcuni dati di *survey* riferiti a investitori *retail* rilevano una netta preferenza di questi ultimi verso alternative di investimento a minore impatto ambientale⁶.

Il presente lavoro si concentra sui profili ESG delle imprese e si pone nel solco della letteratura economica volta a indagare l'interazione tra profili connessi alle tre dimensioni ESG (ossia ambientale, sociale e di governance) e performance reddituali. La ricerca prende le mosse dagli studi già precedentemente svolti (quali, D'Amato et al. 2023) e ne amplia sia l'oggetto sia l'ambito di analisi. Il lavoro si basa su dati riferiti a oltre 850 imprese europee e statunitensi nel periodo 2007- 2021 e utilizza modelli di *machine learning* (di seguito anche ML) al fine di analizzare il legame tra lo score ESG (che sintetizza il profilo di sostenibilità dell'impresa) e l'EBIT (che sintetizza il profilo reddituale). L'ipotesi allo studio in questo lavoro è che i tre pilastri E, S e G abbiano un impatto differente sulle performance delle imprese. I risultati mostrano che lo score riferito alla sostenibilità ambientale (pilastro E) risulta associato positivamente alle performance reddituali in maniera più netta. Il lavoro evidenzia, altresì, la sussistenza di differenze nei risultati relativi alle imprese europee rispetto a quelle statunitensi, presumibilmente connesse al diverso assetto normativo che caratterizza le due giurisdizioni.

La ricerca fornisce anche un contributo alla letteratura sull'utilizzo di tecniche di ML per l'analisi di tematiche di finanza sostenibile mostrando che approcci metodologici di analisi avanzate possono rappresentare un importante valore aggiunto per l'attività di ricerca in tale ambito. Le tecniche di intelligenza artificiale (IA) possono essere caratterizzate dalla capacità di migliorarsi autonomamente, individuando di volta in volta nuove relazioni tra variabili da diversi set di dati. Ciò consente di sfruttare appieno le potenzialità informative dei dati nello studio di fenomeni complessi ed eterogenei quali i profili di sostenibilità, per i quali non sono ancora state individuate metriche condivise e che, pertanto, possono risultare di difficile esplorazione tramite l'uso di modelli di analisi tradizionali meno dinamici e flessibili.

Si osserva, in proposito, che il contesto normativo della finanza sostenibile non è, allo stato, formalmente definito. Come già accennato, a livello europeo il legislatore si sta adoperando affinché possa svilupparsi un ecosistema dell'informazione sostenibile (che include dati, informazioni, metriche e modelli di analisi adeguati alla misurazione e alla rappresentazione delle caratteristiche ESG di attività economiche e finanziarie) che dia la possibilità agli attori economici di utilizzare le informazioni necessarie per prendere le proprie decisioni⁷. In un contesto in cui tale ecosistema si sta

5 Si veda RBC Capital Market (2024).

6 Si veda Natixis Investment Managers (2022).

7 Vanno in questa direzione, tra gli altri, i seguenti interventi normativi (già approvati o allo studio): il Regolamento (UE) 2020/852 (Regolamento Tassonomia), che definisce cosa debba intendersi per attività sostenibili sul piano ambientale; il Regolamento (UE) 2019/2088 (Sustainable Finance Disclosure Regulation – SFDR), che detta obblighi informativi specifici per produttori e distributori di strumenti finanziari, intermediari e consulenti, con l'obiettivo di rendere disponibili informazioni chiare agli investitori finali circa le caratteristiche ESG degli investimenti; la Direttiva (UE)

ancora perfezionando e i mercati, di conseguenza, non sono ancora in grado di apprezzare pienamente i rischi e le opportunità connessi alle tematiche ESG, può risultare particolarmente appropriato l'utilizzo di metodologie di analisi come quelle di ML, che non sono strettamente vincolate a modelli teorici tipicamente usati nella ricerca economica o finanziaria. I metodi di ML presentano, tuttavia, alcuni svantaggi tra cui il più rilevante è rappresentato dalla limitata possibilità di interpretare i risultati. Per ovviare a questa criticità il presente studio, oltre a tecniche di ML, utilizza anche alcuni modelli cosiddetti agnostici perché prescindono dal metodo di ML impiegato. Tali modelli possono essere impiegati per favorire nel concreto la capacità dell'analista di interpretare i risultati, consentendo di determinare il contributo delle variabili utilizzate nel determinare i risultati forniti dal modello.

Lo studio è organizzato come segue. La sezione 2 illustra la letteratura economica sull'utilizzo di tecniche di intelligenza artificiale per l'analisi di dati ESG; la sezione 3 espone l'approccio metodologico alla base dello studio; la sezione 4 descrive i dati oggetto di analisi e illustra le fasi di preparazione del dataset; la sezione 5 mostra i risultati delle stime e la sezione 6 ne approfondisce l'interpretazione; la sezione 7 conclude.

2 La letteratura economica

L'utilizzo di tecniche di *machine learning* sta diventando sempre più diffuso, in generale, in molti campi della ricerca economica e finanziaria e, in particolare, della finanza sostenibile⁸.

Al proposito, Allen et al. (2017) passano in rassegna le possibili applicazioni pratiche di tecniche di *machine learning* nell'analisi dei dati ESG⁹, ponendo in luce come al momento l'impiego di tali strumenti sia particolarmente utile in questo ambito proprio per l'assenza di metriche condivise e standardizzate e che in futuro, via via che sarà raggiunta una maggiore standardizzazione delle metriche e delle forme di reporting delle informazioni relative a profili di sostenibilità, sarà possibile sviluppare modelli di ML con performance ancora migliori.

2022/2464 (Corporate Sustainability Reporting Directive – CSRD) sulla rendicontazione di sostenibilità e i relativi standard di rendicontazione, introdotti dal Regolamento delegato (UE) 2023/2772 (European Sustainability Reporting Standards – ESRS) pubblicato a dicembre 2023; la proposta di regolamento sul rating ESG. Inoltre, la standardizzazione delle informazioni potrà essere perseguita, a livello di prodotto, anche grazie all'introduzione di una ecolabel europea e di uno standard per le obbligazioni *green*. Al proposito, nel 2023 è stato adottato il Regolamento (EU) 2023/2631 (Regolamento Green Bond – EuGBR) che introduce regole uniformi per gli emittenti di obbligazioni che desiderano utilizzare la denominazione 'obbligazione verde europea' o 'EuGB' (*European green bond*) nella commercializzazione dei loro titoli. Il Regolamento, salvo limitate eccezioni, troverà applicazione a partire dal 21 dicembre 2024.

- 8 L'utilizzo di metodologie innovative e della tecnologia (facendo riferimento, più in generale, a metodi di intelligenza artificiale o all'implementazione di DLT) è, inoltre, promossa anche a fini di regolamentazione e vigilanza, come indicato nel *'Financing for Sustainable Development Report 2021'* delle Nazioni Unite, secondo cui applicazioni di SupTech e RegTech (ossia le innovazioni tecnologiche applicate alle attività di supervisione e di *compliance*) possono rafforzare la supervisione e incrementare l'efficienza con riferimento ai temi della finanza sostenibile (United Nations, 2022).
- 9 Ad esempio, strumenti come *natural language o image processing* possono essere utilizzati per estrarre informazioni rilevanti circa i profili ESG per cui non si dispone di dati. Modelli di *deep learning* possono invece essere utilizzati, tra le altre cose, per prevedere il rendimento di un investimento.

Alcuni degli studi che utilizzano tecniche di intelligenza artificiale per indagare l'impatto di fattori ESG sulle performance delle imprese si focalizzano sul profilo di rischio-rendimento di un titolo (Guo et al, 2020; Yu et al. 2022). Altri lavori invece indagano l'efficacia di tecniche di ML a scopo predittivo dei futuri rendimenti azionari partendo da metriche ESG (Strube et al, 2023; Assael et al. 2023), mentre altri mostrano le buone capacità predittive di tali modelli in relazione ai risultati reddituali e la sussistenza di un legame tra performance ESG e redditività (De Lucia et al. 2020; Sharma et al. 2021; D'Amato et al. 2023). Un filone della letteratura si concentra invece sull'approfondimento dell'utilizzo di strumenti di intelligenza artificiale nella costruzione di portafogli efficienti, mostrando come tali modelli possano consentire di integrare profili ESG nell'analisi in modo da garantire migliori performance (Lanza et al. 2020; Margot et al. 2021).

Guo et al (2020), utilizzando tecniche di *natural language processing* per l'estrazione di notizie su profili ESG connessi a società quotate europee e statunitensi e applicando un modello di *deep learning*, mostrano che il flusso di notizie relative a profili ESG è un fattore rilevante in grado di anticipare la volatilità dei prezzi dei titoli azionari.

Al contrario Strube et al. (2023), applicando tecniche di *machine learning*, non trovano evidenza che l'inclusione di rating ESG nell'analisi migliori le performance predittive del modello sull'andamento di titoli azionari in termini di *excess returns*. Lo studio utilizza i rating di sostenibilità MSCI e si basa su dati riferiti a 72 società quotate europee incluse negli indici Euro Stoxx50, Euro Stoxx50 ESG ed Euro Stoxx ESG Leaders50 dal 2018 al 2022.

Anche Assael et al. (2023) utilizzano tecniche di *machine learning* e analizzano il legame tra rendimenti dei corsi azionari e ESG score su un campione di 2.429 società europee. Lo studio mostra che gli score ESG contengono informazioni aggiuntive in grado di spiegare i rendimenti azionari meglio dei soli fondamentali di mercato così come individuati nel modello a tre fattori di Fama e French (1993), ossia dimensione dell'impresa, *book-to-market value* ed *excess return*. I risultati dello studio evidenziano che, sebbene gli score ESG abbiano una profondità storica ancora piuttosto limitata, l'utilizzo di strumenti di *machine learning* rende già possibile dimostrare come essi influenzino i rendimenti annuali dei prezzi azionari. La relazione più significativa rilevata dallo studio si riferisce al dato sulle controversie societarie. Inoltre, l'impatto degli score ESG sui rendimenti azionari sembra più marcato per le società a medio-bassa capitalizzazione.

Tra i lavori che hanno indagato sui legami tra profili ESG e performance economico-finanziarie delle società, De Lucia et al. (2020), attraverso l'utilizzo sia di tecniche di *machine learning* sia di tecniche econometriche tradizionali su un campione di 1.038 società quotate europee, mostrano una relazione positiva tra score ESG e indicatori di redditività dati dal ROA (*return on assets*) e ROE (*return on equity*) e che la dinamica degli score ESG consente di effettuare previsioni piuttosto accurate dell'andamento di tali indicatori. Inoltre, la relazione esistente tra score ESG e indicatori di performance reddituale appare più marcata per le aziende che investono maggiormente

in innovazioni volte alla tutela dell'ambiente o all'incremento della produttività del lavoro e in politiche finalizzate alla salvaguardia della diversità e al rispetto delle pari opportunità.

Anche D'Amato et al. (2023) utilizzano strumenti di *machine learning* al fine di verificare l'esistenza di un legame tra informazioni non finanziarie e redditività. I risultati mostrano che, per un campione di circa 400 società europee appartenenti all'indice Euro Stoxx600 nel periodo tra il 2011 e il 2020, sussiste una relazione positiva tra lo score ESG elaborato da Refinitiv e la redditività sintetizzata dall'indicatore di EBIT (*earnings before interests and taxes*).

Il legame tra indicatori ESG e performance finanziarie è indagato con tecniche di *machine learning* anche da Sharma et al. (2021) che analizzano la rilevanza di dati su profili ESG nelle decisioni di investimento. Il lavoro si basa su un campione di oltre 1.400 società quotate e prende in considerazione diversi score ESG elaborati da Sustainalytics. I risultati evidenziano che gli score ESG contengono informazioni rilevanti ai fini delle decisioni di investimento poiché a migliori performance di sostenibilità si associa una più elevata redditività sintetizzata dagli indicatori ROE e ROA.

Lanza et al. (2020) propongono un approccio innovativo basato sull'utilizzo di tecniche ML volto a identificare gli indicatori ESG che meglio contribuiscono alla costruzione di portafogli efficienti. Tramite l'utilizzo di una vasta gamma di metriche ESG, lo studio mostra che gli indicatori selezionati dalla metodologia *machine learning* sono per la maggior parte di natura ambientale e in buona parte si riferiscono all'esposizione ai rischi connessi al cambiamento climatico o alla capacità di gestire il rischio di transizione. Tra questi, solo uno è rappresentato da uno score ESG elaborato da un *provider* di dati mentre la maggior parte riguarda dati comunicati dalle società.

Margot et al. (2021) mostrano che nella costruzione di un portafoglio di titoli gli strumenti di intelligenza artificiale, in grado di tener conto anche di relazioni non lineari tra le variabili, possono avere performance migliori rispetto alle classiche strategie di selezione dei titoli quali, ad esempio, la strategia *best-in-class*. Lo studio, basato su un campione di 1.500 società incluse nel MSCI World Index, evidenzia pertanto come gli strumenti di *machine learning* siano particolarmente utili nello studio della relazione tra profili ESG e performance finanziaria che tipicamente è di carattere non lineare e risulta influenzata da molteplici fattori quali il settore di attività, il paese di origine e altre caratteristiche societarie specifiche.

In linea generale, la letteratura sembra abbastanza concorde nell'affermare che le tecniche di intelligenza artificiale per l'analisi di tematiche connesse a profili ESG possano rappresentare un valore aggiunto nella ricerca empirica, consentendo di ottenere risultati più accurati rispetto a quelli derivanti dall'applicazione di strumenti di analisi tradizionale. L'utilizzo di queste metodologie consente, tuttavia, di superare solo in parte le criticità connesse alla qualità delle metriche ESG attualmente a disposizione. Alcuni degli studi passati in rassegna si basano su indicatori ESG, elaborati e distribuiti da *provider* di dati, tipicamente caratterizzati da grande eterogeneità. Tuttavia, le metodologie di rating dei profili ESG dei principali *provider* di dati, pur presentando elementi di connessione, si caratterizzano per peculiarità sia nella quantità e

nella tipologia dei dati sottostanti alle elaborazioni sia nella metodologia di aggregazione dei dati necessaria alla costruzione degli indicatori di sintesi¹⁰ (Berg et al. 2022). I risultati degli studi empirici che approfondiscono tematiche ESG sono pertanto maggiormente influenzati dalla scelta dell'indicatore utilizzato rispetto ai lavori che si concentrano esclusivamente su aspetti di tipo economico-finanziario.

Una parte della letteratura che utilizza tecniche di intelligenza artificiale si propone infatti di indagare l'uso di tali strumenti proprio al fine di identificare sistemi utili nella classificazione delle società in base a profili ESG o a scopo predittivo delle performance societarie su specifiche metriche di sostenibilità ambientale anche al fine di individuare strumenti che consentano di superare l'eccessivo ricorso a rating ESG elaborati dai *provider* di dati sulla base di metodologie eterogenee (Lee et al. 2022; Yin e Hsu, 2023). Ad esempio, Lee et al. (2022) propongono un nuovo approccio di analisi dei dati ESG tramite l'utilizzo di tecniche di *machine learning* e *deep learning* nonché di strumenti tradizionali di analisi econometrica. Lo studio, che ha l'obiettivo di mostrare come i dati relativi a profili ESG possono essere analizzati tramite l'utilizzo di tecniche evolute, propone diversi esperimenti evidenziando, tra le altre cose, che sussiste una relazione positiva tra profili ESG e rendimenti annuali dei fondi di investimento o che attraverso l'utilizzo di tecniche di ML è possibile identificare anomalie nei dati ESG o classificare le società in base a punteggi di sostenibilità. Anche Yin e Hsu (2023) propongono analisi in tal senso, mettendo a confronto le performance di alcuni modelli di *machine learning* nel prevedere gli score ESG di imprese non finanziarie, mentre Nguyen et al. (2021) utilizzano tecniche di *machine learning* per la previsione delle emissioni di carbonio delle imprese.

Il presente studio, come detto, prende le mosse dalle ricerche precedentemente svolte, con particolare riferimento a quella di D'Amato et al. (2023), e ne amplia sia l'oggetto sia l'ambito di analisi. Il lavoro, infatti, si propone di verificare non solo la sussistenza di un legame tra fattori ESG e redditività ma anche se a tale relazione concorrano in modo diverso i tre pilastri ESG considerati singolarmente. Il lavoro inoltre estende l'analisi alle società statunitensi, in modo da verificare se tale legame possa essere influenzato dal diverso assetto normativo sulle tematiche ESG che caratterizza l'Unione europea e gli USA.

10 Gli indicatori ESG elaborati da *provider* di dati sono numerosi e si basano tutti sull'individuazione delle tematiche (o attributi) rilevanti per ciascuno dei tre pilastri nonché per la definizione di specifiche metriche per la misurazione delle performance in relazione a ogni tematica, a cui vengono poi associati dei pesi in funzione dell'importanza relativa. Berg et al. (2022) identificano tre distinte fonti di divergenza tra i rating ESG: i) la 'divergenza di ambito' che si riferisce alla situazione in cui i rating si basano su serie diverse di attributi; ii) la 'divergenza di misurazione' che si riferisce alla situazione in cui i *provider* di rating misurano lo stesso attributo utilizzando indicatori diversi; iii) la 'divergenza di peso' che emerge quando si assegna un'importanza relativa diversa agli attributi considerati.

3 L'approccio metodologico

3.1 I metodi di analisi

In generale, le metodologie di ML si distinguono in modelli di apprendimento 'supervisionato' e 'non supervisionato'¹¹. Nei primi l'apprendimento si basa su dati precedentemente 'etichettati' come variabili di input e di output, permettendo così al modello di 'imparare' da tale classificazione; nei secondi, invece, l'algoritmo cerca autonomamente di dare un senso alle informazioni disponibili, identificando relazioni e caratteristiche comuni. Il presente lavoro utilizza modelli di ML supervisionati¹² che consentono di individuare relazioni tra variabili spesso difficili da identificare con i classici modelli econometrici (Athey e Imbens, 2019). Lo studio propone anche un confronto con l'applicazione di un tradizionale modello di regressione lineare.

Al proposito si osserva che le metodologie di ML si differenziano dai modelli econometrici tradizionali principalmente per le assunzioni di base. Nei modelli di regressione lineare, infatti, si ipotizza che i dati provengano da un processo:

$$Y = \mathbf{X}\beta + \epsilon \quad (1)$$

dove Y rappresenta la variabile target, $\mathbf{X} = X_1 + X_2 + \dots + X_p$ è il vettore delle variabili esplicative, o di input, β è un vettore di parametri da stimare con metodi dei minimi quadrati, di massima verosimiglianza o iterativi e ϵ il termine d'errore (residuo). Infatti, più genericamente, la relazione tra la variabile dipendente Y e le variabili esplicative \mathbf{X} è sintetizzata dalla funzione f tale per cui:

$$Y = f(\mathbf{X}) + \epsilon \quad (2)$$

La validità dei risultati della stima dipende dal rispetto delle assunzioni circa le caratteristiche della funzione f . Nello specifico, utilizzando un modello di regressione lineare, è necessario che vengano rispettate le assunzioni circa la linearità di f e quelle riferite alle relazioni che legano le variabili esplicative tra loro e con il residuo (tra cui indipendenza e omoschedasticità). La relativa accuratezza si misura attraverso i test sulla bontà di adattamento e l'analisi dei residui.

I modelli di ML non si basano su un modello teorico di riferimento ma, tramite l'utilizzo di algoritmi e modelli statistici, traggono informazioni e conoscenza direttamente dai dati (James et al. 2022). Pertanto, negli algoritmi di ML non si fanno ipotesi circa la distribuzione che ha generato i dati; il loro obiettivo è quello di trovare la stima \hat{f} della funzione f per ottenere come risultato il valore predittivo \hat{Y} .

11 A quelli riportati nel testo si aggiunge l'"apprendimento per rinforzo", in cui attraverso l'interazione con l'ambiente e l'identificazione di un obiettivo, le operazioni software che mirano a raggiungerlo ricevono una ricompensa (rinforzo), mentre quelle che deviano dall'obiettivo vengono ignorate.

12 Lo sviluppo di questi modelli è andato di pari passo con l'incremento della mole di dati e di informazioni disponibili (big data), dal momento che tecniche di *machine learning* e *non-linear processing* sono in grado di trattare volumi consistenti di dati, anche non strutturati.

L'accuratezza di \hat{Y} come predittore per Y dipende da due quantità che vengono chiamate errore riducibile ed errore irriducibile che, in quanto tale, non può essere minimizzato. La funzione \hat{f} sarà pertanto individuata tra quelle che minimizzano l'errore riducibile. Nello specifico, è possibile esprimere l'errore predittivo in termini di errore quadratico medio con la seguente formula:

$$\begin{aligned} E(Y - \hat{Y})^2 &= E[f(X) + \epsilon - \hat{f}(X)]^2 \\ &= E[f(X) - \hat{f}(X)]^2 + \text{Var}(\epsilon) \end{aligned} \quad (3)$$

dove la prima parte della formula, $E[f(X) - \hat{f}(X)]^2$, rappresenta l'errore riducibile e la seconda, $\text{Var}(\epsilon)$, l'errore irriducibile. L'obiettivo degli algoritmi di ML è quello di ridurre al minimo l'errore riducibile (*mean square error* o MSE) stimando un'adeguata funzione f . L'MSE può essere a sua volta scomposto in:

$$E[f(X) - \hat{f}(X)]^2 = [\text{bias}(\hat{f}(X))]^2 + \text{Var}(\hat{f}(X)) \quad (4)$$

Il primo termine, denominato *bias*, è il valore atteso dell'errore riducibile, ovvero la differenza tra la predizione media del modello e il valore reale che si sta cercando di predire. Esso rappresenta un indicatore dell'accuratezza del modello (*accuracy*) e può essere influenzato da assunzioni errate. Il secondo termine è la varianza e fa riferimento alla sensibilità (*sensitivity*) del modello alle variazioni nel dataset di *training* (ossia del dataset utilizzato per l'addestramento del modello). L'MSE sarà tanto più piccolo quanto minori sono il *bias* e la varianza. Tuttavia, tra queste componenti sussiste un *trade-off*: all'aumentare della complessità di un modello, il *bias* tenderà a diminuire, fornendo un risultato più accurato, ma la varianza tenderà a crescere, rendendolo più sensibile a variazioni dei dati disponibili.

Tra i metodi di apprendimento automatico, i metodi *ensemble* prevedono l'addestramento contemporaneo di più modelli per la soluzione dello stesso problema. Tali modelli vengono poi 'combinati' tra loro per ottenere il risultato finale. Il presente studio utilizza i metodi *random forest* e *gradient boosting*.

Il *random forest* è un algoritmo di apprendimento automatico, ampiamente utilizzato per problemi di classificazione e regressione, che combina diversi modelli per migliorare le prestazioni complessive. Esso consiste nella creazione di un certo numero di alberi decisionali, ognuno dei quali viene addestrato su un sottoinsieme casuale dei dati disponibili. Nella costruzione di ciascun albero, viene preso in considerazione solo un sottoinsieme casuale delle caratteristiche dei dati per ogni divisione del nodo, incrementando così variabilità e diversità degli alberi. Il risultato finale dell'algoritmo è determinato attraverso un 'voto a maggioranza', dove la classe o il valore che ottiene più voti da tutti gli alberi diventa la previsione finale del modello. Rispetto ad altri modelli di ML, il *random forest* ha performance particolarmente efficienti perché riduce

il rischio di *overfitting*,¹³ migliorando il grado di generalizzazione del modello e fornendo previsioni robuste, specialmente in situazioni complesse con molti dati e caratteristiche.

Il *gradient boosting* è un altro algoritmo di apprendimento automatico, anch'esso appartenente alla categoria degli *ensemble learning* come il *random forest*. La principale differenza tra i due approcci sta nel modo in cui vengono combinati i modelli base (solitamente alberi decisionali): dopo aver costruito un singolo modello base, spesso un albero decisionale semplice, si calcolano gli errori residui, ovvero le differenze tra le previsioni del modello iniziale e i valori effettivi nel set di dati di addestramento. Successivamente si costruisce un secondo modello che cerca di correggere gli errori residui commessi dal modello precedente. Tale processo viene ripetuto iterativamente molte volte in modo da costruire modelli aggiuntivi per correggere gli errori residui dei modelli precedenti. La previsione finale è ottenuta sommando le previsioni di tutti i modelli, ognuna pesata in base alla propria capacità di correggere gli errori¹⁴. Il *gradient boosting* è particolarmente efficace nella gestione di dati complessi e nella produzione di modelli altamente accurati, sebbene rispetto al *random forest* sia più sensibile al rischio di *overfitting*.

3.2 I modelli agnostici

Una problematica collegata ai modelli di ML è quella relativa alla loro interpretazione. Nell'approccio dell'apprendimento automatico, infatti, la funzione stimata \hat{f} non ha proprietà predeterminate dall'analista e, in linea generale, non è nota poiché viene elaborata internamente dal modello. Questa caratteristica fa sì che i metodi di ML vengano considerati delle *'black box'* il cui funzionamento risponde a dinamiche che non sono spiegabili.

Esistono, tuttavia, alcuni metodi, chiamati agnostici perché indipendenti dal modello di ML utilizzato, che consentono di favorire l'interpretazione delle relazioni individuate dal modello. Tra questi il presente lavoro utilizza il *partial dependence plot* (PDP), l'*individual conditional expectation* (ICE) e i valori di Shapley.

Nello specifico, il PDP, detto anche grafico delle dipendenze parziali, mostra l'effetto marginale di una variabile di input (*feature*) sul valore stimato da un modello di ML sulla variabile di output, ovvero come una particolare caratteristica influisca sulla previsione. Il grafico è pertanto in grado di mettere in evidenza il tipo di relazione (lineare, monotona, ecc.) tra la variabile di input e la variabile di output (Friedman, 2001).

L'ICE, noto anche come *'aspettativa condizionale individuale'*, mostra come cambia la previsione al variare di una variabile di input attraverso una rappresentazione

13 L'*overfitting* è un fenomeno che si verifica quando un modello statistico o un algoritmo si adatta troppo ai dati di *training*, al punto da catturare anche mere fluttuazioni casuali nei dati anziché la reale distribuzione sottostante, perdendo di generalità e facendo registrare scarse prestazioni sui nuovi dati.

14 Il termine *'gradient'* si riferisce al fatto che il modello cerca di muoversi lungo il *'gradiente'* degli errori per migliorare progressivamente le stime.

grafica che è l'equivalente del PDP riferito alle singole osservazioni di dati (Goldstein et al. 2015). In altre parole, il PDP rappresenta l'effetto medio di una variabile di input sulla previsione, mentre l'ICE mostra le traiettorie di dipendenza costruite sulle singole osservazioni tra la variabile di output e la variabile di input. Questo consente di individuare l'esistenza di relazioni eterogenee fra la due variabili per le singole osservazioni. Dal momento che nei grafici ICE potrebbe non essere facile individuare l'effetto medio dell'input di interesse sulla previsione, questi sono solitamente presentati insieme ai grafici PDP.

I valori di Shapley, infine, permettono di individuare quali variabili di input contribuiscono maggiormente alla previsione (Lundberg e Lee, 2017; Molnar, 2022). Tale tecnica di interpretazione dei risultati si basa sui principi della teoria dei giochi in cui le ricompense ai giocatori (rappresentati dalle variabili di input) vengono assegnate in modo proporzionale al contributo che ognuno di essi apporta alla coalizione, ovvero alla spiegazione della previsione. Il valore di Shapley rappresenta quindi il peso, o contributo marginale, assegnato a ogni variabile di input. Il calcolo dei valori di Shapley ha un costo computazionale estremamente elevato.

4 La descrizione e la preparazione dei dati

4.1 La descrizione

Il lavoro si basa su dati relativi a un campione di oltre 850 società europee e statunitensi a grande e media capitalizzazione appartenenti agli indici Stoxx Europe 600 e S&P 500¹⁵ e riferiti al periodo 2007–2021. Le variabili hanno frequenza annuale e riguardano score ESG, indicatori di redditività e indicatori relativi sia all'area geografica di appartenenza sia al settore di attività.

Gli score ESG

Al fine di studiare la relazione tra la performance di sostenibilità di un'impresa e la sua performance reddituale, giocano un ruolo centrale le metriche per la misurazione dell'impatto delle attività di business delle società sui temi legati ai fattori ESG. In questo ambito, diversi *data provider* hanno sviluppato negli ultimi anni database dedicati alle citate tematiche, riportando le informazioni, i dati e le metriche più rilevanti nonché sviluppando specifici indicatori proprietari (score) che valutano le performance ambientali, sociali e di governance delle società¹⁶. Ai fini del presente lavoro è

15 Lo Stoxx Europe 600 è un indice azionario che rappresenta le performance di 600 imprese appartenenti a 17 paesi europei; le imprese rappresentano circa il 90% della capitalizzazione del mercato azionario europeo. L'indice Standard&Poor 500 è il principale indice azionario statunitense, comprendente le più grandi imprese quotate degli Stati Uniti. La metodologia di calcolo dei due indici si basa su una logica *cap-weighted*, dove il peso delle singole aziende dipende dalla loro capitalizzazione di mercato e, pertanto, le aziende più grandi hanno un impatto maggiore sul valore dell'indice.

16 Gli score e i rating sviluppati dai fornitori di rating o dai *data provider* sono calcolati sulla base di informazioni, principi e metodologie diverse. In mancanza di un approccio condiviso, le valutazioni che vengono rese disponibili sono difficilmente confrontabili e connotate da un basso livello di correlazione. In proposito, Berg et al. (2022) hanno rilevato che il 50% delle divergenze di valutazione riferibili a cinque grandi operatori del settore si spiegano proprio alla luce degli indicatori ESG considerati, della relativa misurazione e del peso attribuito loro.

stato utilizzato lo score ESG elaborato da Refinitiv¹⁷ sia a livello complessivo sia riferito a ciascuno dei pilastri (o *pillar*) associati alle tre dimensioni della sostenibilità, ossia *environmental*, *social* e *governance* (E, S e G).

In particolare, lo score di Refinitiv è un indicatore di impatto che fornisce il livello di performance, impegno ed efficacia dell'impresa con riferimento ai tre pilastri ESG. Il calcolo dello score si basa su 186 variabili relative a performance ESG¹⁸, estratte da informazioni pubblicamente disponibili e verificabili. Tali misure sono raggruppate, a seconda del tema di riferimento, in dieci categorie, a loro volta, associate a uno dei tre pillar ESG. Gli score rappresentano la performance relativa della società nell'ambito del settore di attività e del paese di appartenenza. L'informazione mancante viene trattata come valore nullo e, pertanto, determina un abbassamento del punteggio complessivo assegnato alla società. Questo particolare aspetto metodologico implica pertanto che alle aziende caratterizzate da un reporting limitato dei profili di sostenibilità sia assegnato uno score relativamente più basso.

La Fig. 1 illustra le 10 categorie associate ai tre pilastri. Per ogni categoria sono prese in considerazione diverse metriche, la cui numerosità varia a seconda del fenomeno a cui si riferiscono e della disponibilità delle informazioni.

Fig. 1 – Struttura del ESG score elaborato da Refinitiv



Fonte: LSEG Refinitiv.

17 Per una descrizione dettagliata della metodologia aggiornata a dicembre 2023, si rinvia al documento pubblicato dalla società e disponibile al seguente link: https://www.refinitiv.com/content/dam/marketing/en_us/documents/methodology/refinitiv-esg-scores-methodology.pdf.

18 L'approccio di calcolo è di tipo *bottom up*. Nella metodologia di dicembre 2023, il computo si basa su più di 630 misure ESG rilevate a livello di singola impresa; tra queste ne vengono selezionate 186, che rappresentano le misure maggiormente confrontabili e rilevanti per la valutazione complessiva della società e la relativa attribuzione dello score.

Per ogni metrica j , alla società i viene attribuito un punteggio che dipende dalla posizione che essa ricopre nell'ambito del settore industriale (pilastri E e S) o del paese (pillar G) di appartenenza. Il calcolo di tale punteggio si effettua applicando la seguente formula:

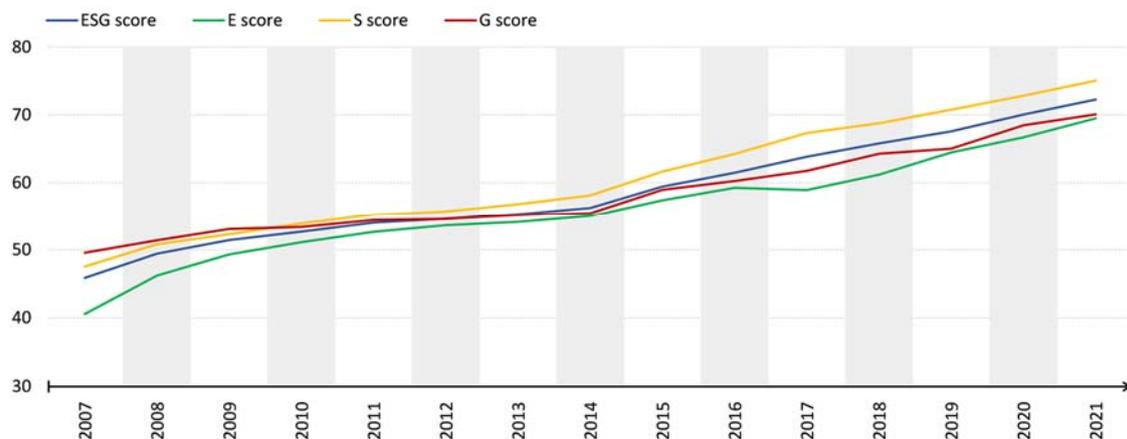
$$s_{ij} = (x + y) / z \quad (5)$$

dove s_{ij} è il punteggio attribuito alla società i per la metrica j , x è il numero di società con un valore della metrica peggiore della società i , y la metà del numero di società con lo stesso valore della società i e z il numero totale di società per le quali la metrica è disponibile. Questo metodo di calcolo, per costruzione, non è sensibile alla presenza di *outliers*.

I punteggi riferiti alle singole metriche sono sommati per ciascuna società. Lo score della categoria è quindi rappresentato dal valore percentile di tale somma nell'ambito del settore industriale (pilastri E e S) o del paese (pilastro G) di appartenenza. Gli score così calcolati vengono poi aggregati assegnando dei pesi alle singole categorie per ottenere lo score riferito a ciascun pilastro (*pillarscore*). L'ESG score complessivo viene calcolato dalla somma ponderata dei suddetti score riferiti ai tre pilastri. I pesi utilizzati in fase di aggregazione derivano dall'applicazione di una matrice di materialità che varia a seconda del settore industriale.

Nella Fig. 2 è riportato l'andamento dello score ESG e delle sue componenti, a partire dal 2007.

Fig. 2 – Dinamiche dello score ESG e degli score riferiti ai tre pilastri per le società incluse nell'analisi (valori medi)



Fonte: elaborazioni su dati LSEG Refinitiv.

Gli score Refinitiv vengono aggiornati periodicamente sia a seguito dell'inclusione di nuove metriche nella metodologia sottostante sia per riflettere l'eventuale ampliamento dell'informativa di sostenibilità fornita dalle società. Inoltre, poiché la metodologia implica una valutazione relativa delle performance ESG, anche l'inclusione di nuove società nell'insieme di analisi può determinare una modifica degli score delle società già presenti.

Gli altri dati inclusi nell'analisi

Con riferimento agli indicatori di redditività, le variabili utilizzate sono rappresentate dall'EBIT (*earnings before interest and taxes*, ossia l'utile al lordo di oneri finanziari e imposte), dal ROE (*return on equity*, che misura la redditività del capitale proprio) e dai ricavi dell'attività (nel prosieguo, *revenue*). Tutti i dati utilizzati sono di fonte Refinitiv.

Nello specifico, il primo indicatore, ossia l'EBIT, viene utilizzato quale variabile dipendente poiché costruito in modo da sintetizzare la performance reddituale di un'impresa non finanziaria indipendentemente dal sistema di tassazione a cui la stessa è sottoposta e del livello di indebitamento. Questo rende l'EBIT molto utile per analisi *cross-countries* e *cross-sectors* poiché consente di depurare il risultato reddituale da fattori tipicamente connessi al paese di appartenenza della società e al settore di attività. Per tali motivi, l'utilizzo dell'EBIT appare particolarmente adeguato nello studio dell'impatto dei fattori ESG sulla redditività delle imprese nell'ambito di un'analisi che coinvolge società appartenenti a paesi diversi e operanti in settori economici eterogenei.

L'inclusione nell'analisi delle altre due variabili reddituali, ossia ROE e *revenue*, viene invece operata al fine di fornire ai modelli di *machine learning* utilizzati ulteriori informazioni circa le caratteristiche dell'impresa in modo da migliorarne la performance. Come si dirà nel prosieguo, infatti, in questi modelli la multicollinearità (ossia l'utilizzo di variabili esplicative tra loro correlate) può rappresentare un valore aggiunto, a differenza dei modelli econometrici tradizionali nei quali, invece, risulta essere un fattore in grado di distorcere i risultati delle analisi.

Nella definizione del settore di attività delle società è stata utilizzata la classificazione adottata da Refinitiv e riferita alla principale linea di business societario. La Tab. 1 riporta la ripartizione delle società del campione per settore industriale.

Tab. 1 – Ripartizione delle società incluse nell'analisi per settore industriale

settore	numero di società	quota sul totale
<i>financials</i>	139	16,2%
<i>industrials</i>	136	15,9%
<i>consumer cyclicals</i>	121	14,1%
<i>technology</i>	103	12,0%
<i>healthcare</i>	79	9,2%
<i>consumer non-cyclicals</i>	76	8,9%
<i>basic materials</i>	70	8,2%
<i>utilities</i>	53	6,2%
<i>real estate</i>	43	5,0%
<i>energy</i>	36	4,2%

Fonte: elaborazioni su dati LSEG Refinitiv.

4.2 La preparazione

Nei modelli di apprendimento automatico il risultato dipende dalle informazioni disponibili. Per questo motivo la preparazione dei dati assume un ruolo rilevante affinché la fase di stima a valle dell'addestramento dell'algoritmo produca risultati non distorti (Han et al. 2012). La preparazione dei dati è stata realizzata attraverso tre fasi.

La prima fase ha riguardato l'attività di *cleaning* del dataset, con particolare riferimento alla gestione dei *missing values*, che ha comportato l'eliminazione delle società per le quali non risultava disponibile uno score ESG per almeno 11 dei 15 anni considerati. Questa operazione ha determinato una riduzione del numero di società incluse nell'analisi da 1.100 a 856, di cui 431 (su 600) appartenenti allo Stoxx Europe 600 e 425 (su 503) allo S&P 500.

La seconda fase ha riguardato la normalizzazione delle variabili quantitative, con lo scopo di evitare che l'eterogeneità nell'ordine di grandezza delle variabili potesse influenzare il processo di stima. Nella presente analisi, in particolare, è stato applicato il metodo di normalizzazione noto come min-max¹⁹ che ha consentito di esprimere tutte le variabili quantitative utilizzate con valori compresi nell'intervallo [0; 1].

19 Il metodo min-max ridimensiona in modo lineare ogni osservazione, trasformandola in un valore compreso all'interno dell'intervallo [0,1] attraverso l'applicazione della seguente formula: $x' = \frac{x - \min x}{\max x - \min x}$. Questo metodo può essere particolarmente utile nei modelli di apprendimento automatico che utilizzano algoritmi sensibili alle differenze di scala tra le caratteristiche.

La terza fase ha riguardato la suddivisione del dataset in due sottoinsiemi, uno per l'addestramento del modello (dataset di *training*, comprendente l'80% delle osservazioni) e l'altro per testare la capacità predittiva del modello addestrato (dataset di test), costituito dal restante 20% delle osservazioni con dati diversi da quelli utilizzati nella fase di addestramento²⁰. La suddivisione delle osservazioni tra i due dataset è stata effettuata in modo casuale.

Dopo aver preparato il dataset, si è quindi proceduto a un'analisi statistica i cui risultati sono riportati nella sezione seguente.

4.3 La correlazione

Un'analisi statistica preliminare del dataset mostra che sussiste una correlazione positiva e significativa tra tutte le principali variabili oggetto di studio. Tale analisi ha preso in considerazione dapprima l'ESG score complessivo e poi ognuno dei tre *pillar* score. La Fig. 3 mostra i coefficienti di correlazione tra gli indicatori reddituali e gli ESG score nonché la loro significatività.

Nello specifico tutti i correlogrammi mostrano una relazione positiva tra alcuni indicatori di redditività (EBIT e *revenue*) e tutti gli score ESG considerati, ossia lo score complessivo e quelli riferiti a ognuno dei tre pilastri E, S e G. Non emerge invece una correlazione nettamente positiva tra il ROE e gli score ESG inclusi nell'analisi, con coefficienti di correlazione prossimi allo zero e in alcuni casi non significativi.

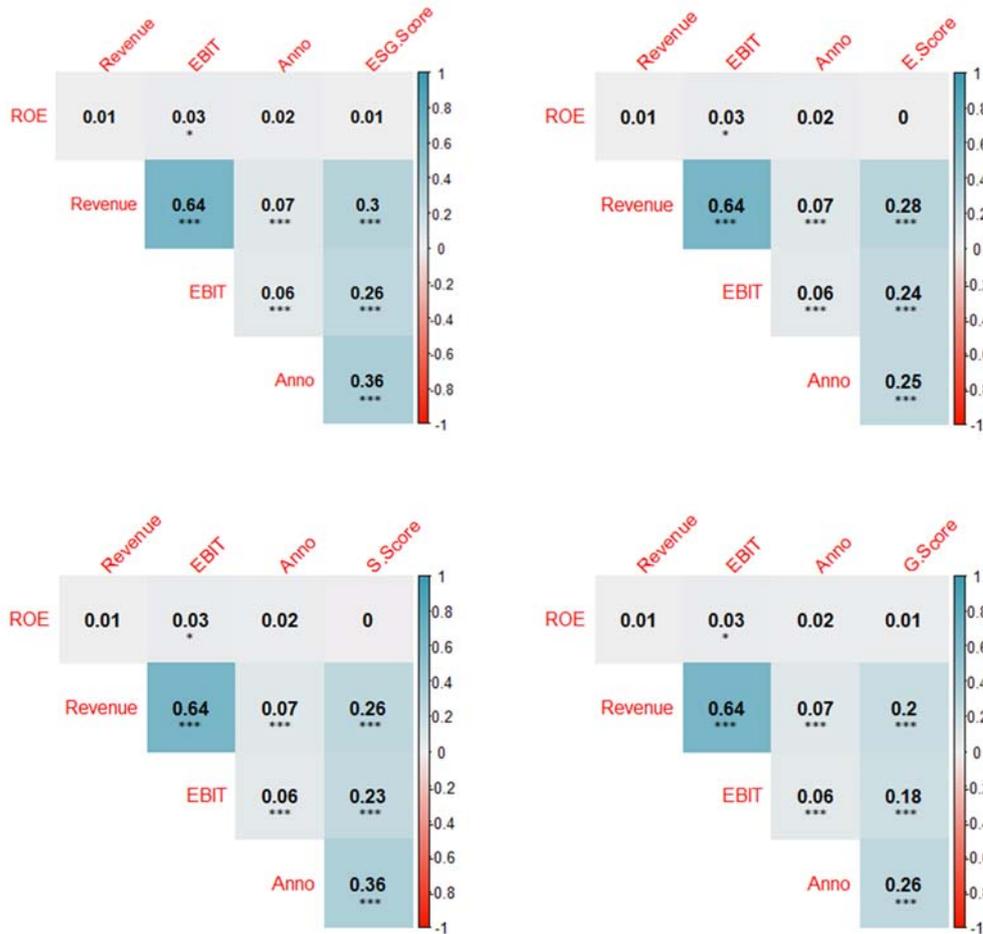
Il calcolo del correlogramma anche per i singoli pilastri dell'ESG score, consente di far emergere che il *pillar* E presenta una correlazione più alta con l'EBIT rispetto agli altri *pillar*.

Tutti gli score ESG risultano inoltre positivamente correlati alla variabile che individua l'anno di riferimento, circostanza che, come detto, deriva dal progressivo miglioramento degli score ESG nel corso del tempo. Si tratta di una dinamica emersa già in fase di descrizione dei dati e illustrata nella Fig. 2.

Le relazioni emerse dalla suddetta analisi statistica sono state poi approfondite nella fase di stima che sarà oggetto della sezione seguente.

20 Di norma, la capacità di predizione del modello applicato ai dati di *training* è migliore di quella che si ottiene applicando lo stesso modello ai dati di test. Nel processo di scelta del modello è necessario però evitare sia un sotto-adattamento (*underfitting*) del modello ai dati sia un sovra-adattamento (*overfitting*) dello stesso.

Fig. 3 – Analisi di correlazione tra le variabili utilizzate nello studio



Fonte: elaborazioni su dati LSEG Refinitiv. Gli asterischi ***, ** e * indicano un livello di significatività pari, rispettivamente, al 99%, 95% e 90%.

5 La stima dei modelli

Le relazioni di base tra le variabili prese in considerazione nell'analisi sono due. In entrambe la variabile di output (ossia la variabile dipendente secondo i modelli di analisi tradizionali) è l'EBIT. Le due relazioni si distinguono tuttavia per alcune variabili di input (dette anche *features*). Nello specifico, la prima relazione, che definiremo 'aggregata', include tra le variabili di input l'indicatore complessivo di performance di sostenibilità delle imprese (ESG score), mentre la seconda, che definiremo 'disaggregata', riporta tra le *features* gli score riferiti ai tre pillar ESG presi singolarmente al fine di approfondire l'impatto di ciascuno. Le due relazioni possono essere approssimate, rispettivamente, con le seguenti notazioni:

$$EBIT \sim anno + ESG\ score + revenue + ROE + settore + continente \quad (6)$$

$$EBIT \sim anno + E\ score + S\ score + G\ score + revenue + ROE + settore + continente \quad (7)$$

Tra le *features* utilizzate nei modelli sono inclusi anche gli altri indicatori di redditività presi in considerazione, ovvero il ROE e i ricavi (*revenue*), dal momento che nei modelli di *machine learning* la multicollinearità non rappresenta necessariamente una problematica da gestire. Al contrario, includere variabili correlate in un modello di *machine learning* può talvolta aiutare la comprensione dei dati, ovvero fornire informazioni sulla struttura degli stessi e sulle loro relazioni intrinseche.

Per la stima della relazione 'aggregata' sono stati utilizzati due metodi di ML (*random forest* e *gradient boosting*) e il metodo della regressione lineare. Il confronto tra le performance dei metodi utilizzati è stato effettuato sulla base dello scarto quadratico medio della stima (*root mean square error* o RMSE) e dell'errore assoluto medio (*mean absolute error* o MAE). I risultati sono riportati nella Tab. 2 con la distinzione di quelli ottenuti sul dataset di *training* da quelli riferiti al dataset di test.

Tab. 2 – Comparazione dei modelli utilizzati in termini di misure di errore

dataset	errore	<i>random forest</i>	<i>gradient boosting</i>	regressione lineare
<i>training set</i>	RMSE	0,01659	0,00856	0,02408
	MAE	0,00620	0,00476	0,01026
test set	RMSE	0,01287	0,01482	0,02250
	MAE	0,00564	0,00680	0,00980

Fonte: elaborazioni su dati LSEG Refinitiv. RMSE sta per *root mean square error* e MAE sta per *mean absolute error*.

Dalla Tab. 2 si osserva che il modello con RMSE e MAE minori è il *gradient boosting*, che tuttavia risulta essere meno preciso utilizzando i dati di test (circostanza piuttosto frequente nei modelli di ML). Con riferimento a questi ultimi, infatti, il modello che minimizza i due errori è il *random forest*, mentre il modello di regressione lineare registra le peggiori performance su entrambi i dataset.

Nella Tab. 3, invece, sono riportati i valori della deviazione standard σ e dell'indice R^2 , che indica la varianza spiegata dal modello. Rispetto a questi indicatori il modello *random forest* risulta il migliore, mentre il modello di regressione fa registrare la peggiore performance riuscendo a catturare in modo meno soddisfacente la relazione (presumibilmente non lineare) esistente tra le variabili oggetto di analisi.

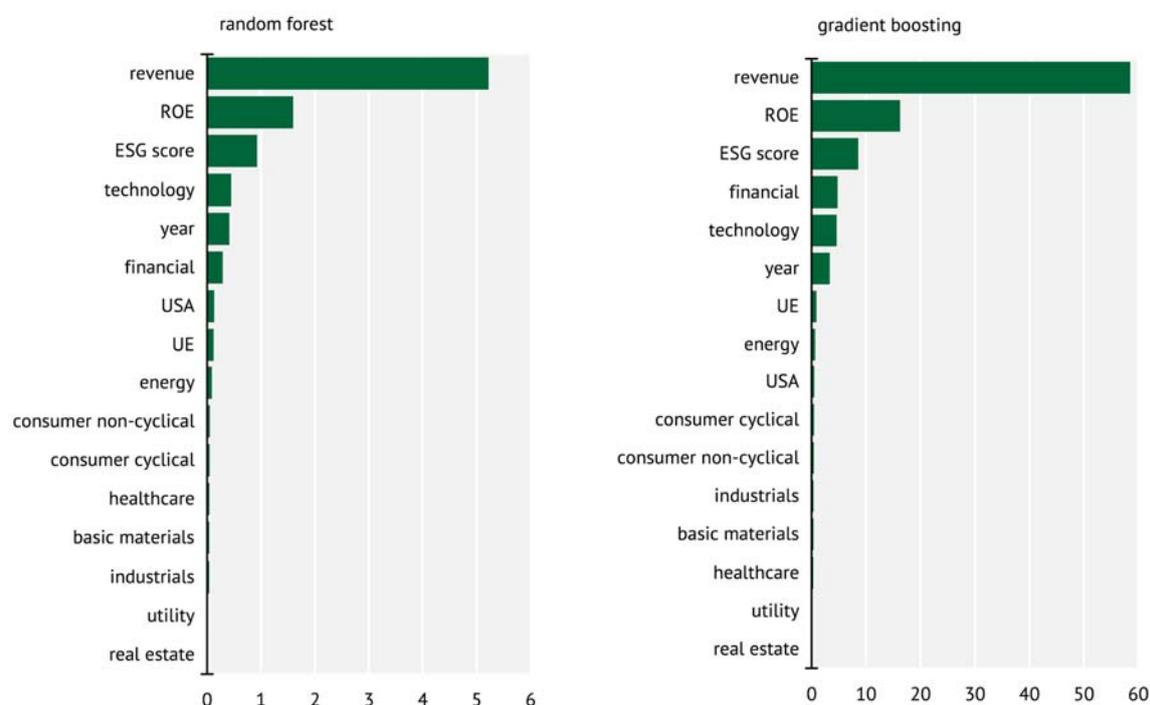
Tab. 3 – Comparazione dei modelli utilizzati in termini di misure di varianza

indicatore	<i>random forest</i>	<i>gradient boosting</i>	regressione lineare
σ	0,01287	0,01482	0,02249
R^2	83,13%	77,65%	48,47%

Fonte: elaborazioni su dati LSEG Refinitiv.

La Fig. 4 mostra i risultati delle stime del *random forest* (grafico di sinistra) e del *gradient boosting* (grafico di destra) per le *features* più rilevanti. In entrambi i casi i due modelli confermano che l'ESG score è un fattore importante nel prevedere l'EBIT, sebbene in misura minore rispetto alle altre due variabili di redditività (ossia *revenue* e ROE). Tali evidenze confermano le indicazioni già emerse nell'analisi del corredo-gramma, ad eccezione del risultato riferito al ROE che non era emerso in quella sede.

Fig. 4 – Risultati delle stime dei modelli ML riferiti alle *features* più rilevanti



Fonte: elaborazioni su dati LSEG Refinitiv. Le misure sull'asse delle ascisse rappresentano l'importanza relativa di ciascuna *feature* all'interno di ciascuno dei modelli.

I risultati della stima del modello di regressione, invece, confermano solo quanto già osservato in merito all'analisi del correlogramma senza aggiungere, pertanto, alcuna informazione utile (Tab. 4).

Tab. 4 – Risultati del modello di regressione lineare

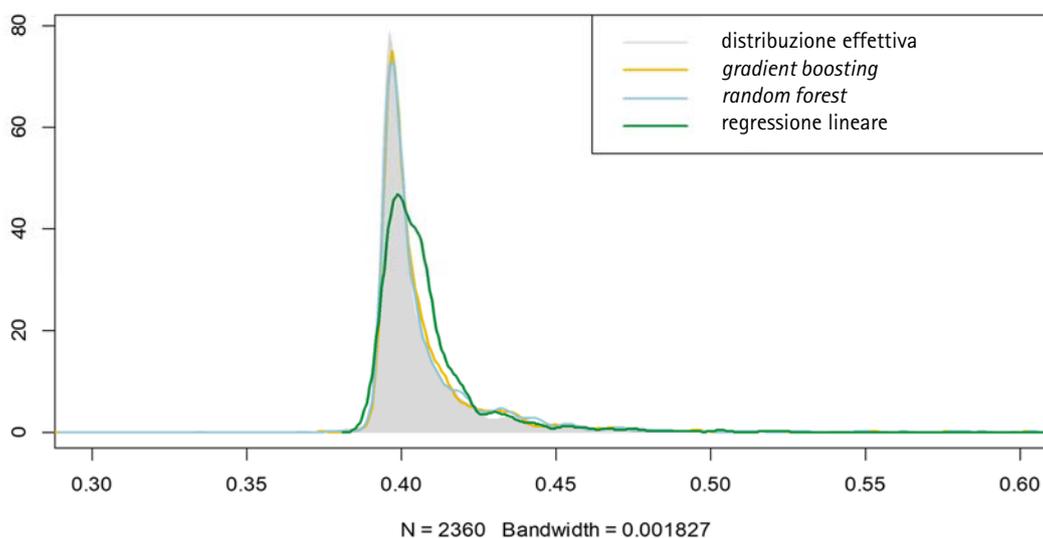
variabili esplicative	coefficiente stimato	standard error	t-value
intercetta	3,271E-01***	1,844E-02	17,736
anno	-2,645E-03**	8,988E-04	-2,943
ESG score	1,465E-02***	1,397E-03	10,487
revenue	3,118E-01***	4,362E-03	71,482
ROE	6,162E-02*	2,880E-02	2,140
consumer cyclicals	-1,327E-03	1,098E-03	-1,208
consumer non-cyclicals	-7,221E-04	1,227E-03	-0,589
energy	-1,307E-03	1,502E-03	-0,871
financials	7,540E-03***	1,064E-03	7,090
healthcare	4,505E-03***	1,199E-03	3,756
industrials	-2,563E-04	1,076E-03	-0,238
real estate	4,161E-05	1,408E-03	0,030
technology	1,024E-02***	1,138E-03	9,003
utilities	1,287E-03	1,330E-03	0,968
UE	-4,093E-03***	5,178E-04	-7,904

Fonte: elaborazioni su dati LSEG Refinitiv. Gli asterischi ***, ** e * indicano un livello di significatività pari, rispettivamente, al 99%, 95% e 90%.

Un migliore adattamento ai dati dei modelli di ML rispetto al classico modello di regressione lineare viene, infine, rilevato anche da un punto di vista grafico.

Nella Fig. 5 sono rappresentate le funzioni di densità stimate attraverso i diversi algoritmi messe a confronto con la distribuzione dei valori effettivi dell'EBIT. Si osserva che le funzioni di densità stimate relative ai modelli di ML sono pressoché sovrapposte alla funzione di densità dei dati osservati, a differenza della funzione di densità stimata utilizzando il tradizionale modello di regressione lineare.

Fig. 5 – Confronto tra le funzioni di densità stimate dai modelli e la distribuzione effettiva dell'EBIT



Fonte: elaborazioni su dati LSEG Refinitiv. Nel grafico N indica il numero osservazioni selezionate e *bandwidth* rappresenta il parametro in base al quale è stato effettuato lo *smoothing* della densità dei dati.

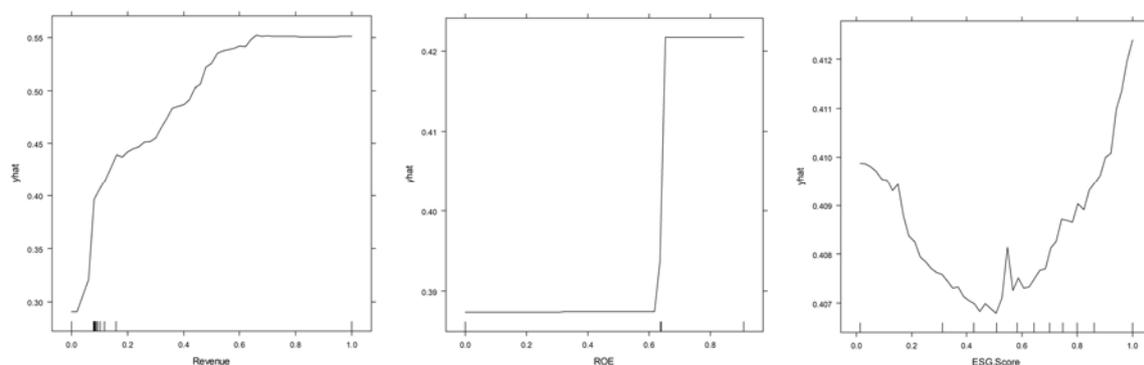
6 L'interpretazione dei risultati

Appurata la migliore performance del modello *random forest* rispetto alle altre metodologie utilizzate, i risultati delle stime sono stati approfonditi attraverso l'uso dei modelli agnostici citati in precedenza, al fine di giungere a una più completa interpretazione.

La Fig. 6 riporta tre PDP riferiti alle variabili più rilevanti emerse dall'analisi della relazione aggregata, ossia *revenue*, ESG score e ROE, consentendo di cogliere ulteriori dettagli sulle relazioni tra queste variabili e la variabile di output, ossia l'EBIT.

Il PDP mostra che la relazione tra ESG score ed EBIT ha un andamento presoché parabolico, in ragione del quale alle società con l'ESG score basso o alto è associato un valore dell'EBIT superiore rispetto alle società con un valore dell'ESG score intermedio. Tale risultato potrebbe suggerire che l'impegno iniziale delle società finalizzato a raggiungere migliori performance di sostenibilità implichi un aumento dei costi nel breve periodo, che si traduce in un peggioramento dell'EBIT. Tuttavia, nel lungo periodo, il miglioramento del profilo di sostenibilità dell'impresa porterebbe a un incremento anche nelle performance reddituali, rilevato da un EBIT più elevato.

Fig. 6 – Partial dependence plot (PDP) della relazione tra EBIT e le variabili maggiormente significative



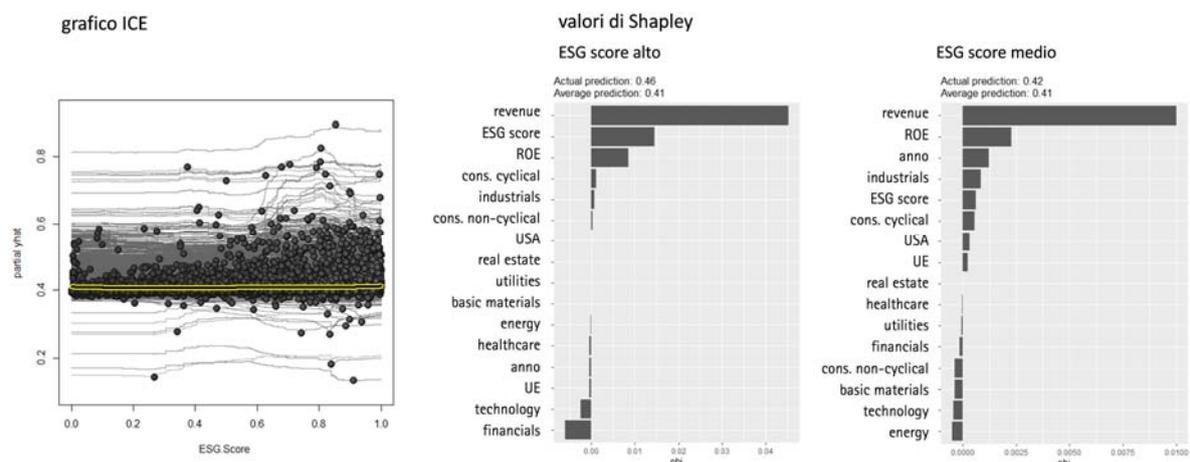
Fonte: elaborazioni su dati LSEG Refinitiv. La misura 'yhat' sull'asse delle ordinate rappresenta la stima media della variabile target EBIT per la *feature* considerata, mantenendo fisse le altre *features* al loro valore medio.

La relazione tra l'EBIT e l'ESG score è stata approfondita sia attraverso il grafico ICE sia attraverso il computo dei valori di Shapley per due osservazioni (Fig. 7). Il grafico ICE mostra la relazione tra l'EBIT e l'ESG score per ogni singola osservazione del dataset, tenendo costanti i valori di tutte le altre caratteristiche di input. La linea in giallo del grafico rappresenta il PDP già commentato, ovvero la media delle traiettorie di dipendenza, ma rappresentato in una scala di valori più ampia e tale da rendere la curva individuata in precedenza estremamente piatta²¹. I puntini del grafico ICE rappresentano i valori osservati della variabile di input e il valore della stima della variabile di output. Nel grafico di sinistra della Fig. 7 si osserva che a valori più bassi dell'ESG score corrisponde una minore variabilità delle stime sull'EBIT. Per valori di ESG score più elevati, invece, si rilevano dinamiche maggiormente eterogenee.

Per i valori di Shapley, si è scelto di analizzare due osservazioni puntuali: una in cui l'ESG score è alto e una con un valore dell'ESG score intermedio. Come si osserva nella Fig. 7, nel primo caso il contributo dell'ESG score alla previsione dell'EBIT è positivo, mentre nel secondo caso è pressoché nullo. Pertanto, i risultati confermano quanto già emerso anche dalle analisi precedenti, osservando anche l'andamento parabolico della Fig. 6.

21 La parte in giallo del grafico di destra nella Fig. 7 e il grafico di sinistra nella Fig. 6 rappresentano i medesimi valori. La differenza tra i due deriva dalla diversa ampiezza della scala di riferimento.

Fig. 7 – Individual conditional expectation (ICE) e valori di Shapley

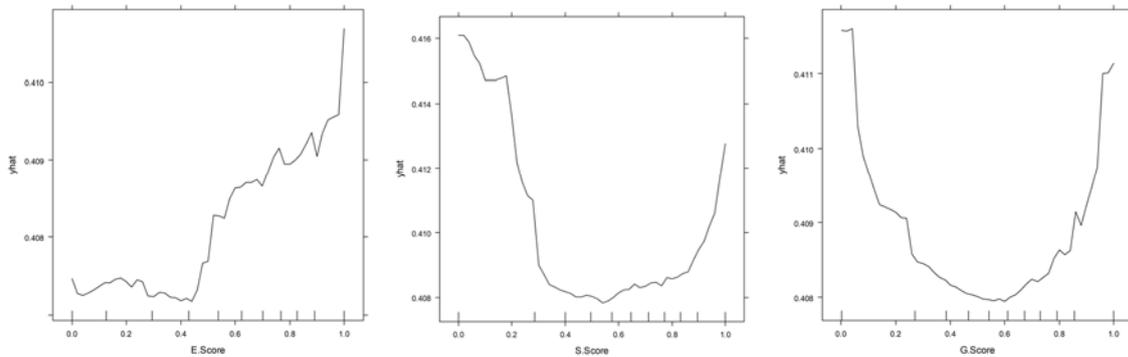


Fonte: elaborazioni su dati LSEG Refinitiv. Nel grafico di sinistra 'partial yhat' rappresenta le stime yhat della variabile target EBIT per ogni osservazione della *feature* considerata, mantenendo fisse le altre *features* al loro valore medio. Nei grafici di destra 'Average prediction' rappresenta la previsione media del modello basata su tutte le osservazioni, 'Actual prediction' si riferisce alla previsione del modello per un'osservazione specifica nel set di dati e 'phi' rappresenta il contributo di ciascuna osservazione alla differenza tra la stima di *actual* e *average prediction*.

Per comprendere al meglio la relazione esistente tra performance di sostenibilità e performance reddituali, i due modelli agnostici sono stati applicati anche alla relazione disaggregata che, come detto, include tra le *features* gli score riferiti ai tre *pillar* ESG presi separatamente.

Dai risultati ottenuti si osserva la relazione positiva tra il pilastro E e l'EBIT, per cui all'aumentare delle performance di sostenibilità ambientale corrisponde un EBIT maggiore (Fig. 8). La relazione tra score *social* e di governance e l'EBIT ha, invece, una forma parabolica positiva tale per cui a valori bassi e alti degli score S e G si associa un EBIT più alto rispetto a quanto avviene per valori intermedi degli stessi. Tale risultato suggerisce, come evidenziato in precedenza in relazione all'ESG score complessivo, che all'aumentare delle performance di sostenibilità sociale e di governance si registra dapprima un peggioramento dei risultati della gestione operativa (EBIT) connesso presumibilmente a un incremento dei costi nel breve periodo e, in seguito, un progressivo miglioramento della performance reddituale dell'impresa. Il risultato disaggregato suggerisce, inoltre, che l'impatto negativo sull'EBIT derivante da un iniziale miglioramento delle performance di sostenibilità dell'impresa, osservato per l'ESG score complessivo, non riguarda la componente ambientale. Pertanto, l'impegno delle imprese verso una maggiore sostenibilità in questo ambito potrebbe associarsi a un incremento delle loro performance reddituali anche nel breve periodo.

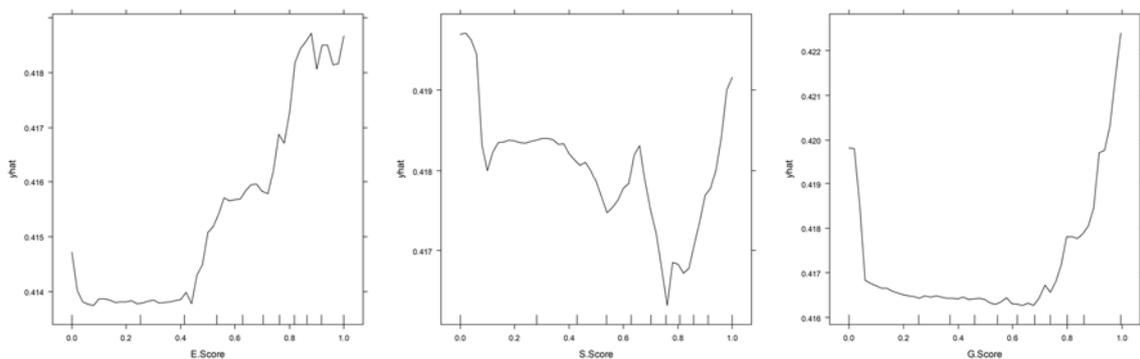
Fig. 8 – *Partial dependence plot* (PDP) della relazione tra EBIT e gli score riferiti ai tre pilastri



Fonte: elaborazioni su dati LSEG Refinitiv. La misura 'y-hat' sull'asse delle ordinate rappresenta la stima media della variabile target EBIT per la *feature* considerata, mantenendo fisse le altre *features* al loro valore medio.

La relazione tra ESG score ed EBIT è stata infine approfondita con un confronto a livello geografico, stimando separatamente lo stesso modello sui dati delle società appartenenti all'indice azionario STOXX Europe600 (Fig. 9) e di quelle appartenenti all'indice S&P500 (Fig. 10).

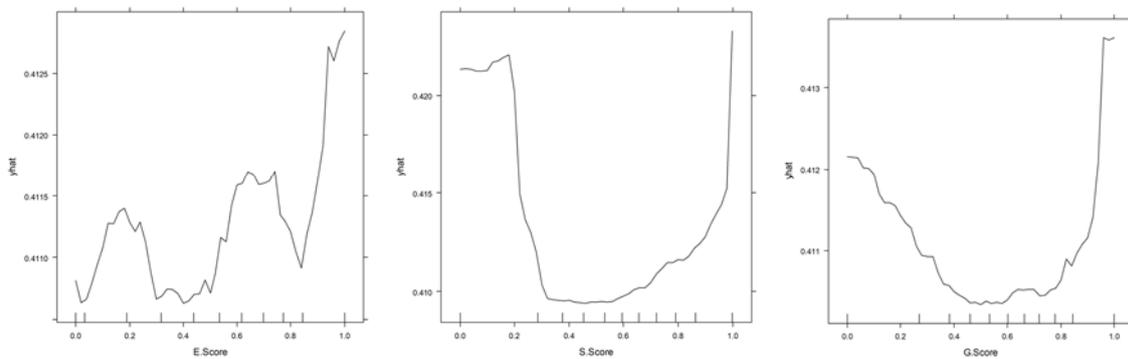
Fig. 9 – *Partial dependence plot* (PDP) della relazione tra EBIT e gli score riferiti ai tre pilastri per le società europee



Fonte: elaborazioni su dati LSEG Refinitiv. La misura 'y-hat' sull'asse delle ordinate rappresenta la stima media della variabile target EBIT per la *feature* considerata, mantenendo fisse le altre *features* al loro valore medio.

I risultati mostrano che tra l'EBIT e gli score riferiti ai singoli pilastri sussiste una relazione differente nelle due aree geografiche considerate. In particolare, con riferimento al pilastro E, il PDP della Fig. 9, ottenuto dai risultati riferiti alle società europee, mostra una tendenza crescente più definita rispetto a quella osservata per le società statunitensi, per le quali il PDP ha una dinamica altalenante.

Fig. 10 – Partial dependence plot (PDP) della relazione tra EBIT e gli score riferiti ai tre pilastri per le società statunitensi



Fonte: elaborazioni su dati LSEG Refinitiv. La misura 'y-hat' sull'asse delle ordinate rappresenta la stima media della variabile target EBIT per la *feature* considerata, mantenendo fisse le altre *features* al loro valore medio.

Tale difformità potrebbe suggerire che la relazione tra performance reddituale e di sostenibilità sia in qualche modo influenzata dal quadro regolamentare di riferimento. Nella UE, dove si osserva un intenso impegno del legislatore sui temi della sostenibilità ambientale, la maggiore attenzione a questo tema da parte dell'impresa si associa a un miglioramento anche delle performance reddituale. Negli Stati Uniti invece, dove il regime regolatorio in materia non appare altrettanto omogeneo, questa evidenza risulta meno chiara.

7 Conclusioni

In un contesto in cui l'ecosistema delle informazioni si sta perfezionando e i mercati, di conseguenza, non sono ancora in grado di prezzare pienamente i rischi e le opportunità connessi alle tematiche ESG, sta aumentando il ricorso a metodologie di analisi basate su tecniche di *machine learning* che, non essendo strettamente vincolate a modelli teorici tipicamente usati nella ricerca economica o finanziaria, possono offrire un maggiore grado di flessibilità e consentire di individuare relazioni difficili da far emergere attraverso il classico approccio econometrico.

Questo studio nasce con l'obiettivo di mostrare come questi metodi di analisi possano aiutare a comprendere quale relazione sussista tra performance ESG e performance reddituale delle imprese. Si tratta di un tema di grande interesse non solo per il mercato ma anche per le istituzioni. Una piena comprensione di tali dinamiche può infatti aiutare i *regulators* a meglio indirizzare le proprie scelte. In questo ambito, l'Unione europea ha assunto un ruolo guida a livello internazionale creando un quadro normativo sempre più ampio e articolato, al fine di favorire, anche attraverso lo sviluppo di un ecosistema dell'informazione sostenibile, il flusso finanziario verso attività economiche in grado di contribuire agli obiettivi di sostenibilità prefissati.

Il presente lavoro illustra un'applicazione di alcune tecniche di ML allo studio della relazione tra performance reddituale e performance di sostenibilità delle maggiori società quotate in Europa e negli USA e rappresenta un esempio di come queste tecniche possono essere utilizzate per analisi in tale ambito. Per ovviare a uno dei principali punti deboli dei metodi di *machine learning*, ovvero la limitata possibilità di interpretare i risultati, lo studio utilizza alcuni modelli cosiddetti agnostici perché prescindono dal metodo di ML impiegato. Questi ultimi sono tipicamente utilizzati per favorire nel concreto la capacità dell'analista di interpretare i risultati, consentendo di determinare il contributo delle variabili di input alle previsioni del modello.

Lo studio si basa sui dati relativi a oltre 850 società europee e statunitensi a maggiore capitalizzazione, su un arco temporale di 15 anni, e analizza il legame tra performance reddituale e di sostenibilità. I risultati mostrano che i tre pilastri E, S e G che compongono l'indicatore contribuiscono in modo differente a questo legame. Lo score riferito alla sostenibilità ambientale (pilastro E) risulta infatti associato positivamente alle performance reddituali in maniera più netta. I risultati ottenuti, peraltro confermati anche in altri studi, suggeriscono che l'attenzione ai temi della sostenibilità da parte delle imprese può costituire un valore aggiunto anche in termini di performance reddituale ed efficienza operativa. Il lavoro mostra, altresì, la sussistenza di differenze significative nei risultati relativi alle imprese europee rispetto a quelle statunitensi, presumibilmente connesse al diverso assetto normativo che caratterizza le due giurisdizioni.

L'utilizzo di tecniche di *machine learning* consente, tuttavia, di superare solo in parte le criticità connesse alla qualità delle metriche ESG attualmente a disposizione. Questo studio, in linea con parte della letteratura sul tema, utilizza indicatori ESG elaborati e distribuiti da un solo *provider* di dati. In un contesto in cui l'intero ecosistema dell'informazione ESG è ancora in fase evolutiva, le metriche elaborate dai *provider* di

dati sono caratterizzate da poca stabilità (poiché soggette a un costante affinamento anche in ragione dei continui sviluppi regolamentari) e da grande eterogeneità (poiché basate su metodologie proprietarie, spesso molto diverse tra loro).

La progressiva definizione di standard e metriche di sostenibilità faciliterà la raccolta e l'analisi dei dati strutturati. Inoltre, l'evoluzione normativa consentirà di aumentare la trasparenza nel mercato degli investimenti sostenibili. In materia di rating ESG, le misure attualmente allo studio, volte ad aumentare la trasparenza circa le metodologie di analisi utilizzate dai fornitori di rating ESG, garantiranno che nel mercato continuino ad essere disponibili approcci di analisi diversi alle tematiche di sostenibilità, incrementando al contempo le informazioni circa le caratteristiche dei rating elaborati.

Riferimenti bibliografici

- AFME (2024), ESG Finance Report Q4 2023; <https://www.afme.eu/Portals/0/DispatchFeauredImages/AFME%20ESG%20Finance%20Report%204Q%202023.pdf>
- Allen, E., Lyons, K. e Tavares, R. (2017), The Application of Machine Learning to Sustainable Finance, *Journal of Environmental Investing* 8, n. 1, <https://cbey.yale.edu/sites/default/files/The%20Application%20of%20Machine%20Learning%20to%20Sustainable%20Finance.pdf>
- Assael, J., Carlier, L. e Challet, D. (2023), Dissecting the Explanatory Power of ESG Features on Equity Returns by Sector, Capitalization, and Year with Interpretable Machine Learning, *Journal of Risk and Financial Management* 16, n. 3: 159, <https://doi.org/10.3390/jrfm16030159>
- Athey, S. e Imbens, G. (2019), Machine Learning Methods That Economists Should Know About, Vol. 11: 685–725, <https://doi.org/10.1146/annurev-economics-080217-053433>
- Breiman, L. (2001), Statistical Modeling: The Two Cultures, *Statistical Science*, Vol. 16, No. 3, 199–231
- D'Amato, V., D'Ecclesia, R. e Levantesi, S. (2023), Firms' profitability and ESG score: A machine learning approach, special issue paper in *Applied Stochastic Models in Business and Industry* John Wiley & Sons Ltd, <https://doi.org/10.1002/asmb.2758>
- De Lucia, C., Paziienza, P. e Barlett, M. (2020), Does good ESG lead to better financial performances by firms? Machine learning and logistics regression models of public enterprises in Europe, *Sustainability* [online], 12(13), article ID 5317; <https://doi.org/10.3390/su12135317>
- Friedman, J. (2001), Greedy Function Approximation: A Gradient Boosting Machine, *The Annals of Statistics*, 29, 1189–1232, <https://doi.org/10.1214/aos/1013203451>
- Goldstein, A., Kapelner, A., Bleich, J. e Pitkin, E. (2015), Peeking inside the black box: Visualizing statistical learning with plots of individual conditional expectation, *Journal of Computational and Graphical Statistics*, 24(1), 44–65, <https://doi.org/10.1080/10618600.2014.907095>

- Guo T., Jamet N., Betrix, V., Piquet, L.A. e Hauptmann, E. (2020), ESG2Risk: A Deep Learning Framework from ESG News to Stock Volatility Prediction, papers 2005.02527, arXiv.org, <https://arxiv.org/abs/2005.02527>
- Han, J., Kamber, M. e Pei, J. (2012), Data mining: concepts and techniques, 3rd edition, capitolo 3
- James, G., Witten, D., Hastie, T. e Tibshirani, R. (2021), An Introduction to Statistical Learning: with Applications in R, Springer Texts in Statistics, <https://doi.org/10.1007/978-1-0716-1418-1>
- Han, J., Kamber, M. e Pei, J. (2012), Data Mining - Concepts and Techniques, Elsevier Inc.; <https://doi.org/10.1016/C2009-0-61819-5>
- Lanza, A., Bernardini E. e Faiella, I., (2020), Mind the gap! Machine learning, ESG metrics and sustainable investment, Banca d'Italia, Questioni di economia e finanza, occasional paper n. 561
- Lee O., Joo, H., Choi, H. e Cheon, M. (2022), Proposing an Integrated Approach to Analyzing ESG Data via Machine Learning and Deep Learning Algorithms, Sustainability, MDPI, vol. 14(14), pages 1-14, July.
- Linciano, N., Cafiero, E., Ciavarella, A., Di Stefano, G., Levantini, E., Mollo, G., Nocella, S., Santamaria, R. e Taverna, M. (2021), La finanza per lo sviluppo sostenibile. Tendenze, questioni in corso e prospettive alla luce dell'evoluzione del quadro regolamentare dell'Unione europea, CONSOB - Quaderno di finanza sostenibile n. 1
- LSEG Refinitiv (2022), Environmental, social and governance scores from Refinitiv, https://www.refinitiv.com/content/dam/marketing/en_us/documents/methodology/refinitiv-esg-scores-methodology.pdf
- Lundberg, S.M. e Lee, S.-I. (2017), A Unified Approach to Interpreting Model Predictions, Advances in Neural Information Processing Systems, Vol. 30, Curran Associates, <https://proceedings.neurips.cc/paper/2017/file/8a20a-8621978632d76c43dfd28b67767-Paper.pdf>
- Margot, V., Geissler, C., de Franco, C. e Monnier, B., (2021), ESG Investments: Filtering versus Machine Learning Approaches, Applied Economics and Finance, Redfame publishing, vol. 8(2), pages 1-16
- Molnar (2022), Interpretable Machine Learning A Guide for Making Black Box Models Explainable, 2nd edition, <https://christophm.github.io/interpretable-ml-book/>
- Morgan Stanley (2024), Sustainable Reality Report, al link <https://www.morganstanley.com/ideas/sustainable-funds-performance-2023-full-year>
- Natixis Investment Managers (2022), Global Survey of Fund Selectors, al link <https://www.im.natixis.com/sg/research/seven-insights-on-how-the-smart-money-is-approaching-esg>

- Nguyen, Q., Diaz-Rainey, I. e Kurupparachchi, D. (2021), Predicting corporate carbon footprints for climate finance risk analyses: A machine learning approach, *Energy Economics*, Volume 95,105129, ISSN 0140-9883; <https://doi.org/10.1016/j.eneco.2021.105129>
- RBC Capital Market (2024), Global ESG Fixed Income Investor Survey al link <https://www.rbccm.com/assets/rbccm/docs/insights/2024/ESG-investor-survey.pdf>
- Sharma, U., Gupta, A., e Gupta, S. K. (2024), The pertinence of incorporating ESG ratings to make investment decisions: a quantitative analysis using machine learning, *Journal of Sustainable Finance & Investment*, 14(1), 184–198, <https://doi.org/10.1080/20430795.2021.2013151>
- Strube, D., Daase, C. e Schietzel-Kalkbrenner, J. (2023), Extending Insights into ESG Ratings: A Combined Approach of Panel Data Regression and Machine Learning for Abnormal Returns and Volatility Analysis, <http://dx.doi.org/10.2139/ssrn.4599177>
- Yu, G., Liu, Y., Cheng, W. & Lee, C.-T. (2022), Data Analysis of ESG Stocks in the Chinese Stock Market Based on Machine Learning, 2nd International Conference on Consumer Electronics and Computer Engineering (ICCECE), <https://ieeexplore.ieee.org/abstract/document/9712837>
- United Nations (2004), Who Cares Wins, https://www.unepfi.org/fileadmin/events/2004/stocks/who_cares_wins_global_compact_2004.pdf
- United Nations (2019), I Principi per l'Investimento Responsabile, <https://www.unpri.org/download?ac=10973>
- United Nations (2022), Financing for Sustainable Development Report 2021, https://financing.desa.un.org/sites/default/files/2022-02/FSDR_2021.pdf
- World Commission on Environment and Development (1987), Our common future, https://www.are.admin.ch/are/it/home/sviluppo-sostenibile/cooperazione-internazionale/l_agenda-2030-peruno-sviluppo-sostenibile/onu-_le-pietre-miliari-dello-sviluppo-sostenibile/1987-rapporto-brundtland.html

Collana Finanza Sostenibile

- 4** – giugno 2024 **L'impatto del fattore ESG sulla performance industriale**
Un'analisi con tecniche di *machine learning*
M. Palynska, F. Medda, V. Caivano, G. Di Stefano, F. Scalese
- 3** – novembre 2022 **Interesse verso gli investimenti sostenibili**
Un esercizio di caratterizzazione degli investitori italiani
sulla base delle indagini CONSOB
D. Costa, M. Gentile, N. Linciano
- 2** – giugno 2022 **Gestione del risparmio e sostenibilità: l'approccio dei gestori in Italia**
Survey sull'applicazione di criteri ESG nell'ambito delle politiche di investimento
e delle attività di *stewardship* da parte dei gestori di attivi
S. Anchino, A. Ciavarella, P. Deriu, F. Fiore, S. Nocella, M. Tambucci, A. Turi;
con la collaborazione di G. Carotenuto, D. Gariboldi, S. La Civita, E. Levantini, A. Russo
- 1** – giugno 2021 **La finanza per lo sviluppo sostenibile**
Tendenze, questioni in corso e prospettive alla luce
dell'evoluzione del quadro regolamentare dell'Unione europea
N. Linciano, E. Cafiero, A. Ciavarella, G. Di Stefano, E. Levantini,
G. Mollo, S. Nocella, R. Santamaria, M. Taverna