

LUISS



DIPARTIMENTO DI IMPRESA E MANAGEMENT

Cattedra di Customer Intelligence
e Logiche di Analisi Dei Big Data

**COME I CRITERI ESG COLLEGANO LA CORPORATE
REPUTATION ED IL CREDIT RATING AZIENDALE.
UN APPROCCIO DI MACHINE LEARNING**

Prof. Emanuele FRONTONI

RELATORE

Prof. Luca ROMEO

CORRELATORE

Vittorio BERTOLINI

Matr: 755671

CANDIDATO

Anno Accademico 2022/2023

Indice

OBIETTIVO DELLA TESI	3
INTRODUZIONE	3
CAPITOLO 1: RUOLO MACHINE LEARNING NEL CONTESTO STORICO ODIERNO	6
CAPITOLO 2: INTRODUZIONE GENERALE AL PROBLEMA	7
CAPITOLO 3: IL CREDIT RISK	10
CAPITOLO 4: MACHINE LEARNING & CREDIT RISK ANALYSIS	13
4.1: Credit Risk Rating.....	16
4.2: Focus tecniche di <i>ensemble</i>	20
4.3: Focus tecniche di <i>ensemble</i> utilizzate nel <i>credit rating</i>	23
CAPITOLO 5: CREDIT RISK E REPUTAZIONE AZIENDALE	24
5.1: Approfondimento sui metodi di misurazione della reputazione	32
5.2: Deep dive nella misurazione della reputation aziendale.....	33
5.2.1: World's Most Admired Companies (WMAC)	33
5.2.2: RepTrak	34
5.2.3: Corporate Character Scale.....	35
5.2.4: Corporate Reputation Reporting Framework.....	35
CAPITOLO 6: CORPORATE REPUTATION E ESG SCORE	37
6.1: Approfondimento sui criteri ESG	39
CAPITOLO 7: CHE COSA ANALIZZARE	46
CAPITOLO 8: METODOLOGIA	48
8.1: Generazione dei dataset	49
8.1.1: Criteri per la scelta delle variabili.....	54
CAPITOLO 9: CORRELATION ANALYSIS	55
9.1: Correlation Analysis per <i>dfref</i> (Annesso A)	58
9.2: Correlation Analysis per <i>dfblo</i> (Annesso B)	62
9.3: Conclusioni della prima analisi di Correlazione.....	64
9.4: Correlation Analysis per <i>dfref_sp</i> (Annesso C)	67
9.5: Correlation Analysis per <i>dfref_moody</i> (Annesso D).....	69
9.6: Correlation Analysis per <i>dfref_egan</i> (Annesso E)	71
9.7: Correlation Analysis per <i>dfblo_sp</i> (Annesso F)	73
9.8: Correlation Analysis per <i>dfblo_moody</i> (Annesso G)	74
9.9: Correlation Analysis per <i>dfblo_egan</i> (Annesso H)	76
9.10: Conclusioni Correlation Analysis	77
CAPITOLO 10: PREDICTIVE ANALYSIS	80
10.1: Predictive Analysis per <i>dfr</i> e <i>dfb</i> (Annesso I).....	84
10.2: Predictive Analysis per <i>dfrs</i> , <i>dfrm</i> e <i>dfre</i> (Annesso L).....	87

10.3: Predictive Analysis per dfbs, dfbm e dfbe (Annesso M)	89
10.4: <i>Features importance</i> (Annesso N).....	91
CAPITOLO 11: CONCLUSIONI	96
11.1: Discussione generale ed implicazioni manageriali	96
11.2: Limitazioni e ricerche future.....	99
BIBLIOGRAFIA	101
SITOGRAFIA	106
ANNESI	110
RIASSUNTO	140

OBIETTIVO DELLA TESI

L'elaborato ha l'obiettivo di indagare come i criteri ESG - ovvero quei criteri rivolti alle sfere ambientale, sociale e di governance - colleghino la *corporate reputation* al *credit rating* aziendale, al fine di fornire al manager uno strumento valido con il quale analizzare in maniera olistica le performances dell'azienda sotto un complessivo profilo qualitativo/quantitativo. In particolare, tramite l'impiego di un algoritmo di *Machine Learning*, saranno in prima istanza valutati gli impatti delle variabili (ESG e finanziarie) sul *credit rating* e in seconda istanza sarà determinato un algoritmo che partendo da tali variabili potrà prevedere con grande affidabilità le valutazioni di credito delle agenzie di rating più importanti.

INTRODUZIONE

I tumultuosi cambiamenti della nostra epoca impattano su vari settori della vita di tutti i giorni con eventi di portata epocale che un tempo si presentavano a scadenze molto più rarefatte. Lo vediamo in tutti i campi, da quello politico, a quello economico, scientifico, sociale, militare e addirittura morale e religioso, con trasformazioni che sono sotto gli occhi di tutti. Ovviamente, questo non poteva non riflettersi anche in quell'ampio ambito nel quale economia e tecnologia interagiscono tra di loro, a causa dell'irrompere all'attenzione dell'opinione pubblica, anche di quella meno preparata, di quella che potremmo definire la frontiera estrema dell'informatica. Il riferimento è, ovviamente, all'Intelligenza Artificiale (*Artificial Intelligence* – AI), e ai dibattiti che ha innescato tra quanti ne auspicano un continuo sviluppo nell'interesse comune e coloro che, sempre nell'interesse comune, ne temono le conseguenze. Lasciando da parte questo aspetto, certamente interessante ma estraneo a questo studio, resta però il fatto che questa nuova frontiera offre nuove possibilità anche agli operatori dell'economia che ora si trovano tra le mani uno strumento poderoso e dalle possibilità ancora da approfondire per le analisi e per le previsioni del settore. In altre parole, siamo di fronte ad una “rivoluzione”, non solo scientifica e tecnica, che per quel che riguarda l'ambito di questo studio impatta anche sul marketing stesso, in maniera altrettanto forte che nei confronti della finanza e di tutta la sfera economica. E si tratta di uno strumento che non è più solo alla portata degli specialisti o di quanti se lo possono “permettere”, ma è a disposizione del grande pubblico, oggi in grado di imparare ad utilizzarlo con relativa facilità. Insomma, è una materia ormai imprescindibile per chi voglia affrontare il problema economico in maniera scientifica e sicura, per perseguire un “*efficientamento*” sostanziale delle funzioni aziendali in termini di velocità ed applicabilità.

L'AI è certamente uno strumento estremamente versatile, che rende possibile l'analisi congiunta di numerosi tra i fattori che devono essere considerati nel fare impresa, consentendo al responsabile e ai

pianificatori di avere una visione di insieme del problema di competenza, pur partendo dall'esame degli aspetti di dettaglio. Soprattutto, è uno strumento che consente di analizzare contemporaneamente, mettendoli in sistema, aspetti quantitativi e aspetti qualitativi, facendo una sintesi tra questi due modi di concepire il processo produttivo e commerciale.

Si tratta di una sintesi sempre più necessaria, per portare quantità e qualità ad andare a braccetto mediante un processo che influenza profondamente la *reputazione aziendale*, concetto difficile da quantificare, ma che gioca un ruolo chiave nella salute aziendale, tradizionalmente analizzata soprattutto in maniera quantitativa.

Prima di procedere con lo studio, sono ancora necessarie a mio avviso alcune riflessioni su due aspetti derivanti da questo contesto generale. Il riferimento è alla velocità di analisi e decisionale e l'altro alla gestione delle enormi quantità di dati e informazioni resi disponibili dalla globalizzazione dei mezzi di informazione.

In merito al primo aspetto è superfluo sottolineare come sia ormai estremamente facile comunicare con una persona dall'altra parte del mondo, senza neanche la necessità di viaggiare. Il messaggio è istantaneo, le idee si trasmettono in un battito di ciglia, le informazioni si moltiplicano e diventano sempre più incalzanti. Essere veloci, saper cavalcare quest'onda, sapersi muovere e cambiare direzione, gestire situazioni diverse, rappresenta oggi più che mai una capacità essenziale, anche con riferimento al business vero e proprio ([Silva P., 2021](#)). Ovviamente, tutto questo è possibile solo se l'azienda concepisce questo concetto dalla generazione dell'idea alla base di un progetto, al suo design, fino ad arrivare alla creazione del prototipo, allo sviluppo del prodotto o servizio e, solo in ultima istanza, al lancio sul mercato. Per questo, serve programmazione, servono strumenti adatti, servono conoscenze e capacità, oltre che giusti investimenti nella strategia di Marketing ([Indeed Editorial Team, 2022](#)). Le industrie nascono e scompaiono ad un ritmo sempre più incalzante, si affermano e vengono dimenticate, crescono ed entrano in declino, mentre la circolazione di denaro è sempre più rapida e virtuale, mediante strumenti che ci permettono di scambiare valute diverse in pochissimo tempo fra persone a grande distanze, senza alcuna perdita di tempo.

Nel mentre, gli operatori, non solo economici, vengono subissati da una mole enorme di dati informativi, magari in contrasto tra di loro anche a causa dei diversi tempi che richiedono per essere diffusi da fonti sparse per il globo (il dato affidabile oggi al momento della diffusione potrebbe non esserlo più domani, alla sua ricezione). Non è quasi più concesso il "*ci penso dopo*" oppure il "*vediamo cosa succede*": potrebbe essere troppo tardi già tra pochi giorni, od ore, per analizzare le informazioni che filtrano dai mass media e per farsi una propria idea, portando una indeterminatezza che se non governata potrebbe paradossalmente allungare i tempi di decisione anziché contrarli. Il famoso Generale statunitense David Mc Chrystal, Comandante dell'Operazione ISAF in Afghanistan nel 2009, osservava in proposito pochi anni fa "*paradoxically, the seemingly **instantaneous communications available up and down the hierarchy had***

*slowed rather than accelerated decision making. Leaders who could be contacted in moments felt compelled to withhold authority on decisions of significant importance (or for which they might ultimately be held responsible). [...] **Communications may have been instantaneous, but decisions never were.** The aggregate effects were crippling” E ancora “while military leaders a century ago yearned for the ability to see and control more of their battlefield, their heirs today have been inundated with too much of a good thing. At our headquarters, I had simultaneous access to live updates and real-time video from offices and operations across the world and was connected to almost every decision of consequence. This was great for establishing holistic awareness, **but it also created a nightmare of paperwork and approvals – time that could otherwise have been spent solving real problems**”.*

Insomma, la velocità con la quale arrivano grandi quantità di attivazioni alle quali rispondere altrettanto velocemente è una necessità ormai acquisita in tutti i settori e quelli relativi al consumo non potevano rimanerne esclusi. Anzi. Diventano così fondamentali le euristiche con le quali l’acquirente, in maniera inconscia, gestisce la fase decisionale del suo processo di acquisto di un prodotto o servizio qualsiasi e sulle quali il marketing cerca di far leva ([Ketrion S., Spears N. & Dai B., 2016](#)).

Questo non si riflette ovviamente solo sul consumatore, ovvero su colui al quale il business si rivolge, bensì anche sul lavoratore, ovvero colui che rende possibile il business. Numerose ricerche dimostrano come la perdita di tempo a causa di questo *overload* informativo non sia cosa di poco conto, anche analizzando la mole di informazioni ricevute via mail da un lavoratore medio, le quali generano interruzioni continue nel lavoro quotidiano facendo perdere fino al 28% della giornata lavorativa e riducendo (si stima) del 31% la qualità della vita dei lavoratori ([Hemp P., 2009](#)). Il senso di insicurezza, il senso di impotenza e di soffocamento generale che ne conseguono, insomma, caratterizzano una fase storica nella quale sono intervenuti grandissimi cambiamenti in gusti, interessi ed approccio alla vita lavorativa ([Open Knowledge team, 2021](#)) dei quali è necessario tenere conto. E’ necessario tenere conto della “*planned obsolescence*” ([European Economic and Social Committee, 2016](#)) dell’oggetto desiderato, e bisogna riuscire a esercitare il proprio pensiero critico per collocare all’interno dell’*hype cycle* di Gartner ciò che ci si para davanti. L’*hype* infatti guida la maggior parte delle informazioni e si gonfia e si sgonfia a seconda del momento storico in cui ci si trova. Basti pensare ad una manciata di mesi fa, quando le prime informazioni su *Chat Gpt* venivano rilasciate. Tutti ne hanno iniziato a parlare, tutti volevano essere parte di questa innovazione che sembrava essere ormai arrivata al punto di maggior splendore ([David E., 2022](#)). Dall’altro lato però tutti hanno cominciato a farsi delle domande nel momento in cui l’*hype* ha cominciato a regolarizzarsi. Questa applicazione dei modelli AI è stata, è e sarà al centro di numerose discussioni e proiezioni future, e certamente rappresenta solo la punta dell’iceberg di un trend futuro.

CAPITOLO 1: RUOLO MACHINE LEARNING NEL CONTESTO STORICO ODIERNO

Fatta questa premessa di carattere essenzialmente concettuale e focalizzata soprattutto sulle sfide alle quali deve far fronte l'operatore non solo economico nel mondo odierno, tornando al tema dell'elaborato c'è da osservare che sono da tempo stati sviluppati vari metodi per valutare lo stato di salute aziendale, cercando di ridurre per quanto possibile le asimmetrie informative che esistono fra consumatori, investitori ed aziende.

Uno degli strumenti più largamente utilizzati in questo contesto è quello del *credit rating*, valutazione effettuata da agenzie ad hoc sulla salute creditizia aziendale per fornire agli *stakeholders* informazioni dirette, anche se spesso c'è confusione su ciò che viene considerato all'interno del processo di analisi. Quello che è certo, è che oggi ci troviamo ad un punto nel quale i tradizionali criteri di valutazione utilizzati si dimostrano incapaci, da soli, di corrispondere alle richieste del pubblico sempre più attento ad aspetti una volta considerati marginali, ma oggi al centro del dibattito pubblico come quelli ambientali, sociali e della *governance* societaria, ricompresi sotto la sigla ESG (*Environmental, Social, Governance*).

Si tratta di nuovi criteri che sostanzialmente cercano di "misurare" quantitativamente aspetti che attengono molto più alla dimensione qualitativa e che in passato venivano sostanzialmente trascurati. Ma oggi non è più possibile evitare di porre la necessaria attenzione a questa dimensione del "fare impresa" per cui la domanda sul grado col quale questi criteri ESG impattano sulla salute aziendale, e dunque sul *rating* aziendale, richiede risposte certe ed affidabili.

Questo elaborato cerca di analizzare questa dimensione – che potremmo definire un *fil rouge* che collega la reputazione aziendale ed il marketing alla salute aziendale ed alla finanza e nel quale i criteri ESG giocano un ruolo molto importante - studiandone le componenti nonché la forza degli impatti che hanno sulla valutazione di credito aziendale.

A questo fine, si inizia dall'analisi dello stato dell'arte, evidenziando come le connessioni fra marketing e *corporate reputation* con il mondo finanziario siano, ad oggi, poco esplorate, per poi passare ad un'analisi vera e propria di queste connessioni.

Partendo poi da un dataset relativo al *credit rating*, si includeranno nello stesso le variabili relative alle componenti ESG che verranno estratte dalle banche dati più importanti nel panorama odierno.

A quel punto si andranno a sviluppare diverse tipologie di analisi, da quelle di correlazione a quelle predittive, che ci permetteranno di ottenere una visione olistica di ciò che sta dietro al fenomeno.

Il *machine learning* rappresenterà lo strumento col quale queste analisi verranno effettuate ed affrontate, garantendo velocità, precisione e scalabilità dei modelli e dei risultati.

Questo studio si propone come punto di partenza per le decisioni strategiche aziendali, garantendo una visione a 360° di ciò che deve collegare la visione del marketing e la visione finanziaria, per il rafforzamento della *corporate reputation* e per ottimizzare il *rating* e, dunque, la salute aziendale.

Ciò posto, è chiaro che la disciplina del *Machine Learning* applicata ad un contesto così complesso assicurerà un'analisi sempre più veloce e più sofisticata allo stesso tempo, nonché sempre più profonda e multidisciplinare. Per tornare alle parole del Generale statunitense, avremo finalmente uno strumento che potrà far fronte alla velocità di informazione ed alla crescente mole di dati, assicurando le condizioni per un *decision process* più veloce ed efficiente. Il mondo economico non può far altro che tenersi pronto a cogliere tutti gli aspetti positivi che ne deriveranno, ampliando così le possibilità del proprio business e delle persone stesse.

CAPITOLO 2: INTRODUZIONE GENERALE AL PROBLEMA

La materia del *decision making* non può essere considerata scollegata dalla fase di analisi che deve precederla per permettere al management di prendere le decisioni più mirate e analiticamente fondate per ogni situazione in cui la realtà aziendale deve far fronte. Nello specifico, si osserva come sia ormai da considerarsi centrale per ogni qualsivoglia scelta strategica e/o operativa l'analisi dei rischi attinenti a diversi domini: da quelli più vicini al Marketing, come nel caso del rischio di deterioramento della *customer relationship* ([Yang X., Bai j. & Wang X., 2022](#)), a quelli più vicini alla sfera percettiva e comportamentale dei consumatori target.

Dunque, la *risk analysis* rappresenta il capostipite delle analisi aziendali. Senza di essa, non sarà possibile ottenere *insights* sul futuro affidabili e con le quali andare a programmare strategicamente le mosse della propria impresa nel breve, medio e lungo termine. La strategia e chi la determina sono dunque il cervello dell'organismo aziendale, come asserito dal Von Clausewitz in una affermazione che, riadattata al contesto economico, sottolinea come la strategia sia l'impiego della competizione come mezzo per il raggiungimento degli obiettivi di business ([Emblemsvag J. & Kjolstad L. E., 2002](#)).

Come detto, i rischi che una realtà economica si trova ad affrontare in un determinato momento storico sono tantissimi, a partire da quelli finanziari che è necessario porre maggiormente all'attenzione. Infatti, in un mondo dove le risorse sono soggette a limitazioni spesso innescate da cause varie (esempio, il Covid o la guerra in Ucraina), un errore in tal senso potrebbe comportare la cessazione dell'attività. La sostenibilità economica, quindi, è una chiave della longevità aziendale e rappresenta un importante indicatore della salute aziendale ([Stobierski T., 2020](#)). Importante è sottolineare come la conoscenza dei rischi sia cruciale anche per coloro che si trovano dall'altra parte del tavolo ed a testimonianza di questo si possono trovare

numerose ricerche che vanno a studiare ad esempio il comportamento degli individui davanti a rischi sequenziali dello stesso o di diverso tipo ([Webb E. C. & Shu S. B., 2018](#)).

In questi termini, lo sviluppo dei *Big Data* e dei modelli di *Machine Learning* giocano il ruolo di protagonisti. L'analisi e lo studio dei *Big Data* ormai è un qualcosa che accompagna il management di molteplici aziende ([Choi T.M, Wallace S.W. & Wang Y., 2018](#)), che così riescono ad ottimizzare le proprie mosse e scelte strategiche ed a ridurre le problematiche legate ai diversi domini nei quali operano, come nel caso del Marketing ([Rust R.T. & Huang M.H., 2014](#)). Inoltre, questo tipo di analisi è anche qualcosa che può essere utilizzato, fra le altre cose, per indirizzare la scelta sulle clientele da raggiungere, segmentate in base a livelli di rischio differenti ([Ascazara E., 2018](#)).

L'implementazione del *Machine Learning* ha inoltre permesso lo sviluppo e la proliferazione di modelli predittivi estremamente accurati che si sono andati ad attestare come *tool* sempre più utilizzati dalle aziende. Esempi concreti nel mondo del Marketing, uno dei domini in cui il *Machine Learning* si sta sviluppando di più per andare a coprire una moltitudine estremamente estesa di problematiche ([Duarte V., Zuniga-Jara S. & Contreras S., 2022](#)), possono essere quelli relativi alla creazione di *customer experience* sempre più adeguate per i *target* che si scelgono ([Diebner R., Malfara D., Neher K., Thompson M. & Vancauwenberghe M., 2021](#)), ma anche implementazioni connesse al *product development* vero e proprio ([Balaji A., Janardhanan R., Johnston S. & Kaka N., 2018](#)).

Il *Machine Learning*, grazie ai benefici che genera con l'implementazione di modelli quantitativi estremamente accurati ([Deloitte Access Economics, 2017](#)), è dunque uno strumento fondamentale per analizzare tantissimi aspetti della vita aziendale, dal Marketing, all'analisi dei comportamenti umani ([Brea C., Bicanic S., Li Y. & Bhardwaj S., 2020](#)), a tutti gli altri aspetti della realtà economica, nonché in altri ambiti, come nel caso della consulenza ([Chui M., Henke N. & Miremadi M., 2019](#)) e della sanità ([Harabor V., Mogos R., Nechita A., Adam A. et al., 2023](#)).

Tornando alla *financial risks analysis*, si fa riferimento a diverse tipologie di rischio che possono essere affrontate anche con modelli predittivi di *machine learning* ad hoc per le diverse casistiche. Nello specifico, il *financial risk management*, deve tener di conto di 4 tipologie principali di rischio finanziario: 1) *Market risk*; 2) *Credit risk*; 3) *Insurance and Demographic risk*; 4) *Operational risk* ([Mashrur A., Luo W., Zaidi N.A. & Robles-Kelly A., 2020](#)).

Focalizzandoci dunque fra il lato Marketing, per il quale abbiamo visto che il *Machine Learning* rappresenta ormai un strumento sempre più utilizzato ed in diffusione, ed il lato *Financial*, per il quale possiamo fare la stessa osservazione per quanto riguarda la crescente applicazione dei modelli predittivi ([Kou G., Chao X., Peng Y., Alsaadi F.E. & Herrera-Viedma E., 2018](#)), si osserva con chiarezza come questi due domini, vengano considerati spesso in maniera distaccata, senza andare a considerare le relazioni e le connessioni che nella maggior parte dei casi si hanno fra Marketing strategico e *financial risk analysis* ([Kosova T.,](#)

[Smerichevskiy S., Yaroshevskaya O., Smerichevskaya S. & Zamay O., 2022](#)). Ad esempio, è questo il caso di segmentazione ad hoc a partire dall'analisi del *credit risk* per quanto riguarda le carte di credito ([Fiorio L., Mau R., Stieltz J. & Welander T., 2014](#)). Inoltre, laddove queste connessioni vengono in parte prese in considerazione, non si hanno studi con *tool* di ricerca e di analisi quantitativa abbastanza moderni, come nel caso dello studio di Zhao Yi, Zhao Ying & Song I. ([2009](#)), dove non vengono utilizzati modelli predittivi allo scopo di studiare, ancora una volta, il *credit risk* relativo al possibile stato di insolvenza di un debito dei consumatori nel mercato delle carte di credito.

L'analisi del rischio ed il *risk management* inteso come disciplina vera e propria, rappresenta dunque uno strumento troppo importante per qualsivoglia realtà aziendale odierna e rappresenta, oggi più che mai, un vantaggio competitivo non più trascurabile ([Elahi E., 2013](#)). Dalle evidenze, dalla crescita della potenza di *computing*, dall'aumento dei dati a disposizione e dalla progressiva implementazione di algoritmi di *Machine Learning* appena descritta, si può dunque dire che la disciplina del *risk analytics*, ha raggiunto il suo *prime* ([Dash R., Kremer A., Nario L. & Waldron D., 2017](#)).

In conclusione, lo sviluppo di un modello ad hoc per andare a gestire il rischio di credito, ad esempio, potrebbe portare alla definizione di un algoritmo utile anche alla identificazione di segmenti di mercato più idonei e maggiormente profittevoli per le aziende stesse, unendo dunque il lato strategico del Marketing, a quello di *financial risk analysis*, per poi arrivare in un secondo momento al marketing operativo vero e proprio, riducendo al minimo le possibilità di grave errore da parte del management aziendale. Questo potrebbe essere fatto senza dubbio seguendo i modelli già utilizzati per problemi affini ([Mashrur A., Luo W., Zaidi N.A. & Robles-Kelly A., 2020](#)), facendo una selezione fra quelli più utilizzati nella *financial risk analysis*, come *KNN*, *Decision Tree* e *Naive Bayes* ([Lei X. Et al, 2022](#)) o quelli relativi ad esempio al *credit risk management* in generale ([Kosova T., 2021](#)), o alla materia del *credit scoring* ([Markov A., Seleznyova Z. & Lapshin V., 2022](#)). Partendo da ciò, analizzando poi anche le tipologie dei modelli applicati per i problemi più propriamente del dominio del Marketing ([Duarte V., Zuniga-Jara S. & Contreras S., 2022](#)), sfruttando anche *framework* strategici per l'applicazione del *machine learning* nel Marketing stesso ([Huang M. H. & Rust R. T., 2021](#)), si potrebbe infine arrivare ad una profonda comprensione del problema e, in ultima istanza, si potrebbe evidenziare definitivamente il legame tanto indissolubile quanto necessario fra strategia di Marketing e *financial risk analysis*, fornendo un'importante *tool* declinabile dal management aziendale per vari scopi diversi.

CAPITOLO 3: IL CREDIT RISK

Come anticipato, il *Credit Risk*, rappresenta uno dei rischi più importanti che una entità economica deve considerare per le significative influenze che ha in molteplici domini, da quello bancario, a quello *corporate* e in quanto rappresenta uno *step* significativo per la messa a terra di ogni strategia aziendale.

In generale, possiamo dire che l'analisi del *Credit Risk* ci permette di studiare la probabilità che un debitore non sia in grado di pagare il proprio debito nei confronti di un creditore. Dunque, lo studio di questo aspetto permette alle aziende di identificare misure e definire strumenti per mitigare questo rischio.

Come precedentemente detto, il rischio di credito è analizzato innanzitutto dalle banche e da altre istituzioni finanziarie per valutare la capacità di credito dei loro clienti. Si tratta di attività cruciale per la salute aziendale e per questo viene continuamente rinnovata in maniera tale da essere più adatta ad ogni cambiamento micro e macroeconomico.

Un cambiamento in tal senso lo abbiamo avuto come conseguenza del Covid-19, che ha portato il mondo finanziario ad affacciarsi ad una situazione limite alla quale, senza un'opportuna gestione dei rischi, sarebbero conseguite grandi probabilità di cessazione della continuità aziendale. In particolare, nella crisi causata dal Covid-19, della quale tutt'oggi stiamo scontando varie conseguenze non solo economiche, abbiamo assistito ad un cambio di *creditworthiness* in una moltitudine molto elevata di settori.

Le banche, dal canto loro, hanno dovuto mettere in atto azioni diverse, per esempio, nella raccolta di dati, attivando valutazioni scrupolose con metodologie e criteri adatti al periodo in corso.

Tutto ciò però non è da vedersi esclusivamente come una condizione negativa, in quanto questi nuovi approcci hanno fornito alle banche la possibilità di migliorarsi e posizionarsi in maniera migliore rispetto alla competizione, sia dal punto di vista del business vero e proprio, sia dal punto di vista reputazionale ([Koulouridi E., Kumar S., Nario L., Papanides T. e Vettori M., 2020](#)).

Oltre che dalle banche, il rischio di credito viene preso in esame dalle Agenzie di Credito (CRA), che hanno molti ruoli e responsabilità all'interno dello scenario economico internazionale. Per questo, spesso vengono criticate da parte degli Stati o delle stesse aziende che pongono dubbi sulla bontà del loro operato e della loro obiettività, soprattutto a seguito di crisi ([CFR Staff, 2015](#)) internazionali. E ciò, sia dal punto di vista economico e politico, sia da quello degli investitori e di coloro che vengono valutati, categorie che spesso coincidono. Per queste ragioni, le CRA nel 20° secolo sono state spesso aspramente criticate per le *performance* talvolta deludenti, come a seguito della crisi dei debiti sovrani europei, spingendo diversi studi alla dimostrazione della loro condotta talvolta non conforme ai criteri da loro stesse indicati ([Haspolat F.B., 2015](#)). Nonostante ciò, si osserva un tendenziale cambiamento di approccio da parte delle CRA che ha fatto sì che la percezione potesse cambiare gradualmente nell'ultimo periodo, grazie ad un comportamento più difensivo rispetto ai periodi pre-crisi ([Rand B., 2023](#)).

In merito a queste agenzie di rating, è necessario un ulteriore approfondimento a causa dell'importante ruolo che giocano nel contesto della valutazione del *Credit Risk*. Innanzitutto, si sottolinea come queste ricoprano una funzione altamente importante nei mercati finanziari, come già anticipato in precedenza parlando delle loro criticità, poiché nascono con l'obiettivo finale di ridurre l'asimmetria informativa che esiste naturalmente fra debitori e creditori sia nelle valutazioni corporate, sia nelle valutazioni degli Stati. Questa duplice applicazione dei *rating*, sia lato aziendale, sia lato statale, è riconosciuta largamente in tutto il globo e viene spesso accompagnata e raffittita da normative varie che vanno ad aggiungersi a quelle già esistenti in materia.

Esistono infatti agenzie riconosciute, grandi ed autorevoli, e agenzie non riconosciute sulle quali sorvoleremo ([Elkhoury M., 2008](#)). Ci limiteremo in questo momento, quindi, a porre il focus esclusivamente sulle 3 più importanti, ovvero *Moody's Investor Services*, *Standard and Poor's* e *Fitch Group*, poiché coprono circa l'80% del mercato internazionale, costituendo dunque uno pseudo oligopolio ([CFI Team, 2022](#)). Queste agenzie sono soggette a stretta vigilanza - a causa dei dubbi e dei rischi a cui sono soggette, come il rischio di conflitto di interesse ([Bush C., 2022](#)), di aggio e di *insider trading* - e nel tempo sono state emanate numerose direttive volte a regolamentarne il ruolo.

In particolare, riguardo all'Unione Europea, si cita l'articolo 3 del [Regolamento \(CE\) n°1060/2009](#) relativo alle agenzie del credito che definisce e delinea in modo chiaro qual è il ruolo di suddette entità e cosa si debba intendere per *rating*, ovvero “*un parere relativo del merito creditizio di un'entità, di un'obbligazione di debito o finanziaria, di titoli di debito, di azioni privilegiate o di altri strumenti finanziari, o di un emittente di un debito, di un'obbligazione di debito o finanziaria, di titoli di debito, di azioni privilegiate o altri strumenti finanziari, emessi utilizzando un sistema di classificazione in categorie di rating stabilito e definito*”. Inoltre, sempre lo stesso Regolamento stabilisce che le metodologie adottate debbano essere “*rigorose, sistematiche, continuative e soggette a convalida sulla base dell'esperienza storica, inclusi i test retrospettivi*”. Questo, dunque, delinea il tema delle metodologie, che seppur diverse fra agenzia ed agenzia, devono rispettare dei criteri comuni fondamentali.

In conclusione di questa necessaria parte dedicata alle *Credit Rating Agencies* (CRAs), si evidenzia come queste utilizzino classificazioni tra di loro differenti ma comunque confrontabili, permettendo un'analisi approfondita delle valutazioni, nonostante le discrepanze più o meno significative esistenti fra le valutazioni compiute dalle varie aziende, come dimostrato in alcuni studi ([Caridad L., Nunez-Tabales J., Seda P. & Arencibia O., 2020](#)).

Inoltre, è importante evidenziare come anche le aziende utilizzino proprie risorse per la valutazione del credito. In particolare, la loro attività si concentra sullo studio della solvibilità dei clienti per sostenere o

meno la di concessione dei prestiti. L'importanza di tutto ciò è facilmente quantificabile, in quanto questo approccio di analisi permette alle aziende stesse di evitare ingenti perdite finanziarie, raffinando il processo di *decision making* in ambito di concessione di crediti.

Per completare il quadro possiamo definire in maniera più chiara quali sono i differenti tipi di rischio, in maniera tale da avere uno strumento di lettura iniziale quanto più affidabile possibile. Questi sono principalmente riconducibili a tre categorie principali:

1. Credit Default Risk: questo rischio si verifica in particolare quando il debitore non è in grado di soddisfare interamente l'obbligazione di prestito al quale è vincolato. Questa tipologia riguarda tutte le transazioni finanziarie sensibili al credito, come prestiti, obbligazioni, titoli e derivati;
2. Rischio di Concentrazione: si ha quando si è esposti ad un'unica controparte o ad un unico settore. In questo caso il rischio è quello generato dal potenziale molto elevato di subire perdite di grande entità, che possono rappresentare un grande rischio per il creditore. Si deve dunque valutare la diversificazione all'interno dei portafogli, che dovrà necessariamente essere elevata per far sì che questo rischio sia contenuto.
3. Rischio di Paese: si verifica nel caso in cui il Paese debitore blocca gli obblighi di pagamento in valuta estera, generando dunque l'inadempienza ai propri oneri. Questa tipologia di rischio risulta chiaramente correlata alla stabilità ed alle performance di natura macroeconomiche del Paese debitore e dunque risulta esposto a possibili variazioni del contesto economico ed ambientale in cui si trova il determinato Paese preso in esame ([CFI Team, 2023](#)).

Ricapitolando, dunque, è possibile identificare numerosi ambiti di applicazione della valutazione del *credit risk*. L'attività descritta rappresenta infatti un'importante punto di partenza per qualsivoglia realtà economica, dagli istituti finanziari, alle aziende commerciali, e permette di assicurare il management riguardo le mosse da prendere. Rappresenta dunque un approccio necessario e di primaria rilevanza, non trascurabile e degno di essere approfondito dal punto di vista normativo e metodologico.

Riguardo quest'ultimo punto è importante soprattutto sviluppare dei sistemi che permettano una rappresentazione quanto più veritiera possibile di ciò che viene analizzato, con approcci sistematici e scalabili e proprio in questo ambito è fondamentale mettere in gioco statistiche rilevanti ai fini descritti. In questa direzione sono indirizzate tutte le entità che prevedono la valutazione del credito come parte integrante della propria strategia aziendale ed in questa direzione trovano spazio di applicazione i più moderni strumenti statistici.

Il *Machine Learning* si applica dunque in questo contesto, fornendo un *tool* di lettura della realtà estremamente affidabile, sofisticato e rapido.

CAPITOLO 4: MACHINE LEARNING & CREDIT RISK ANALYSIS

Come visto, il *Machine Learning* ha trovato terreno fertile nel campo del *Credit Risk Analysis* e nell'industria finanziaria in generale ed è ora possibile, tramite di esso, sviluppare modelli predittivi capaci di fornire stime accurate ed estremamente funzionali sul rischio di credito di varie entità, in pochissimo tempo.

Le applicazioni del *Machine Learning* in materia sono numerose ed elencarle tutte sarebbe dispersivo e fine a sé stesso. Invece, ai fini di questo studio è importante andare a identificare quegli ambiti in grado di aiutare l'analisi riducendo maggiormente i tempi di ricerca e selezione degli algoritmi, permettendo quindi la scelta di quelli più utilizzati ed esplorati in letteratura, almeno in un primo momento.

Uno degli ambiti più esplorati in materia è sicuramente quello del *Credit Scoring*. La materia ha trovato largamente utilizzo a causa dell'enorme crescita del credito al consumo fra il 1970 ed il 2005, soprattutto negli Stati Uniti dove si sono registrate crescite fino al 231%, mentre riguardo ai volumi di prestiti bancari garantiti da immobili si è arrivati fino al 705%; anche in Europa abbiamo assistito a tassi di crescita molto variabili fra regione e regione, comunque estremamente rilevanti e il *credit scoring* è stato identificato come strumento statistico necessario per sostenere questi aumenti vertiginosi. La materia è stata da sempre al centro di discussioni, ma la prima vera e propria applicazione si è avuta con la ricerca di David Durand (1941) e con la sua classificazione in buoni e cattivi prestiti.

In materia di disciplina dello *scoring* del credito al consumo ([Crook J. N., Edelman D. B. & Thomas L. C., 2007](#)), si deve sottolineare come gli accordi di Basilea II siano stati un punto chiave col quale è stato determinato il modo in cui le banche dei principali paesi debbano calcolare il loro capitale di riserva, che a sua volta dipende dall'utilizzo di modelli di *scoring* efficaci per stimare la probabilità di perdita in caso di inadempienza del debitore ([Cornford A., 2005](#)). Questo focus normativo è estremamente importante perché è ciò che modella continuamente l'evolversi dello studio della materia del *Credit Risk* in generale.

La rilevanza del *topic*, dunque, non è cosa nuova e merita sicuramente l'attenzione degli strumenti più moderni di analisi. La valutazione del *Credit Scoring* vede infatti l'applicazione di strumenti statistici dal momento del primo screening, nel quale si valuta una possibile richiesta di prestito, per tutta la durata della

sua attivazione, fino ad arrivare alla cancellazione finale del debito. Questi strumenti statistici di valutazione del rischio servono proprio alla gestione del conto e alla stima del rischio del prestito stesso.

Si evidenzia come, fra gli altri, in materia si registra una ricorrenza dell'applicazione della *Logistic Regression* con ottimi risultati quale metodo più comune in materia di computazione del *Credit Scoring*, soprattutto per quanto riguarda la stima di rischio del prestito di cui si è appena accennato. Inoltre, si è notata la grande validità del *Support Vector Machine* in questo ambito che, però, nonostante la grande accuratezza presenta problemi di gestione che potrebbero pregiudicare il conseguimento di risultati soddisfacenti.

Inutile dire che l'applicazione pratica di algoritmi di *Machine Learning* per la risoluzione e l'analisi delle problematiche relative ha permesso di fare enormi passi in avanti in questo contesto, in termini di velocità ed accuratezza, soprattutto rispetto alle performance computazionali degli istituti di credito.

In particolare, numerose ricerche studiano metodi alternativi efficaci, come quello condotto da Bastos J. A. (2022), dove si evidenzia l'importanza di algoritmi quali il *Boosted Decision Trees*, che risulta competitivo nella comparazione effettuata con il *Support Vector Machine* ed il *Multilayer Perceptron*. Il funzionamento del *Boosted Decision Trees* è particolare ed è interessante capirne il funzionamento, vista l'importanza che ha in numerose tipologie di ricerche in settori diversi. Si tratta di una tecnica di apprendimento che aggrega diversi *Decision Trees* per formare un unico classificatore, formato dalla votazione a maggioranza ponderata delle classificazioni effettuate da ogni singolo *Decision Tree*. Nello studio di Bastos viene inoltre ribadita la diffusione della *Logistic Regression* in materia, oltre al fatto che vengono citati numerosi altri algoritmi utilizzati, tra cui il KNN.

Tornando all'analisi del **rischio di credito (Credit Risk)** in generale, è importante sottolineare ancora una volta come questo sia composto da numerosi fattori, quali la necessaria attenzione con la quale si eroga il prestito (come si è visto nel *Credit Scoring*), il monitoraggio continuo dei pagamenti dei clienti e altri modelli di comportamento, finalizzati alla riduzione sostanziale dell'accumulo di attività non performanti (o *non-performing assets*) e di frodi.

Importante, a quest'ultimo proposito, è specificare che cosa sono i *non-performing assets* (NPA), ovvero prestiti che hanno cessato di generare reddito per la Banca, in quanto assieme alle frodi negli ultimi anni stanno aumentando in numero, enfatizzando l'importanza e la centralità del loro monitoraggio.

È interessante notare come il numero delle ricerche riguardo la predizione di NPA ha avuto il proprio picco a partire dal 2014; a seguire, in tema di *fraud detection*, assistiamo infatti a un grande picco in corrispondenza del 2019, mentre, come anticipato in precedenza, si nota un incremento dell'interesse

attorno al *Credit Score* dopo il 2004, anno di entrata in vigore dell'accordo di Basilea II. Infine, riguardo alle tendenze di ricerca, possiamo identificare una generale proliferazione del materiale di studio a partire dal 2013-2014.

Ciò detto, prendendo in esame 136 *paper* in materia, Bhatore S., Mohan L, & Reddy Y. R. (2020) mettono in risalto come, nel caso del *Credit Scoring*, gli algoritmi relativi ai *Neural Networks* (o NN) siano quelli più largamente studiati, mentre il *Support Vector Machine*, seppur largamente utilizzato, diventa anche in questo caso lento e dispendioso in presenza di dataset molto numerosi e, per questo, a seconda dei casi è preferibile evitarlo.

Infine, a riguardo del *Credit Scoring* si identificano gli *hybrid* e gli *ensemble models* come possibili ambiti di ricerca futuri con possibili risvolti positivi, in quanto essendo meno studiati rispetto agli altri rendono possibili più ampi margini di miglioramento. Per quanto riguarda la previsione degli NPA, si sottolinea come SVM e *Neural networks* siano i più utilizzati, anche se negli ultimi tempi hanno trovato largo impiego gli *hybrid models*. Infine, riguardo all'individuazione di frodi, si identificano come algoritmi più utilizzati i classificatori basati sulle reti neurali (NN).

Un discorso a parte deve essere fatto nell'ambito del ***Credit Risk Rating*** e delle sue metodologie. Innanzitutto, si sottolinea che il *Credit Risk* è una componente essenziale dell'industria finanziaria e bancaria. Presenta numerose *challenges*, in continuo mutamento e, di certo, non facili da soddisfare. Molte di queste *sfide* sono ben note agli istituti che si occupano nello specifico di questa materia e per questo sono facilmente individuabili, ma altre sono "sotto-*challenges*" che devono essere evidenziate caso per caso. Fra quelle più note, si hanno senza dubbio:

- 1) La complessità crescente dei requisiti in termini normativi;
- 2) La qualità e la possibilità di accesso ai dati oggetto di studio;
- 3) La mancanza di personale qualificato in materia;
- 4) Il cambiamento rapido e costante del mercato, che rende necessario essere in grado di fare analisi con l'obiettivo di predire l'andamento del mercato o dell'azienda (il *Machine Learning* risulta molto utile in questo caso);
- 5) Il rischio di controparte, che può avere effetti devastanti sulle strategie di management del rischio;
- 6) I rischi legati alla cyber-sicurezza (che oltre al danno economico, creano ingenti e talvolta insanabili danni reputazionali, di cui vedremo successivamente l'importanza);
- 7) La condizione di Recessione economica, che rende ampiamente più frequenti default e deteriora la qualità del credito;

- 8) La necessità di mantenere l'allineamento con la strategia aziendale, nonostante talvolta possa essere complicato far convivere interessi di business diversi con quello del *credit risk management*;
 - 9) L'adattamento alle nuove tecnologie, che deve avvenire rapidamente ed in maniera efficace (il *Machine Learning* fa parte di ciò);
 - 10) Il bilanciamento fra rischi e ritorni finanziari.
- ([GDS Link, 2023](#)).

Tornando invece sulle metodologie, queste sono in continua evoluzione e variano profondamente fra i vari player che si trovano a effettuare le valutazioni di credito, per cui si hanno approcci diversi fra Credit Rating Agencies, banche ed aziende. I fattori impattanti sono molteplici e possono essere sia finanziari che non propriamente finanziari, facendo rientrare in queste classificazioni di sintesi, con le loro problematiche, tutti quegli aspetti che talvolta non vengono considerati all'unisono.

Sarà dunque estremamente rilevante andare ad analizzare qual è l'impatto che determinate strategie di Marketing hanno sulle valutazioni di credito finali. Tutto ciò renderà possibile perseguire in maniera ancora più efficiente uno degli scopi principali della materia, ovvero quello di ridurre le asimmetrie informative fra debitori e creditori, permettendo inoltre alle aziende di adottare linee di condotta che consentano di essere valutate in uno specifico modo. Questo porterebbe benefici a tutta la catena coinvolta, dalle CRA che agirebbero con più trasparenza, ai consumatori/investitori che sarebbero di certo più tutelati comprendendo ed avendo modo di avere visibilità di uno dei fattori alla base della valutazione, alle aziende che, definendo in maniera diligente la propria strategia di Marketing, potrebbero raggiungere maggiori benefici all'interno del meccanismo di valutazione del credito aziendale, ottenendo delle valutazioni migliori.

Ecco che questo rappresenta il punto di partenza per il lavoro di revisione, tramite il quale è possibile andare a sviscerarne l'ambito, valutando i vari approcci metodologici già presenti in letteratura con lo stesso *modus operandi* utilizzato in precedenza, in maniera tale da potersi orientare al momento dell'analisi vera e propria dell'elaborato finale in questione.

4.1: Credit Risk Rating

Il concetto di *Credit Risk Rating* è già stato introdotto in precedenza, ma è ora necessario chiarire le ragioni che ne rendono necessario uno studio approfondito. Come detto, questa analisi può essere fatta sia per i Paesi, che per il lato *Corporate*. Riguardo a quest'ultimo, prendiamo in considerazione il caso in cui le aziende (debitori) abbiano bisogno di raccogliere finanze per poter sostenere i propri progetti. Per farlo, possono avvalersi dello strumento relativo all'emissione di titoli che possono essere

acquistati dagli investitori (creditori). Questi ultimi, si esporrebbero quindi inevitabilmente ad un certo grado di rischio di insolvenza da parte dell'azienda, che nel malaugurato caso non riuscisse a rispettare i termini dell'obbligazione emessa, non sarebbe in grado di ripagare il creditore e dunque potrebbe fallire. Questa è la situazione che l'analisi del *Credit Risk* deve in qualche modo mitigare e la valutazione di credito da parte delle agenzie (CRA) si propone l'obiettivo di andare a smussare quell'asimmetria informativa che potrebbe portare l'investitore a fare scelte di investimento scorrette o altamente rischiose. Le analisi condotte in materia sono varie e si va da applicazioni classiche ad applicazioni più particolari, come nel caso dell'utilizzo del *preference learning* per studiare le relazioni tra più caratteristiche e le performance delle alternative in una maniera più chiara e trasparente ([Luciano F., Diogo Ferreira, Julio Cezar & Adiel Teixeira, 2022](#)). Quest'aspetto merita sicuramente un approfondimento più accurato.

Prima però di passare all'analisi metodologica vera e propria, è importante ancora una volta tenere in considerazione come queste agenzie funzionino e le loro differenze. Innanzitutto, è necessario mantenere il focus *sulle* tre più grandi agenzie perché, come detto, sono queste a rappresentare la stragrande maggioranza di un mercato che, peraltro, presenta grandi barriere all'ingresso. Queste, inoltre, presentano differenze in termini di classificazione vera e propria, e talvolta tendono a dare valutazioni diverse delle stesse entità, a testimonianza delle discordanze in termini di valutazione fra l'una e l'altra agenzia, anche se queste discordanze riguardano più frequentemente le valutazioni di credito statali che *corporate*. Dal lato dell'investitore, infine, possiamo sottolineare ancora una volta l'importanza dei *rating*, in quanto permettono di ridurre le tempistiche di analisi degli strumenti presi in considerazione, riducendo alla lettura della valutazione, e dunque della sintesi del rischio, il tempo di analisi necessario. Per questo, rappresentano una sorta di euristica accolta dal consumatore/investitore che rimarrebbe altrimenti travolto dall'eccessivo ammontare di informazioni, talvolta confuse e contrastanti. Detto ciò, è chiara l'importanza della fiducia degli investitori nei confronti delle agenzie e quindi della reputazione delle stesse (Eijffinger S. & Masciandro D., 2011).

Prendiamo ora in considerazione la metodologia utilizzata e studiata in materia, cercando di fornire una panoramica *accurata* di quelle che dovrebbero essere le soluzioni e le applicazioni più performanti di *Machine Learning* e non solo. In particolare, si sottolinea che il *Machine Learning* può essere il futuro del *Credit Risk Rating* (in parte comincia già ad esserlo) e in generale del *Financial Risk Management* in quanto riesce a far corrispondere al continuo crescere di informazioni e dati da analizzare a velocità sempre più elevata, delle metodologie estremamente accurate e rapide, grazie alla sua potenza computazionale ([Bacham D. & Zhao J., 2017](#)). Tutto questo, si aggiunge al fatto che i modelli di *Machine Learning* possono aiutare le banche a migliorare la propria capacità di previsione

nei sistemi di allerta del credito fino al 25%, grazie all'aumento di accuratezza, alla riduzione degli errori generati da valutazioni soggettive errate e alla possibilità di aggregare fonti di dati interne ed esterne per generare insights migliori e, di conseguenza, migliori decisioni ([Bahillo J. A., Ganguly S., Kremer A. & Kristensen I., 2016](#)). Tutti questi sono solo la punta dell'iceberg dei benefici che questa rivoluzione tecnologica può portare e per questo è fondamentale essere pronti a recepire tutto ciò che potrebbe svilupparsi da qui a poco.

Il concetto di *credit rating* è presente all'interno dei mercati finanziari da tantissimo tempo (1860 circa) e per la prima volta venne introdotto da H. V. Poor. Da quel momento, i rating creditizi divennero sempre più centrali *all'interno* della vita finanziaria mondiale e si svilupparono diverse agenzie che dedicavano le loro forze alla computazione di diverse classificazioni utili allo scopo. Per comprendere la rapida espansione di questo approccio, basti pensare che al giorno d'oggi il 99% delle obbligazioni societarie è stato valutato in questi termini da una delle agenzie di credito operanti. Questa rapida espansione è stata possibile grazie ai molteplici benefici che questi rating portano con loro, sia per gli investitori, che per le aziende e per l'economia in generale.

- Come *detto*, gli investitori traggono beneficio dal fatto che si tratta di una fonte di rapida lettura delle informazioni chiave dei titoli, risultando dunque soluzione conveniente ed economica che spinge gli individui ad investire su titoli societari con rendimenti più alti.
- Dal *punto* di vista delle aziende, questi rappresentano uno strumento molto importante che permette loro di entrare sul mercato con un certo grado di sicurezza grazie alla possibilità di raccogliere fondi a costi più bassi. Inoltre, dal punto di vista del marketing si hanno anche dei benefici in termini di *brand perception*, in quanto queste aziende possono utilizzare i rating benevoli per innalzare il livello di fiducia degli investitori e migliorare il proprio marchio.
- *Infine*, per quanto riguarda l'economia in generale, si hanno dei vantaggi in termini di crescita economica, in quanto dei rating precisi spingono più investitori ad essere presenti sui mercati, portando più finanze per le aziende valutate.

Tutti questi benefici, perciò, sono fondamentali per tutte le parti coinvolte e, per questo, nel tempo si sono sviluppate *metodologie* sempre più accurate e convenienti, sia dal punto di vista economico, che da quello delle tempistiche. Appurato che i metodi computazionali classici richiedono tempi di analisi più elevati, con una maggior probabilità di errore, con lo sviluppo della Big Data Analysis hanno via via trovato largamente applicazione in materia anche gli algoritmi di *machine learning* ([Mark W., Kuldeep K. & Adrian G., 2022](#)). Per questo, in letteratura, troviamo ricerche che utilizzano i metodi tradizionali, i metodi di *machine learning* e quelli relativi alle tecniche di *ensembling*.

Per quanto riguarda i metodi più tradizionali, si citano innanzitutto la *Linear Regression* ([Stepanova M. & Thomas L. C., 2001](#)), nonché l'analisi del discriminante lineare che viene utilizzata da Khemakhem S. & Boujelbene Y. ([2015](#)) in maniera complementare ai *Neural Networks*, di cui vedremo più avanti. I risultati della loro ricerca sono interessanti in quanto mostrano come sia chiaro che i due approcci siano del tutto complementari: l'analisi del discriminante serve ad evidenziare quali siano le variabili più rilevanti, mentre l'analisi tramite i *Neural Networks* fornisce risultati più accurati.

Meritevoli di essere citati sono anche i *network Naive Bayesian* studiati da Hajek P., Olej V. & Prochazka O., ([2016](#)) che rappresentano delle valide soluzioni in termini di accuratezza. In particolare, nella loro ricerca, questi vengono utilizzati per estrapolare informazioni qualitative che vengono utilizzate per i rating di credito e che difficilmente sono esplicitate da coloro che i rating li effettuano. Per fare ciò utilizzano la tecnica di *Latent Semantic Analysis* per estrapolare queste informazioni dai documenti ricollegabili alle aziende. La struttura della ricerca si può vedere in questa immagine che coglie l'importanza delle variabili qualitative estrapolate tramite questa metodologia. I risultati finali dello studio, per quanto riguarda il classificatore *Naive Bayesian*, dimostrano come questo funzioni in maniera estremamente coerente con gli altri classificatori utilizzati per la comparazione e, addirittura, fornisca un risultato leggermente migliore.

Questi tre approcci appena citati lasciano aperte numerosi percorsi da esplorare. Per esempio, la ricerca condotta nello studio di Khemakhem S. & Boujelbene Y. risente fortemente del carattere regionale dal quale i dati provengono e per questo difficilmente può essere estesa senza approfondimenti ulteriori a dataset diversi; mentre nel caso dello studio che ha evidenziato il *Naive Bayes* come valido classificatore, possiamo dire che la traccia di maggior interesse, più che dal classificatore, viene lasciata dalla volontà degli autori di esplorare quelle variabili a carattere qualitativo in fase di *credit risk prediction* tramite la *Traditional Latent Semantic Analysis*.

Inoltre, si possono citare altri approcci che vanno ad analizzare le relazioni non-lineari fra le variabili in gioco, come nel caso del *Decision Tree* e del KNN. Si sottolinea come il *Decision Tree* dia risultati migliori del KNN quando si è in presenza di dataset non perfettamente bilanciati ([Abdou H. & Pointon J., 2011](#)) e che in linea generale, gli approcci non-parametrici “performano” meglio degli approcci tradizionali. Tuttavia, ci sono delle discrepanze per quanto riguarda la performance relativa di queste tecniche, quando i dataset presentano vari gradi di sbilanciamento.

Continuando l'*overview*, si evidenzia l'esistenza in letteratura di una moltitudine di approcci di *Machine Learning* per la predizione dei *Credit Rating*, come nel caso dell'*Artificial Neural Network* ([Kumar K. & Bhattacharya S., 2006](#)), per i quali si ottengono ottimi risultati per previsioni nel breve

periodo, nonché ottime capacità di gestione di dati mancanti, di *outlier* e di *multicollinearità*. Altro punto a favore di questa tecnica è la semplicità di configurazione, anche a confronto di altri approcci, come quello della *regressione*. Tuttavia, si sostiene che sarebbe utile ampliare la considerazione data alle variabili macroeconomiche come input, per tendere a migliorare le performance nelle previsioni di lungo termine, dove rimane carente in termini di precisione.

Successivamente, si può parlare del *Support Vector Machine* ([Cristianini N. & Scholkopf B., 2002](#)) e del *Gaussian Process Classifier* ([Shian-Chang H., 2011](#)), dove si evidenziano i risultati migliori ottenuti con il SVM che però, come già accennato, ha notevoli debolezze come la lentezza computazionale quando si ha a che fare con un numero molto elevato di dati, come spesso accade in ambito finanziario. Perciò l'applicazione del GPC tende a scalzare il SVM, grazie alla sua robustezza in presenza di grandissime quantità di dati.

Infine, relativamente alle tecniche di *ensemble* utilizzate nelle ricerche più moderne, si citano il *Random Forest* ([Wu H. C. & Wu Y. T., 2016](#)) ed il *Gradient Boosted Machines* ([Abdou H. & Pointon J., 2011](#)) che nonostante una più difficile interpretabilità generano una performance predittiva estremamente elevata.

Si nota come ognuno dei modelli presentati mostra limitazioni talvolta molto difficili da risolvere, soprattutto relativamente a dati relativi a dataset sbilanciati o fortemente geo localizzati. Queste problematiche sono dovute alla difficoltà di reperire dati in materia, che rappresenta ad oggi una delle sfide sicuramente più importanti. Altro punto debole dei modelli utilizzati è senza dubbio la difficoltà di identificare con precisione le variabili utilizzate in fase di rating e la difficoltà di inserire altre variabili non finanziarie, estremamente difficili da misurare. Per questo, la capacità di svolgere un'analisi di tipo multidisciplinare acquisisce un peso non indifferente e degno di essere approfondito.

4.2: Focus tecniche di *ensemble*

Prima di continuare, vista la loro importanza in termini di performance, è utile andare ad approfondire le tecniche di *ensemble* di cui si è appena accennato.

Queste sono tecniche di Machine Learning che hanno come particolarità quella di combinare molteplici algoritmi di base per ottenere risultati migliori. Dunque, anziché generare un unico modello sperando che questo ottenga ottimi risultati o che addirittura risulti essere il migliore fra quelli utilizzati o presenti in letteratura, questi metodi prendono in considerazione più modelli, facendone una media e producendo un modello finale composto ([Lutins E., 2017](#)).

Questo approccio prevede l'utilizzo di tecniche più o meno articolate, delle quali è fondamentale aver chiaro quali sono le connotazioni statistiche alla loro base per poter fare la scelta più consapevole possibile al momento della decisione finale.

Per quanto riguarda quelle meno complesse, si citano *Max Voting*, *Averaging* e *Weighted Averaging*.

1. *Max Voting*: questa tecnica viene generalmente utilizzata con problemi di classificazione e prevede che le predizioni determinate da ogni modello rappresentino un voto. Si prenderà come predizione finale quella che è stata "votata" dalla maggioranza dei modelli coinvolti.
2. *Averaging*: viene utilizzata soprattutto per le predizioni in problemi di regressione o per la determinazione di probabilità in quelli di classificazione. Con questa tecnica prendiamo la media delle predizioni di tutti i modelli per determinare il risultato finale.
3. *Weighted Average*: può essere considerato come l'estensione della tecnica di averaging, in quanto ora si assegna un peso a seconda dell'importanza di ogni singola predizione effettuata dai modelli.

Parlando ora delle tecniche più complesse, è importante introdurre lo *Stacking*, il *Blending*, il *Bagging* e il *Boosting*. Per la discussione relativa queste quattro tecniche di ensemble, introduciamo il concetto per cui un dataset viene normalmente diviso in due parti, ovvero una parte di train, sulla quale si deve necessariamente effettuare la fase di allenamento del proprio algoritmo, ed una parte di test, sulla quale vengono fatte le predizioni finali.

1. *Stacking*: in questa tecnica si utilizzano le previsioni di differenti modelli fatte sul train set per costruire un nuovo modello che servirà a sua volta alla predizione finale sul test set.
2. *Blending*: l'approccio in questione segue la stessa metodologia dello *stacking*, con la differenza che le predizioni vengono effettuate esclusivamente su una parte del train set, ovvero sul *validation set* (supponendo che il train set sia diviso a sua volta in *training set* e *validation set*). Dunque, il *validation set* e le relative predizioni sono poi utilizzati per modellare un algoritmo che verrà utilizzato in ultima istanza sul test set.
3. *Bagging*: il concetto alla base è quello di combinare i risultati di molteplici modelli al fine di ottenere un risultato generalizzato. Questo però va contestualizzato, in quanto se si utilizzano più modelli sullo stesso insieme di dati è altamente probabile che questi diano lo stesso risultato. Per questo si può utilizzare la tecnica del *Bootstrapping*, con la quale è possibile creare dei sottoinsiemi con sostituzione del dataset originale. Il *Bagging*, che sta per *Bootstrap AGGREGatING*, sfrutta questi sottoinsiemi per ottenere un'idea corretta del dataset intero.
4. *Boosting*: questa tecnica è un processo sequenziale, in cui ogni modello successivo cerca di correggere gli errori di quello precedente, assegnando in questo processo dei pesi più elevati alle

osservazioni predette in maniera incorretta che man mano vengono rilevate e per le quali il nuovo modello cercherà correzione. Dunque, vengono creati molteplici modelli che correggono gli errori di quelli che vengono precedentemente. Questi modelli appartenenti al processo vengono chiamati *weak learners* ed il modello finale (*strong learner*), sarà la media ponderata di tutti questi algoritmi. Ricapitolando, dunque, questa tecnica di ensemble combina più *weak learners* che non funzionano molto bene sull'intero set di dati, ma solo su una parte di questo, migliorando dunque, nel complesso le prestazioni del modello finale.

Per riassumere, dunque, si evidenzia come le tecniche di *Bagging* e *Boosting* siano fra le più utilizzate, e per questa ragione è utile ricordare alcuni degli algoritmi che sfruttano i due approcci. È il caso del *Random Forest* e del *Bagging Meta-estimator* per quanto concerne la tecnica di *Bagging* e dell'*AdaBoost*, del *Gradient Boosting*, dell'*extreme*, del *light Gradient Boosting* e del *CatBoost* per quanto riguarda gli approcci di *Boosting* ([Singh A., 2023](#)).

Infine, è utile analizzare quali sono i vantaggi e gli svantaggi che effettivamente questi approcci portano con loro.

Per quanto riguarda i vantaggi, questi hanno sicuramente una capacità e accuratezza predittiva più elevata rispetto ai modelli individuali, sono molto efficaci sia con tipologie di dati lineari e non lineari all'interno del dataset poiché si possono combinare differenti modelli e gestire la situazione, si hanno anche meno problemi di *overfitting* ed *underfitting* del modello e si ha un grado di stabilità più alto.

A proposito degli svantaggi, invece, si sottolinea la maggior difficoltà di lettura degli output del modello, la complessità di apprendimento di utilizzo dell'approccio e che presenta costi più elevati sia in termini di spazio che in termini di tempo.

In conclusione, quindi, è possibile dire che le tecniche di ensemble, se studiate ed applicate in modo corretto, possono portare dei grandi benefici in termini di performance (Makhijani C., 2020). In particolare, si evidenzia anche la grandissima applicabilità dell'*ensemble learning* soprattutto quando questo risulta essere *tree-based*, soprattutto nelle funzioni Marketing, nel *Supply-chain management* e nel *manufacturing*, ma anche in quella *Finance* e IT, con una rilevanza per industrie specifiche molto elevata nel caso *Banking*, *Insurance* e *Retail* ([Chui M., Manyika J, Miremadi M., Henke N., et al., 2018](#)).

4.3: Focus tecniche di ensemble utilizzate nel *credit rating*

Come si è visto, le tecniche di *ensemble* hanno trovato spazio in materia, soprattutto in tempi più recenti, grazie alle loro miglior performance, anche in relazione agli aspetti negativi di cui si è parlato. Dunque, si può notare come il *tradeoff* fra benefici e svantaggi propenda tendenzialmente dalla parte dei vantaggi.

Perciò è utile esplorare più nel dettaglio la letteratura in materia, aggiungendo diversi approcci a quelli già introdotti in precedenza. In particolare, sono già stati analizzati gli studi di Wu H. C. & Wu Y. T. (2016) e quelli di Abdou H. & Pointon J. (2011), nel quale venivano introdotti rispettivamente il *Random Forest* ed il *Gradient Boosted Machines*.

Facendo dunque riferimento alla letteratura relativa al *Credit Risk Rating*, troviamo ricerche che introducono metodologie molto sofisticate che mettono insieme numerosi aspetti interessanti. È il caso di Wang M. & Ku H. (2021) che ispirati dal lavoro di Zhang S., Xu J., Zhang Q. J. & Root D. E. (2016) che proponeva una rete neurale artificiale estremamente efficace per risolvere il problema relativo al dispendio di tempo generato dall'addestramento delle reti neurali artificiali (o *Artificial Neural Network*), propongono un modello PANN (o *Parallel Artificial Neural Networks*) che risulta essere un modello ensemble molto elaborato, costruito sulla base della tecnica di calcolo parallelo, utilizzando la tecnica di *ensembling* basata sul *weighted averaging*, di cui si è già discusso in precedenza. Questo modello, in particolare, ha presentato ottimi risultati, generando una accuratezza più alta di circa il 3/5% rispetto ai metodi più tradizionali, nonostante una maggior lentezza computazionale, rappresentando dunque una valida soluzione in ambito di *Credit Risk Rating*.

Per completezza, all'analisi è opportuno introdurre anche alcune delle più rilevanti ricerche riguardo alla tematica del *Credit Scoring* a causa della similitudine al *Credit Risk Rating* per quanto riguarda la tipologia del problema, ovvero la classificazione. Si è già introdotto il concetto di *Credit Scoring*, ma per meglio comprendere le differenze e le similitudini con il rating del rischio, è necessario approfondire il tema. Si tratta, per l'appunto, di un punteggio che si pone come obiettivo quello di prevedere il comportamento creditizio di un debitore e quindi di prevedere la probabilità di rimborso del prestito. Le aziende utilizzano abitualmente questo score, in modo tale da riuscire a classificare i diversi richiedenti di prestito e, di conseguenza, i relativi tassi e condizioni contrattuali (Consumer Financial Protection Bureau, 2022). L'output dell'analisi è anche in questo caso, come nel *Credit Risk Rating*, un sistema di raggruppamento in classi definite a priori in maniera più o meno convenzionale.

Anche in questo ambito, le ricerche hanno mostrato la supremazia dell'*Ensemble Learning* in termini di performance. Esistono studi che comparano varie metodologie, come il *Random Forest*, l'*AdaBoost*, l'*XGBoost* ed il *LightGBM*, con altri algoritmi di *Machine Learning* singoli, come il *Neural Network*, la *Logistic Regression*, il *Decision Tree*, etc., ma i risultati propendono tendenzialmente a favore degli algoritmi di ensemble, tranne in alcuni casi isolati. Ancora una volta, anche in domini affini, si sottolinea la forza e la capacità predittiva di questo approccio ([Li Y. & Chen W., 2020](#)).

CAPITOLO 5: CREDIT RISK E REPUTAZIONE AZIENDALE

Si è già sottolineata l'importanza e l'incisività del *credit risk* per la vita aziendale, ma non si sono ancora trattate le molteplici conseguenze che una elevata o bassa valutazione di tale credito può portare all'azienda stessa ed ai suoi investitori.

Uno degli aspetti più importanti è senza dubbio quello della *reputation* aziendale. Una elevata reputazione aziendale attira un maggior numero di clienti, i quali percepiscono un maggior valore relativo a quella realtà, arrivando fino a pagare prezzi premium per prodotti e servizi relativi a quella azienda. Nell'attuale economia, inoltre, il 70-80% del valore di mercato è il risultato di beni immateriali tutt'altro che facili da misurare e quantificare, come la *brand equity* ed il capitale intellettuale.

Dunque, le organizzazioni, qualunque esse siano, sono particolarmente esposte ai rischi legati alla loro reputazione.

Nonostante la centralità di questo concetto, quindi, la maggior parte delle aziende non predispone una sovrastruttura adeguata al controllo e dunque al management di questo rischio, facendo nella maggior parte dei casi, un lavoro solo parziale e poco affidabile; ancor peggio, molte realtà si limitano non alla gestione approssimativa di tale rischio, bensì alla gestione della crisi. Questo significa che prima di far fronte alle conseguenze eventuali che si potrebbero avere, si lascia che il rischio si trasformi da potenziale a reale. Questo approccio presenta evidentemente molteplici lacune che non permettono al management di intervenire per tempo mitigando così tale rischio e riducendo notevolmente le conseguenze negative per l'azienda. Come anticipato in precedenza, negli anni la gestione dei rischi è stata largamente presa in analisi dai regolatori e dalle organizzazioni stesse, in modo da strutturare una sofisticata metodologia per gestire le varie possibili situazioni che un'azienda può trovarsi ad affrontare. In tale contesto, si fa riferimento sia a condizioni macroeconomiche che a situazioni microeconomiche, ma spesso non senza valutare con la dovuta attenzione la reputazione aziendale, che viene frequentemente trascurata.

A titolo esemplificativo si possono prendere a riferimento due casi significativi, come il documento del *Committee of Sponsoring Organizations of the Treadway Commission* (COSO) e l'accordo di Basilea II di cui si sono già discusse le caratteristiche in precedenza. In nessuno di questi due rilevanti casi, infatti, si tratta del rischio relativo alla reputazione, palesando una importante lacuna relativa a standard comuni che

genera a sua volta grande confusione nella gestione di tale rischio, anche nelle aziende più stabili e sofisticate. Dunque, è fondamentale, prima di procedere, conoscere su cosa affonda le proprie radici il rischio reputazionale e dunque in cosa consiste la reputazione stessa.

È possibile identificare tre determinanti principali:

1. *Reputation-reality gap*, vale a dire la differenza tra la percezione dovuta alla reputazione e la realtà. Per cominciare l'analisi, dobbiamo riconoscere che la reputazione è fondamentalmente una percezione che ha come variabili le reputazioni dei vari stakeholders in categorie specifiche del prodotto o servizio aziendale (come la qualità dei prodotti o la *governance* aziendale). Più alta è la reputazione dei vari stakeholders in più categorie, più alta sarà la reputazione aziendale nel suo complesso, magari a prescindere dal suo valore effettivo che potrebbe essere quindi sovrastimato. Avremo dunque delle situazioni in cui la reputazione aziendale potrà eccedere la realtà stessa. In questi casi si avrà un *gap* che dovrà essere monitorato, poiché rappresenta sostanzialmente il rischio di non poter corrispondere alle aspettative generali. Svolgerà quindi un ruolo chiave la capacità dell'organizzazione di soddisfare queste ultime e, nel caso in cui non possano essere rispettate, ridurle.
2. *Changing beliefs and expectations*, relativamente alle situazioni nelle quali le convinzioni ed aspettative degli stakeholders cambiano. Se a seguito di ciò non si ha una risposta dell'azienda ed il carattere della stessa rimane inalterato non seguendo dunque gli stakeholders, si ha un incremento del divario fra reputazione e realtà, generando come conseguenza un aumento dei rischi sostenuti. L'azienda dovrà quindi essere in grado di adeguare i suoi obiettivi e, se del caso, la sua stessa struttura ad una realtà che muta.
3. *Weak internal coordination*, quando si verifica uno scarso coordinamento fra le diverse *business units* e funzioni aziendali. Questa condizione può generare circostanze dove una funzione alza troppo le aspettative, per esempio su un prodotto o servizio, rendendo impossibile alle altre unità di rispettarle, provocando un aumento notevole del gap tra aspettative stesse e la realtà. Per comprendere meglio pensiamo al caso più comune dove la funzione Marketing promuove un prodotto dalle caratteristiche estremamente sofisticate che poi il dipartimento relativo alla produzione non riesce effettivamente a seguire. Il risultato può quindi sfociare in un prodotto che richiede di essere rivisitato o in un risultato tardivo con conseguenze estremamente negative sulla reputazione dell'azienda stessa.

Detto questo, è ora importante sottolineare che se la reputazione è una percezione, allora questa percezione deve essere misurata ([Eccles R. G., Newquist S. C. & Schatz R., 2007](#)).

Per procedere in tal senso è necessario quindi analizzare la composizione della *Corporate Reputation*, cercando di rendere misurabile una variabile molto soggettiva per sua natura in quanto non direttamente visualizzabile.

Innanzitutto, almeno in prima approssimazione, è importante sottolineare il collegamento fra *Corporate Reputation* e *Credit Risk*, in quanto la *Risk Reputation* può essere fatta rientrare in tutti quegli aspetti che vanno ad influenzare la misurazione della business risk in fase di valutazione del credito. Si tratta, in questo caso, di aspetti - come il *market share*, la forza del *brand*, la posizione all'interno della competizione ecc. - non esclusivamente finanziari che influenzano e vengono influenzati a loro volta anche dalla *Corporate Reputation*. Questa fornisce informazioni chiave, quali il grado di notorietà dell'impresa per la sua efficienza operativa e la sua solidità finanziaria. In particolare, è possibile sottolineare come questa efficienza (performance) operativa sia menzionata come elemento preso in considerazione dalle valutazioni fatte da S&P (Standard and Poor's, 2011).

Dunque, sembra evidente come la *Corporate Reputation* entri nella valutazione fatta dagli analisti delle varie agenzie per l'analisi del credito, fornendo importanti messaggi circa la *Creditworthiness* aziendale. In aggiunta a quanto detto, tale valutazione evidenzia come le aziende più rinomate siano tendenzialmente più attrattive per i lavoratori più talentuosi, valorizzandone così le prestazioni e conseguentemente migliorandone le performance sui mercati (Luo X. & Bhattacharya C. B., 2006).

Per quanto riguarda l'approccio da utilizzare per la succitata misurazione, è possibile seguire il metodo ripreso anche dallo studio di Alexander Himme & Marc Fischer (2014) che analizza i driver del costo del capitale, ponendo il focus proprio sulle metriche non finanziarie che entrano in gioco in questo caso. Questo studio, a sua volta, riprende l'approccio utilizzato ancora oggi da Fortune (2019) con il suo "*World's most admired companies*" in cui la reputazione aziendale deriva dalla valutazione di alcune dimensioni principali, ovvero: la solidità finanziaria, il grado di innovazione, gli investimenti a lungo termine, la capacità di attrarre-sviluppare-trattenere le persone con più talento, la qualità dei prodotti e/o dei servizi, la qualità del management, la responsabilità sociale, l'uso oculato degli asset aziendali e la competitività globale. Tramite la valutazione di questi aspetti infatti è possibile creare una misura che rifletta il potenziale di un'azienda circa la possibilità di accrescere i propri ricavi futuri e la propria efficienza operativa.

Ci sono ovviamente dei limiti nelle applicazioni messe in atto da Fortune. Infatti, in accordo con quanto studiato da Brown B. & Perry S. (1994), ma anche con quanto analizzato negli studi di Fryxell G. E. & Wang J. (1994) che già in tempi addietro avevano evidenziato alcune problematiche, questa metodologia è da prendere in considerazione solo tenendo bene in mente che è condizionata da un bias finanziario provocato dai risultati e dalle prospettive finanziarie delle aziende interessate e quindi da considerarsi come limitate nella loro utilità ai fini di ricerca. Questo fondamentalmente perché le analisi messe in atto sono fatte da esperti finanziari che tendono a dare maggior importanza agli aspetti finanziari della questione, andando però così a snaturare una misurazione che deve guardare più al lato non-finanziario della medaglia.

Per questa ragione molti autori tendono a porre molta più fiducia sui media e sulle strategie di marketing messe in atto in campo aziendale. La reputazione generata dai media, infatti - come suggeriscono OuYang Z., Xu J., Wei J & Liu Y. (2017) - è correlata positivamente al rendimento azionario post-crisi, generando dunque un grande beneficio laddove sia avvenuto effettivamente un evento negativo, tutelando così l'andamento azionario dell'azienda ed evitando enormi perdite. I media rappresentano dunque degli importanti segnalatori di qualità aziendale che fungono da paracadute nei momenti di crisi più importanti. Oltre alla reputazione proveniente dai media, acquisisce anche grande importanza la visibilità dei media stessi, poiché quest'ultima influenza la prima negli stock market. Infatti, le imprese con maggior visibilità mediatica, hanno ovviamente maggior necessità di dover rispondere a pressioni esterne che le spingono ad impegnarsi in campagne di pubbliche relazioni, per migliorare la propria percezione. Dunque, è evidente come le aziende cerchino di ottenere con il tempo una reputazione mediatica favorevole per segnalare un determinato livello di qualità del proprio business ed in generale della loro attività.

La conclusione naturale, dunque, può essere quella che i manager aziendali debbano impegnarsi in maniera consistente per influenzare positivamente la copertura mediatica, generando e sviluppando nuove relazioni positive con i media prima di una qualsiasi crisi. Questo ha importanti implicazioni nelle fasi di *risk assessment* aziendali.

Quindi, un aspetto importante diventa dunque quello della comunicazione, che acquisisce grandissima importanza in questo ambito. Žabkar & Arslanagić-Kalajdžić (2013), nel loro studio relativo all'impatto della reputazione aziendale e della condivisione di informazioni sulla creazione di valore, evidenziano come la comunicazione aziendale risulti cruciale per costruire, proteggere e mantenere la *Corporate Reputation*.

Tutte queste considerazioni ci portano, dunque, a riflettere su altre forme di misurazione oltre a quella fornita da Fortune. Febra L., Costa M. & Pereira F. (2023), nel loro innovativo approccio mirato a studiare le relazioni tra reputazione, ritorni e rischi, vanno a prendere in considerazione, non più le metriche indicate da Fortune, bensì quelle utilizzate dal The Reputation Institute che, nel 1998, ha lanciato il proprio progetto per colmare le lacune presenti nei modelli di misurazione della reputazione. Si è generato dunque il *Reputation Quotient* (RQ), che risulta ad oggi essere una delle misure più popolari per la misurazione della reputazione aziendale tra gli accademici. Questo Quoziente è un elenco di 32 voci che tiene in conto le diverse percezioni di reputazione di vari gruppi di stakeholder nei confronti dell'azienda considerata. Si considera il richiamo emotivo, i prodotti ed i servizi, la vision e la leadership, la responsabilità sociale ed ambientale, il *working environment* ed in ultima istanza la performance finanziaria. Questo Quoziente risulta dunque essere estremamente valido, grazie alla sua ampiezza di visione ed alla sua affidabilità.

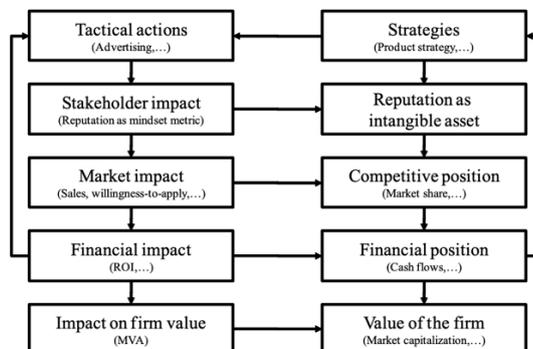
Figura 1 - Elementi chiave per la computazione del Reputation Quotient.¹



Per vedere invece l'applicabilità del *Reputation Quotient* (RQ) in ambito bancario, possiamo far riferimento allo studio condotto da Kanto D. S., de Run E. C. & Hassan A. (2016) sull'industria bancaria Malaysiana. In particolare, il *Reputation Quotient*, oltre ai benefici di cui già si è parlato in precedenza, presenta numerosi vantaggi in ambito cross-culturale, essendo già stato applicato in regioni del mondo come Stati Uniti d'America, Europa ed Australia. Lo studio si pone l'obiettivo di dimostrare ancora una volta il fit del quoziente su un mercato diverso, quello Malaysiano. L'output dello studio è positivo ed ancora una volta si ha evidenza della applicabilità dell'RQ ai fini di ricerca.

Sempre nell'ambito della misurazione della *reputation* aziendale, è interessante citare lo studio condotto da Raithel S. & Schwaiger M. (2012) nel quale si analizza il link fra *Corporate Reputation* e *Corporate Financial Performance*, prima di tutto per la "Chain of effects" (Figura 2) determinata nello studio.

Figura 2 - Chain of Effects.²

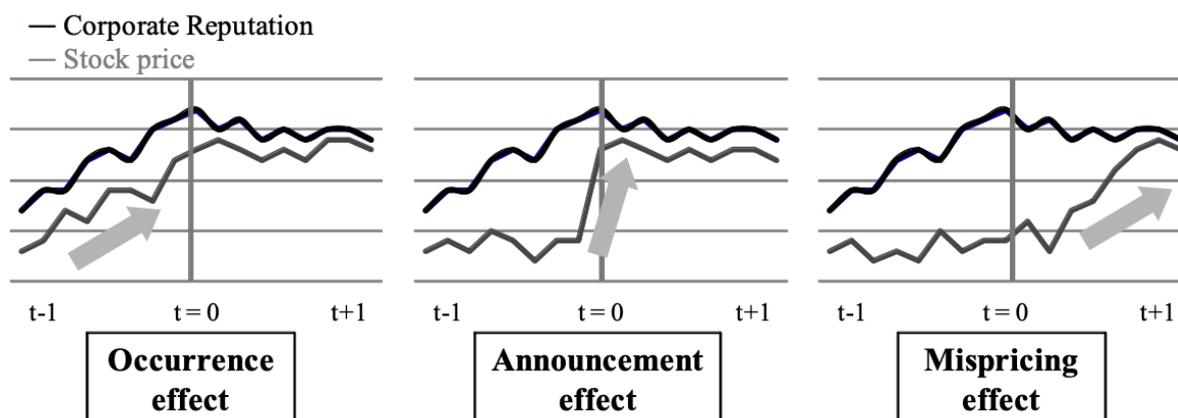


¹ Nielsen (2019). How does The HarrisPoll Reputation Quotient measure corporate reputation?. Twitter

² Raithel S. & Schwaiger M. (2012). Evaluating Corporate Reputation: The Link with Corporate Financial Performance. Research Gate.

Secondo gli autori, la reputazione aziendale, come anche detto in precedenza è la somma aggregata dei vari stakeholder e può essere buona o cattiva, alta o bassa. Una buona reputazione crea legami più forti fra azienda e stakeholder e dunque un aumento del valore e della soddisfazione degli stessi. Quindi, una buona reputazione porta fondamentalmente ad un impatto sul mercato, generando quote di mercato più elevate, un aumento della *willingness to apply* di nuovi talentuosi dipendenti e prezzi più elevati, generando a sua volta un rafforzamento della posizione di mercato dell'azienda. Tutti questi effetti generano anche un impatto finanziario, portando dunque a maggiori profitti con *cash flows* più rapidi, stabili e meno vulnerabili. A sua volta si ha poi l'impatto positivo sul valore dell'azienda che può essere considerato in ultima analisi la capitalizzazione di mercato, ovvero il valore per gli azionisti. Numerose ricerche evidenziano anche come un'elevata reputazione aumenti il grado di accesso al mercato dei capitali per le aziende, riducendone i costi (Ritter J. & Beatty R. P., 1986). Quindi buona reputazione significa migliore performance e ovviamente questo significa a sua volta aumento del valore di mercato dell'azienda. Inoltre, la ricerca di Raithel e Schwaiger identifica tre effetti principali relativi alla reputazione ed al valore azionario, vale a dire l'*Occurrence effect*, l'*Announcement effect* e il *Mispricing effect*.

Figura 3 - Occurrence effect, Announcement effect e Mispricing effect.³



Il primo di questi, l'*Occurrence effect*, è quello con il quale gli investitori reagiscono ad eventi imprevisti correlati alla realizzazione dell'evento. Dunque, gli investitori hanno già incorporato nelle loro aspettative l'effetto dell'annuncio eventuale di tale evento e il prezzo delle azioni incorpora tutto ciò ancor prima che effettivamente accada. In secondo luogo, si trova l'*Announcement effect*, dove gli investitori reagiscono immediatamente ad informazioni impreviste o ad eventi discreti, come nel caso di una nuova classifica riguardo la reputazione aziendale stilata da Fortune. Infine, è possibile identificare il *Mispricing effect*, dove gli investitori non apprezzano le implicazioni di valore a lungo termine della reputazione aziendale,

³ Raithel S. & Schwaiger M. (2012). Evaluating Corporate Reputation: The Link with Corporate Financial Performance. Research Gate.

adattando le loro aspettative sopra o sottostimate all'annuncio dell'evento, utilizzando informazioni impreviste causate da una maggiore o minore *reputation*, come nel caso di vendite e/o profitti inaspettatamente maggiori o minori.

Esistono vari modi per valutare questi effetti ed il lavoro sopracitato è un ottimo punto di partenza per un'analisi più approfondita. La cosa evidente che emerge risulta infine essere che la *Corporate Reputation* e la performance finanziaria, hanno connessioni evidenti e già dimostrate.

Un altro studio degno di menzione è senz'altro quello condotto da Schwalbach J. & Dunbar R. L. M. (2000), il quale sottolinea come la variabile reputazionale sia soggetta a fluttuazioni nel tempo e dunque risulta fondamentale monitorarla e saperla gestire, oltre al fatto che un'alta reputazione può oltretutto funzionare da salvagente in caso di eventi inaspettati. Infine, si evidenzia come la performance finanziaria, oltre che essere influenzata dalla reputazione, come visto nello studio precedentemente citato, influenza a sua volta la futura reputazione aziendale (si parla, nello specifico, di *performance effect*, il quale risulta estremamente forte e rapido nella sua esplicitazione).

Fatte tutte queste premesse ed evidenziato come anche la performance finanziaria, che è a sua volta connessa alla valutazione del credito, influenzi la *Corporate Reputation*, diventa cruciale andare ad analizzare nel dettaglio la connessione fra *Corporate Reputation* e valutazione del *Credit Risk*. Ciò al fine di focalizzare come, dal punto di vista manageriale, una eventuale conoscenza e capacità di gestione di tali variabili possano incrementare il benessere dell'azienda, accrescendo dunque ed affinando la crescente letteratura multisetoriale relativa al Marketing (per quanto concerne l'aspetto connesso alla *Brand/Corporate Reputation*) ed alla Finanza (per quanto riguarda gli aspetti collegati al *Credit Risk Rating* ed alle sue conseguenze). In tale contesto, il *Machine Learning* di cui si è già ampiamente discusso in precedenza si conferma strumento computazionale estremamente promettente, il cui ricorso è destinato ad un indubitabile incremento.

Il rapporto tra *Credit Rating* e *reputation aziendale*, dunque, viene solitamente approcciato a partire dalla seconda componente, ovvero quella reputazionale. Quindi, si tenderà a ricercare risposte alla domanda relativa agli effetti sul *Credit Rating* in funzione di alterazioni (incrementi o decrementi) della *reputation aziendale*, essendo stata dimostrata una stretta connessione fra i due aspetti. In sostanza, si tratta di un problema complesso che consiste nell'ottenere un output chiaro, ponendo in relazione un elemento oggettivo e misurabile come il rating del credito aziendale e una variabile particolare, non visibile ad occhio nudo e difficilmente valutabile.

Ma tutto ciò può essere affrontato col metodo inverso, cercando cioè di capire quali siano le conseguenze di una variazione del *Credit Rating* nei confronti della *reputation aziendale*. Questo cambio di prospettiva ci porta dunque a considerare come asset, non più la reputazione, bensì il *Credit Rating*, che diventa così un vero e proprio asset reputazionale.

D'altronde la reputazione aziendale merita un serio approfondimento, vista la sua importanza da un lato e la sua difficoltà computazionale dall'altro. Famosissime ed emblematiche, al riguardo, sono le citazioni di Warren Buffet come quella per la quale *"It takes 20 years to build a reputation and five minutes to ruin it. If you think about that, you'll do things differently"* e che ci porta a comprendere la crucialità della questione, nonché quanto questa debba sempre essere monitorata, anche laddove si pensa che non ci possano essere conseguenze dirette su di essa. Una seconda citazione molto significativa ed importante è certamente quella per la quale *"Lose money for the firm, and I will be understanding. Lose a shred of reputation for the firm, and I will be ruthless"* che invece ci porta a ragionare non più in termini di input di serie A (misurazioni finanziarie) e input di serie B (misurazioni non finanziarie tra cui la *reputation aziendale*), bensì ci porta a ragionare in termini molto più di ampie vedute: la reputazione, che è una misurazione non finanziaria, risulta essere importante come, se non di più, delle altre misurazioni finanziarie.

Questi aspetti sono portati alla luce ed analizzati dallo studio di Barakat A., Ashby S. & Fenn P. (2018), i quali analizzano in maniera accurata il ruolo di asset o liability reputazionali delle raccomandazioni azionarie e dei *rating* creditizi. In particolare, si arriva ad un risultato molto interessante per la ricerca in questione, laddove si conferma la teoria della "legittimità istituzionale" per la quale i *rating* più elevati fungono da *asset* reputazionale, capaci quindi di indurre l'investitore a concedere all'azienda che si trova in perdita il beneficio del dubbio. Ciò, dunque, rappresenterebbe un salvagente non di poco conto, in quanto tale realtà aziendale si vedrebbe meno penalizzata rispetto ad una a *rating* più basso, alleviando quindi il danno reputazionale dovuto a rischi operativi. Generalizzando, dunque, gli autori, che hanno condotto la propria ricerca sulla possibilità che si verifichi un rischio operativo - ovvero un rischio di perdita derivante da processi interni, persone, sistemi, eventi esterni o altri fattori che possono interrompere o modificare il flusso delle regolari operazioni aziendali - supportano l'idea che le raccomandazioni azionarie ed i *rating* di credito guidano gli effetti reputazionali causati da eventi o notizie negative.

Altro grande contributo alla materia in questione è stato portato da Fiordelisi F., Soana M. G. & Schwizer P. (2013), che nel loro studio indagano quali siano le determinanti del rischio reputazionale nel settore bancario. In particolare, dalla loro ricerca emerge che si possono identificare sei fattori che possono influenzare la *reputation aziendale*: la rischiosità della banca, la redditività, il livello di asset intangibili, la capitalizzazione dell'impresa, la grandezza dell'impresa, l'entità della perdita operativa e l'unità di business

che registra la perdita operativa. In particolare, la rischiosità della banca prevede la misurazione di tre fattori, ovvero: l'indice beta, che esprime il rischio sistematico della banca; la deviazione standard del rendimento azionario, che esprime il rischio complessivo assunto da un'azionista; la leva finanziaria di mercato della banca, che invece fornisce un'indicazione importante sull'esposizione della banca ai rischi di insolvenza. Questi elementi sono estremamente vicini ai concetti analizzati con il *credit risk* e la valutazione tramite *rating* da parte delle agenzie. Perciò, questo studio e le sue conclusioni, ci portano a considerare anche il *credit risk* come fattore che influenza la *reputation* aziendale, quando avviene un qualche evento negativo. In particolare, si arriva a concludere che la probabilità di un danno alla reputazione aumenta all'aumentare dei profitti e delle dimensioni della banca, oltre al fatto che le banche grandi vengono penalizzate maggiormente delle banche più piccole, *ceteris paribus*, dopo una perdita operativa.

5.1: Approfondimento sui metodi di misurazione della reputazione

Abbiamo già discusso dell'applicabilità del *Reputation Quotient* in ambito di ricerca, ma è opportuno scandagliare nuovamente ed in maniera più approfondita ciò che può essere utilizzato per la valutazione di questa variabile.

Secondo Berens G. e van Riel C. (2004), esistono 3 principali stream di misurazione della reputazione, che corrispondono: al "*Trust*", ossia la "Fiducia", che corrisponde alla predizione delle performance future, in base ai dati storici; alle "*Social Expectations*", ovvero le "Aspettative sociali" che gli stakeholder nutrono nei confronti delle aziende, nella quale si misura la reputazione tramite l'utilizzo di scale cognitive in continua evoluzione; alla "*Corporate Personality*", ovvero "Personalità aziendale", nella quale si tenta di personificare le reputazioni aziendali, per l'appunto.

Lo studio condotto da Khan S. & Digout J. (2017), evidenzia come si possano ricondurre alcuni dei più famosi metodi di misurazione della reputazione a questi 3 stream. In particolare, attribuisce allo stream del "*Trust*" l'approccio di Fortune, già discusso in precedenza. In secondo luogo, per quanto riguarda le "*Social Expectations*", possiamo rimandare all'approccio relativo al *Reputation Quotient*, di cui abbiamo, anche in questo caso, discusso in precedenza, ma anche il modello chiamato "*RepTrak*" di cui discuteremo a breve. Per quanto riguarda l'ultimo stream, invece, ovvero quello relativo alla "*Corporate Personality*", si cita il "*Corporate Character Scale*".

A questi si aggiunge la metodologia risultato della ricerca condotta dagli autori, relativa alla *Corporate Reputation Reporting Framework*, della quale faremo riferimento con CRRF, che si riferisce a tre dimensioni chiave:

1. *Being known*: ovvero essere conosciuti, che si riferisce a quanto è conosciuta l'azienda oggetto di valutazione;
2. *Being known for something*: ovvero essere conosciuti per qualcosa, che fa riferimento al modo in cui l'organizzazione studiata viene percepita dagli stakeholder durante varie situazioni;
3. *Generalized favorability*: ovvero favore generalizzato, che rappresenta la complessiva simpatia ed il generale legame emotivo degli stakeholder con l'azienda in questione.

5.2: Deep dive nella misurazione della reputation aziendale

Per ricapitolare dunque le misurazioni che è bene approfondire, facciamo riferimento a questa classificazione:

1. *Ranking Lists and Monitors*: al quale appartiene il ranking generato dalla rivista Fortune ogni anno, con la dicitura WMAC.
2. *Scales*: al quale si fa riferimento utilizzando la metodologia *RepTrak e Reputation Quotient (RQ)*.
3. *Personification Metaphors*: nel quale facciamo riferimento all'approccio del *Corporate Character Scale (CSS)*.
4. *Corporate Reputation Reporting Framework*: al quale facciamo riferimento con l'approccio utilizzato nella ricerca appena descritta, ovvero il CRRF.

5.2.1: World's Most Admired Companies (WMAC)

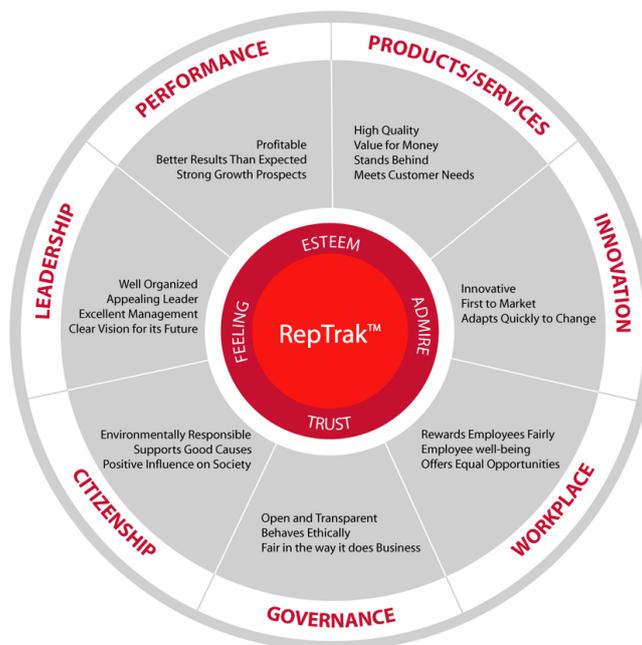
Per cominciare l'analisi del WMAC di Fortune, è opportuno sottolineare nuovamente le sue caratteristiche fondamentali. Si tratta di un ranking che viene redatto su base annuale e che non presenta altissimo grado di convalidazione interculturale, in quanto non ricopre la totalità delle nazioni presenti nel globo. Nello specifico, nella più recente indagine, risalente al 2022, si ha una mappatura che prevede solo 188 aziende non statunitensi provenienti da 28 paesi e 447 provenienti dagli Stati Uniti d'America per cui il dataset risulta altamente sbilanciato. E' inoltre redatto tramite questionario customizzato per l'industria che viene somministrato ad un campione di circa 15.000 dirigenti, direttori esterni ed analisti di settore ([Korn Ferry, 2022](#)). Questo approccio, secondo quanto riportato nella ricerca di Khan S. & Digout J. precedentemente citata, produce reputazioni altamente instabili e non eccessivamente affidabili in generale. Infatti, viene sottolineato come non rappresenti i punti di vista di tutte le parti interessate, in quanto, come evidenziato in precedenza, coloro a cui viene somministrato il questionario sono solo esperti del settore, quindi affetti da *bias*

relativo al mondo finanziario per lo più. Oltre a ciò, non vengono valutati i fattori affettivi, estremamente rilevanti nelle questioni riguardanti le reputazioni aziendali.

5.2.2: RepTrak

In secondo luogo, si osserva come *RepTrak* sia un modello estremamente diverso dal punto di vista della significatività ai fini di ricerca. Fombrun C. J., Ponzi L. J. & Newburry W. (2015) validano nel loro studio le sette dimensioni su cui questo è fondato, in quanto il *Reputation Institute*, padre del metodo, non ha pubblicato tali analisi. Queste sette dimensioni presentano 3 o 4 attributi sottostanti e permettono la misurazione della reputazione in modo molto più stabile. La versione finale del *RepTrak* è stata ultimata dall'istituto nel 2005-2006 ed è il derivato finale del *Reputation Quotient* di cui abbiamo già parlato in precedenza, e che prevedeva inizialmente 6 dimensioni per 20 attributi. I fondamenti metodologici del modello e la sua validazione non sono stati resi pubblici dall'istituto e per questo, la capacità di ricerca da parte dei professionisti in materia è stata fortemente limitata. Lo studio di Fombrun et al. si pone dunque l'obiettivo di convalidare le sette dimensioni per poter prevedere la reputazione aziendale derivante dal *RepTrak System*, esaminandone la stabilità in 5 diversi gruppi di stakeholders appartenenti ad industrie differenti e a 6 nazioni distinte. La scala utilizzata del *RepTrak system* è una scala a 23 indicatori che permette, oltre ad un'analisi interculturale, anche comparazioni varie tra le varie aziende.

Figura 4 - RepTrak System.⁴



⁴ Chan T. J., Sathasevam T., Noor P. N. M., Khiruddin A. M., & Hasan N. A. M. (2018). Application of Selected Facets of RepTrak™ Reputation Model on Carlsberg Malaysia as One of the Companies in Tobacco, Gambling, Alcohol and Pornography (TGAP) Industry. *International Journal of Academic Research in Business and Social Sciences*, vol. 8(1).

5.2.3: Corporate Character Scale

In terzo luogo, si tratta il **CCS** (Corporate Character Scale). Questo metodo non è finalizzato alla definizione della *Corporate Reputation*, bensì a scoprire il motivo per il quale alcune aziende hanno una reputazione migliore di altre (Davies G. et al., 2001). Questo metodo di personificazione della reputazione aziendale fornisce risultati stabili e può essere utilizzato per ottenere il punto di vista di più stakeholders, oltre al fatto che è adatto ad analisi interculturali. Peraltro, si è notato come questo tipo di misurazione non sia estremamente chiaro, in quanto non è facilmente comprensibile se un risultato sia positivo o negativo, posto il fatto che non effettua una vera e propria misurazione, come detto. Dunque, questo tipo di misurazione non presenta grandi capacità di predizione.

Figura 5 - Elementi Corporate Character Scale.⁵

<i>Dimension</i>	<i>Facet</i>	<i>Item</i>
Agreeableness	Warmth	Friendly, pleasant, open, straightforward
	Empathy	Concerned, reassuring, supportive, agreeable
	Integrity	Honest, sincere, trustworthy, socially responsible
Enterprise	Modernity	Cool, trendy, young
	Adventure	Imaginative, up-to-date, exciting, innovative
	Boldness	Extrovert, daring
Competence	Conscientiousness	Reliable, secure, hardworking
	Drive	Ambitious, achievement oriented, leading
	Technocracy	Technical, corporate
Chic	Elegance	Charming, stylish, elegant
	Prestige	Prestigious, exclusive, refined
	Snobbery	Snobby, elitist
Ruthlessness	Egotism	Arrogant, aggressive, selfish
	Dominance	Inward-looking, authoritarian, controlling
Informality	None	Casual, simple, easy-going
Machismo	None	Masculine, tough, rugged

5.2.4: Corporate Reputation Reporting Framework

Infine, si analizza il modello proposto da Khan S. & Digout J, ovvero il **CRRF** (*Corporate Reputation Reporting Framework*). I dati in questo caso possono essere estratti, sia mediante sondaggi, sia tramite monitoraggio di segnali online. Questo modello aiuta a comprendere i fenomeni che sottendono una certa reputazione, rappresentando la *Corporate Reputation* in maniera completa ed equilibrata. Come detto in precedenza, il modello è basato su tre dimensioni principali:

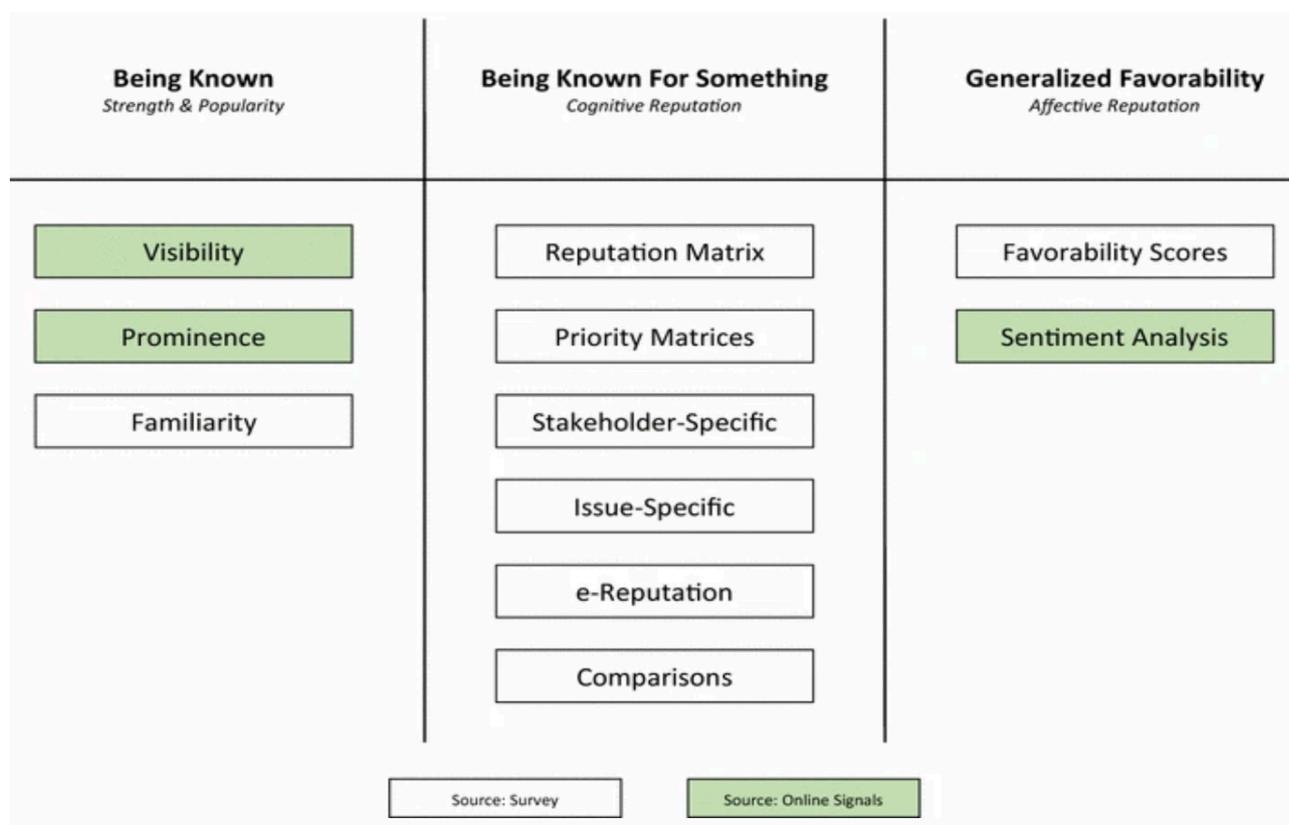
1. *Being Known*: composta a sua volta da tre fattori principali quantitativamente definibili.

⁵ Davies G. et al. 2001. The personification metaphor as a measurement approach for corporate reputation. *Corporate Reputation Review*, vol. 4, pp: 113-127.

- a. *Visibility*: ovvero visibilità, rappresenta quante persone parlano dell'azienda in questione. Si parla di metriche ben note come il "e-Word of mouth" ed il "User Generated Content". In generale si fa riferimento agli "earned media" e si può monitorare e quantificare ogni metrica utilizzando software come Brand24, Cision e Meltwater.
 - b. *Prominence*: ovvero rilievo, che rappresenta l'impatto che ha un'azienda sugli "owned media". Si monitora il traffico sul sito web dell'azienda, l'engagement negli account sui social media, ecc, tramite l'utilizzo di software come Alexa, SEMrush e SimilarWeb.
 - c. *Familiarity*: ovvero familiarità, misura quanto bene sia conosciuta l'azienda dagli individui. Misurabile tramite una scala validata nelle survey.
2. *Being Known For Something*: in questo caso abbiamo sei sottocomponenti da monitorare.
 - a. *Reputation matrix*: la quale prevede una compilazione a due step (configurazione e questionari) dove si pongono su due ascisse diverse i gruppi di stakeholders e le categorie da misurare con possibilità di scelta fra "-1" ovvero in disaccordo, "0" ovvero neutrale e "1" ovvero in accordo.
 - b. *Priorirty matrix*: la quale misura l'importanza della questione per gli stakeholder, a che industria questi appartengono e l'importanza all'interno dell'organizzazione. In questo caso la scala dovrebbe essere da 1 a 3, rappresentando priorità decrescente.
 - c. *Stakeholder-Specific Reputations*: ossia la reputazione specifica di un particolare gruppo di stakeholders per un'organizzazione. Questi risultati derivano dalla ponderazione delle colonne della reputation matrix.
 - d. *Issue-Specific Reputations*: ossia la reputazione specifica di un particolare aspetto. Questo risultato deriva dalle righe della matrice della reputazione.
 - e. *E-Reputation*: la reputazione che si ha online viene valutata tramite l'utilizzo di una scala validata formata da 4 item e che può assumere, di nuovo, valori compresi fra 1 e -1.
 - f. *Comparisons*: poiché le reputazioni che gli stakeholders hanno sono implicitamente relative a qualcosa, è utile porre la questione anche in termini di confronti specifici.
 3. *Generalized Favorability*: le componenti di questa dimensione sono molto volatili in quanto guidate da emozioni e sensazioni. Si hanno 2 componenti:
 - a. *Favorability scores*: ovvero i punteggi di preferenza. Si possono utilizzare scale prevalidate, mantenendo la bipolarità dei valori tipica del CRRF (fra -1 e 1) e misurando facendo distinzione fra gruppi di stakeholders diversi.
 - b. *Sentiment Analysis*: questa analisi coglie l'umore nel breve termine della corporate e-reputation. Questa è un'analisi svolta su big data e viene effettuata tramite processi di text mining, analisi e machine learning.

Concludendo l'analisi del CRRF, si sottolinea la dimensione generale e multidimensionale dell'approccio che permette un utilizzo estensivo anche all'interno del mondo aziendale. La principale difficoltà relativa all'utilizzo dell'approccio è senza dubbio la difficoltà relativa al reperimento di tutte le informazioni, aspetto che purtroppo viene trascurato dagli autori, che si concentrano più sul segnalare cosa è importante ed il perché. Nonostante ciò, l'apprendimento automatico ed i progressi scientifici in questa direzione risulteranno fondamentali per un'applicabilità totale dell'approccio.

Figura 6 – Elementi Corporate Reputation Reporting Framework.⁶



CAPITOLO 6: CORPORATE REPUTATION E ESG SCORE

In precedenza, sono già stati introdotti i concetti di Credit Risk e Credit Rating, analizzandone l'importanza e la centralità nell'applicazione di modelli statistici di ultima generazione, nonché di *Corporate Reputation* e delle sue modalità di misurazione, evidenziando punti di forza e debolezza. Così facendo si è andati dunque a introdurre e a sottolineare l'importanza della reputazione aziendale anche all'interno delle valutazioni che vengono fatte dal punto di vista aziendale e si è visto come la reputazione genera spesso

⁶ Khan S. & Digout J. (2018). The corporate reputation reporting framework (CRRF). *Corporate Reputation Review*, vol. 21, pp: 22-36.

delle conseguenze dal punto di vista finanziario e come questa risulti, nei momenti di crisi, come un vero e proprio paracadute per le sorti aziendali, altrimenti troppo esposte a ciò che succede attorno ad esse.

In sostanza, la reputazione è un parametro di sempre maggiore importanza nel mondo economico in generale ed uno degli strumenti con cui questa stessa viene costruita e sedimentata in maniera più efficace è la comunicazione aziendale: in altre parole, il marketing vero e proprio. L'abilità di comunicare, di saper misurare la risposta ed il comportamento dei clienti a specifiche policy e strategie aziendali, di far seguito alle promesse fatte con azioni concrete e di sostanza, sono ciò che davvero conta per costruire una reputazione buona e solida. Questo ovviamente non può prescindere dalle performance aziendali sul mercato che ovviamente devono essere buone; l'azienda deve proporre buoni prodotti e buoni servizi, deve essere rispettabile sia lato consumatori, sia lato dipendenti; deve avere buoni indicatori finanziari e questo deve avere buoni riflessi sul mercato azionario ed obbligazionario, se l'azienda ne fa parte.

I consumatori, i dipendenti, gli investitori ed in generale tutti gli stakeholder che fanno parte della regolare vita aziendale della realtà presa in considerazione, sono elementi che contribuiscono – ognuno per la propria parte - alla sedimentazione della sua reputazione generale, come abbiamo visto.

Ciò conferisce un carattere multidisciplinare alla materia riferita a questo aspetto del mondo corporate, imponendo un approccio che potremmo definire olistico, rifuggendo dalla tentazione di separate analisi settoriali e scollegate.

In particolare, negli ultimi anni, anche a causa delle continue crisi che si sono verificate che non hanno fatto altro che intensificare il fenomeno, stiamo assistendo ad una crescente attenzione nei confronti dei criteri ESG da parte degli stakeholders sopra menzionati. I criteri ESG sono così diventati un mezzo affidabile per facilitare la lettura e valutazione delle aziende da parte degli interessati, rispetto ad un ampio spettro di obiettivi socialmente desiderabili. Questi aspetti saranno dunque centrali nella maggior parte delle questioni economiche del futuro e, in parte, già lo sono.

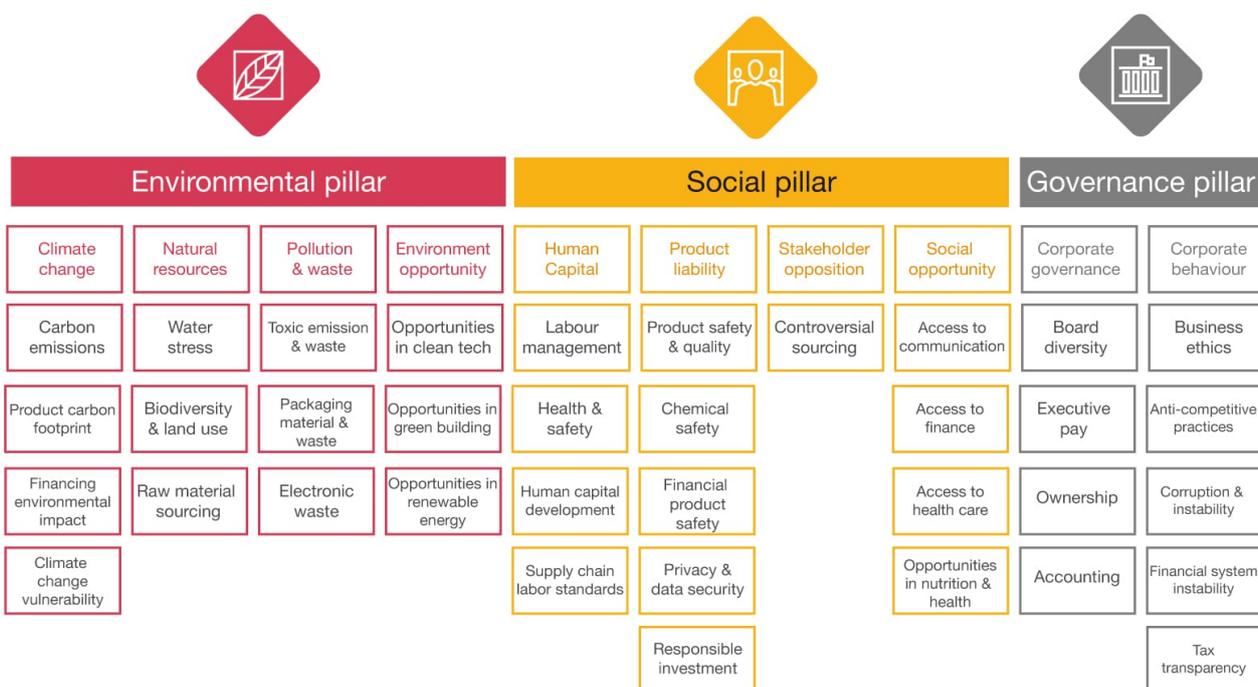
Inoltre, questi concetti sono altamente influenzati dall'opinione pubblica e, con questa, interagiscono. Sono caratteri intrinsecamente reputazionali ed un numero sempre più elevato di società si trova costretta a fornire quante più informazioni al riguardo possibili, sia a causa delle regolamentazioni sempre più stringenti in materia, sia perché spinte dal mercato stesso. Ovviamente, questo ha un impatto anche nei confronti del parametro della *velocità* introdotto nell'esordio dell'elaborato, ragion per cui la circolazione pressoché istantanea di informazioni che spesso diventano virali non permette più alle aziende di essere titubanti né reticenti; chi non riesce a stare dietro al mercato ed all'opinione pubblica, insomma, rischia di andare

incontro a conseguenze estremamente gravi, in primis dal punto di vista reputazionale ([Bergman M. S. et al. 2020](#)).

6.1: Approfondimento sui criteri ESG

Entrando più nel dettaglio, ESG sta per Environment, ovvero “ambiente”, Social, ovvero “sociale”, e Governance, che in italiano può essere generalizzato con “amministrazione”; tutti aspetti che si allineano a quelle che sono le più grandi sfide delle nuove generazioni, con la grande enfasi sulle tematiche del cambiamento climatico, sulla necessità di una transizione ad un’economia più circolare, sul problema dell’aumento delle disuguaglianze, ecc. Tutte sfide che non si sono limitate ad influenzare le opinioni pubbliche ma che hanno attratto una crescente attenzione anche da parte dei regolatori.

Figura 7 - Criteri ESG.⁷



Questi, come i consumatori stessi, gli investitori, e tutti gli altri stakeholder, non si limitano più, infatti, a richiedere alle aziende un’adeguata amministrazione del capitale, bensì richiedono anche un’adeguata amministrazione del capitale sociale ed ambientale che le aziende stesse possiedono e gestiscono. Per

⁷ PWC (n.d.). Environmental, Social & Governance - What’s it all about?

questo, possedere un quadro di governance sufficientemente efficace all'amministrazione di questi aspetti è diventato un tema centrale per le aziende prese in considerazione.

Nel dettaglio, analizzando più in profondità i tre pilastri appena citati (Deloitte, 2022) vediamo che:

1. L'*Environmental pillar* riguarda tutti quegli aspetti relativi alle emissioni di gas serra o di elementi inquinanti, sia nell'aria, che nell'acqua o nel sottosuolo. L'attenzione è anche posta sull'utilizzo delle risorse e di come queste vengano smaltite o riutilizzate, in ottica di perseguire il concetto di economia circolare. Si prendono in considerazione, inoltre, le problematiche relative all'utilizzo del suolo e delle conseguenze che un utilizzo sconsiderato di tale risorsa può comportare, come la riduzione di biodiversità e la deforestazione. Tutti questi aspetti devono poi essere accompagnati dalla registrazione di quelli che possono essere gli aspetti positivi della sostenibilità aziendale;
2. il *Social pillar* fa invece riferimento a come le aziende gestiscono lo sviluppo dei dipendenti, le pratiche di lavoro, la sicurezza e la qualità dei propri prodotti. Vengono anche presi in considerazione gli standard di lavoro, salute e sicurezza della loro catena di fornitura e le questioni di approvvigionamento problematiche, oltre al fatto se le aziende garantiscono o no l'accesso ai loro prodotti e servizi a gruppi sociali svantaggiati.
3. il *Governance pillar*, infine, si riferisce ai diritti degli azionisti ed alla diversità del consiglio di amministrazione, nonché alle modalità di retribuzione dei dirigenti e all'allineamento dei compensi alle performance di sostenibilità aziendali. Inoltre, con questo "pilastro" ci si riferisce anche al comportamento aziendale, con particolare attenzione alla corruzione ed alle pratiche anticoncorrenziali.

È evidente come i concetti di ESG stiano diventando sempre più fondamentali per tenere traccia della vita aziendale, andando a toccare tutti quegli aspetti più qualitativi che fino a qualche anno fa non venivano presi in considerazione. Questo rende queste tematiche cruciali per la gestione del marchio e della reputazione aziendale, oltre per tutte quegli altri aspetti che giocano un ruolo chiave nella determinazione del valore delle aziende.

Come detto, i pilastri ESG vanno a coprire una moltitudine di elementi molto importanti della realtà, elementi che risultano estremamente rilevanti per l'interesse e l'opinione pubblica (Dow Jones, 2022). Come affermato da Matt Donahue, infatti, i dipartimenti di comunicazione devono sapere se i messaggi derivanti dalla valutazione ESG hanno o meno la risonanza voluta e che cosa stanno facendo i propri competitor in tali ambiti.

Inoltre, la capacità di monitorare e saper leggere i dati riguardo al posizionamento ESG della concorrenza e della percezione dei consumatori riguardo le proprie mosse e strategie in materia non può far altro che aiutare sostanzialmente i team che si occupano di veicolare tali messaggi all'esterno, generando così il miglior impatto possibile sulla reputazione aziendale.

Matt Donahue, Market Specialist per Dow Jones, sottolinea come tutte queste informazioni possano aiutare la vita aziendale identificando quegli influencer o quelle pubblicazioni che meglio faranno comunicare all'esterno tutti i risultati ottenuti, definendo la strategia di marketing in maniera precisa ed estremamente efficace.

Peraltro, tenere insieme tutti questi dati e tutte queste informazioni è estremamente complesso, per cui diventa indispensabile saper sfruttare quelle tecniche all'avanguardia ormai facilmente disponibili, assicurandosi la capacità di esercitare approcci multidisciplinari alla materia.

Altro aspetto molto importante, oltre alle performance in materia, è poi quello della comunicazione ad essa collegata.

Conoscere i media di riferimento, conoscere i canali comunicativi, il modo con cui le altre aziende si pongono e limitare al massimo il divario fra realtà (performance) e ciò che viene comunicato, è cruciale, per mantenere, migliorare e rinforzare la propria reputazione.

Come visto in precedenza parlando di reputazione in generale, questa rappresenta un capitale molto complicato da costruire e, talvolta, non bastano anni di duro lavoro in tale direzione. Inoltre, è molto facile distruggerla, basta pochissimo tempo. Spesso, l'intervallo temporale che separa la più serena e routinaria attività aziendale dalla necessità di cessare l'attività o ricominciare da zero, sono una manciata di ore di mala gestione e mala comunicazione. Una singola scelta sbagliata, al giorno d'oggi, può bastare per scatenare un effetto cascata devastante generato dalla velocità di circolazione delle informazioni. Ciò che si considera vero oggi, domani potrebbe quindi essere messo in discussione, e tutto questo deve essere considerato dalle aziende, non per ingessarne l'azione ma per predisporle alle pianificazioni di contingenza e, spesso, al cambiamento organizzativo del lavoro stesso.

I criteri ESG non fanno altro che andare ad aumentare la rilevanza di tutti quegli aspetti che prima venivano tenuti sottobanco perché molto scomodi e difficili da gestire. Oggi, invece, basta una rapida visione delle pubblicazioni in materia ESG negli ultimi anni per vedere come le cose stiano cambiando rapidamente, sia dal punto di vista dell'impegno effettivo delle aziende, sia dal punto di vista del volume di tali pubblicazioni, sia dal punto di vista di chi con queste aziende ha a che fare nel quotidiano.

Facendo qualche esempio, è ampiamente riconosciuto come le componenti ESG aziendali possano influenzare la volontà degli investitori di porre le loro attenzioni su quelle aziende che si comportano meglio da questo punto di vista in determinati momenti storici. È il caso di quello odierno, dove le preoccupazioni circa la sostenibilità e il cambiamento climatico risultano centrali. Questo, dunque, genererebbe un aumento della domanda di questi titoli e conseguenti benefici finanziari e reputazionali per l'azienda (L. Pastor, R. F. Stambaugh & L. A. Taylor, 2020).

Inoltre, come studiato da T. Duan, F. W. Li & R. Michaely (2022), si evidenzia come anche il comportamento dei consumatori sia influenzato dagli elementi ESG. Per esempio, le sedi commerciali delle aziende coinvolte in eventi negativi in materia, affrontano un calo nelle visite maggiore quanto più alta è la loro performance ESG, presentando di fatto un comportamento del tutto simile a quello che si ha quando si parla di *Corporate Reputation* in generale.

Come riportato da T. R. Teor, I. A. Ilyna & V. V. Kulibanova (2022), inoltre, la questione ESG, risulta essere una questione generazionale, che influenza maggiormente le generazioni più giovani. Nello specifico, lo studio cita infatti il questionario di *RepTrak*, azienda di cui si è già parlato in precedenza, che rappresenta una delle realtà più importanti in materia di reputation aziendale, che sottolinea quanto questi principi siano di primaria importanza per la Generazione Z e, più in generale, per i consumatori tra i 20 ed i 40 anni.

In generale, dunque, le aziende devono, dovranno ed in parte già stanno rispondendo alle crescenti sfide ESG. La maggior parte dei consumatori, nello specifico, sembrano ormai molto più inclini a dare attenzione alle aziende che perseguono policy virtuose da questi punti di vista, come indicato anche dal sondaggio di PWC del 2021 chiamato Consumer Intelligence Series riguardo ESG. Infatti, da questo si evince come per consumatori e dirigenti non sia più sufficiente reagire e adeguarsi al mercato ed al lato legal della questione, bensì sia necessario che le aziende si comportino in maniera molto più proattiva anche al di là di quanto è semplicemente “previsto”.

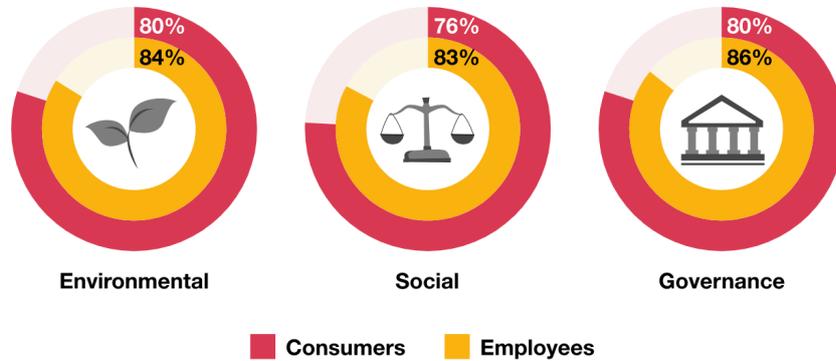
Anche a seguito del Covid-19, si registra un aumento dei consumatori coscienti che ora sembrano premiare o penalizzare in maniera più concreta le aziende più o meno virtuose, anche rimettendoci dal punto di vista della spesa economica e dell'economicità delle loro decisioni.

Dunque, esiste una forte relazione tra le decisioni di acquisto e la consumer engagement e le componenti ambientali, sociali e di governance. Tutto questo, ancora una volta, evidenzia come le tematiche siano estremamente attuali e come le aziende debbano mettersi all'opera per non rischiare di danneggiare la propria reputazione e dunque le proprie performance (PWC, 2021).

Figura 8 - Impatto ESG sugli acquisti dei consumatori.⁸

ESG commitments are driving consumer purchases and employee engagement

I am more likely to buy from / work for a company that stands up for...



Il Marketing, dunque, dovrebbe cominciare a fare scelte molto più precise per andare a veicolare, in funzione dei valori ESG aziendali, i messaggi necessari per poter far godere dei massimi benefici a tutta la catena interna aziendale.

Questa è una delle più grandi sfide di sempre dal punto di vista del Marketing, il quale non si pone più come unico obiettivo quello della promozione della crescita e dei profitti, bensì ricerca sempre di più di costruire, mantenere e migliorare la reputazione dell'azienda e del suo marchio. Per questo si prevede che i criteri ESG, diventeranno sempre più centrali e sempre più fondamentali per i marketer del futuro.

Soprattutto a seguito del Covid-19, le pratiche ESG hanno acquisito più importanza e sono diventate sempre più centrali nelle scelte dei consumatori. Ciò nonostante, convincere i team di marketing della loro importanza e convincere gli altri reparti aziendali dei benefici ottenibili a cascata su tutte le funzioni interne dell'azienda, non è un compito per niente facile. Ma rappresenta una strada obbligata che potrebbe permettere, nel prossimo futuro, di ottenere un pensiero critico e una consapevolezza maggiore rispetto a quelle che devono essere le vere sfide aziendali del futuro. Insomma, una maggiore partecipazione di tutti gli aventi causa.

Per fare questo bisogna cominciare ad istruire le persone all'interno delle organizzazioni per coinvolgerle nello scopo dell'azienda, ben definito ed accettabile ai lavoratori, e più in generale a tutti gli stakeholder coinvolti nella quotidianità aziendale.

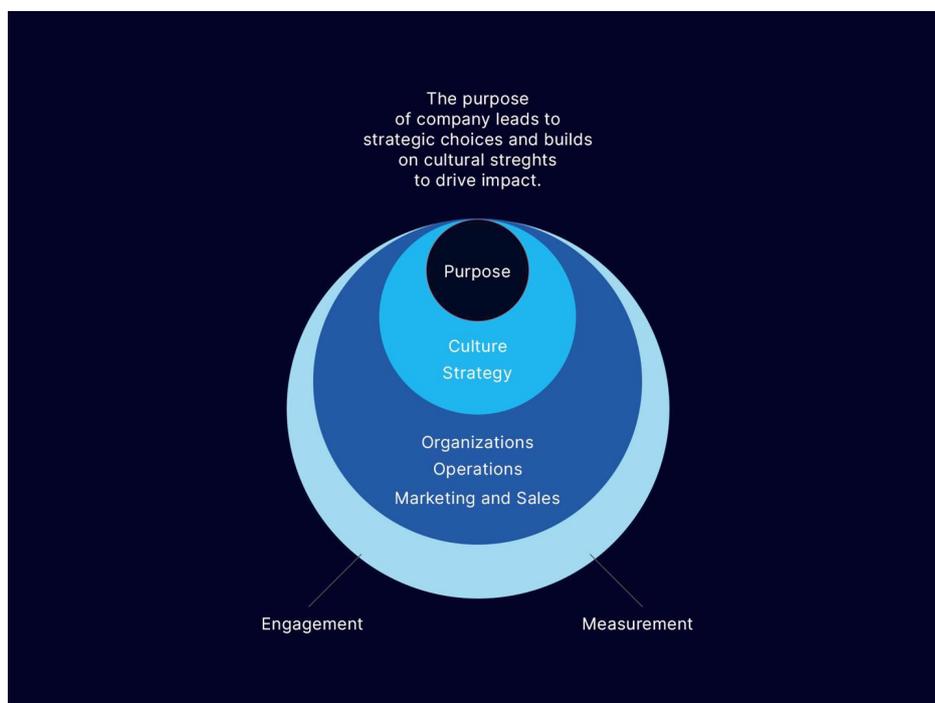
⁸ PWC (2021). Beyond compliance: Consumers and employees want business to do more on ESG - How business can close the expectations gap.

Secondo un articolo di Deloitte (2019), che riporta il Global Marketing trends del 2020 redatto dalla stessa azienda, le cosiddette aziende *purpose-driven* (orientate al raggiungimento di uno scopo), aumentano velocemente le loro quote di mercato e crescono in generale molto più velocemente, in media tre volte più velocemente rispetto ai loro competitor. Questo si aggiunge anche all'aumento della soddisfazione sia dei dipendenti, sia dei consumatori. Questo per tre ragioni principali, lo SCOPO:

- è un elemento chiave di differenziazione dalle altre aziende;
- significa un qualcosa per tutte le persone coinvolte;
- ha un valore "identitario" e rappresenta anche "chi" sei.

Insomma, lo scopo si posiziona a un livello gerarchico superiore rispetto alla singola task assegnata ad ogni elemento organizzativo dell'azienda e questo lo rende strumento indispensabile anche per l'identità stessa aziendale e per l'elaborazione di uno "spirito di squadra" vincente. Ovviamente, per quanto esposto in precedenza, tale scopo non può che essere inquadrato in un'ottica ESG di soddisfazione.

Figura 9 - L'importanza dello scopo.⁹



Come riportato ancora una volta dall'articolo scritto da Hendricks L., Chief Marketing Officer riconosciuta globalmente, in un articolo di Forbes (2022), secondo il report EQ Shareholder Voice, molti investitori si mostrano insoddisfatti o frustrati dalle aziende poco etiche e che non comunicano

⁹ Angelini Industries. (2023). Quando "il prendersi cura" è Passato, Presente e Futuro.

abbastanza in materia ESG. Loro, come altri stakeholders mostrano dunque la volontà di ottenere maggiori informazioni a riguardo.

E queste sono sfide concrete che diventano sempre più importanti per il marketing, che si trova ad affrontare oggi una sfida fondamentale non solo per il business della singola azienda.

L'autrice dell'articolo suggerisce poi alcune strategie che potrebbero essere messe in atto per affrontare, almeno ad alto livello, queste sfide, come la scelta di sponsorizzazioni adeguate o la definizione di strategie volte ad affrontare accuse di *green washing*, ma anche come creare una collaborazione più stretta fra la funzione di marketing e quella di finanza all'interno dell'organizzazione.

Tutto ciò rende la gestione delle criticità e dei momenti a favore molto più semplice e crea un'unione molto più profonda fra i vari dipartimenti e dipendenti.

Oggi come oggi, non è più possibile che un marketer di successo non conosca a pieno quali sono i pilastri e le fondamenta ESG, come non è più possibile che un dipendente della funzione finanza non conosca le varie tendenze che si stanno creando attorno ad essa. Il CEO, a sua volta, insieme ai manager, deve essere consapevole di ciò che si deve e ciò che non si deve fare in materia e deve essere pronto ad eventuali cambiamenti.

Tutto questo è possibile andando ad aumentare il grado di allineamento fra mercato ed azienda, fra consumatori e dipendenti, fra dipendenti di una funzione e dipendenti di un'altra, fra manager e sottoposti ed in generale fra tutti gli stakeholders coinvolti, dai media allo stagista di turno.

La considerazione che va però fatta come chiosa all'analisi finora proposta è che non basta, come spesso accade, fermarci alla sterile esaltazione della mera sostenibilità ambientale (concetto assai ampio e complesso), non basta considerare solo uno dei tre pilastri fondanti della materia semplicemente perché più al centro di altri dell'attenzione pubblica. Sarebbe infatti come costruire un ponte dandogli sostegno solo con un pilone, quando nella fase progettuale era stato evidente come ne fossero necessari almeno 3. Si parla di pilastri proprio per trasmettere quanto l'importanza dei tre sia parimenti uguale, almeno a livello concettuale.

Il rischio, come sostenuto nell'articolo di Ricardo Viana Vargas per la London School of Economics (2023), è che il marketing, con le sue campagne, si focalizzi troppo su uno di questi tre pilastri, nello specifico quello ambientale. Difatti, secondo l'autore, ESG sta purtroppo diventando il termine breve, e aggiungerei, più sofisticato, con il quale riferirsi alla sostenibilità ambientale e non al complesso

anche sociale ed amministrativo della questione. Si riporta anche come, a seguito del già citato aumento di interesse nella tematica a seguito del Covid-19, la maggior parte delle organizzazioni intervistate nel 2022 da Global Data in un loro studio, abbiano classificato soprattutto obiettivi in termini ambientali (69% del totale riguardo il cambiamento climatico e la lotta all'inquinamento), mentre solo il 16% ha individuato obiettivi a sfondo sociale ed il 15% obiettivi di *governance*. È chiaro, dunque, come le aziende stiano cercando di ottemperare ai loro “doveri” in campo ESG ponendo maggiore attenzione alla questione ambientale, ma questo potrebbe portare a conseguenze negative su molteplici fronti. Ancora, l'autore evidenzia come ci sia il rischio, ad esempio, di forzare la nostra società ad abbracciare l'utilizzo di veicoli elettrici, senza però formare davvero nel profondo una generazione che sia consapevole di ciò che significa nel profondo elettricità sostenibile e di come queste forme alternative debbano essere prodotte. Tornando all'esempio precedente, deve evitarsi il rischio di costruire un ponte altamente sbilanciato, predisponendo tutti i tre piloni progettati con la dovuta cura. E questo vale per l'azienda che deve evitare il grave rischio di un'interpretazione parziale del dettato ESG e di come questo debba essere strettamente collegato a tutte le funzioni in essa presente. Il ponte, altrimenti, rischia di crollare. La consapevolezza e la conoscenza devono essere quindi trasmesse in maniera efficace a tutti gli interessati, mostrando i benefici veri che si possono ottenere, anche nelle performance economiche aziendali, tramite un approccio multidisciplinare a queste tipologie di sfide.

Tornando dunque al concetto dell'allineamento sopra menzionato e considerando quanto appena detto, come si può raggiungere tale consapevolezza? Questa è solo una delle domande a cui si proverà a rispondere nei prossimi capitoli.

CAPITOLO 7: CHE COSA ANALIZZARE

A questo punto è bene riallacciare tutto il discorso fatto finora.

1. Si è partiti dall'introduzione della realtà odierna in termini di velocità ed efficienza, inserendo nel discorso il concetto di *Machine Learning* che, come detto, rappresenta uno degli strumenti più efficaci per far fronte alle nuove esigenze lavorative e quotidiane degli individui.
2. Si è poi passati all'overview degli ambiti di utilizzo di questo *Machine Learning* e dei modelli predittivi, andando ad analizzare quei settori dove lo studio e l'applicazione degli stessi risulta più esplorata, evidenziando anche quali sono le tecniche migliori, con quale frequenza e per quali problemi queste vengono utilizzate.
3. A seguire, si è condotta un'ampia analisi del concetto di *financial risk management*, focalizzandosi sull'analisi di questo particolare rischio e, ancora una volta, sulle tecniche statistiche più moderne per

affrontare tale tipologia di problemi, dove si è visto come si stia affermando con forza l'applicazione del *Machine Learning*.

4. A termine di ciò si è poi passati alla trattazione del *Credit Risk*, una tipologia di *Financial Risk* su cui si sono fatte delle considerazioni in più, riguardo alla natura e alle applicazioni statistiche utilizzate in questo momento storico, passando dunque nuovamente dall'analisi del mondo del *Machine Learning*.
5. Trattando il *Credit Risk* si è poi introdotto il concetto di *Credit Rating*, concetto chiave dell'elaborato in questione, analizzando il ruolo e funzionamento delle agenzie di credito.
6. Concludendo questo focus iniziale sul settore finanziario aziendale, ci si è spostati sul lato più qualitativo, introducendo i concetti di *Corporate Reputation*, che per loro natura hanno maggiore attinenza con la dimensione riferita al marketing da innumerevoli punti di vista, sia quantitativi che qualitativi.

In questo contesto, si sono esplorate le varie direzioni individuate in letteratura per analizzare il fenomeno, il quale desta più di qualche problema nella sua misurazione, in quanto prettamente a carattere qualitativo. Si è esposto questo concetto a causa della sua grandissima rilevanza nel mondo aziendale odierno, in termini di marketing, ma come si è visto anche in termini finanziari, almeno per certi aspetti.

In questa parte dell'elaborato abbiamo più volte sottolineato l'importanza e la difficoltà della trattazione dell'argomento nella maniera più olistica possibile, in quanto, come si è visto, questi temi ricoprono tutte le attività svolte dall'azienda, sia internamente che esternamente. Si tratta di una modalità di approccio che, peraltro, è ancora oggi poco esplorata e dunque meritevole di essere approfondita.

Per fare ciò, si è passati alla trattazione dei pilastri ESG, a causa della loro incidenza sui concetti di reputazione aziendale, e si è visto come questi risultino concetti estremamente attuali e, per quel che può contare, sulla bocca di tutti anche dei non "addetti ai lavori". Sono stati quindi analizzati gli effetti che questi generano sull'opinione pubblica e come questi siano percepiti dai soggetti. Inoltre, sono stati fatti degli approfondimenti, circa gli effetti sui consumatori di performance ESG più elevate da parte delle aziende e di situazioni negative in materia. Si è visto come la relazione fra questi concetti e le strategie di marketing sia, oggi più che mai, meritevole di approfondimento, a causa dei rischi connessi ad eventuali bias dovuti all'esaltazione di uno solo dei pilastri fondanti questo concetto.

A termine di questo processo, ci si è domandati come poter allineare e, dunque, far sì che il management aziendale tratti in maniera coerente e olistica questi concetti, esaltando ancora una volta i possibili benefici derivanti da un approccio del genere su tutte le funzioni aziendali.

Ora, per rispondere a questa domanda, focalizzandoci dunque sui concetti di credit rating e ESG, è possibile andare ad analizzare su larga scala come i secondi, più a carattere qualitativo, siano legati ai primi, che invece presentano caratteristiche prettamente finanziarie.

A tale scopo, si può ricorrere al linguaggio Python e al *Machine Learning*, in maniera tale da permetterci di utilizzare una vasta gamma di dati in maniera estremamente efficiente e di condurre più analisi simultaneamente, riducendo al minimo il rischio di condurre un'analisi parziale e poco rappresentativa, e consentendoci di visualizzare come, anche in funzione della reputazione aziendale con i concetti ESG, si possa prevedere il *credit rating* di un'azienda.

In tal modo si potrà andare ad indagare la relazione che esiste fra reputazione aziendale e credit rating, tramite l'utilizzo di concetti estremamente attuali come quello di ESG, per poi ottenere dei risultati dal punto di vista manageriale che possano orientare le scelte future messe in atto, garantendo multidisciplinarietà di visione, eticità del lavoro e ottimizzazione dello scopo aziendale.

Per fare questo, risponderemo alla domanda:

“COME I CRITERI ESG COLLEGANO LA CORPORATE REPUTATION ED IL CREDIT RATING AZIENDALE. UN APPROCCIO DI MACHINE LEARNING”

CAPITOLO 8: METODOLOGIA

Al fine di rispondere alla domanda, a questo punto si entra nello sviluppo vero e proprio del problema, mediante l'analisi dei dati disponibili. Questi devono essere contenuti in un dataset di determinate caratteristiche e contenente tutti i valori necessari (finanziari e non finanziari, come si vedrà oltre) e riferiti alle aziende oggetto dello studio.

Il lavoro, nel suo complesso, attraverserà tre passaggi principali:

1. *Generazione dei dataset*;
2. *Correlation Analysis*: con l'analisi di correlazione, andremo ad indagare nello specifico, l'intensità del legame tra le variabili contenute nel dataset generato in maniera quantitativa.
3. *Predictive Analysis with machine learning*: con questa fase invece, ci si pone come obiettivo quello di determinare un algoritmo quanto più efficace ed efficiente possibile, date le premesse presentate nella parte iniziale dell'elaborato, per determinare, a partire da una serie di metriche presenti nel dataset di partenza, il credit rating aziendale futuro.

Queste due analisi statistiche principali permetteranno di indagare in maniera chiara e profonda ciò che è lo scopo dell'elaborato.

8.1: Generazione dei dataset

Prima di cominciare con l'analisi è stato necessario trovare un set di dati sufficientemente ampio da utilizzare come base del dataset finale. Infatti, per lo scopo prefissato, non si trovano in letteratura dataset simili ma si hanno, nella maggioranza dei casi, dataset focalizzati sulle metriche finanziarie o sulle metriche qualitative, ma non dataset che correlino assieme le prime (più facilmente misurabili) con le seconde. Oltre a questo problema, la grandezza di tali set risulta spesso insoddisfacente, presentando poche centinaia di rilevazioni. Scegliere un dataset così poco ampio avrebbe sicuramente generato uno svantaggio in termini di scalabilità dei risultati, focalizzandosi solo su poche realtà.

Sfruttare dunque le tecniche di analisi di Big Data risulta di primaria importanza.

- Fase 1: Identificazione Dataset di partenza (indici finanziari)

Lo studio di Makwana R., Bhatt D., Delwadia K., Shah A. & Chaudhury B. (2022), che ha come obiettivo quello di andare a utilizzare degli algoritmi per ottenere una regola empirica sugli indici finanziari per prevedere il credit rating aziendale, utilizza un dataset creato dagli autori che presenta le caratteristiche ricercate. Questo dataset è stato poi reso disponibile nella piattaforma Kaggle, dal quale è stato rilevato come base per la presente analisi.

L'utilità di questo dataset è enorme, in quanto, oltre ai rating di numerose aziende e ad un numero considerevole di rilevazioni, mette in mostra alcuni dei *financial ratios* che, come dimostrato dagli autori, influiscono maggiormente sulla definizione del rating di credito aziendale.

In particolare, il dataset presenta 7805 rilevazioni in un periodo dal 2010 al 2016, copre 678 aziende di 12 settori diversi, presenta una scala di rating basata sulla classificazione effettuata da S&P a 23 gradi unificando le scale provenienti complessivamente da 7 agenzie di credito diverse e presenta 16 variabili finanziarie.

Nonostante l'importanza dei dati finanziari in esso contenuti, si nota come manchino alcune metriche importanti, come i *Total Assets* aziendali. Questi rappresentano una metrica estremamente rilevante in materia di *Credit Rating* e *Credit Risk*, in quanto fornisce un'idea quantificabile della grandezza dell'azienda presa in considerazione. Inoltre, questa metrica, ha un ruolo importante nella definizione di variabili finanziarie molto importanti per la valutazione della salute aziendale, come il ROTA, ovvero il *Return On Total Assets*, che imponendo al numeratore l'EBIT (*Earning Before Interest & Tax*, metrica presente nel dataset in questione) ed i *Total Assets* al denominatore, ci fornisce un'idea di quanti profitti l'azienda riesca ad ottenere, prima di tasse ed interessi.

- **Fase 2: Generazione Dataset intermedio con inserimento dei dati ESG Score estratti utilizzando Refinitiv**

Trovato il dataset dal quale partire per la creazione dei dataset soggetti alle analisi attuate, si è passati alla prima fase di estrazione di nuovi dati.

Nello specifico, utilizzando l’add-in *Refinitiv* per Excel, si sono andate ad estrarre dalla banca dati le informazioni relative all’ESG score, all’ESG score grade, all’Environmental pillar score, al Social pillar score, al Governance pillar score, all’ESG controversies score e, per sopperire alla mancanza della variabile finanziaria descritta al termine della “Fase 1”, ai Total Assets.

Sfruttando l’enorme banca dati, una delle più grandi e affidabili a livello mondiale, si sono potuti identificare i dati necessari all’unione con il dataset di destinazione, ovvero quello selezionato nella “Fase 1”. In particolare, infatti, le valutazioni ESG da parte di Refinitiv vengono effettuate su base annuale, a differenza di quelle di rating che vengono fatte molto più frequentemente. Dunque, è stato necessario estrarre le informazioni relative all’ultima rilevazione effettuata da Refinitiv rispetto alle date indicate nel dataset di destinazione per quanto riguarda la definizione dei credit rating. Infatti, si presume che le informazioni derivanti dallo score ESG, al momento del credit rating nell’anno attuale, siano le ultime disponibili rispetto alla valutazione di credito in questione.

Estratti questi dati, con l’ausilio del Software Excel e dell’add-in della banca dati, è stato possibile incrociare i dati, in base al mese e all’anno (seguendo il criterio sopra descritto) e all’ISIN aziendale (generato a sua volta dal CIK presente nel dataset iniziale, ma non sufficiente all’identificazione delle aziende in Refinitiv) che a sua volta è stato inserito nel dataset di destinazione.

A termine di ciò è stata necessaria una fase accessoria di data cleaning, che ha portato all’eliminazione di alcune rilevazioni. In particolare, si è proceduto ad eliminare tutte le rilevazioni relative ad una stessa azienda nel caso in cui essa non presentasse alcun dato *Refinitiv*, come nell’immagine sotto riportata, sia per i dati *ESG-related*, sia per i *Total Assets* di cui abbiamo parlato in precedenza.

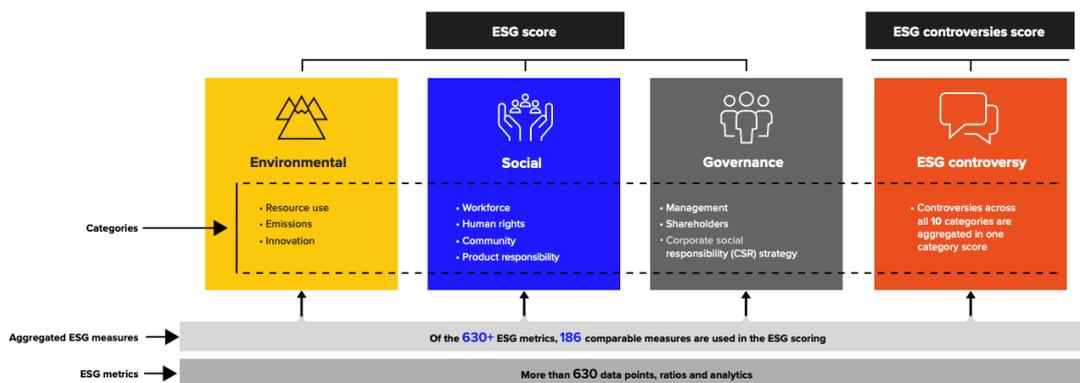
Figura 10 - Esempio di rilevazioni rimosse nella fase di Data Cleaning.

Identificativo azienda	Data	ESG Score	ESG Score Grade	Environmental Pillar Score	Social Pillar Score	Governance Pillar Score	ESG Controversies Score
AWR.N	31/12/14	NULL	NULL	NULL	NULL	NULL	NULL
AWR.N	31/12/13	NULL	NULL	NULL	NULL	NULL	NULL
AWR.N	31/12/12	NULL	NULL	NULL	NULL	NULL	NULL
AWR.N	31/12/11	NULL	NULL	NULL	NULL	NULL	NULL
AWR.N	31/12/10	NULL	NULL	NULL	NULL	NULL	NULL
AWR.N	31/12/09	NULL	NULL	NULL	NULL	NULL	NULL
AWR.N	31/12/08	NULL	NULL	NULL	NULL	NULL	NULL
AWR.N	31/12/07	NULL	NULL	NULL	NULL	NULL	NULL
AWR.N	31/12/06	NULL	NULL	NULL	NULL	NULL	NULL
AWR.N	31/12/05	NULL	NULL	NULL	NULL	NULL	NULL

Sono poi state eliminate anche tutte quelle rilevazioni corrispondenti a valori mancanti che non si trovavano fra due valori rilevati, mentre nel caso occorresse, si è proceduto a riempire tali valori, con la media dei due estremi. Per esempio, se a seguito dell’incrocio con la tabella di destinazione, si fosse verificato che un valore relativo all’ESG mancasse, come quello relativo all’anno 2011, ma si avesse

avuto sia quello del 2010 che quello del 2012, si sarebbe effettuata la media fra questi due per determinare anche i missing values. Così è stato fatto anche nelle valutazioni riguardo i Total Assets. A termine del *data cleaning*, la matrice era formata da 6143 rilevazioni per 35 colonne. Alle originarie si sono aggiunte: quella relativa all'ISIN aziendale, al *Reuters Instrument Code*, all'*ESG score*, all'*ESG score grade*, all'*Environmental pillar score*, al *Social pillar score*, al *Governance pillar score*, all'*ESG controversies score* ed ai *Total Assets*.

Figura 11 - Metriche ESG di Refinitiv.¹⁰



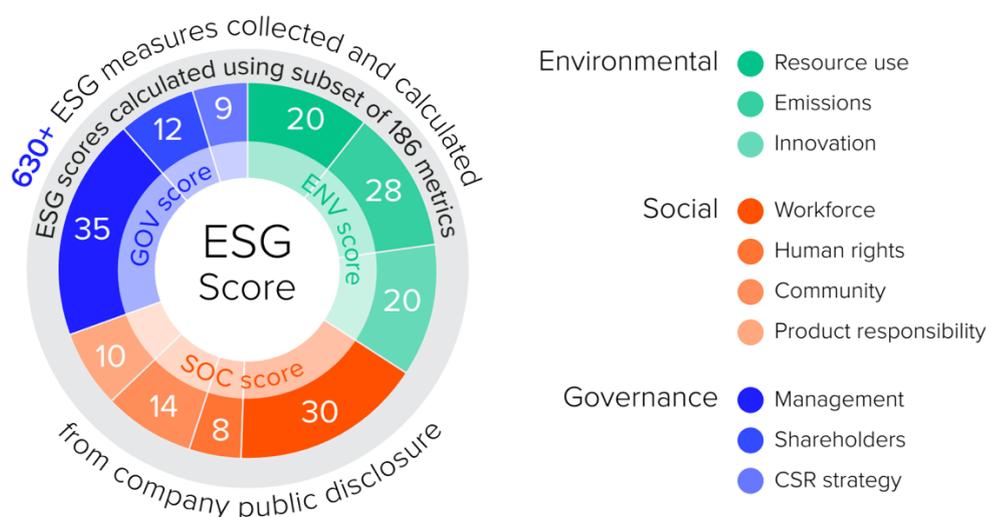
Le prime due, ovvero ISIN e Reuters Instrument Code sono servite all'identificazione dell'azienda, mentre riguardo i *Total Assets*, va detto, oltre a quanto descritto sopra, che per favorire una eventuale comparazione fra azienda ed azienda e trasformare i valori assoluti ottenuti nella fase di estrazione in valori relativi più facilmente interpretabili, si è proceduto con la Trasformazione Logaritmica (in logaritmo naturale) in Excel.

Riguardo alle altre variabili, si può dire che:

- Environmental Pillar Score*: è lo score relativo alle performance in campo ambientale calcolato da Refinitiv. Nello specifico, vengono considerate un sotto insieme di 68 metriche a tale scopo.
- Social Pillar Score*: è a sua volta lo score relativo alle performance in campo sociale calcolato dalla banca dati. Vengono, in questo caso, utilizzate 62 metriche.
- Governance Pillar Score*: è infine lo score legato alla performance in ambito amministrativo da parte delle aziende. Vengono utilizzate 51 metriche.
- ESG Score*: è lo score complessivo che viene calcolato da Refinitiv in base a dati verificabili e di dominio pubblico, considerando anche i 3 score pesati e normalizzati (quindi che vanno da 0 a 100) sopra menzionati riguardanti i pilastri principali dei concetti ESG.

¹⁰ Refinitiv. (2022). Environmental, Social And Governance Scores From Refinitiv.

Figura 12 - ESG Score di Refinitiv e le metriche sottostanti.¹¹



- e. *ESG Controversies Score*: rappresenta lo score calcolato in base a 23 argomenti tipo di *controversie* a tema ESG. Questo tiene conto dell'avvenimento di eventuali avvenimenti negativi che possono alimentare controversie e perdite di reputazione da parte dell'azienda.
- f. *ESG Score Grade*: misura su una scala a 10 il range di valutazione ESG che viene dato ad un'azienda, orientando chiunque prenda visione dei dati, nella lettura di ciò che si osserva.

Figura 13 - ESG Score Range di Refinitiv con relative descrizioni.¹²

Score range	Grade	Description
0.0 <= score <= 0.083333	D -	'D' score indicates poor relative ESG performance and insufficient degree of transparency in reporting material ESG data publicly.
0.083333 < score <= 0.166666	D	
0.166666 < score <= 0.250000	D +	
0.250000 < score <= 0.333333	C -	'C' score indicates satisfactory relative ESG performance and moderate degree of transparency in reporting material ESG data publicly.
0.333333 < score <= 0.416666	C	
0.416666 < score <= 0.500000	C +	
0.500000 < score <= 0.583333	B -	'B' score indicates good relative ESG performance and above-average degree of transparency in reporting material ESG data publicly.
0.583333 < score <= 0.666666	B	
0.666666 < score <= 0.750000	B +	
0.750000 < score <= 0.833333	A -	'A' score indicates excellent relative ESG performance and high degree of transparency in reporting material ESG data publicly.
0.833333 < score <= 0.916666	A	
0.916666 < score <= 1	A +	

ESG laggards
↑
↓
ESG leaders

Infine, in questa fase, è stata fatta una piccola modifica all'interno delle variabili provenienti dal dataset di partenza. Infatti, si è sostituito la variabile *Rating Date*, con due distinte colonne: *Rating Month* e *Rating Year*. Questo permette di mantenere nell'analisi la condizione temporale nella quale viene

¹¹ Refinitiv. (2022). Environmental, Social And Governance Scores From Refinitiv.

¹² Ibidem.

effettuata la valutazione di credito da parte delle agenzie di credito, ma ci consente anche di facilitare la lettura delle informazioni.

Al termine di questa fase, dunque, si ha un dataset intermedio di 6143 rilevazioni per 35 colonne.

- **Fase 3: Generazione Dataset con dati *ESG Disclosure Score* estratti utilizzando Bloomberg**

Costruito il dataset con i dati di *Refinitiv*, si è passati alla composizione del dataset finale con i dati estratti da Bloomberg.

L'attività si è concentrata ancora una volta nell'utilizzo dell'add-in per Excel fornito dalla banca dati, tramite utilizzo del terminale Bloomberg. Tramite questo è stato possibile estrapolare i dati per il periodo preso in considerazione e per le aziende considerate. Anche in questo caso è stato necessario l'utilizzo dell'ISIN per l'identificazione e l'incrocio successivo con il dataset di destinazione costruito nella Fase 2.

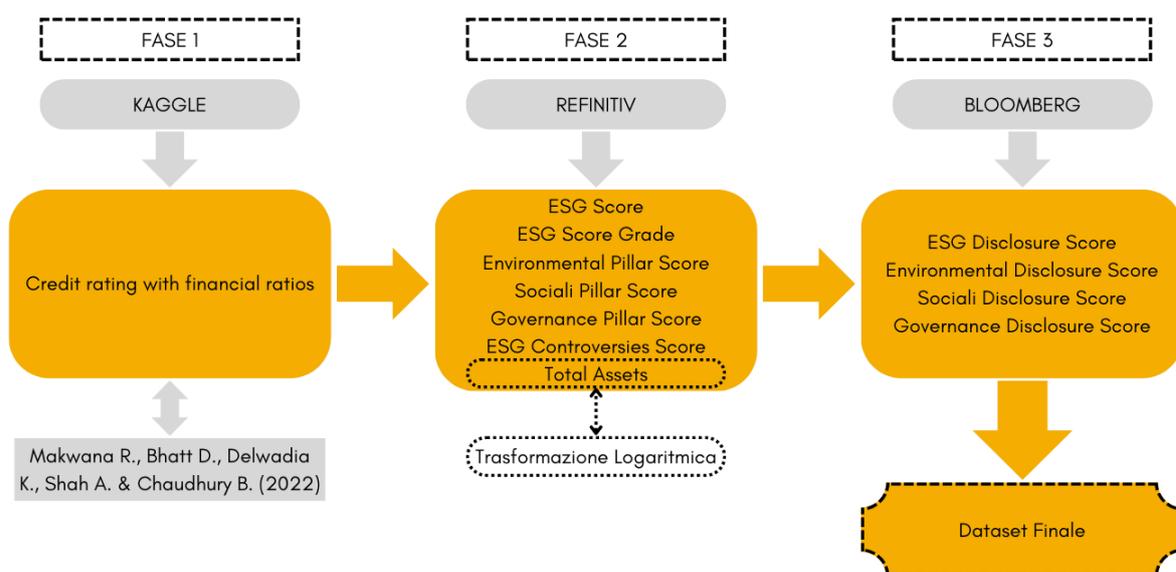
Una volta estratti i dati relativi alle variabili misurate da Bloomberg, è stato effettuato l'incrocio sopra menzionato con il dataset di destinazione seguendo le stesse direzioni seguite anche nella Fase 2 per la costruzione del dataset con i dati *Refinitiv*. In tal modo, si è cercato di mantenere il massimo della coerenza possibile. Infatti, le considerazioni sulle tempistiche da considerare sono state le medesime e, pertanto, si è associato ad i vari rating il valore ESG relativo all'ultima misurazione effettuata dalla banca dati che, anche in questo caso, è condotta su base annuale.

Allo stesso modo, la fase di *data cleaning* ha mantenuto le stesse modalità di quella precedentemente condotta, portando anche in questo caso all'esclusione dal dataset finale di alcune rilevazioni.

L'output finale dell'elaborato è dunque da considerarsi come un vero e proprio subset del dataset costruito in Fase 2, composto da 5989 rilevazioni e 39 colonne. Le variabili introdotte in questa fase sono principalmente 4:

- a. *ESG Disclosure Score*: è una valutazione riservata che viene effettuata da Bloomberg e che può acquisire un valore variabile da 0 a 100. Questa metrica misura il livello di pubblicazioni ambientali, sociali e di *governance*, utilizzando un accurato approccio di ponderazione per settore e regione considerata. All'interno della metrica vengono considerati equamente tutti e tre i pilastri ESG.
- b. *Environmental Disclosure Score*: è la valutazione del livello di pubblicazioni ambientali che viene raggiunto da un'azienda. Anche in questo caso il punteggio varia da 0 a 100 ed è ponderato seguendo gli stessi criteri del punto precedente.
- c. *Social Disclosure Score*: rappresenta la valutazione del livello di pubblicazioni su tematiche sociali dell'azienda e valgono le stesse considerazioni delle altre metriche Bloomberg introdotte.
- d. *Governance Disclosure Score*: anche in questo caso abbiamo una misura di sintesi del livello di pubblicazioni per gli argomenti relativi all'amministrazione aziendale. Valgono, di nuovo, le stesse considerazioni fatte per gli altri punti.

Figura 14 - Fasi relative alla generazione dei Dataset.



8.1.1: Criteri per la scelta delle variabili

La scelta *effettuata* in fase di definizione dei lavori riguardo queste metriche è stata presa seguendo dei principi generali che è importante riportare, per avere conoscenza della ratio dietro la costruzione dei dataset stessi.

In particolare, si è scelto di estrapolare i dati da due delle banche dati più importanti a livello globale, per garantire l'affidabilità dei risultati e il massimo numero di questi. Infatti, uno degli obiettivi principali del lavoro è quello di permettere la massima scalabilità dei risultati stessi e dunque lavorare su un set di dati che permetta di utilizzare le tecniche di analisi dei Big Data più attuali ed efficaci.

In questo modo, seppur avendo ridotto il numero delle rilevazioni del dataset finale (quello generato dall'incrocio tra il primo dataset, i dati derivanti da *Refinitiv* e quelli di *Bloomberg*) rispetto a quello di partenza (5989 contro 7085), si è potuto fare affidamento su un bacino più che soddisfacente di dati estremamente affidabili.

Riguardo alle variabili, nello specifico, possiamo fare una distinzione.

- Per quanto concerne la scelta delle variabili *Refinitiv*, queste sono state ritenute interessanti poiché misurano effettivamente la performance aziendale in campo ESG (facendo riferimento ad *ESG Score, ESG Score Grade, Environmental pillar score, Social pillar score e Governance pillar score*), dandoci dunque una chiara idea di quella che è effettivamente la buona condotta aziendale, quantificandola e misurandola. In questo modo è stato possibile verificare come

effettivamente le aziende performano in questi campi. Per quanto riguarda invece la metrica chiamata *ESG Controversies score*, si può dire che questa variabile aiuta a comprendere come determinati eventi negativi o situazioni più scomode in questo ambito influenzino negativamente l'azienda da molteplici punti di vista, anche quello reputazionale. Per questo è stato molto importante inserire quest'ultima, poiché aiuta a comprendere come la *Corporate Reputation* e di conseguenza il marketing debbano e possano muoversi per contrastare questi effetti. Per quanto riguarda i *Total Assets*, invece, vale ciò che è stato detto in precedenza. Questi ci forniscono informazioni dettagliate sulla grandezza di un'azienda e rappresentano una variabile molto importante all'interno della valutazione di salute finanziaria di tali realtà. Non prendere in considerazione questa metrica, avrebbe sicuramente reso l'analisi incompleta.

- Parlando ora invece delle scelte in merito alle metriche di Bloomberg, si sottolinea come si sia cercato di mettere più in risalto il lato della comunicazione da parte delle aziende che agiscono in maniera virtuosa (almeno a giudicare dalle pubblicazioni) in campo ESG. Nello specifico, queste metriche ci permettono di valutare come le aziende si stiano comportando anche nei confronti del pubblico e dunque dei consumatori e dei vari stakeholders coinvolti. Ovviamente, questo livello di pubblicazioni è un dato che va trattato con cautela, in quanto potrebbero esserci dei problemi nel caso in cui ad un alto punteggio di queste variabili non corrispondano prestazioni in materia ESG altrettanto valide. In sostanza, nelle misurazioni in questione, manteniamo un occhio di riguardo molto più attento riguardo alle questioni del marketing e della comunicazione di marketing e, tramite la lettura di queste, si possono avere grandissimi suggerimenti in materia, orientando le possibili strategie di marketing aziendali verso il miglioramento di queste variabili.

Concludendo, la lettura di queste variabili, unite ai concetti più finanziari provenienti dal dataset iniziale, ci danno una visione di insieme del problema difficilmente trovabile in letteratura e che ci permette di andare a fondo su molteplici questioni, dalla comunicazione di marketing, alle misurazioni finanziarie.

CAPITOLO 9: CORRELATION ANALYSIS

Dopo aver costruito i dataset sopra riportati, si è cominciata l'analisi vera e propria. Come detto, l'analisi è stata condotta con l'utilizzo del linguaggio Python, il quale ha permesso di trattare i dati con la massima efficienza.

Per prima cosa si è dunque deciso di condurre un'analisi di Correlazione sui due dataset elaborati, ovvero sia quello intermedio (costruito nella Fase 2), sia quello finale (costruito nella Fase 3). L'analisi di

correlazione ci è utile a verificare l'esistenza di una relazione significativa tra le variabili indipendenti considerate - ovvero gli indici finanziari provenienti dal dataset iniziale (Fase 1) e dall'estrapolazione via Refinitiv dei Total Assets, gli indici relativi alle performance ESG provenienti dal dataset intermedio (Fase 2) e gli indici relativi agli score di pubblicazione riportati nel dataset finale (Fase 3) - e la variabile dipendente dell'analisi, ovvero il Rating creditizio, derivante dal dataset iniziale (Fase 1). Inoltre, l'analisi di correlazione ci permette di visualizzare concretamente una eventuale ridondanza delle variabili indipendenti presenti. Ciò è prevedibile, poiché alcune variabili presenti all'interno del dataset presentano lo stesso scopo (ad esempio, si è deciso di mantenere tutte quelle variabili identificative dell'azienda come ISIN e CIK, che fondamentalmente portano le stesse informazioni).

In aggiunta, la decisione di condurre due analisi di correlazione utilizzando i due dataset è finalizzata anche ad ottenere una prova duplice di una eventuale correlazione tra variabili mostrata nel dataset intermedio. Infatti, avendo correlazione sia sul dataset intermedio che su quello finale, ci è possibile proseguire anche consapevoli dell'assenza di bias dovuto alla selezione di un sottoinsieme di dati, come nel caso del dataset finale che, come si ricorda, è fondamentalmente un *subset* del dataset intermedio.

Dunque, è necessario introdurre le analisi di correlazione che si è deciso di utilizzare:

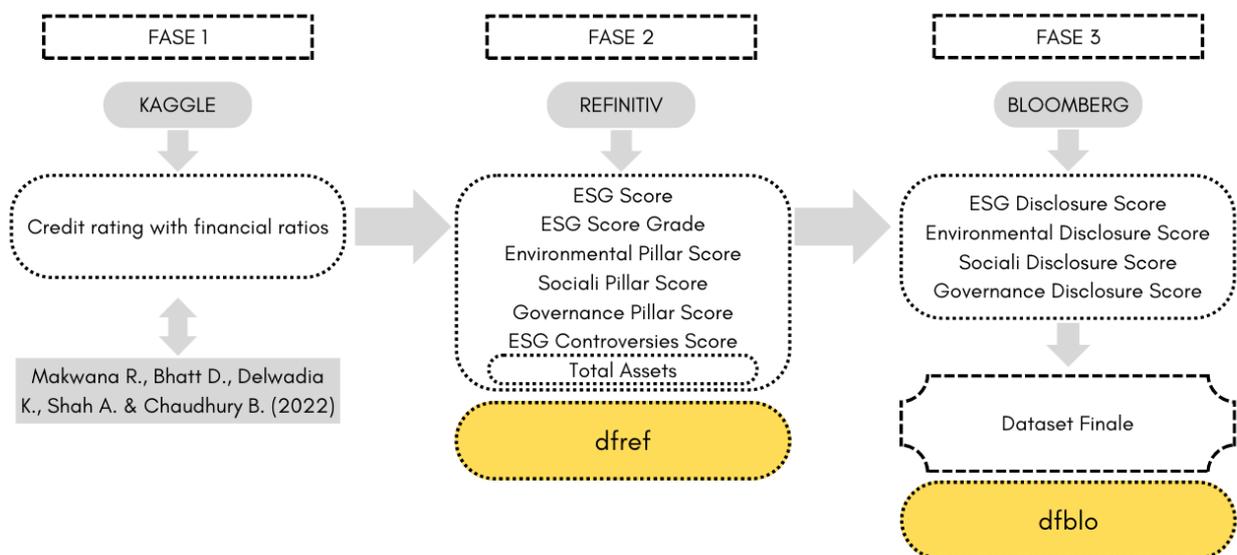
1. *Correlazione di Pearson*: questa tipologia di correlazione, permette di misurare la forza e la direzione di una relazione lineare tra due **variabili continue**. Si fa riferimento a variabili continue quando queste possono assumere un qualsiasi valore all'interno del proprio intervallo di riferimento, mentre per relazione lineare si intende una qualsiasi relazione matematica che possa essere rappresentata su un piano cartesiano sotto forma di retta.
2. *Correlazione di Spearman*: in questo caso, si misura la forza e direzione di una relazione monotona tra due **variabili continue o ordinali**. Si precisa che una relazione monotona è una relazione che all'aumentare o alla diminuzione di una variabile non presenta un aumento o una diminuzione lineare dell'altra, mentre per variabile ordinale si fa riferimento ad una variabile che può assumere un valore stabilito all'interno di un intervallo, come nel caso di una scala di rating in cui si possono assumere solo i valori definiti (AAA, AA+, ecc) fra il valore massimo e quello minimo. Questo tipo di correlazione si calcola come quella di Pearson, con la differenza che i valori vengono convertiti in ranghi prima della misurazione.
3. *Correlazione di Kendall*: questo tipo di correlazione ci permette di misurare forza e direzione della relazione monotona che intercorre tra due **variabili ordinali**.

Si è deciso, almeno inizialmente, di condurre l'analisi con queste tre tipologie di correlazioni per cogliere e analizzare anche le differenze in termini di continuità ed ordinalità presenti fra le varie metriche.

Passiamo dunque alla descrizione della fase di *Exploratory Data Analysis* e di *Preprocessing* che ha anticipato i risultati delle correlazioni predette.

Ci si riferirà d'ora in poi al dataset intermedio con la dicitura *dfref* (data frame derivante dall'aggiunta dei dati di *Refinitiv* – Fase 2) ed al dataset finale con *dfblo* (data frame derivante dall'aggiunta anche dei dati Bloomberg – Fase 3).

Figura 15 - Fasi relative alla generazione dei Dataset con nomenclatura utilizzata durante l'analisi



- **Fase di Exploratory Data Analysis**

In questa fase si è andati ad esplorare le informazioni generali dei dataset in analisi, in modo tale da osservare se ci fossero variabili nulle rimaste a seguito della fase di unione dei dataset sopra descritta e se ci fossero differenze circa il tipo delle informazioni a disposizione (*integer, float, object, ecc*).

Da questa analisi preliminare è emersa la necessità di effettuare una fase di *Preprocessing* dove vengano uniformate le modalità di misurazione all'interno dei dataset, i quali presentavano dati di tipo diverso (*object, float, integer*).

- **Fase di Preprocessing**

In questa fase ci si è posti come obiettivo quello di uniformare quanto più possibile i dati presenti all'interno dei dataset, come appena detto.

Per questo si sono fatte due attività di encoding:

- a. Innanzitutto, si è fatto un *label encoding* per attribuire un numero alle variabili qualitative presenti in analisi. In particolare, questo encoding è stato fatto sulle variabili: “*Corporation*”, “*Rating Agency*”, “*CIK*”, “*ISIN*”, “*Reuters Instrument Code*”, “*Ticker*”, “*Sector*” e “*SIC Code*”.
- b. In secondo luogo, si è fatta un *ordinal encoding* per codificare tutte quelle variabili ordinali presenti nei dataset. Questa attività è stata necessaria sia per la variabile “*Rating*” proveniente dal dataset iniziale (Fase 1), sia per “*ESG score grade*”, proveniente dal dataset *Refinitiv* (Fase 2).

Entrambe le attività si sono ripetute sia per *dfref* che per *dfblo*.

9.1: Correlation Analysis per *dfref* (Annesso A)

L’analisi di Correlazione ha, in questo caso, condotto alla generazione di 3 matrici 35x35.

Come detto in precedenza, l’analisi è stata condotta con il linguaggio Python, che ha permesso un’analisi puntuale tramite *Heatmap* della questione.

Dall’analisi delle 3 matrici, si possono facilmente visualizzare risultati molto interessanti riguardo alla **rilevanza** (la forza), alla **direzione** (relazione positiva o negativa), all’**irrilevanza** e alla **ridondanza** delle relazioni prese in esame.

Per discutere i risultati ottenuti, prenderemo in considerazione come principale matrice quella di Spearman, in quanto i risultati complessivi possono essere generalizzabili anche alle altre matrici di correlazione (infatti non vi sono discordanze in termini di rilevanza e direzione dei risultati più importanti). Si è deciso di fare questa scelta in quanto l’analisi di Spearman è indicata per l’analisi di tutte quelle relazioni monotone fra variabili ordinali o continue. Nello specifico, ci si aspetta che le relazioni all’interno di questo studio difficilmente siano del tutto lineari e le variabili con cui si ha a che fare sono sì continue, ma anche ordinali. Inoltre, la nostra attenzione ricade soprattutto su alcune di queste ultime (variabili ordinali), che in questa fase sono il *Rating* e l’*ESG score grade*.

1. Dunque, prendiamo innanzitutto in esame i risultati ottenuti in termini di **ridondanza delle variabili** utilizzate.

Come anticipato precedentemente, un certo livello di ridondanza fra alcune variabili era del tutto pronosticabile, soprattutto per quelle che sono state definite come *variabili identificative* dell’azienda. Infatti, tutte quelle variabili che presentavano lo stesso scopo e motivo di esistere all’interno del dataset sono risultate estremamente correlate. Questo risultato, in termini di rilevanza dell’analisi, non aggiunge nulla a ciò di cui già si era a conoscenza.

Per questo motivo, queste evidenze possono essere utilizzate per una eventuale selezione delle variabili in una successiva analisi, andando a selezionare solo una o un paio di queste variabili identificative.

A scopo esemplificativo, si riporta di seguito la prima sezione presa in analisi nella matrice di correlazione di Spearman.

Si rimanda all'Annesso A per qualsiasi approfondimento su qualsiasi matrice di correlazione riferita a *dfref*.

Figura 16 - Variabili identificative e variabili di settore nella matrice di correlazione di Spearman per *dfref*



Dunque, possiamo senz'altro dire che si ha ridondanza:

- Per le **variabili identificative** (nome della *Corporation*, *CIK*, *ISIN*, *Reuters Instrument Code* e *Ticker*)
- Per le **variabili di settore** (*Sector* e *SIC Code*).

In questo caso, non si hanno delle relazioni estremamente forti dal punto di vista della correlazione, ma conoscendo la struttura del dataset, si può concludere che esse possano essere, come quelle sopra descritte, ridotte ad un'unica delle due.

Continuando l'analisi, si evidenziano altri casi di ridondanza per le:

- a. **Variabili finanziarie:** per quanto riguarda le metriche *Operating Margin* ed *EBIT Margin*. Queste mostrano infatti gli stessi livelli di correlazione per tutte le variabili presenti nel dataset. Anche in questo caso, si può concludere nella stessa maniera, ovvero mantenendo solo una delle due metriche in una successiva analisi.
- b. **Variabili ESG:** con riferimento a *ESG score* e *ESG score grade*, come si può vedere nell'immagine riportata qui in basso che presenta una piccola sezione del dataset (si rimanda, di nuovo, all'Annesso A).

Figura 17 – Ridondanza variabili ESG

Variable	Rating	ESG score	ESG score grade	Environmental pillar score	Social pillar score	Governance pillar score	ESG Controversies Score																												
Rating	-0.17	0.00	0.01	-0.14	-0.18	-0.09	-0.10	-0.04	-0.09	-0.03	-0.09	-0.35	-0.25	0.07	0.26	0.26	0.15	0.35	0.36	0.09	0.30	0.20	0.38	0.38	0.05	0.04	0.76	0.47	1.00	0.40	0.40	0.40	0.39	0.25	-0.25
ESG score	-0.03	0.02	0.01	-0.09	-0.16	-0.18	-0.09	0.00	-0.07	-0.09	-0.02	-0.19	-0.10	0.04	0.08	0.08	0.01	0.12	0.15	0.05	0.16	0.12	0.18	0.16	-0.05	-0.00	0.33	0.52	0.40	1.00	0.99	0.90	0.92	0.69	0.98
ESG score grade	-0.03	0.02	0.01	-0.09	-0.16	-0.17	-0.09	0.01	-0.07	-0.09	-0.02	-0.19	-0.11	0.04	0.08	0.08	0.01	0.11	0.15	0.05	0.16	0.11	0.18	0.16	-0.05	-0.00	0.33	0.52	0.40	0.99	1.00	0.90	0.91	0.68	0.98
Environmental pillar score	-0.04	0.02	0.00	-0.08	-0.14	-0.17	-0.09	0.02	-0.06	-0.14	-0.03	-0.17	-0.06	0.03	0.10	0.10	0.04	0.13	0.15	0.01	0.16	0.12	0.17	0.15	-0.06	-0.01	0.32	0.52	0.40	0.90	0.90	1.00	0.80	0.46	0.95
Social pillar score	-0.04	0.02	0.01	-0.07	-0.16	-0.14	-0.06	-0.04	-0.04	-0.07	0.01	-0.11	-0.13	0.07	0.10	0.10	0.01	0.14	0.16	0.09	0.18	0.11	0.22	0.20	-0.04	0.00	0.34	0.45	0.39	0.92	0.91	0.80	1.00	0.47	0.92
Governance pillar score	0.01	0.02	0.00	-0.08	-0.11	-0.15	-0.08	0.04	-0.07	-0.06	-0.05	-0.14	-0.07	-0.00	0.01	0.01	-0.01	0.05	0.07	-0.01	0.06	0.09	0.05	0.05	-0.03	0.01	0.21	0.35	0.25	0.69	0.68	0.46	0.47	1.00	0.93
ESG Controversies Score	0.07	-0.02	0.13	0.01	-0.01	0.05	0.03	-0.08	0.01	-0.04	0.12	0.10	0.07	-0.06	-0.03	-0.03	-0.01	-0.08	-0.04	-0.02	-0.04	-0.02	-0.08	-0.08	0.01	0.02	-0.15	-0.48	-0.25	-0.36	-0.35	-0.35	-0.32	-0.33	1.00

Si nota chiaramente, come queste due metriche abbiano le stesse relazioni con le altre variabili presenti in tabella. Anche in questo caso, ci troviamo di fronte ad un risultato estremamente pronosticabile, in quanto l'*ESG score grade*, non è altro che il grado riportato in una scala a 10, dell'*ESG score* calcolato dalla stessa banca dati.

Questi sono dunque i principali risultati ottenuti in termini di ridondanza. Tutto ciò ci porta a concludere che si potrebbe pensare di trascurare alcune delle variabili inizialmente riportate e mantenute nei dataset, in modo da snellire la procedura di analisi ed esaminazione dei risultati senza perdere informazioni preziose allo scopo finale della ricerca.

A seguito dell'analisi condotta al fine di evidenziare le relazioni fra variabili ridondanti, è corretto prendere in esame quelle che sono, invece, le relazioni che possiamo definire poco importanti al fine della ricerca in questione.

2. Dunque, prendiamo in esame l'**irrelevanza di alcune relazioni**, sempre tramite l'analisi della matrice di Spearman.

Innanzitutto, si nota come *Rating Year* e *Rating Month*, non presentino alcun tipo di relazione con le metriche in gioco. Per questa ragione, in una successiva analisi, si potrebbe decidere di trascurare anche queste variabili temporali, nonostante la rilevanza che di fatto hanno avuto in fase di

In particolare, si riporta a titolo esemplificativo, come il *Credit Rating* presenti una relazione positiva molto più forte con l'*ESG score* (0,40) o con il *Social Pillar score* (0,39), rispetto a quella con variabili finanziarie molto importanti, come l'*EBIT Margin* (0,15) o il *ROE* (0,30).

Si sottolinea anche la relazione estremamente negativa fra il Rating e l'*ESG controversies score* (-25%), a testimonianza della grande importanza di sapersi dotare di un sistema preventivo molto forte riguardo a queste controversie, sapendo dunque gestire media, pubblico ed in generale pressioni esterne ed interne al medesimo modo.

Inoltre, è molto interessante la forza delle relazioni fra Total Assets e le altre variabili estrapolate da Refinitiv. Questo testimonia in maniera lampante quanto sia forte e quanto sia importante saper gestire le questioni che tendenzialmente vengono considerate di meno poiché molto più qualitative rispetto a quelle finanziarie. Le evidenze mostrano che queste relazioni esistono e sono estremamente forti (La relazione di correlazione che si ha fra Total Assets e *ESG controversies score*, ad esempio, è una relazione negativa pari al 49%).

Prima di passare oltre, si sottolinea per completezza di analisi anche la grande rilevanza che vi è fra molte relazioni tra variabili finanziarie, che possono facilmente essere viste all'interno delle matrici nell'Annesso A.

Concludendo, si può evidenziare come potrebbe essere interessante andare più in profondità ai risultati ottenuti in questa analisi (così come nella successiva condotta per *dfblo*). Per fare ciò, al termine di queste due analisi, si procederà con una riduzione delle variabili che hanno presentato ridondanza o irrilevanza all'interno dell'analisi condotta sulle relazioni di correlazione, su sottoinsiemi facenti riferimento alle agenzie di valutazione del credito più frequenti all'interno del dataset. A questa analisi, si farà riferimento al termine della rassegna delle evidenze ottenute dallo studio delle matrici di correlazione per *dfblo* (ovvero per il dataset finale).

9.2: Correlation Analysis per *dfblo* (Annesso B)

Si prende ora in rassegna l'output dell'analisi di Correlazione riferita al dataset finale, a cui si fa riferimento con *dfblo*. La matrice ottenuta è 39x39 ed oltre alle variabili presenti nelle matrici di correlazione analizzate nel capitolo 9.1, si hanno adesso anche quelle relative agli score di pubblicazione estratte da Bloomberg.

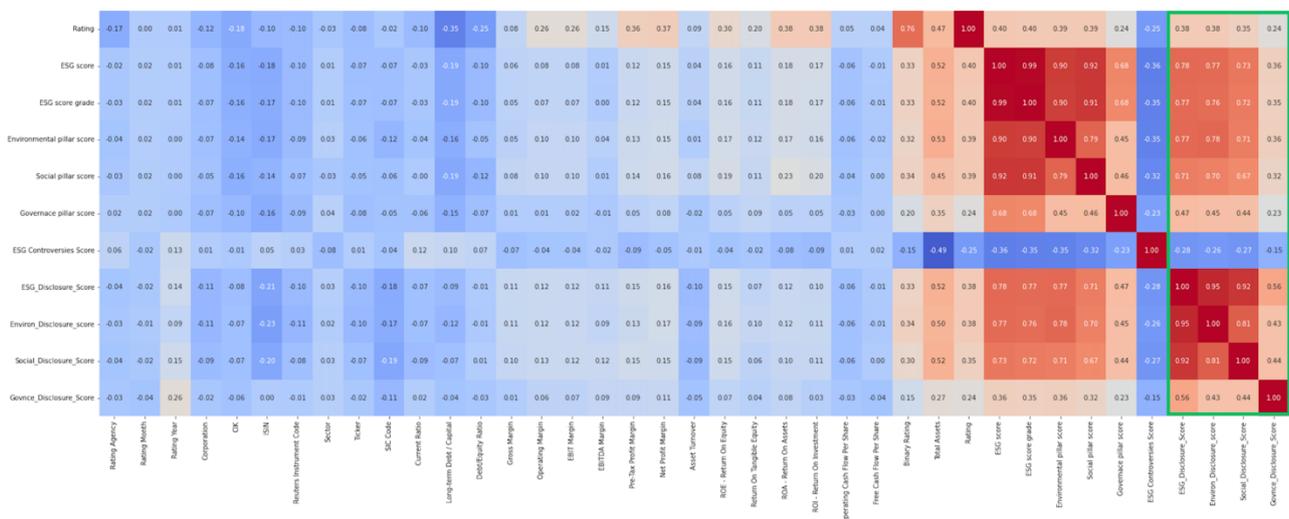
Anche in questo caso, si procede con la spiegazione della sola matrice di Spearman, tramite Heatmap, per le stesse ragioni richiamate nel capitolo 9.1.

Andando nel dettaglio dello studio, si può concludere con le stesse considerazioni fatte per *dfref* per quanto riguarda la **ridondanza delle relazioni** tra variabili, l'**irrilevanza** di alcune di esse e della **rilevanza** di altre.

Queste conclusioni ci permettono di scongiurare il pericolo di un possibile bias dovuto alla selezione di alcune rilevazioni in quanto il dataset finale rappresenta un subset di quello intermedio, anche se le rilevazioni di differenza non sono un numero eccessivo.

Le considerazioni rimangono dunque le medesime per tutte le variabili e le metriche prese in considerazione nel capitolo 9.1, ma le osservazioni più interessanti in questo caso derivano dall'analisi delle relazioni che si hanno con le metriche estratte da Bloomberg.

Figura 19 - Sezione della matrice di Spearman relativa a *dfblo*, con focus sulle metriche ESG di Bloomberg



Infatti, si nota facilmente, come, anche nel caso in cui gli *ESG score* riguardino il livello di pubblicazioni riferite all'azienda, si ottengano dei risultati estremamente significativi per la tesi sostenuta in questo studio (correlazione con Rating).

Facendo degli esempi:

- 1) *ESG Disclosure score*: 0,38;
- 2) *Environmental Disclosure score*: 0,38.

È dunque evidente come le variabili considerate più qualitative alle quali facciamo riferimento con l'*ESG disclosure score*, l'*Environment disclosure score*, il *Social disclosure score* ed il *Governance disclosure score*, risultino altamente legate al *credit rating* così come alle metriche finanziarie, prendendo in analisi la variabile *Total Assets*. Qualsiasi approfondimento a riguardo può essere fatto tenendo in considerazione l'Annesso B.

Tutto ciò, anche in questo caso, si traduce in relazioni fra credit rating e questo tipo di variabili indipendenti, anche più forte delle relazioni del primo con le variabili più finanziarie e quantitative.

Arrivati a questo punto dell'analisi, è importante cominciare a trarre qualche conclusione.

9.3: Conclusioni della prima analisi di Correlazione

Ricapitolando quanto detto nei paragrafi precedenti, è estremamente interessante osservare come la tendenza generale, sia in fase di analisi del dataset intermedio che del dataset finale, sia quella di avere una rilevanza della correlazione, e dunque dei legami, fra variabili ESG e *Rating Creditizio* pari o addirittura superiore a quella fra variabili finanziarie e valutazione di credito. Ciò non vale invece per la variabile *Total Assets*, che, come ci si aspettava, rappresenta una delle prime metriche finanziarie da osservare in materia.

Ad esempio, per *dfref* evidenziamo la correlazione di Spearman (*ma che anche cambiando in Pearson o Kendall, darebbe i medesimi risultati in termini generali*) fra:

- ***Rating e ESG Score: 0,40;***
- ***Rating e Environmental pillar score: 0,39;***
- ***Rating e Social pillar score: 0,39;***
- ***Rating e Governance pillar score: 0,24;***
- ***Rating e Total Assets: 0,47.***

A questi valori di correlazione, si aggiungono per *dfblo* quelli fra:

- ***Rating e ESG disclosure score: 0,38;***
- ***Rating e Environmental disclosure score: 0,38;***
- ***Rating e Social disclosure score: 0,35;***
- ***Rating e Governance disclosure score: 0,24.***

In conclusione, e alla luce dei risultati ottenuti, è interessante andare ora a vedere quali sono le agenzie di credito che presentano una frequenza maggiore. Infatti, il dataset è sbilanciato e, quindi, i risultati ottenuti nelle matrici di correlazione dei dataset intermedio e finale mostrano risultati di sintesi che potrebbero presentare variazioni rispetto a ciò che invece accade per ogni singola agenzia.

Quindi, vista anche la loro importanza in tema di *credit rating*, è utile condurre la stessa analisi con le rilevazioni delle tre agenzie più frequenti all'interno dei dataset intermedio e finale.

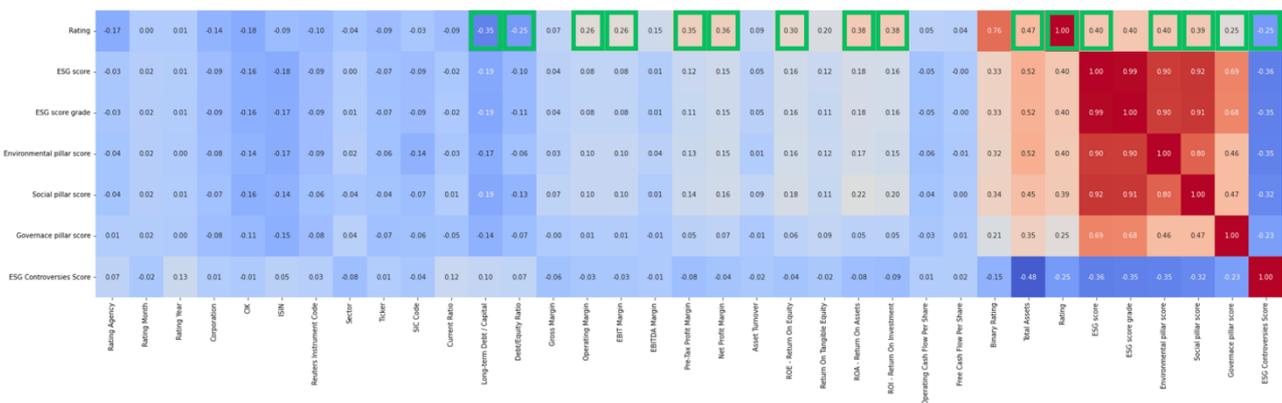
Prima però di andare a creare questi subset, che saranno rispettivamente 3 per il dataset intermedio e 3 per il dataset finale, è utile andare a fare una *Features selection* prendendo in considerazione solo quelle

variabili che dall'analisi aggregata hanno mostrato delle correlazioni con il *Rating creditizio* più elevate.

La ratio che si è decisa di seguire è quella di selezionare SOLO le variabili con correlazione di Spearman maggiore di 0,2 oppure minore di -0,2 escludendo i valori compresi tra questi due estremi. Inoltre, si è deciso di trascurare tutte quelle variabili ridondanti di cui si è già parlato in precedenza. Le variabili così selezionate risultano essere per il dataset intermedio (a cui ora si farà riferimento con *dfref_red*):

- 1) **ISIN**, che nonostante non presenti alta correlazione, è necessaria per identificare le aziende;
- 2) **Long-term Debt / Capital**: -0,35;
- 3) **Debt/Equity Ratio**: -0,25;
- 4) **EBIT Margin**: 0,26;
- 5) **Pre-Tax Profit Margin**: 0,35;
- 6) **Net Profit Margin**: 0,36;
- 7) **ROE - Return On Equity**: 0,30;
- 8) **ROA - Return On Assets**: 0,38;
- 9) **ROI - Return On Investment**: 0,38;
- 10) **Total Assets**: 0,47;
- 11) **Rating**, che è la variabile dipendente dello studio;
- 12) **ESG score**: 0,40;
- 13) **Environmental pillar score**: 0,40;
- 14) **Social pillar score**: 0,39;
- 15) **Governance pillar score**: 0,25;
- 16) **ESG Controversies Score**: -0,25.

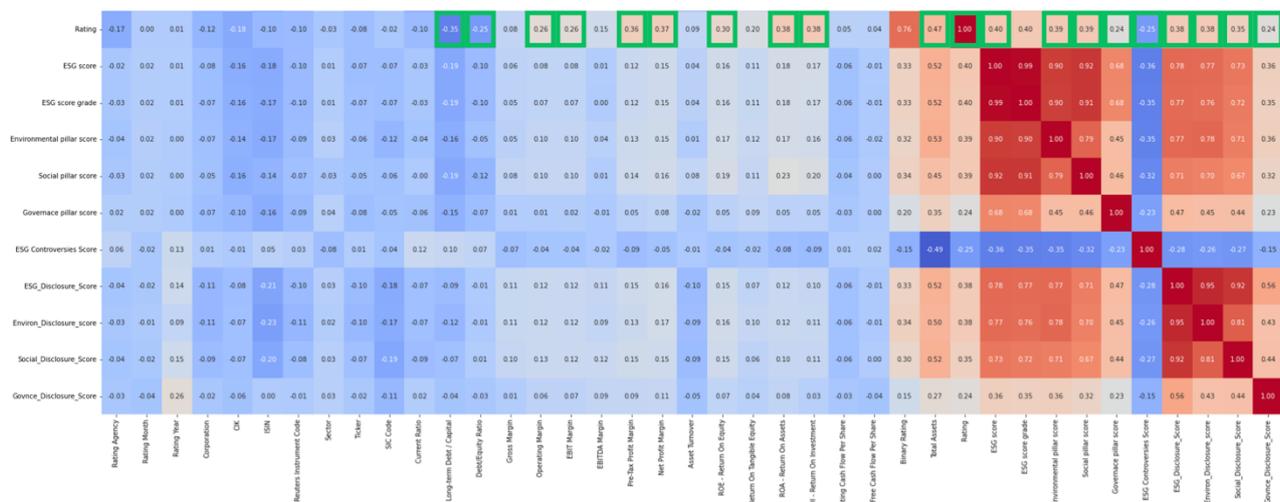
Figura 20 - Variabili di *dfref* con correlazione con il Rating maggiore a 0,2 o minore di -0,2.



A queste variabili, per il dataset finale (a cui ora si farà riferimento con *dfblo_red*) si aggiungono tutte le metriche estrapolate da Bloomberg, ovvero:

- 1) **ESG Disclosure score:** 0,38;
- 2) **Environmental Disclosure score:** 0,38;
- 3) **Social Disclosure score:** 0,35;
- 4) **Governance Disclosure score:** 0,24.

Figura 21 - Variabili di *dfblo* con correlazione con il Rating maggiore a 0,2 o minore di -0,2.



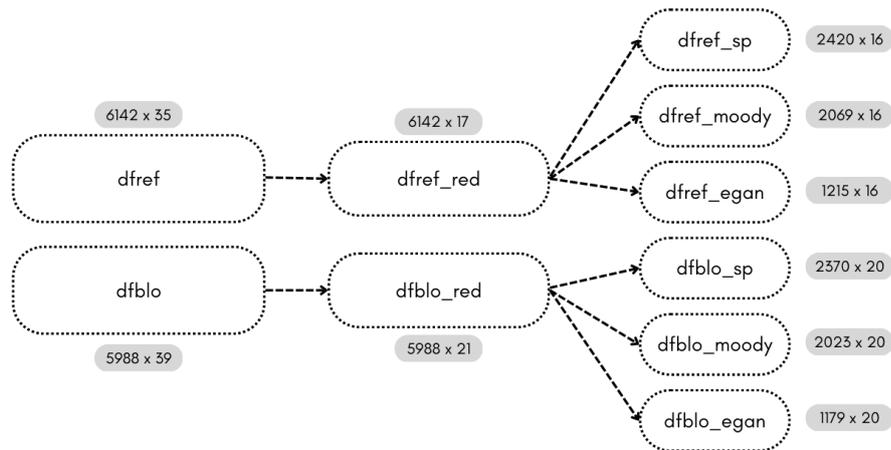
Le matrici così ottenute sono dunque composte sia da variabili finanziarie particolarmente rilevanti, sia da quelle ESG di cui si è già ampiamente discussa l'importanza.

In particolare, le dimensioni dei subset generati in questa fase sono:

- 1) **dfref_sp** (dfref con solo le rilevazioni di S&P): 2420 x 16;
- 2) **dfref_moody** (dfref con solo le rilevazioni di Moody's): 2069 x 16;
- 3) **dfref_egan** (dfref con solo le rilevazioni di Egan-Jones): 1215 x 16;
- 4) **dfblo_sp** (dfblo con solo rilevazioni di S&P): 2370 x 20;
- 5) **dfblo_moody** (dfblo con solo rilevazioni di Moody's): 2023 x 20;
- 6) **dfblo_egan** (dfblo con solo le rilevazioni di Egan-Jones): 1179 x 20.

Su questi dataset verrà dunque effettuata un'analisi di correlazione nella stessa maniera dei dataset intermedio e finale, andando ad investigare, attraverso l'analisi della matrice di Spearman, se ci siano differenze nelle tendenze generali fra analisi aggregata e analisi per Rating Agency e se ci siano delle discordanze in termini di importanza delle relazioni fra agenzia ed agenzia.

Figura 22 - Step per la creazione dei subset di dfref e dfblo, con relative grandezze dei dataset.



A questo punto, utilizzando ancora una volta il linguaggio Python, si procede alla computazione delle heatmap di correlazione per i subset sopra indicati.

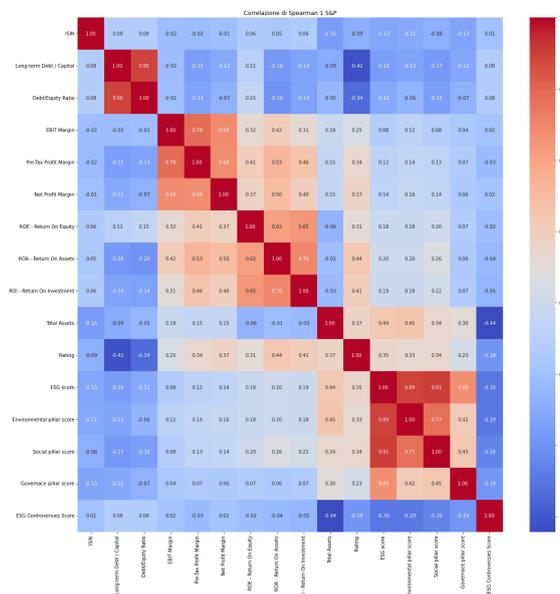
9.4: Correlation Analysis per *dfref_sp* (Annesso C)

Come primo subset oggetto di studio, prendiamo *dfref_sp*, ovvero il dataframe intermedio ridotto (*dfref_red*), filtrato per le sole rilevazioni relative a S&P.

Come effettuato in precedenza, per mantenere un certo livello di comparabilità fra risultati e puntualità degli stessi, effettueremo il commento della sola matrice di Spearman, sia per questo subset, sia per gli altri, in quanto la tendenza generale rimane la stessa in tutti i subset per tutte le modalità di correlazione prescelte.

Si rimanda comunque all'Annesso C (per il caso in questione) e seguenti, per un approfondimento in questa direzione.

Figura 23 - Matrice di Correlazione di Spearman di *dfref_sp*.



Nel caso preso in analisi in questo paragrafo, è interessante notare una leggera controtendenza rispetto a quanto appurato precedentemente nelle analisi generali su *dfref* e *dfblo*. Infatti, si nota sempre la solita correlazione elevata fra variabili finanziarie, ma questa volta si ha che, a livello di intensità, la correlazione fra Rating e variabili finanziarie risulta essere tendenzialmente più importante rispetto a quella fra Rating e variabili ESG.

Figura 24 - Focus sulle correlazioni delle variabili ESG per *dfref_sp*

Rating	-0.09	-0.42	-0.34	0.25	0.34	0.37	0.31	0.44	0.41	0.37	1.00	0.35	0.33	0.34	0.23	-0.19
ESG score	-0.13	-0.16	-0.11	0.08	0.12	0.14	0.18	0.20	0.19	0.44	0.35	1.00	0.89	0.91	0.68	-0.30
Environmental pillar score	-0.11	-0.13	-0.06	0.12	0.14	0.16	0.18	0.20	0.18	0.45	0.33	0.89	1.00	0.77	0.42	-0.29
Social pillar score	-0.08	-0.17	-0.15	0.08	0.13	0.14	0.20	0.26	0.22	0.34	0.34	0.91	0.77	1.00	0.45	-0.26
Governance pillar score	-0.13	-0.12	-0.07	0.04	0.07	0.06	0.07	0.06	0.07	0.30	0.23	0.68	0.42	0.45	1.00	-0.19
ESG Controversies Score	0.01	0.08	0.08	0.02	-0.03	0.02	-0.02	-0.04	-0.05	-0.44	-0.19	-0.30	-0.29	-0.26	-0.19	1.00
	ISIN	Long-term Debt / Capital	Debt/Equity Ratio	EBIT Margin	Pre-Tax Profit Margin	Net Profit Margin	ROE - Return On Equity	ROA - Return On Assets	ROI - Return On Investment	Total Assets	Rating	ESG score	Environmental pillar score	Social pillar score	Governance pillar score	ESG Controversies Score

Nello specifico, riportando degli esempi di correlazione fra Rating e le variabili finanziarie, si ha un maggior peso del legame positivo rispetto alle variabili ESG nei seguenti casi:

- 1) Correlazione con **ROA**: 0,44;
- 2) Correlazione con **ROI**: 0,41;
- 3) Correlazione con **Net Profit Margin**: 0,37;
- 4) Correlazione con **Total Assets**: 0,37.

che risultano maggiori di:

- 1) Correlazione con **ESG Score**: 0,35;
- 2) Correlazione con **Environmental pillar score**: 0,33;
- 3) Correlazione con **Social pillar score**: 0,34.

Inoltre, anche per i legami negativi si ha:

- 1) Correlazione con **Long-term Debt / Capital**: -0,42;
- 2) Correlazione con **Debt/Equity Ratio**: -0,34;

i quali risultano avere impatti peggiori rispetto alla Correlazione con **ESG Controversies Score**: -0,19.

Anche in questo caso, infine, si sottolinea la grande incidenza fra variazioni del livello di controversie dovute a questioni ESG (*ESG controversies score*) e *Total Assets*, a testimonianza di quanto danno può generarsi dal coinvolgimento in situazioni conflittuali (scandali) e problematiche dovute a queste questioni.

Dunque, le buone pratiche di marketing devono andare a braccetto con l'etica aziendale. Questa deve essere messa in risalto dal marketing, il quale svolge senz'altro un ruolo chiave nell'evitare un'esposizione scriteriata a media e pubblico su alcune questioni che potrebbero generare effetti estremamente negativi per l'azienda, non solo dal punto di vista reputazionale, ma anche da quello finanziario e strutturale. Come si vedrà, questa considerazione, vale anche per le altre agenzie.

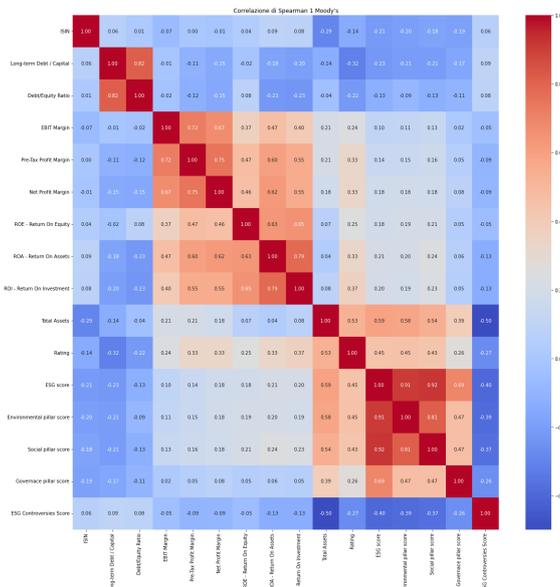
9.5: Correlation Analysis per *dfref moody* (Annesso D)

Ci si concentra ora sul dataset *dfref_moody*, ovvero il dataset intermedio ridotto con solo le rilevazioni relative all'agenzia Moody's.

Le osservazioni effettuate nella premessa del capitolo 9.4, valgono ovviamente anche in questo caso, con l'unica osservazione che ora si sta facendo riferimento ad un dataframe leggermente più piccolo rispetto al precedente.

Si rimanda all'Annesso D per approfondimenti.

Figura 25 - Matrice di Correlazione di Spearman di *dfref_moody*.



Si nota subito come in questa analisi ci si riallinei effettivamente alla tendenza generale delle considerazioni effettuate sulla matrice di Spearman per *dfref*. La forza dei legami fra le variabili ESG e Rating creditizio, risulta ora essere tendenzialmente più impattante rispetto a quella fra Rating e variabili finanziarie.

Figura 26 - Focus sulle correlazioni delle variabili ESG per dfref_moody

Rating	-0.14	-0.32	-0.22	0.24	0.33	0.33	0.25	0.33	0.37	0.53	1.00	0.45	0.45	0.43	0.26	-0.27
ESG score	-0.21	-0.23	-0.13	0.10	0.14	0.18	0.18	0.21	0.20	0.59	0.45	1.00	0.91	0.92	0.69	-0.40
Environmental pillar score	-0.20	-0.21	-0.09	0.11	0.15	0.18	0.19	0.20	0.19	0.58	0.45	0.91	1.00	0.81	0.47	-0.39
Social pillar score	-0.18	-0.21	-0.13	0.13	0.16	0.18	0.21	0.24	0.23	0.54	0.43	0.92	0.81	1.00	0.47	-0.37
Governance pillar score	-0.19	-0.17	-0.11	0.02	0.05	0.08	0.05	0.06	0.05	0.39	0.26	0.69	0.47	0.47	1.00	-0.26
ESG Controversies Score	0.06	0.09	0.08	-0.05	-0.09	-0.09	-0.05	-0.13	-0.13	-0.50	-0.27	-0.40	-0.39	-0.37	-0.26	1.00
	ISIN	Long-term Debt / Capital	Debt/Equity Ratio	EBIT Margin	Pre-Tax Profit Margin	Net Profit Margin	ROE - Return On Equity	ROA - Return On Assets	ROI - Return On Investment	Total Assets	Rating	ESG score	Environmental pillar score	Social pillar score	Governance pillar score	ESG Controversies Score

Come si legge facilmente, ora si ha uno spostamento effettivo dell'importanza delle correlazioni fra variabili ESG e Rating. Infatti, ad esempio, per il Rating:

- 1) Correlazione con **ESG score**: 0,45;
- 2) Correlazione con **Environmental pillar score**: 0,45;
- 3) Correlazione con **Social pillar score**: 0,43;

mentre la correlazione positiva più alta con le variabili finanziarie - escluso Total Assets che risulta essere la variabile più significativa con 0,53 – risulta essere la Correlazione con ROI: 0,37.

Può essere fatto un discorso leggermente diverso per le correlazioni negative, in quanto si ha in ordine (considerando le più importanti):

- 1) Correlazione con **Long-term Debt/Capital**: -0,32;
- 2) Correlazione con **ESG Controversies score**: -0,27;
- 3) Correlazione con **Debt/Equity ratio**: -0,22.

Si può quindi concludere che risulta essere fondamentale fare una distinzione fra le varie agenzie di rating - delle quali già si sa che mettono in atto metodologie computazionali diverse - in quanto sono emerse delle differenze nell'importanza dei legami fra le variabili finanziarie e quelle più qualitative. Saper quantificare le variazioni dell'importanza di tali impatti è fondamentale per fare un'analisi quantitativa efficace in tale direzione.

Infatti, ora è evidente come esse risultino essere estremamente importanti non solo per l'opinione pubblica, ma anche per la valutazione dello stato di salute creditizio aziendale.

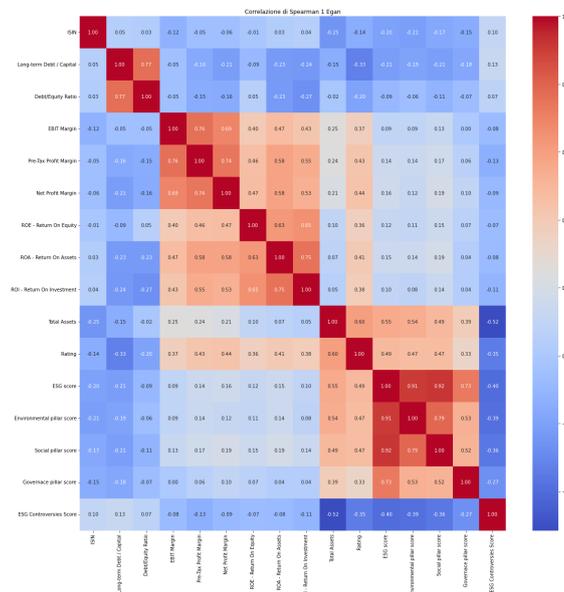
9.6: Correlation Analysis per *dfref_egan* (Annesso E)

Per concludere l'analisi dei subset generati da *dfref*, si prende ora in considerazione *dfref_egan*, ovvero il sottoinsieme generato con le sole rilevazioni relative a Egan-Jones. Questo risulta essere di gran lunga il dataframe più piccolo, anche se di dimensione assolutamente non trascurabile.

Fatte le solite doverose premesse, che valgono per tutti i capitoli precedenti e successivi, riguardo alla correlazione considerata (Spearman), si può procedere ora con l'analisi della matrice.

Come sempre, l'Annesso E può essere utilizzato per approfondire.

Figura 27 - Matrice di Correlazione di Spearman di *dfref_egan*.



La tendenza generale risulta essere, anche questa volta, privilegiare l'importanza dei legami fra variabili ESG e Rating creditizio.

Si ha una leggera differenza rispetto agli altri due dataset, in quanto, in questo caso, il delta fra correlazione variabili *ESG-Rating* e variabili *finanziarie-Rating* (eccezion fatta anche in questo caso per la correlazione *Rating-Total Assets* che si conferma così di gran lunga la più rilevante con 0,60), risulta essere più sottile.

Inoltre, si può notare una leggera differenza anche in termini di forza delle correlazioni, che ora risulta essere più elevata.

A sostegno di quanto detto, basta far riferimento al numero di correlazioni con il Rating maggiore o uguale a 0,40 oppure minore o uguale a -0,40.

Rispetto alla matrice di S&P, che ne presenta 4, e a quella di Moody's, la quale ne presenta anch'essa 4, la matrice di Egan-Jones, presenta 7 correlazioni maggiori o uguali a 0,40 e minori o uguali a -0,40.

Figura 28 - Focus sulle correlazioni delle variabili ESG per *dfref_egan*

Rating	-0.14	-0.33	-0.20	0.37	0.43	0.44	0.36	0.41	0.38	0.60	1.00	0.49	0.47	0.47	0.33	-0.35
ESG score	-0.20	-0.21	-0.09	0.09	0.14	0.16	0.12	0.15	0.10	0.55	0.49	1.00	0.91	0.92	0.73	-0.40
Environmental pillar score	-0.21	-0.19	-0.06	0.09	0.14	0.12	0.11	0.14	0.08	0.54	0.47	0.91	1.00	0.79	0.53	-0.39
Social pillar score	-0.17	-0.21	-0.11	0.13	0.17	0.19	0.15	0.19	0.14	0.49	0.47	0.92	0.79	1.00	0.52	-0.36
Governance pillar score	-0.15	-0.18	-0.07	0.00	0.06	0.10	0.07	0.04	0.04	0.39	0.33	0.73	0.53	0.52	1.00	-0.27
ESG Controversies Score	0.10	0.13	0.07	-0.08	-0.13	-0.09	-0.07	-0.08	-0.11	-0.52	-0.35	-0.40	-0.39	-0.36	-0.27	1.00
	ISIN	Long-term Debt / Capital	Debt/Equity Ratio	EBIT Margin	Pre-Tax Profit Margin	Net Profit Margin	ROE - Return On Equity	ROA - Return On Assets	ROI - Return On Investment	Total Assets	Rating	ESG score	Environmental pillar score	Social pillar score	Governance pillar score	ESG Controversies Score

Arrivati a questo punto, è utile, come negli altri casi, fare degli esempi per analizzare la rilevanza di alcune correlazioni positive chiave del Rating creditizio:

- 1) Correlazione con **Pre-Tax Profit Margin**: 0,43;
- 2) Correlazione con **Net Profit Margin**: 0,44;
- 3) Correlazione con **ROA**: 0,41;

che risultano, nonostante la forza di tali legami, inferiori alla:

- 1) Correlazione con **ESG score**: 0,49;
- 2) Correlazione con **Environmental pillar score**: 0,47;
- 3) Correlazione con **Social pillar score**: 0,47.

Inoltre, in linea con l'analisi generale effettuata su *dfref* - ma anche su *dfblo* - si ha che l'impatto negativo peggiore si ha in corrispondenza della correlazione fra *Rating-Long-term Debt/Capital*, mentre abbiamo equivalenza fra correlazione *Rating-Debt/Equity ratio* e *Rating/ESG Controversies score*.

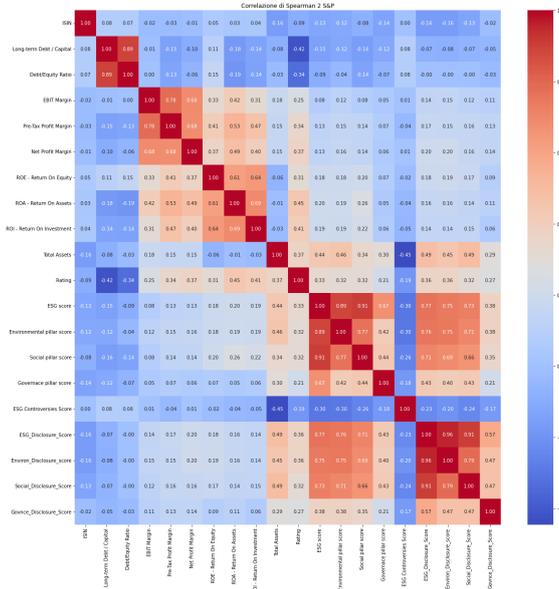
Concludendo, risulta estremamente evidente, per *dfref*, che si hanno differenze, talvolta importanti, fra agenzia ed agenzia. Questa tesi, se sostenuta anche dallo studio condotto su *dfblo*, giustificherebbe concretamente la rilevanza dello studio condotto su diverse agenzie di rating, e aprirebbe l'interrogativo su cosa potrebbe succedere nella fase di analisi predittiva.

9.7: Correlation Analysis per *dfblo_sp* (Annesso F)

Passiamo, dunque, all'analisi dei subset di *dfblo_sp*.

Come anticipato nel paragrafo precedente, anche in questo caso la matrice di correlazione analizzata è quella di Spearman e nell'Annesso F si può ottenere una visione esaustiva di tutte le matrici computeate.

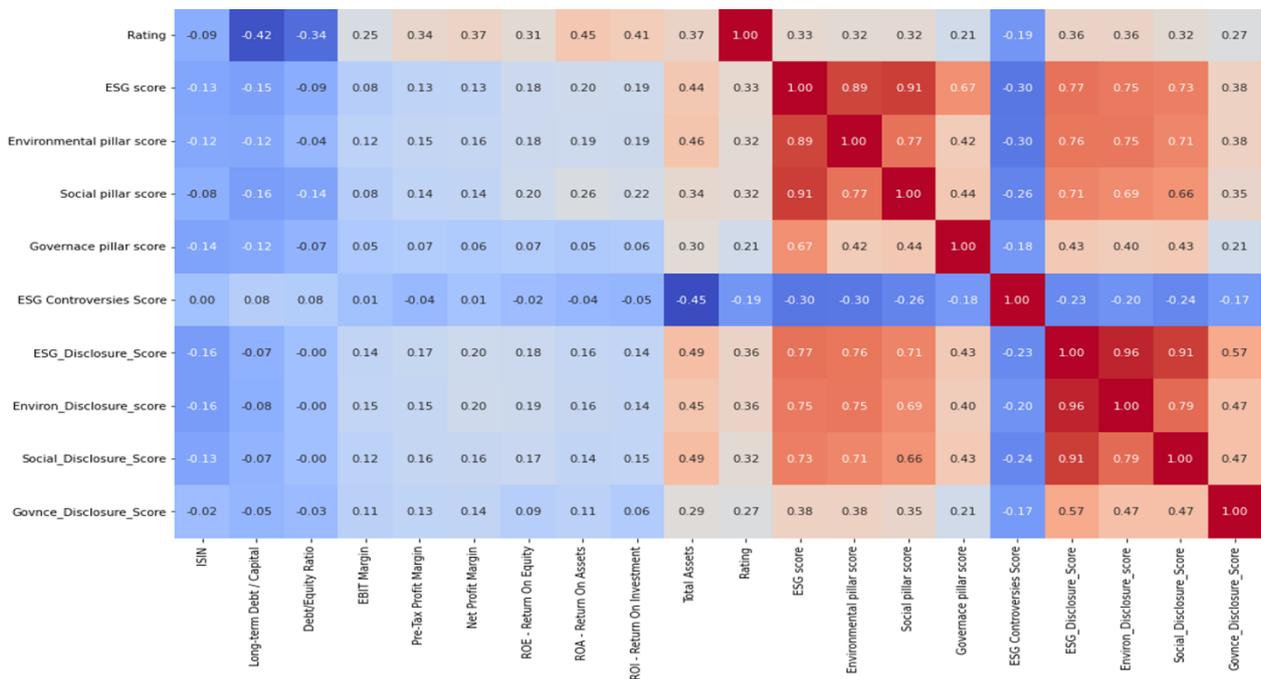
Figura 29 - Matrice di Correlazione di Spearman di *dfblo_sp*.



Anche in questo caso, come osservato in *dfref_sp* (paragrafo 9.4), abbiamo una sottile inversione di tendenza generale rispetto all'analisi di correlazione effettuata su *dfblo* e su *dfref*.

Infatti, il peso dei legami di correlazione con la variabile Rating risulta essere maggiore in corrispondenza delle variabili finanziarie.

Figura 30 - Focus sulle correlazioni delle variabili ESG per *dfblo_sp*.



Nello specifico, tralasciata qualche piccola variazione del valore delle singole correlazioni fra le variabili indipendenti - già ampiamente analizzate nei paragrafi precedenti - e Rating, è interessante andare ad analizzare la rilevanza delle nuove variabili ESG considerate, ovvero quelle estratte dalla banca dati Bloomberg.

In dettaglio, le correlazioni con il *Rating creditizio* di queste variabili misurano:

- 1) Correlazione con *ESG disclosure score*: 0,36;
- 2) Correlazione con *Environmental disclosure score*: 0,36;
- 3) Correlazione con *Social disclosure score*: 0,32.
- 4) Correlazione con *Governance disclosure score*: 0,27.

È sicuramente interessante sottolineare come la forza del legame fra Rating e score di pubblicazione risulti spesso maggiore o uguale agli score ESG estratti nella fase relativa alla costruzione della matrice intermedia. Infatti, abbiamo che:

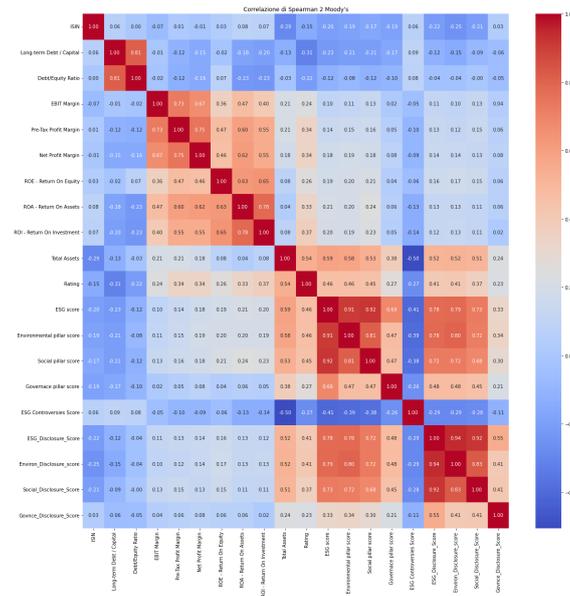
- 1) La correlazione fra *ESG score e Rating* risulta essere meno rilevante di quella fra *ESG disclosure score e Rating*.
- 2) La correlazione fra *Environmental pillar score e Rating*, risulta essere meno rilevante di quella fra *Environmental disclosure score e Rating*.
- 3) La correlazione fra *Governance pillar score e Rating*, risulta essere meno rilevante di quella fra *Governance disclosure score e Rating*, anche se si mantiene il risultato ottenuto anche negli altri capitoli relativo alla minor rilevanza delle variabili riguardanti la *Governance* (che pur rimane importante).

Questi risultati sottolineano ancora una volta l'importanza da parte delle organizzazioni di saper rivolgersi agli stakeholder esterni ed interni all'azienda, anche agendo con un buon livello di pubblicazioni a sostegno delle tematiche ESG. Tutto ciò, ovviamente, agisce insieme a buone prestazioni finanziarie e ESG, senza le quali non si potrebbe puntare ad ottimizzare i benefici ottenibili.

9.8: Correlation Analysis per *dfblo moody* (Annesso G)

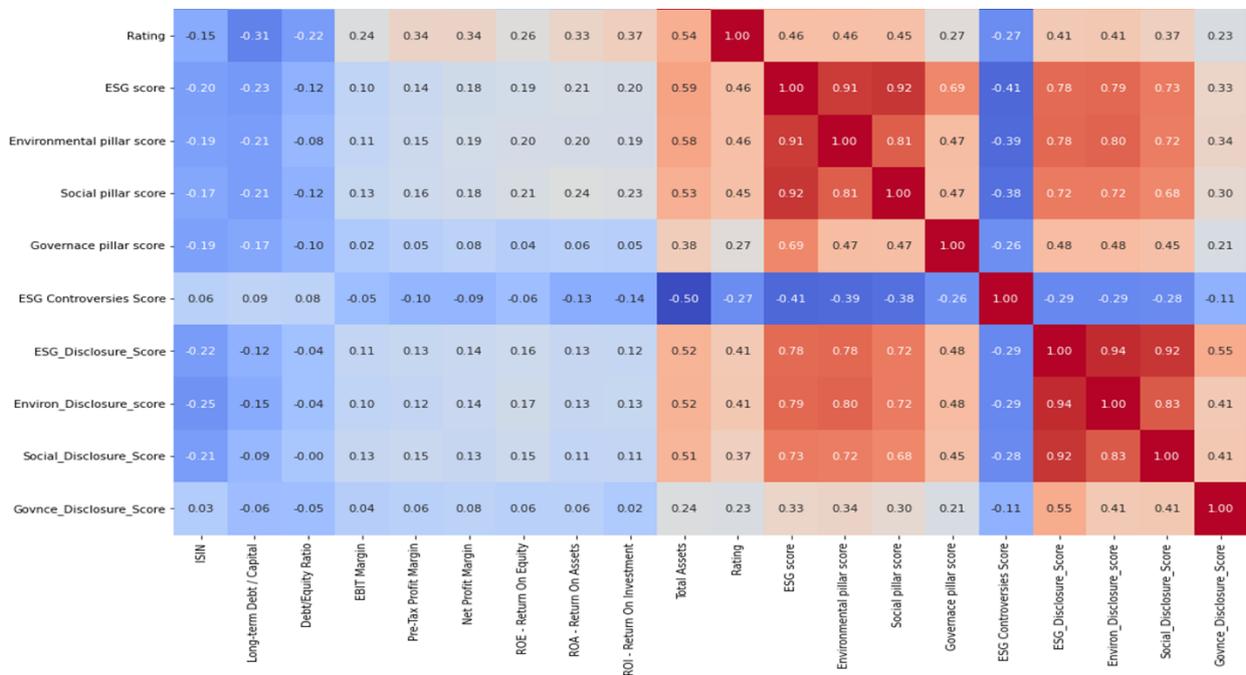
Come secondo studio riguardo i subset di *dfblo_red*, in modo speculare a quanto fatto con le analisi sui subset di *dfref_red*, analizziamo la correlazione di Spearman nel dataset *dfblo_moody*.

Figura 31 - Matrice di Correlazione di Spearman di dfblo_moody.



Anche in questo caso, specularmente a quanto osservato nella analisi di *dfref_moody*, si osserva un riallineamento a ciò che era stato computato nelle analisi di correlazioni generali su *dfref* e *dfblo*. L'impatto delle correlazioni fra **Rating e variabili ESG**, questa volta includendo anche le variabili estratte da Bloomberg riguardo gli score di pubblicazione, risulta maggiore rispetto a quello fra **Rating e variabili finanziarie**, eccezion fatta per **Total Assets**.

Figura 32 - Focus sulle correlazioni delle variabili ESG per dfblo_moody.



In particolare, ponendo il focus sulle metriche di Bloomberg, non vale più quanto detto nel capitolo precedente (9.7), in quanto gli score ESG di *Refinitiv* risultano per questa agenzia più rilevanti rispetto a quelli di Bloomberg, per quanto concerne la loro correlazione con il **Rating**.

Questo va detto, però, sottolineando che si ha, in questo caso, un aumento tendenziale della rilevanza di tutte le metriche ESG in relazione al loro legame con il Rating.

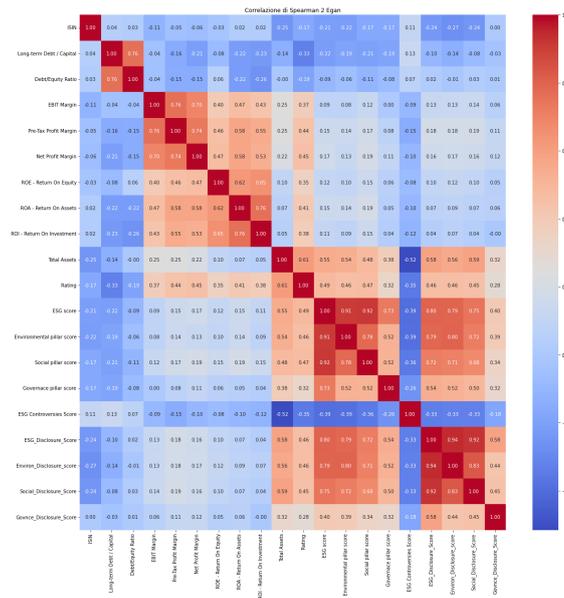
Nello specifico, si evidenzia che:

- 1) La correlazione fra **ESG disclosure score e Rating** è pari a 0,41, al pari di quella fra **Environmental disclosure score e Rating**.
- 2) La correlazione fra **Social disclosure score e Rating** è pari a 0,37.
- 3) Anche in questo caso, abbiamo che la variabile relativa al **Governance disclosure score** ha un legame meno forte con il **Rating** rispetto alle altre.

9.9: Correlation Analysis per *dfblo_egan* (Annesso H)

Come ultimo dataset, si analizza *dfblo_egan* e la sua matrice di correlazione di Spearman.

Figura 33 - Matrice di Correlazione di Spearman di *dfblo_egan*.



Anche in questa analisi, come per quella su *dfref_egan*, possiamo effettuare le stesse considerazioni per quanto riguarda le metriche in comune fra le due matrici.

In particolare, abbiamo anche per questa azienda un impatto più forte da parte delle correlazioni fra **Rating** e variabili ESG (quelle di Bloomberg comprese), rispetto a quelle fra **Rating** e variabili finanziarie, allo stesso modo dello studio condotto nel capitolo 9.6.

È interessante, anche in questo caso, effettuare una riflessione fra i delta che esistono fra rilevanza dei legami fra variabili finanziarie e variabili ESG (considerate anche le variabili di Bloomberg).

Figura 34 - Focus sulle correlazioni delle variabili ESG per dfblo_egan.

Rating	-0.17	-0.33	-0.19	0.37	0.44	0.45	0.35	0.41	0.38	0.61	1.00	0.49	0.46	0.47	0.32	-0.35	0.46	0.46	0.45	0.28
ESG score	-0.21	-0.22	-0.09	0.09	0.15	0.17	0.12	0.15	0.11	0.55	0.49	1.00	0.91	0.92	0.73	-0.39	0.80	0.79	0.75	0.40
Environmental pillar score	-0.22	-0.19	-0.06	0.08	0.14	0.13	0.10	0.14	0.09	0.54	0.46	0.91	1.00	0.78	0.52	-0.39	0.79	0.80	0.72	0.39
Social pillar score	-0.17	-0.21	-0.11	0.12	0.17	0.19	0.15	0.19	0.15	0.48	0.47	0.92	0.78	1.00	0.52	-0.36	0.72	0.71	0.68	0.34
Governance pillar score	-0.17	-0.19	-0.08	0.00	0.08	0.11	0.06	0.05	0.04	0.38	0.32	0.73	0.52	0.52	1.00	-0.26	0.54	0.52	0.50	0.32
ESG Controversies Score	0.11	0.13	0.07	-0.09	-0.15	-0.10	-0.08	-0.10	-0.12	-0.52	-0.35	-0.39	-0.39	-0.36	-0.26	1.00	-0.33	-0.33	-0.33	-0.18
ESG_Disclosure_Score	-0.24	-0.10	0.02	0.13	0.18	0.16	0.10	0.07	0.04	0.58	0.46	0.80	0.79	0.72	0.54	-0.33	1.00	0.94	0.92	0.58
Environ_Disclosure_score	-0.27	-0.14	-0.01	0.13	0.18	0.17	0.12	0.09	0.07	0.56	0.46	0.79	0.80	0.71	0.52	-0.33	0.94	1.00	0.83	0.44
Social_Disclosure_Score	-0.24	-0.08	0.03	0.14	0.19	0.16	0.10	0.07	0.04	0.59	0.45	0.75	0.72	0.68	0.50	-0.33	0.92	0.83	1.00	0.45
Govnce_Disclosure_Score	0.00	-0.03	0.01	0.06	0.11	0.12	0.05	0.06	-0.00	0.32	0.28	0.40	0.39	0.34	0.32	-0.18	0.58	0.44	0.45	1.00
	ISIN	Long-term Debt / Capital	Debt/Equity Ratio	EBIT Margin	Pre-Tax Profit Margin	Net Profit Margin	ROE - Return On Equity	ROA - Return On Assets	ROI - Return On Investment	Total Assets	Rating	ESG score	Environmental pillar score	Social pillar score	Governance pillar score	ESG Controversies Score	ESG_Disclosure_Score	Environ_Disclosure_score	Social_Disclosure_Score	Govnce_Disclosure_Score

Andando più nel dettaglio riguardo alle correlazioni fra Rating e variabili ESG, osserviamo come la rilevanza sia maggiore rispetto alle analisi condotte per le analisi negli altri dataset.

Ciò si verifica anche per le correlazioni fra Rating e variabili finanziarie, anche se questi valori rimangono inferiori ai primi.

In particolare, ponendo il focus sulle correlazioni fra metriche di Bloomberg e Rating, abbiamo che:

- 1) La correlazione fra **Rating e ESG disclosure score** è pari a 0,46, così come quella con l'**Environmental disclosure score**;
- 2) La correlazione fra **Rating e Social disclosure score** è pari a 0,45;
- 3) La correlazione fra **Governance disclosure score e Rating** tocca nell'analisi sulla matrice relativa all'agenzia Egan-Jones, il suo valore massimo, ovvero 0,28.

9.10: Conclusioni Correlation Analysis

L'analisi di correlazione è stata uno strumento molto utile per andare ad indagare le relazioni fra le metriche che compongono i due dataset principali del nostro studio, ovvero quelli creati dall'unione del dataset di partenza con i dati *Refinitiv* (dataset intermedio - *dfref*) ed anche con i dati di *Bloomberg* (dataset finale - *dfblo*).

I risultati hanno suggerito come le variabili ESG siano estremamente correlate alle metriche finanziarie ed al Rating stesso, il quale sembra essere più influenzato dalle prime che dalle seconde, almeno in linea generale.

Questo ha delle conseguenze importanti per le decisioni che devono essere prese dalle organizzazioni, sia in funzione del pubblico ed in generale degli stakeholders esterni, sia in funzione di quelli interni. L'analisi generale ha messo in risalto come il focus non debba dunque concentrarsi su una visione parziale del problema, anche se di più facile approccio, bensì su una visione quanto più olistica possibile.

Le metriche ESG rappresentano l'attualità ed il futuro aziendale, non solo dal punto di vista reputazionale, bensì anche dal punto di vista della salute finanziaria aziendale.

Le conclusioni alle quali si è giunti in seguito all'analisi sui dataset intermedio e finale, ha posto il focus su alcune metriche in particolare, le quali mostravano una più alta correlazione, sia in termini positivi, sia in termini negativi.

Per questo si è ritenuto interessante, innanzitutto, andare a ridurre il numero delle variabili che, in origine, era molto elevato e conteneva un alto numero di metriche ridondanti o irrilevanti ai fini dell'analisi.

Proseguendo si è anche riflettuto sull'output ottenuto più in termini qualitativi. Infatti, stando anche a quanto detto in fase di revisione della letteratura e riflettendo sul metodo di raccolta delle rilevazioni del dataset di partenza, si è notato uno sbilanciamento a favore di alcune agenzie rispetto ad alcune altre. Questo aspetto è sostanzialmente fisiologico, in quanto anche nel mercato reale assistiamo a questo fenomeno - con Moody's, S&P e Fitch che risultano largamente le più attive ed affidabili - ma si è ritenuto interessante andare a fare una valutazione più di dettaglio di quali siano le metriche che presentano legami più forti con i Rating, per le 3 agenzie di rating più presenti all'interno dei dataset. Effettivamente, si sono evidenziate delle differenze, talvolta anche rilevanti, su quelle che sono le tendenze generali all'interno di questi subset.

In particolare, si nota una certa peculiarità di risultati all'interno delle stesse agenzie:

- 1) Nell'analisi di *dfref_sp e dfblo_sp*, si raggiungono risultati estremamente simili;
- 2) Nell'analisi di *dfref_moody e dfblo_moody*, allo stesso modo, otteniamo dei risultati assolutamente allineati;
- 3) Anche per quanto riguarda *dfref_egan e dfblo_egan*, otteniamo risultati allineati in termini di tendenze generali.

Quanto detto anche nei capitoli precedenti, può essere così sintetizzato facendo un recap delle tendenze che si sono ottenute in queste analisi:

- 1) **Tendenze generali delle analisi di correlazione di *dfref_sp* e *dfblo_sp*:** questi sono gli unici casi che hanno mostrato un disallineamento rispetto a quanto scoperto nelle analisi generali su *dfref* e *dfblo*. Infatti, si ha uno spostamento tendenziale dell'importanza verso le relazioni fra Rating e variabili finanziarie, anche se i legami fra Rating e variabili ESG rimangono una componente estremamente rilevante.
- 2) **Tendenze generali delle analisi di correlazione di *dfref_moody* e *dfblo_moody*:** in queste analisi abbiamo un totale allineamento a quanto mostrato nelle analisi generali, sia in termine di rilevanza dei legami, sia in termini di valori veri e propri. Difatti, le correlazioni, in linea generale, si allineano molto a quelle ottenute dai dataset *dfref* e *dfblo*.
- 3) **Tendenze generali delle analisi di correlazione di *dfref_egan* e *dfblo_egan*:** nei casi riportati, si ha allineamento alle analisi su *dfref* e *dfblo* per quanto concerne la rilevanza delle correlazioni fra Rating e variabili finanziarie e fra Rating e variabili ESG. Infatti, queste ultime relazioni risultano, così come in Moody's, più rilevanti, ma abbiamo un innalzamento generale dei valori della rilevanza di tutte le variabili scelte per comporre le matrici ridotte sulle quali l'analisi è svolta.

Inoltre, si possono fare anche delle osservazioni generali su tutte queste analisi riferite ai subset generati:

- 1) Innanzitutto, si ha una grandissima rilevanza della correlazione fra ***total assets e variabili ESG*** (sia *Refinitiv* che *Bloomberg*), a testimonianza dell'importanza dal punto di vista finanziario di quest'ultime.
- 2) Con focus alle variabili ESG, quelle legate alla ***Governance*** mostrano i legami più deboli con il Rating, anche se rimangono sempre interessanti ed impattanti.

Questi risultati, dunque, uniti a quanto osservato durante la fase di revisione della letteratura, ci portano a conclusioni interessanti che possono essere studiate più a fondo tramite un'analisi predittiva con *machine learning*. In particolare, sorge dunque una domanda: cosa succederebbe in un'analisi predittiva e come cambierebbe il livello di importanza delle varie features se non ci si fermasse ad un'analisi generale, ma si conducesse tale studio anche per i subset analizzati in questo caso?

Tale approccio, permetterebbe una visione a 360° della questione e ad una analisi olistica del fenomeno.

CAPITOLO 10: PREDICTIVE ANALYSIS

La seconda tipologia di analisi svolta è stata quella predittiva.

In primo luogo, si tratta di **inquadrare il problema**. Per lo scopo ultimo della nostra analisi, ovvero prevedere - *a partire da tutte quelle variabili identificate come più impattanti nella fase di analisi della correlazione* - la valutazione di credito che sarebbe poi stata fatta dalle agenzie prese in esame, il problema poteva essere affrontato come una classificazione multi-classe. Questa scelta è stata fatta per molteplici ragioni, fra cui, le più importanti, sono state:

1. Offrire un'analisi che possa essere indicativa anche per quelle classi di Rating che non presentano un numero di rilevazioni sufficiente allo sviluppo di un algoritmo efficace. Nell'immagine che segue, è possibile osservare la distribuzione delle rilevazioni in *dfr* (*dfref_red*) per ogni classe di Rating presente nello studio. Si ricorda, per una corretta lettura dell'immagine che era stata condotta un'*ordinal encoding* per la variabile Rating, che ha cambiato le classi in numeri da 0 (D) a 22 (AAA).

Figura 35 - Distribuzione delle rilevazioni per *dfref_red* (*dfr*)



2. Allinearsi agli studi precedenti presi in esame e dai quali lo studio in questione si sviluppa (molti casi, come quello da cui il Dataset di partenza è stato preso, affrontano il problema come una classificazione binaria), sviluppando un'analisi più dettagliata ed approfondita;
3. Allinearsi anche alle informazioni presenti sul sito di S&P riguardo alla classificazione utilizzata - che ricordiamo essere alla base delle valutazioni di Rating impiegate dagli autori dello studio del nostro dataset di partenza - che hanno ridotto alla stessa scala di valutazione di credito tutte le scale utilizzate dalle diverse agenzie presenti nel dataset.

Per quest'ultima ragione, citando la pagina ufficiale di Standard & Poor's ([link](#)), siamo partiti dalla distinzione binaria effettuata dall'agenzia stessa, ovvero:

- a. Per i Rating rispettivamente pari a “D, C, CC, CCC, B, BB”, si parla di *Speculative grade*;
- b. Per i Rating rispettivamente pari a “BBB, A, AA, AAA”, si parla di *Investment grade*.

Per far fronte alle necessità di un primo bilanciamento delle classi dei nostri dataset finale ed intermedio, si è deciso di mantenere la classe relativa a *Speculative grade* e di andare più nel dettaglio per quanto riguarda quella chiamata *Investment grade*.

Quindi, riprendendo la nomenclatura e la scala utilizzata all'interno dei dataset utilizzati, si è deciso di creare la variabile dipendente ***Rating quality grade*** da sostituire all'interno dell'analisi predittiva alla variabile dipendente chiamata ***Rating***. Le classi generate sono quindi, a salire:

Classe 0: Speculative grade investment: nella quale vengono fatti convergere i Rating “D, C, CC, CC+, CCC-, CCC, CCC+, B-, B, B+, BB-, BB, BB+”;

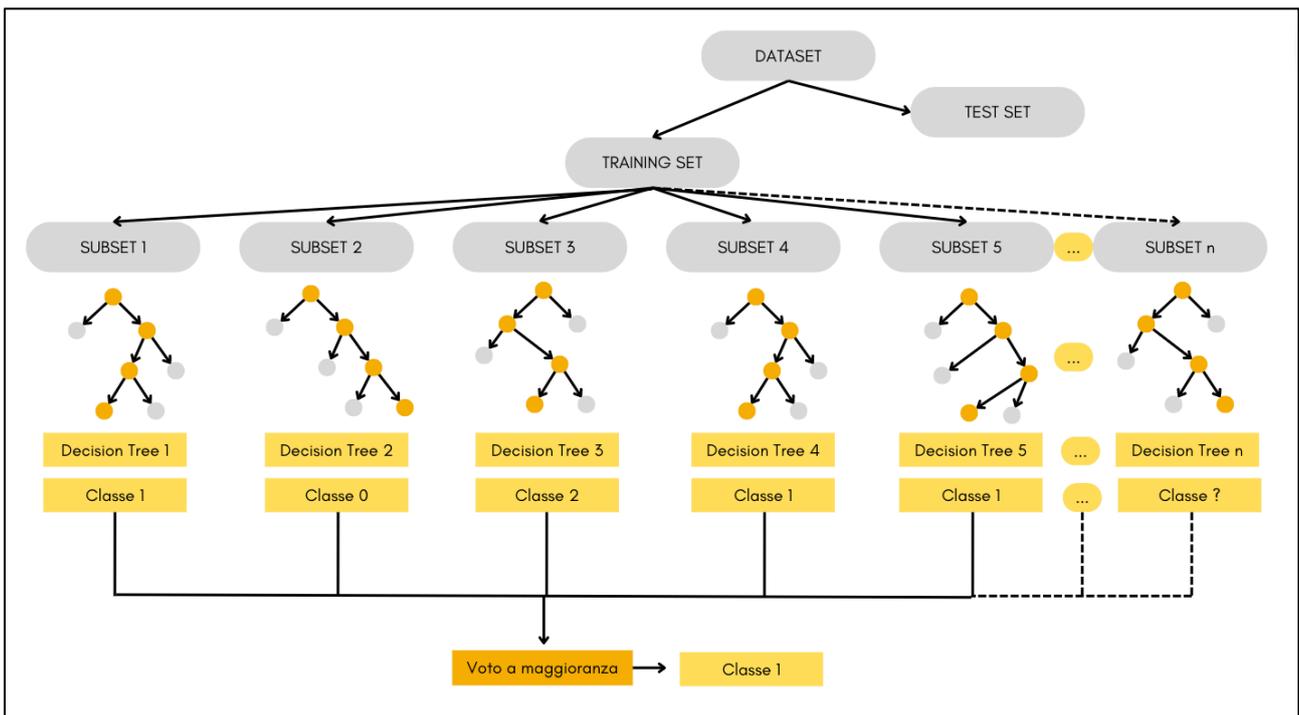
Classe 1: Adequate grade investment: nella quale convergono “BBB-, BBB, BBB+, A-”;

Classe 2: Optimal grade investment: in cui convergono “A, A+, AA-, AA, AA+, AAA”.

Una volta inquadrato il problema di classificazione, va sottolineato come si sia deciso di optare per uno di quegli algoritmi che sono stati analizzati in fase di review della letteratura, individuati come più facilmente applicabili, a fronte di performance comunque estremamente valide.

In particolare, dunque, si è optato per la tecnica di *ensemble learning* chiamata ***Random Forest*** per la cui comprensione occorre capire innanzitutto il funzionamento della tecnica chiamata *Decision Tree Classifier*. Si tratta sostanzialmente di un albero decisionale, che smarca le possibili conseguenze per ogni possibile decisione. In particolare, questo algoritmo, divide in maniera ricorsiva il dataset sul quale viene applicato, in base alle caratteristiche più significative di quest'ultimo. Così facendo, al termine dell'albero decisionale, si avranno delle previsioni relative alle nostre classi.

Figura 36 - Come funziona un Random Forest?



Come passo successivo, è poi utile fare delle precisazioni riguardo la nomenclatura utilizzata, che utilizzeremo anche da questo punto in poi.

In maniera analoga a quanto fatto per le classificazioni, si è effettuata l'analisi predittiva su ogni dataset e subset dello studio, in modo da esaltare le differenze fra dataset intermedio e finale, ma soprattutto fra agenzie, con la differenza che si sono presi in considerazione direttamente i dataset con le variabili identificate come più significative relativamente alla correlazione con il Rating.

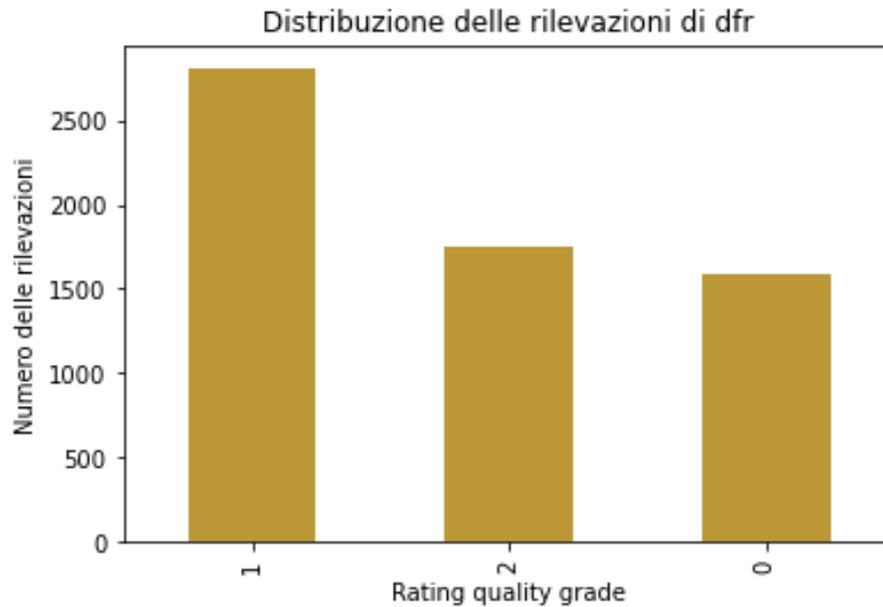
Dunque:

- 1) Il Dataset Intermedio (Fase 2), ovvero *dfref_red*, si chiamerà ***dfr***.
- 2) Il Dataset Finale (Fase 3), ovvero *dfblo_red*, si chiamerà ***dfb***.
- 3) Il subset *dfref_sp*, si chiamerà ***dfrs***.
- 4) Il subset *dfref_moody* si chiamerà ***dfrm***.
- 5) Il subset *dfref_egan* si chiamerà ***dfre***.
- 6) Il subset *dfblo_sp* si chiamerà ***dfbs***.
- 7) Il subset *dfblo_moody* si chiamerà ***dfbm***.
- 8) Il subset *dfblo_egan* si chiamerà ***dfbe***.

Prima di procedere, si è poi passati allo studio del bilanciamento delle tre nuove classi e si è notato come queste presentavano forti sbilanciamenti, che avrebbero influenzato negativamente l'affidabilità dello studio.

Nell'immagine seguente, si osserva il caso di *dfr*, che ci mostra come lo sbilanciamento delle classi non possa essere trascurabile.

Figura 37 - Distribuzione delle rilevazioni per *dfr* nelle 3 nuove classi.



Infine, è utile prendere in rassegna le altre fasi ricorrenti e coincidenti delle analisi predittive messe in atto. In tutte queste analisi, è stata fatta una suddivisione in **training set** e **test set**, impostando la grandezza di quest'ultimo pari al 20% del totale. Ciò significa che il modello di apprendimento ha effettuato la propria fase di allenamento su dei set di dati corrispondenti all'80% dei dataset totali, mentre la predizione è stata effettuata sul restante 20%. Inoltre, si è deciso di approcciare al problema della distribuzione delle classi all'interno del training set e del test set con la tecnica del **stratified k fold**, impostando $k=10$. Questo è stato anche molto importante per la successiva fase.

A seguito della divisione del dataset in *training* e *test set*, infatti si è proceduto all'**ottimizzazione degli iperparametri** del modello, ovvero all'**hyperparameters tuning**.

Ogni modello infatti presenta degli iperparametri con cui funziona che non vengono selezionati in maniera autonoma dall'algorithmo stesso. Attraverso la ricerca a griglia, o **Grid Search**, è possibile andare a studiare la performance e dunque a selezionare diverse combinazioni di iperparametri all'interno del modello.

In particolare, quelli che sono stati selezionati nell'analisi condotta per il Random Forest classifier sono:

- 1) **n_estimators**: che rappresenta il numero degli alberi decisionali che possono essere all'interno del modello. Per questi si è scelto di selezionare la migliore opzione fra 1, 2 o 5.
- 2) **max_depth**: che ci dice quanto possono essere lunghi gli alberi decisionali all'interno del modello. In particolare, i valori inseriti sono 1, 5 e 10.
- 3) **max_features**: che sta ad indicare il numero delle caratteristiche da considerare nella computazione del miglior sezionamento del dataset.

Terminata dunque la descrizione dei processi preliminari messi in atto per l'utilizzo del *Random Forest Classifier*, si passano ora in rassegna i principali risultati dello studio. Si risponderà, dunque, alla domanda: “è possibile effettuare un'analisi predittiva con buone performance, utilizzando le variabili emerse come più impattanti durante la fase di correlazione e valutando l'importanza di ogni singola feature?”. La risposta, come vedremo, è in tutti i casi affermativa, anche se esistono delle piccole differenze fra i vari dataset che meritano di essere esplorate.

10.1: Predictive Analysis per dfr e dfb (Annesso I)

Prima di continuare, è utile fare un piccolo approfondimento sulle misure di performance del modello che sono state utilizzate.

Per fare ciò, è importante andare a dare una definizione di True Positive, True Negative, False Positive e False Negative in una matrice di confusione per una classificazione multi-classe, come i casi in questione. Quindi:

- 1) **True Positive (TP)**: sono i valori lungo la diagonale. Rappresentano il numero delle previsioni effettuate correttamente. Dunque avremo che *True Label = Predicted Label*, stando alla nomenclatura utilizzata in *Figura 42*.
- 2) **False Negative (FN)**: rappresenta la somma delle predizioni lungo la stessa riga dei TP in questione. In particolare, utilizzando l'esempio di *Figura 42*, avremo per Speculative Grade $TP=265$ e $FN=50+4$.
- 3) **False Positive (FP)**: rappresenta il numero delle predizioni effettuate su una classe, che non dovrebbero essere classificate in tale classe. Dunque, la somma dei valori presenti nella colonna di TP, senza considerare TP. Nell'esempio di Speculative grade di *Figura 42*, avremo $FP=52+9$.
- 4) **True Negative (TN)**: è la somma di tutte le altre celle all'interno della confusion matrix. Nell'esempio di prima, $TN=398+110+68+273$.

Parlando delle misure di performance, invece, si ha:

- 1) **Accuracy**: questa misura rappresenta il numero delle rilevazioni classificate correttamente, quindi la somma tra **True Positive** e **True Negative**, rispetto al numero delle rilevazioni totali, ovvero la somma tra **True Positive**, **True Negative**, **False Positive** e **False Negative**. Questa misura è compresa fra 0 e 1, dove quanto più ci si avvicina a 1, tanto più avremo un modello con buone performance.

Figura 38 - Formula dell'Accuracy¹³

$$Accuracy = \frac{TN + TP}{TN + FP + TP + FN}$$

2) **Precision**: questa misura rappresenta il numero delle previsioni positive che sono corrette, e quindi il numero delle **True Positive**, rispetto alla somma dei **True Positive** e dei **False Positive**, e quindi al numero totale delle rilevazioni che vengono classificate come corrette, anche se corrette non sono (**FP**). Anche in questo caso, si va da 0 a 1 e tanto più ci si avvicina ad 1, tanto più il nostro algoritmo ha buone performance.

Figura 39 - Formula della Precision¹⁴

$$Precision = \frac{TP}{TP + FP}$$

3) **Recall**: questa misura, alla quale ci si riferisce anche con Sensitivity, misura quanto il classificatore ha predetto correttamente i casi positivi rispetto a tutti quelli presenti nel set di dati. Come nei casi precedenti, il valore ottenuto può variare da 0 a 1 con il medesimo significato.

Figura 40 - Formula della Recall¹⁵

$$Recall = \frac{TP}{TP + FN}$$

4) **F1-score**: risulta essere una misura molto importante, in quanto calcola la media armonica sia di **Precision** che di **Recall**, andando di fatto a considerarli entrambi, senza perdere informazioni preziose. Al medesimo modo degli altri casi e con lo stesso significato, la misurazione può variare fra 0 e 1 e sarà 1 solo quando sia **Recall** che **Precision** saranno uguali ad 1.

¹³ Harikrishnan N. B. (2019). Confusion Matrix, Accuracy, Precision, Recall, F1 Score. Medium, Analytics Vidhya.

¹⁴ Ibidem.

¹⁵ Ibidem.

Figura 41 - Formula dell'*f1-score*¹⁶

$$F1\ Score = 2 * \frac{Precision * Recall}{Precision + Recall}$$

Fatte dunque queste opportune precisazioni ed osservazioni, possiamo ad analizzare i risultati ottenuti in fase di analisi predittiva.

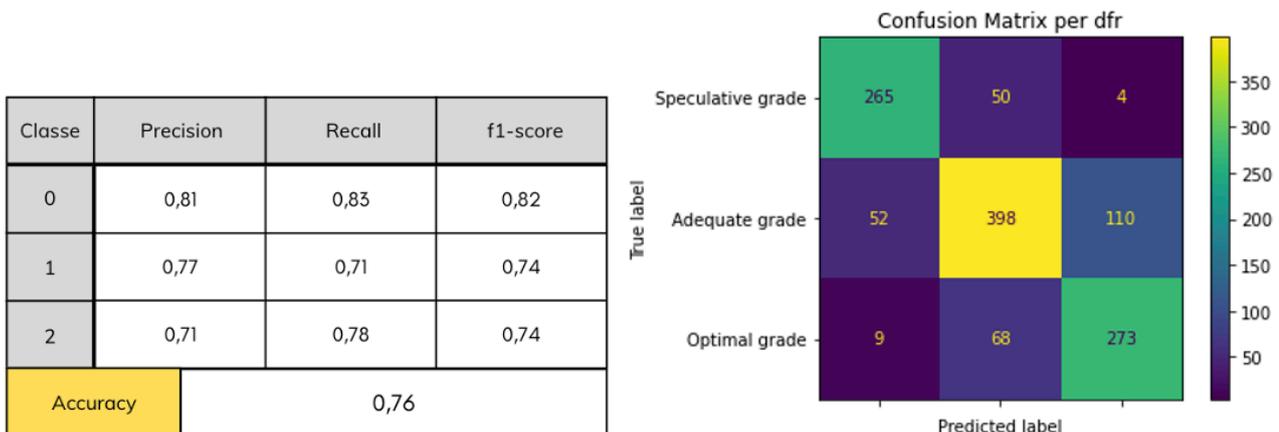
In particolare, osserviamo come l'*accuracy* sia un valore univoco, che non risulta sufficiente per andare a dare una valutazione complessiva ad un modello basato su un dataset sbilanciato come nel nostro caso.

Per questo, porremo particolare attenzione sì all'*Accuracy*, ma anche all'*f1-score*, che invece è una misura che abbiamo per ogni singola classe oggetto di predizione.

La scelta dell'*f1-score* è dovuta alla sua importanza ed alla sua attenzione sia ai valori di *Precision*, sia a quelli di *Recall*.

La prima analisi predittiva è stata svolta su *dfr*.

Figura 42 - Classification Report e Confusion Matrix per *dfr*

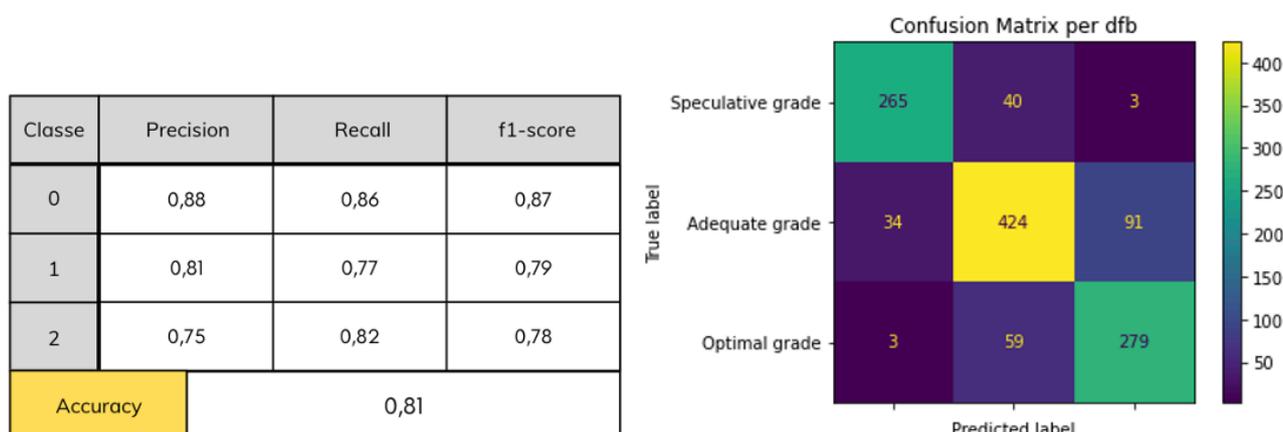


Il modello per *dfr* presenta dei risultati soddisfacenti sia in termini di *Accuracy*, pari a **0,76**, sia in termini di *f1-score*, che per la classe 0 misura **0,82** e per le classi 1 e 2, misura **0,74**.

¹⁶ Harikrishnan N. B. (2019). Confusion Matrix, Accuracy, Precision, Recall, F1 Score. Medium, Analytics Vidhya.

In secondo luogo, si è proceduto con l'analisi del dataset finale ridotto, ovvero quello arricchito con le variabili estratte da Bloomberg, che in questa fase chiamiamo *dfb*.

Figura 43 - Classification Report e Confusion Matrix per *dfb*



Si nota come le performance del modello applicato a *dfb*, e dunque al dataset finale ridotto alle variabili con più alta correlazione con il Rating, presenti una miglior performance rispetto al modello predittivo per *dfr*.

Nello specifico, sia la misura di accuratezza (*Accuracy*) che quelle di *f1-score*, hanno risultati migliori.

Questi sono:

- 1) *Accuracy*: 0,81.
- 2) *F1-score*: per la classe 0 si ha 0,87, per la classe 1 si ha 0,79 e per la classe 2 si ha 0,78.

Dunque, ampliando l'analisi ad un dataset con valori ESG sia relativi alla performance, sia relativi al livello di pubblicazioni ESG da parte dell'azienda, si ottengono dei risultati predittivi migliori rispetto a quelli ottenuti sul dataset con solo le variabili ESG legate alle performance.

Questo risultato offre un interessante punto di riflessione, di cui si tratterà nelle conclusioni.

10.2: Predictive Analysis per *dfrs*, *dfrm* e *dfre* (Annesso L)

Passiamo ora all'analisi sui subset di *dfr*, ovvero *dfrs*, per quanto riguarda l'agenzia S&P, *dfrm*, per quanto riguarda l'agenzia Moody's, e *dfre*, per quanto riguarda l'agenzia Egan-Jones.

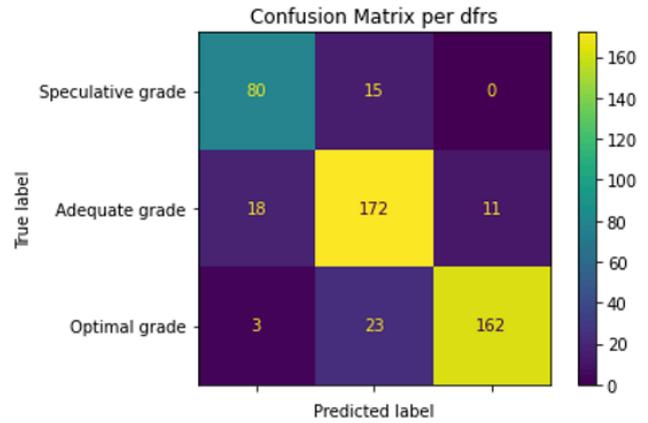
L'analisi predittiva è stata replicata in maniera del tutto equivalente a quanto fatto per *dfr* e *dfb*, al fine di ottenere dei risultati confrontabili e di facile lettura.

In primo luogo, riportiamo i report di classificazione e la matrice di confusione per le tre analisi:

1) *Dfrs*:

Figura 44 - Classification Report e Confusion Matrix per dfrs

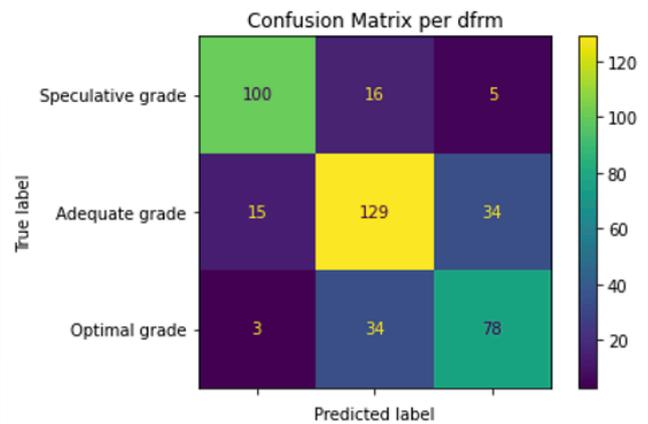
Classe	Precision	Recall	f1-score
0	0,79	0,84	0,82
1	0,82	0,86	0,84
2	0,94	0,86	0,90
Accuracy		0,86	



2) *Dfrm*:

Figura 45 - Classification Report e Confusion Matrix per dfrm

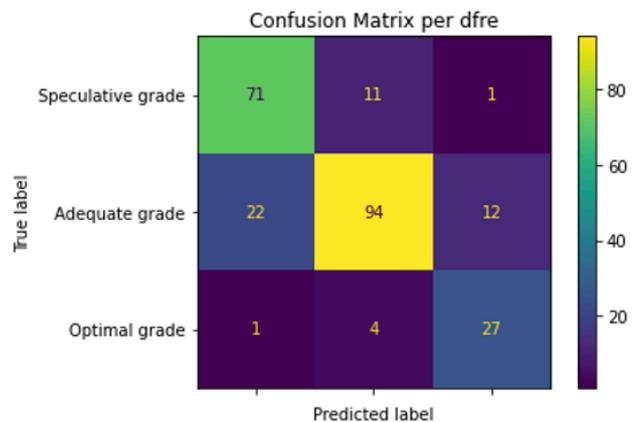
Classe	Precision	Recall	f1-score
0	0,85	0,83	0,84
1	0,72	0,72	0,72
2	0,67	0,68	0,67
Accuracy		0,74	



3) *Dfre*:

Figura 46 - Classification Report e Confusion Matrix per dfre

Classe	Precision	Recall	f1-score
0	0,76	0,86	0,80
1	0,86	0,73	0,79
2	0,68	0,84	0,75
Accuracy		0,79	



Osservando i risultati ottenuti in termini di performance del modello ed i risultati che emergono dalla lettura delle *Confusion Matrix*, appare evidente come il modello si applichi in maniera estremamente più precisa all'agenzia Standard & Poor's, mentre risulta più debole con il dataset che fa riferimento alle rilevazioni di Moody's.

In linea generale, dunque, si può dire che l'utilizzo di questo modello per la predizione del *range* di *Credit rating*, relativo alla variabile ***Rating quality grade***, è particolarmente indicato su set di rilevazioni provenienti dall'agenzia Standard & Poor's, anche se si hanno ottimi risultati anche con gli altri due subset.

Facendo un paragone con i risultati ottenuti applicando il modello predittivo al dataset generale ***dfr***, possiamo anche concludere dicendo che tendenzialmente si avrà un beneficio nell'effettuare la predizione su dei subset composti da sole rilevazioni relative alla stessa agenzia. Infatti, nonostante la predizione su ***dfr*** sia leggermente preferibile di quella effettuata su ***dfre***, il delta fra i vari *f1-score* e fra le *Accuracy* delle due applicazioni, non è tale da giustificare la preferenza dell'una sull'altra. Anzi, sarebbe comunque preferibile utilizzare un set di dati riguardo delle valutazioni effettuate da una stessa agenzia, anche a fronte di performance leggermente peggiori, a causa dell'affidabilità dei dati inseriti ed alla comparabilità fra gli stessi dati all'interno del subset.

Dunque, per quanto riguarda le analisi svolte su ***dfr***, ***dfrs***, ***dfrm*** e ***dfre***, si può concludere dicendo che:

- 1) L'analisi predittiva svolta su ***dfrs*** risulta di gran lunga la più affidabile in termini di performance registrate, con un'*Accuracy* complessiva di 0,86 e con degli *f1-score* elevati per tutte le classi (si segnala un 0,90 per la classe 2).
- 2) Il modello si comporta meglio per ***dfrs*** e ***dfre*** rispetto a quanto faccia per ***dfr***.
- 3) Nonostante l'analisi compiuta su ***dfr*** presenti *Accuracy* e *f1-score* tendenzialmente migliori rispetto all'analisi svolta su ***dfre***, sarebbe comunque da preferirsi un'analisi capillare sui vari subset delle agenzie, in quanto non si avrebbero dei benefici eccezionali.

Infine, sottolineiamo l'efficacia del modello predittivo di *Ensemble Learning*, che può essere dunque applicato con una certa tranquillità su questa tipologia di problemi, nonostante la natura diversa delle variabili in gioco, come ampiamente descritto in precedenza.

10.3: Predictive Analysis per *dfbs*, *dfbm* e *dfbe* (Annesso M)

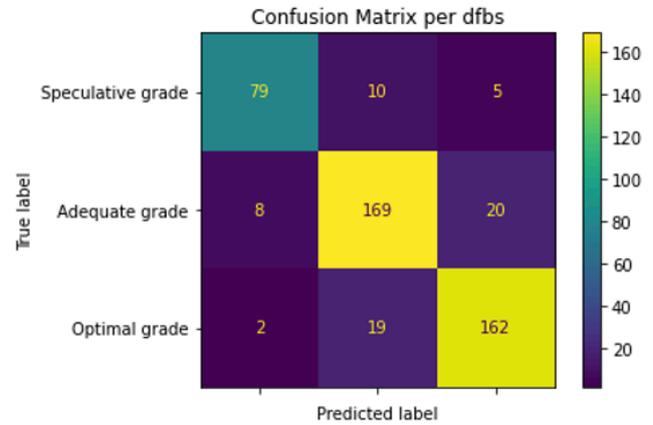
A questo punto dell'analisi, si è applicato il modello anche ai subset di ***dfb***, ovvero ***dfbs***, ***dfbm*** e ***dfbe***. Così come per i subset di ***dfr***, si è replicato lo studio in maniera speculare a quelli precedenti.

Dunque, riportiamo i *Classification Report* e le *Confusion Matrix* ottenute:

1) *Dfbs*:

Figura 47 - Classification Report e Confusion Matrix per dfbs

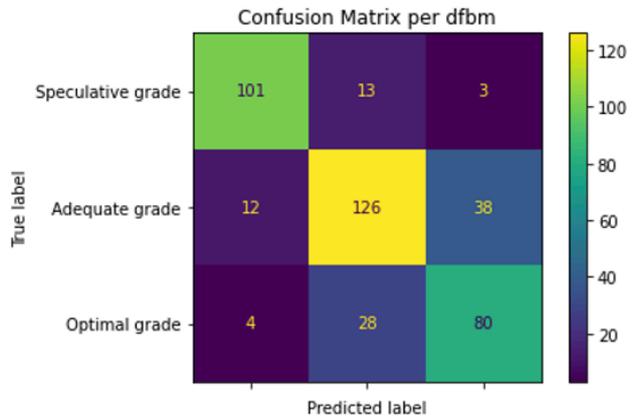
Classe	Precision	Recall	f1-score
0	0,89	0,84	0,86
1	0,85	0,86	0,86
2	0,87	0,89	0,88
Accuracy		0,86	



2) *Dfbm*:

Figura 48 - Classification Report e Confusion Matrix per dfbm

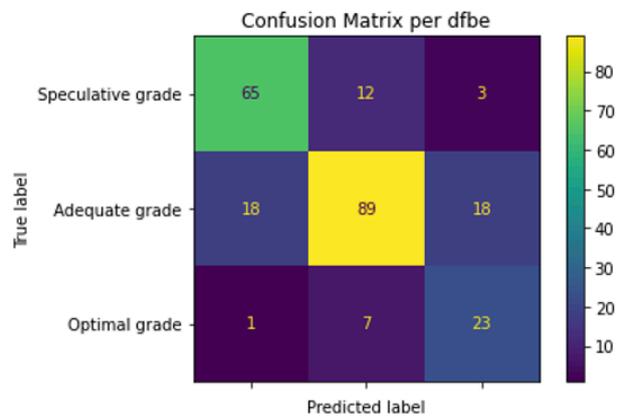
Classe	Precision	Recall	f1-score
0	0,86	0,86	0,86
1	0,75	0,72	0,73
2	0,66	0,71	0,69
Accuracy		0,76	



3) *Dfbc*:

Figura 49 - Correlation Report e Confusion Matrix per dfbc

Classe	Precision	Recall	f1-score
0	0,77	0,81	0,79
1	0,82	0,71	0,76
2	0,52	0,74	0,61
Accuracy		0,75	



Anche in questo caso, l'osservazione dei risultati ottenuti, tramite l'ausilio del *Classification Report* e della *Confusion Matrix*, risulta immediata: si ottengono dei risultati ottimi quando si va ad applicare il modello predittivo sul subset relativo alle rilevazioni di Standard & Poor's, mentre si può parlare di risultati sufficientemente buoni per l'analisi effettuata sulle altre due agenzie.

Bisogna però sottolineare come, nel caso di *dfbe*, si abbia un risultato non propriamente soddisfacente, in quanto l'*f1-score* relativo alla classe 2, e quindi alla classe relativa agli "*optimal grade investment*", risulti solo pari a 0,61. Questo score rappresenta dunque il risultato più basso in termini di *f1-score* di tutta l'analisi.

Per questo motivo, l'analisi condotta sul dataset comprensivo degli score ESG di pubblicazione della sola Egan-Jones dovrebbe quanto meno esser ponderato e calato in un'analisi più accurata.

In linea generale, nonostante gli ottimi risultati, si sottolinea come, eccezion fatta per *dfbs*, gli score ottenuti in termini di *Accuracy* e di *f1-score* per *dfbm* e *dfbe*, ci pongono davanti ad una questione. Infatti, questi presentano dei valori inferiori, non trascurabili, rispetto allo studio generale condotto su *dfb*, il quale presenta delle performance più elevate in tutti i casi.

Dunque, un'analisi così condotta potrebbe senz'altro andare a cogliere le differenze fra le varie agenzie, ma risulterebbe senz'altro limitata dal punto di vista della capacità predittiva del modello, che in questa fase rappresenta la nostra priorità.

È dunque consigliabile effettuare per questa tipologia di dataset, entrambe le analisi.

Infine, si sottolinea, facendo un paragone fra le performance del modello su *dfb*, *dfbs* e *dfbm* e su *dfr*, *dfrs* e *dfrm*, come nel caso dell'analisi condotta sui dataset comprensivi anche delle variabili ESG di Bloomberg, si ottengano risultati migliori (eccezion fatta per *dfbe* rispetto a *dfre*).

Questo conferma il delta delle performance delle analisi condotte su *dfb* e *dfr* e ci suggerisce che per aumentare la capacità predittiva del nostro modello, sia utile immettere all'interno dello studio gli *score* di pubblicazione in questione.

Anche questo risultato merita una considerazione accessoria nelle conclusioni dell'elaborato, in quanto dovrebbe portare la programmazione aziendale verso scelte strategiche ben precise riguardo alle pubblicazioni da fare.

10.4: Features importance (Annesso N)

Come ultimo passaggio dell'analisi predittiva, è stata analizzata l'importanza delle varie *features* all'interno dei singoli studi condotti. Questo è stato possibile con l'ausilio dell'attributo adattato "*feature_importances_*" con Python. In particolare, si analizza la media e la deviazione standard

dell'accumulo della diminuzione delle impurità presenti all'interno di ogni albero decisionale del modello utilizzato.

Per commentare i risultati, è interessante mettere a paragone *dfr* con *dfb*, *dfrs* con *dfbs*, *dfrm* con *dfbm* e *dfre* con *dfbe*.

Si premette che questo tipo di analisi, ci permette di fare delle osservazioni accessorie sulle *features* che abbiamo individuato nella fase di analisi della correlazione come più importanti.

In particolare, è utile per una eventuale ulteriore selezione di *features* e per comprendere il funzionamento sottostante alla performance di un modello.

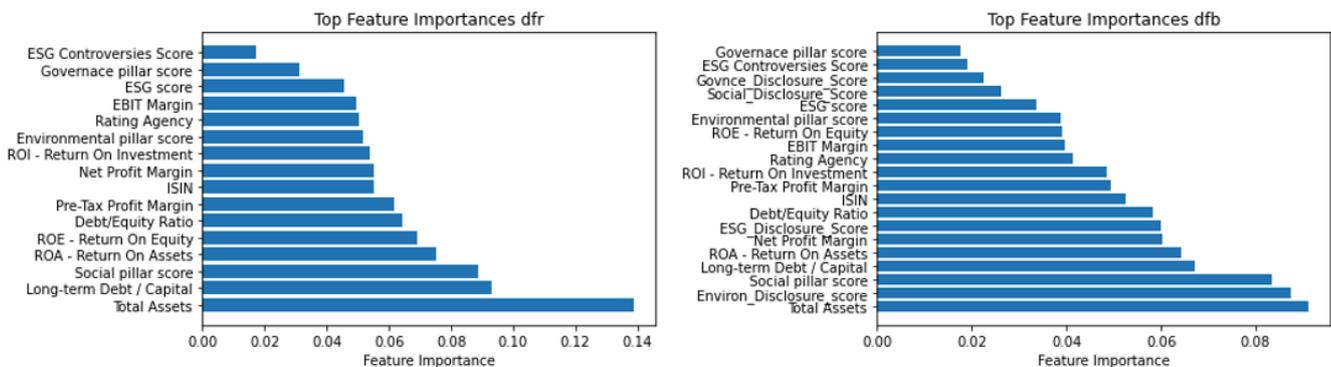
Quindi, visti gli ottimi risultati ottenuti all'interno degli algoritmi implementati nelle varie singole analisi, è sicuramente interessante andare ad analizzare come le discordanze fra le varie performance si siano create e come le variabili ESG abbiano influito su tale processo.

Questo rappresenta l'ultima analisi importante dello studio; analisi che dovrebbe garantire maggiore interpretabilità alle conclusioni finali di cui si parlerà nel prossimo capitolo.

Dunque, si procede come detto, riportando le rappresentazioni grafiche dell'importanza delle features all'interno dei nostri modelli.

1) *dfr* e *dfb*:

Figura 50 - Importanza delle features per *dfr* e *dfb*



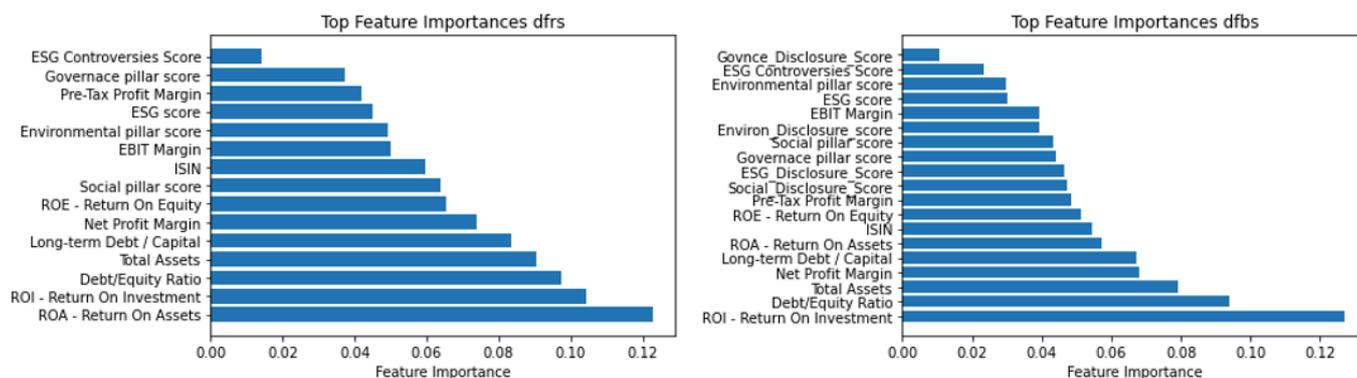
Le osservazioni più interessanti che emergono dai grafici riportati sono senz'altro:

- Si nota come la variabile finanziaria **Total Assets** inserita nell'analisi rappresenti la più rilevante in termini di incidenza sull'analisi predittiva. Questo sta a significare che la scelta di inserire tale variabile all'interno della nostra analisi, si è rivelata molto importante in termini di performance del modello;
- Nel caso di *dfr*, abbiamo come variabile ESG più importante quella relativa a **Social Pillar Score**. Questa rappresenta la terza più rilevante in termini relativi all'interno dell'analisi.
- In entrambe le analisi condotte, assistiamo ad un "salto" fra l'importanza delle tre migliori variabili con il resto delle metriche indagate.

- Nel caso di *dfb*, **Environmental Disclosure score** rappresenta la seconda variabile per importanza, a poca distanza da **Total Assets** e **Social Pillar score**, che invece sta al terzo posto. È molto interessante notare come in questo caso si abbia una metrica finanziaria, una ESG relativa alle performance effettive ed una relativa al livello di pubblicazioni. Dunque, lavorare su tutti e tre i campi, facendo attenzione alla specificità delle singole variabili in questione, permette di ottenere un ottimo livello di performance dell'algoritmo.
- In entrambi i casi, a parte le ultime 2/3 variabili che comunque rimangono in maniera cumulata estremamente rilevanti, anche a causa delle connessioni che hanno con le altre variabili ESG, abbiamo un grande blocco centrale di metriche che presentano importanza con scarti relativamente trascurabili. Questo si allinea a quanto evidenziato circa l'importanza di tutte le variabili precedentemente scelte, seppur persista un certo grado di differenza fra alcune di esse.
- In entrambi i casi, le variabili ESG spiegano cumulativamente una grande fetta di prevedibilità del modello.
- Nel modello applicato su *dfb*, si sottolinea la grande incidenza del livello di pubblicazione riguardo le tematiche ESG. Fra le prime 7 metriche per rilevanza, troviamo infatti 2 variabili relative agli score di *Bloomberg* ed una sola relativa agli score di *Refinitiv*.
- La variabile Social pillar score, presenta una grande importanza all'interno di queste analisi. Perciò le performance ottenute in termini sociali devono rappresentare un caposaldo delle strategie aziendali, anche se non possono prescindere dal contributo delle altre variabili per ottenere buoni risultati predittivi.
- Ogni metrica all'interno del modello contribuisce alla performance globale e non si hanno metriche con incidenza vicina allo zero. Si sostiene dunque che si possa pensare di mantenere la totalità di queste, per evitare perdite di informazioni.

2) *dfrs* e *dfbs*:

Figura 51 - Importanza delle features per *dfrs* e *dfbs*

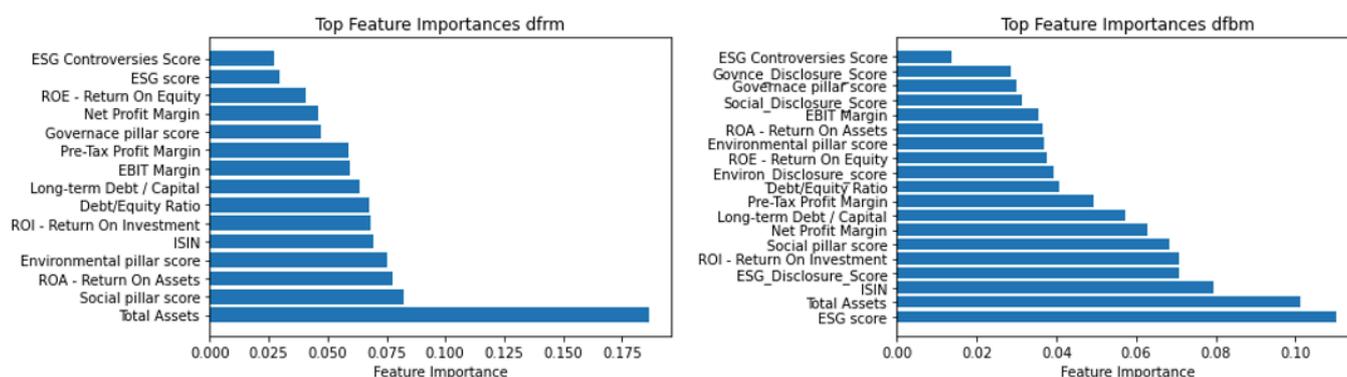


In questo caso, si indagano alcune controtendenze rispetto all'analisi precedente:

- *Total Assets* non rappresenta più la metrica con incidenza più alta. Si ha grande importanza in *dfrs* per il ROA e per *dfbs* per il ROI. Queste metriche staccano di qualche punto percentuale le restanti.
- Anche in questo caso, a parte le ultime 2/3 metriche, non si hanno enormi salti all'interno del blocco centrale, ma si assiste fondamentalmente ad una crescita graduale di importanza.
- Si assiste a dei risultati allineati alle conclusioni ottenute dall'analisi di correlazione effettuata sui due subset, in quanto si ha una leggera prevalenza della rilevanza delle metriche finanziarie. Dunque, seppur non si assista generalmente ad un netto distacco fra variabili finanziarie e ESG in termini di rilevanza, le prime tendono ad essere per Standard & Poor's leggermente più impattanti.
- Ancora una volta, si sottolinea come il peso cumulato delle variabili inserite in analisi sia estremamente rilevante ed anche in questo caso, si sostiene il mantenimento di tutte le variabili, in quanto il modello *performa* bene e si potrebbe prediligere il mantenimento di tutte le informazioni.
- *Social pillar score*, *Social disclosure score* e *ESG disclosure score*, rappresentano anche in questo caso variabili ESG molto importanti. A queste, si aggiunge nell'analisi in *dfbs* *Governance pillar score*, con un impatto maggiore al 4%.

3) *dfrm* e *dfbm*:

Figura 52 - Importanza delle features per *dfrm* e *dfbm*



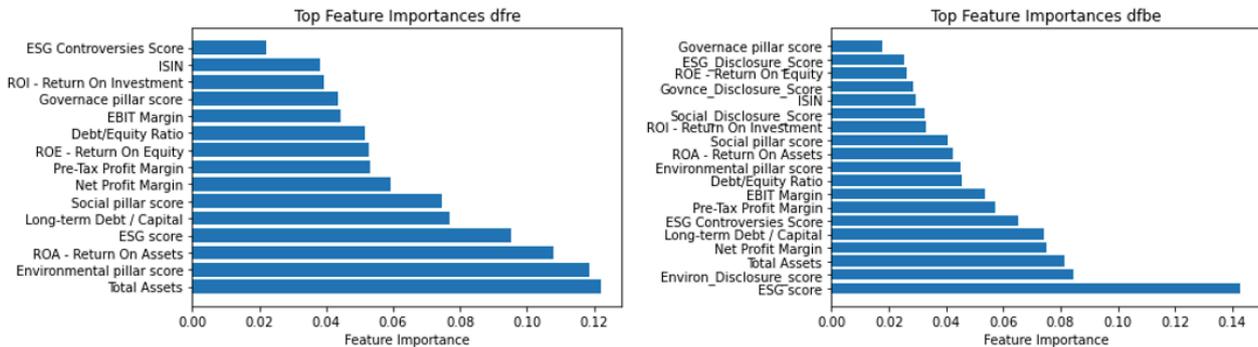
- Nell'analisi condotta su *dfrm*, assistiamo al salto senza dubbio maggiore in termini di rilevanza. *Total Assets*, infatti, mostra con largo distacco la sua maggiore importanza all'interno dell'analisi predittiva effettuata.
- In leggera controtendenza, nell'analisi svolta sul dataset comprensivo delle variabili di pubblicazione ESG estratte da Bloomberg, vediamo un salto meno netto con un'importante differenza. In questo caso, infatti, si ha ora una prevalenza della variabile ESG score, anche

rispetto a *Total Assets*. Inoltre, si segnala la grande importanza del livello di pubblicazioni relative ai criteri ESG.

- In entrambi i casi, si assiste anche a grande importanza della variabile *Social pillar score*.
- Anche in questo caso non si hanno irrilevanze tali da giustificare esclusioni particolari in quanto tutte le variabili portano un beneficio al modello.

4) *Dfre e dfbe*:

Figura 53 - Importanza delle features per *dfre* e *dfbe*



- Nell'analisi condotta relativamente all'agenzia Egan-Jones, si nota come si assista ad un salto importante in relazione all'applicazione del modello su *dfbe*. Questa analisi presenta, in particolare, l'ESG score come variabile nettamente più importante.
- Anche in questi casi, nel blocco centrale si assiste ad una crescita graduale e regolare delle importanze relative delle *features*.
- Questo è l'unica applicazione del modello su cui si sono espresse delle perplessità per quanto riguarda l'f1-score. In particolare, si fa riferimento all'analisi condotta su *dfbe*. Si potrebbe perciò pensare di fare una *feature reduction* per valutare eventuali benefici. Spetta a noi analizzare il *tradeoff* eventuale fra perdita di informazioni e miglioramento della prestazione dell'algoritmo, che rimane tutto sommato buona e soddisfacente.

Per concludere questa ultima fase di analisi, si sottolinea come tutte le variabili ESG indagate nell'elaborato, svolgano il loro ruolo anche all'interno della prevedibilità del Rating aziendale.

È interessante senz'altro osservare le variazioni che esistono fra le varie agenzie e fra le due analisi condotte su dataset intermedio (fase 2) e dataset finale (fase 3).

Questo aggiunge senz'altro spirito critico nella valutazione dei singoli casi che si trova ad affrontare l'azienda durante la sua attività.

I manager, dunque, possono utilizzare tale strumento per approfondire in maniera elaborata ciò che deve sottostare alla definizione della strategia messa in atto.

Come risultato principale, però, va sottolineato come tutte le situazioni abbiano presentato un apporto equilibrato fra variabili finanziarie e variabili ESG, che testimonia ancora una volta la tesi sostenuta all'interno dell'elaborato in questione.

Includere dunque questa tipologia di informazioni e sforzarsi di avere un approccio olistico alla questione, porta dunque a benefici quantificabili e misurabili in termini di prevedibilità e programmazione aziendale.

CAPITOLO 11: CONCLUSIONI

Passiamo ora in rassegna le principali conclusioni dello studio, andando ad effettuare una discussione generale su ciò che si è ottenuto, sottolineando le implicazioni manageriali che l'elaborato porta con sé e le sue limitazioni, che possono rappresentare un punto di partenza importante per il proseguo futuro dell'analisi.

11.1: Discussione generale ed implicazioni manageriali

L'elaborato in questione cerca di mettere in risalto alcune delle limitazioni e delle lacune metodologiche utilizzate per affrontare questo tipo di problemi multidisciplinari che, inevitabilmente, si presentano alle aziende quando si entra nel mondo reale.

Il *fil rouge* analizzato è quello che connette la realtà che spesso viene considerata come prettamente qualitativa del marketing, a quella che per definizione viene vista come più quantitativa della finanza. In particolare, questo studio, ha indagato ciò che sottostà alla valutazione della salute finanziaria aziendale e ciò che influenza e condiziona la sua prevedibilità. La questione risulta di primaria importanza per un'infinità di stakeholders, da coloro che ne devono studiare i profili di rischio nelle importantissime fasi di *Risk Assessment* aziendale, a coloro che invece hanno a che fare con l'azienda più o meno indirettamente, come i consumatori o gli investitori.

Una delle misurazioni che in questo ambito viene considerata in maniera più frequente è senza dubbio il *Credit Risk Rating*. Questa valutazione di rischio viene effettuata da agenzie specifiche che hanno lo scopo principale di andare ad alleviare l'asimmetria informativa che si crea fra le parti circa la salute aziendale, che in questo caso viene inquadrata dalla valutazione creditizia di tale realtà.

Queste agenzie, emettendo queste valutazioni, innescano conseguenze importantissime per le organizzazioni che vengono valutate, sia che si tratti di Stati (che a loro volta vengono valutati), sia che si tratti di aziende.

Queste ultime, dunque, con ricorrenza annuale si trovano ad affrontare conseguenze positive e/o negative derivanti da queste valutazioni e perciò spetta a loro decidere se inseguire una valutazione e comportarsi di conseguenza a posteriori, oppure provare ad indagare che cosa viene valutato e come poter reagire a priori alle possibili problematiche che possono andare a comportare una valutazione peggiore.

Dunque, questa misurazione pressoché finanziaria è in realtà permeata da tutte le funzioni della realtà aziendale; realtà aziendale che deve provare a programmare la propria strategia non in funzione di un *Credit Rating* subito, bensì di un *Credit Rating* influenzato dalle proprie scelte e decisioni.

Nelle prime fasi dell'elaborato, oltre alla descrizione di quanto appena detto, si è cercato di chiarire come la reputazione aziendale vada ad influenzare l'opinione sulla salute finanziaria delle organizzazioni e quindi come vada anche ad influenzare la valutazione che ne deriva. Quindi, ci si è domandati se e come questo avvenga davvero.

In particolare, essendo le agenzie molteplici ed essendo dunque le modalità di valutazione diverse e talvolta anche contrastanti tra loro, è importante cercare uno strumento che possa aiutare a generalizzare i risultati in modo tale da permettere al management aziendale di comportarsi di conseguenza.

Il modo per fare ciò è stato individuato in questo studio nell'applicazione di un modello di *Ensemble Learning* ed in particolare nel *Random Forest Classifier*, che è risultato uno degli algoritmi più utilizzati e con migliori performance nel panorama attuale.

Inoltre, lo studio propone di utilizzare misurazioni ESG pratiche ed affidabili che coprano quanti più ambiti possibile, per rappresentare nell'analisi la *Corporate Reputation*, dei quali essi sono parte integrante.

Questi criteri, infatti, rappresentano l'attualità e il futuro delle aziende e influenzano l'opinione pubblica e tutti i vari stakeholders coinvolti nell'attività quotidiana aziendale.

In particolare, con la scelta delle misurazioni di Refinitiv circa le performance aziendali riguardo ai criteri ESG e con la scelta delle misurazioni Bloomberg circa gli score di pubblicazione ESG, si ha una visione completa del quadro; una visione che ci permette di trarre anche importanti conclusioni su ciò che debba essere fatto dall'azienda in fase di attuazione della strategia di marketing aziendale, per esempio.

Infatti, come è stato dimostrato tramite le matrici di correlazione, queste variabili impattano in maniera estremamente concreta sulla valutazione di credito che viene fatta dalle agenzie, sia che si guardi al complesso, sia che si guardi alle rilevazioni relative alle singole agenzie stesse. Ciò comporta che i vertici aziendali e le varie funzioni coinvolte, debbano apprendere in profondità cosa questi criteri cerchino di comunicare e cosa cerchino di raggiungere, per far sì che gli *score* analizzati possano avere effetti benefici sostanziali. Infatti, si è visto come queste variabili abbiano un impatto paragonabile e in alcune occasioni superiore a quelle variabili finanziarie che vengono viste come principali fautrici delle valutazioni effettuate dalle agenzie.

Perciò, trascurare le più importanti, ma in generale, trascurare una qualsiasi di queste variabili, considerando anche il profondo legame che le variabili ESG in questione hanno l'un l'altra, potrebbe compromettere la reputazione aziendale e dunque la valutazione di credito successiva fatta su di essa, compromettendo a sua volta la salute aziendale ed a cascata tutte le funzioni interne alle organizzazioni. La concretezza dei risultati ottenuti, suggerisce anche come ad un determinato buon livello di pubblicazioni, debba corrispondere un buon livello di performance effettivamente raggiunta in campo ESG dall'azienda, in quanto si vede come queste due tipologie di variabili impattino pressoché nella stessa maniera sul *rating* effettuato.

Limitarsi ad una comunicazione estremamente spinta su queste tematiche senza poi far seguito con azioni concrete a quanto detto, dunque, non porterebbe ai benefici sperati, in quanto si avrebbe un impatto positivo solo parziale, con il possibile *tradeoff* negativo riguardo ad un aumento del rischio di controversie legate a queste materie, come il caso di un'accusa di *green washing*, che ora sappiamo avere una relazione estremamente negativa quantificabile con il Rating.

Tutto ciò, quindi, deve spingere ulteriormente i manager all'interno delle organizzazioni ad affrontare le questioni in maniera assolutamente bilanciata.

Un'altra conclusione ottenuta sempre da questa analisi di correlazione, è stata senz'altro quella di quantificare l'impatto delle questioni *Environment, Social e Governance*, che, alla luce di quanto osservato, devono essere tutte affrontate in maniera estremamente seria. Trascurare anche solo una di esse – che sia la *Governance*, ovvero quella con impatto positivo minore, anche se non trascurabile - o che sia qualsiasi altra componente, comprometterebbe direttamente l'impatto positivo sul Rating, ma anche indirettamente andando a diminuire quello generato dalla variabile ESG score complessiva. Un duplice effetto negativo che basta a incoraggiare le aziende a comportarsi di conseguenza.

E ancora, tutto ciò può e deve essere letto come possibilità concreta di porre il proprio focus su alcune variabili chiave, come effettuato nella fase di analisi predittiva in questo studio. Questo potrebbe

portare ad applicare un algoritmo predittivo volto a identificare la qualità dell'investimento sull'azienda, percepita dalle varie agenzie di rating (*Rating quality grade*).

In questa maniera, il management, viste le proprie performance in ambito finanziario ed in ambito ESG, potrebbe essere in grado di prevedere con una buona accuratezza quale potrebbe essere la valutazione di credito effettuata dalle agenzie nei propri confronti e nei confronti dei suoi competitor. Inoltre, dalla stessa analisi, emerge come l'impatto degli score relativi alle pubblicazioni aziendali in materia ESG, ovvero quelle variabili inserite a seguito dell'estrazione delle stesse da Bloomberg, generi un effetto positivo in termini di capacità predittiva dell'algoritmo. Si hanno, infatti, benefici diffusi sia in termini di *accuracy* che in termini di *f1-score*, che devono portare a fare delle attente riflessioni in materia.

Quindi, data la forte interconnessione tra gli elementi di questo studio, per ottenere migliori previsioni si potrebbe puntare a fare aumentare il proprio score di pubblicazione, comportando impatti positivi sia sul Rating che sulle altre variabili ESG. Variabili che però, ancora una volta, dovranno essere trattate in maniera egualitaria, per permettere all'azienda di godere di un beneficio concreto.

Questo potrebbe e dovrebbe indirizzare le mosse aziendali verso scelte strategiche adeguate, migliorando così la comunicazione interna all'azienda e lo scopo che questa deve perseguire, attraverso collaborazioni, iniziative positive, *advertising*, ecc.

L'obiettivo dell'azienda deve essere dunque quello di migliorare ed ampliare la conoscenza e la consapevolezza delle varie tematiche ESG all'interno di tutte le funzioni aziendali, evidenziando rischi e benefici di scelte programmate nell'una o nell'altra direzione. Si dovrebbe comprendere che ogni funzione deve andare a braccetto con l'altra, poiché dalle decisioni dell'una dipendono le sorti dell'altra e viceversa.

L'azienda, dunque, mostra così di poter essere vista come una scacchiera, dove ogni mossa ha una conseguenza in termini di possibilità e soprattutto di rischi; muovendosi in una direzione, si rischia di lasciare scoperta una pedina fondamentale della nostra organizzazione e di comprometterne la salute stessa.

11.2: Limitazioni e ricerche future

Per concludere l'elaborato, parliamo infine delle limitazioni riscontrate.

Sicuramente le limitazioni più grandi alle quali è stato necessario far fronte sono quelle relative ai dati ed alla loro tipologia.

In primo luogo, la costruzione del dataset, non è stato un processo lineare in quanto in letteratura non si trovano, ad oggi, dataframe con le caratteristiche ricercate in questo studio. Il dataset di partenza

(Fase 1), ha tuttavia rappresentato un ottimo inizio per la ricerca e l'analisi condotta, grazie anche al lavoro effettuato con l'estrazione dei dati ESG.

Altra limitazione sempre al riguardo dei dati, è senz'altro stata quella relativa alla mancanza di tutte le rilevazioni temporali per le aziende appartenenti al dataset di partenza. Infatti, quest'ultimo, fa riferimento ad un arco temporale che va dal 2010 al 2016, ovvero gli anni in cui i criteri ESG hanno cominciato ad affermarsi davvero. Per questo, le banche dati utilizzate, che, come detto, rappresentano le migliori fonti dalle quali estrarre i dati ricercati, hanno rappresentato un'ottima soluzione anche se non hanno potuto evitare una relativamente piccola perdita di informazioni che si è convertita in una diminuzione delle rilevazioni totali del dataset intermedio (Fase 2) e del dataset finale (Fase 3).

In ultima istanza, sempre riguardo ai dati, connesso a quanto abbiamo appena detto si ha il fatto che le rilevazioni fanno riferimento ad un arco temporale relativamente breve. Ciò è causato dal fatto che la materia, seppur studiata, lo è ancora oggi soprattutto con metodi tradizionali, che non prevedono l'analisi e lo studio dei Big Data. Si pronostica che, nei prossimi anni, con l'aumento delle attenzioni attorno alle questioni relative al *Machine Learning* e con l'aumento dei corsi universitari multidisciplinari che vanno ad istruire il mondo economico in questo ambito, saranno disponibili archi temporali più ampi ed un numero sicuramente maggiore di dataset al quale fare riferimento.

Quindi, le ricerche future vanno nella stessa direzione intrapresa dalla società e dalle istituzioni accademiche. Sarebbe dunque interessante sviluppare nuovi dataframe che permettano un bilanciamento maggiore all'interno delle classi scelte, in modo da poter andare ad analizzare ancora più nel dettaglio le previsioni possibili. Con questo si potrebbe, dunque, andare ancor più in profondità alla classificazione attualmente proposta che già rappresenta un passo in avanti rispetto a quella proposta dalla letteratura di partenza.

A seguito di ciò, si potrebbe poi pensare di aumentare ancor di più il numero delle variabili ESG ed in generale di variabili relative alla reputazione aziendale, senza andar in contro ad una perdita di dati ulteriore, testando nuovi classificatori e nuovi approcci al problema.

Tutto ciò garantirebbe l'approccio olistico la cui l'importanza si è ampiamente discussa nel testo elaborato, permettendo così grande programmabilità al management aziendale riguardo a campagne marketing particolari per la propria reputazione e riguardo a questioni finanziarie legate alla valutazione di credito.

BIBLIOGRAFIA

- Abdou H. & Pointon J. (2011). Credit scoring, statistical techniques and evaluation criteria: A review of the literature. *Intelligent Systems in Accounting, Finance & Management*, vol. 18 (2-3), pp. 59–88. DOI: [10.1002/ isaf.325](https://doi.org/10.1002/isaf.325).
- Ascarza E. (2018). Retention futility: Targeting high-risk customers might be ineffective. *Journal of Marketing Research*, vol. 55, pp. 80-98. DOI: [10.1509/jmr.16.0163](https://doi.org/10.1509/jmr.16.0163).
- Barakat A., Ashby S. & Fenn P. (2018). The reputational effects of analysts' stock recommendations and credit ratings: Evidence from operational risk announcements in the financial industry. *International Review of Financial Analysis*, vol. 55, pp. 1-22. DOI: <https://doi.org/10.1016/j.irfa.2017.10.011>.
- Bastos J. A. (2022). Predicting Credit Scores with Boosted Decision Trees. *Forecasting 2022*, vol. 4, pp. 925-935. DOI: <https://doi.org/10.3390/forecast4040050>.
- Berens G. e van Riel C. (2004). Corporate associations in the academic literature: Three main streams of thought in the reputation measurement literature. *Corporate Reputation Review*, vol. 7 (2), pp. 161-178. DOI: <https://doi.org/10.1057/palgrave.crr.1540218>
- Brown B. & Perry S. (1994). Removing the Financial Performance Halo From Fortune's “Most Admired” Companies. *Academy of Management Journal*, vol. 37 (5), pp. 1347-1359. DOI: <https://doi.org/10.2307/256676>
- Bush C. (2022). Dealing with the conflicts of interest of credit rating agencies: a balanced cure for the disease. *Capital Market Law Journal*, vol.17 (3), pp. 334-364. DOI: <https://doi.org/10.1093/cmlj/kmac012>.
- Caridad L., Nunez-Tabales J., Seda P. & Arencibia O. (2020). Do Moody’s and S&P Firm’s ratings differ?. *Economics & Sociology*, vol.13 (4), pp. 173-186. DOI: [10.14254/2071-789X.2020/13-4/11](https://doi.org/10.14254/2071-789X.2020/13-4/11).
- Chan T. J., Sathasevam T., Noor P. N. M., Khiruddin A. M., & Hasan N. A. M. (2018). Application of Selected Facets of RepTrak™ Reputation Model on Carlsberg Malaysia as One of the Companies in Tobacco, Gambling, Alcohol and Pornography (TGAP) Industry. *International Journal of Academic Research in Business and Social Sciences*, vol. 8(1). DOI: [10.6007/IJARBSS/v8-i1/3804](https://doi.org/10.6007/IJARBSS/v8-i1/3804).
- Choi T.M., Wallace S. W. & Wang Y. (2018). Big Data Analytics in Operations Management. *Production and Operations Management Society*, vol.27 (n°10), pp. 1868-1883. DOI: [10.1111/poms.12838](https://doi.org/10.1111/poms.12838).
- Cornford A. (2005). Basel II: The Revised Framework of June 2004. *United Nations Conference on Trade and Development*, vol. 178.

- Cristianini N. & Scholkopf B. (2002). Support Vector Machines and Kernel Methods: The New Generation of Learning Machines. *AI Magazine*, vol. 23 (3), pp. 31-41- DOI: <https://doi.org/10.1609/aimag.v23i3.1655>.
- Crook J. N., Edelman D. B. & Thomas L. C. (2007). Recent developments in consumer credit risk assessment. *European Journal of Operational Research*, vol. 183, pp. 1447-1465. DOI: [10.1016/j.ejor.2006.09.100](https://doi.org/10.1016/j.ejor.2006.09.100).
- Davies G. et al. 2001. The personification metaphor as a measurement approach for corporate reputation. *Corporate Reputation Review*, vol. 4, pp: 113-127. DOI: <https://doi.org/10.1057/palgrave.crr.1540137>.
- Duarte V., Zuniga-Jara S. & Contreras S. (2022). Machine learning and Marketing: a systematic literature review. *IEEE Access*, vol. 10, pp. 93273-93288. DOI: [10.1109/ACCESS.2022.3202896](https://doi.org/10.1109/ACCESS.2022.3202896).
- Durand, D. (1941). *Risk Elements in Consumer Instalment Financing*. National Bureau of Economic Research, New York.
- Eijffinger S. & Masciandro D. (2011). *Handbook of Central Banking, Financial Regulation and Supervision – After the financial crisis*. Edward Elgar Publishing Limited.
- Elahi E. (2013). *How Risk Management Can Turn into Competitive Advantage: Examples and Rationale*. University of Massachusetts Boston. DOI: [10.1108/14636681311321121](https://doi.org/10.1108/14636681311321121).
- Elkhoury M. (2008). *Credit Rating Agencies and Their Potential Impact on Developing Countries*. United Nations Conference on Trade and Development, vol.186.
- Emblemvag J. & Kjolstad L. E. (2002). Strategic risk analysis – a field vision. *Management decision* (40/9), pp. 842-852. DOI: [10.1108/00251740210441063](https://doi.org/10.1108/00251740210441063).
- Febra L., Costa M. & Pereira F. (2023). Reputation, return and risk: A new approach. *European Research on Management and Business Economics*, vol. 29 (1). DOI: <https://doi.org/10.1016/j.iedeen.2022.100207>.
- Fiordelisi F., Soana M. G. & Schwizer P. (2013). The determinants of reputational risk in the banking sector. *Journal of Banking & Finance*, vol. 37 (5), pp. 1359-1371. DOI: <https://doi.org/10.1016/j.jbankfin.2012.04.021>.
- Fombrun C. J., Ponzi L. J. & Newbury W. (2015). Stakeholder Tracking and Analysis: The RepTrak® System for Measuring Corporate Reputation. *Corporate Reputation Review*, vol. 18, pp. 3-24. DOI: <https://doi.org/10.1057/crr.2014.21>.
- Fryxell G. E. & Wang J. (1994). The Fortune Corporate 'Reputation' Index: Reputation for What?. *Journal of Management*, vol. 20 (1). DOI: <https://doi.org/10.1177/014920639402000101>.

- Harabor V., Mogos R., Nechita A., Adam A. et al., (2023). Machine learning approaches for the prediction of hepatitis B and C Seropositivity. *International journal of Environmental Research and Public Health*, vol. 20(3). DOI: <https://doi.org/10.3390/ijerph20032380>.
- Haspolat F.B. (2015). Analysis of Moody's Sovereign Credit Ratings: Criticism towards rating agencies are still valid?. *Procedia Economics and Finance*, vol.30, pp. 283-293. DOI: [10.1016/S2212-5671\(15\)01296-4](https://doi.org/10.1016/S2212-5671(15)01296-4).
- Himme A. & Fischer M. (2014). Drivers of the cost of capital: the joint role of non-financial metrics. *International Journal of Research in Marketing*, vol. 31, pp. 224-238. DOI: <https://doi.org/10.1016/j.ijresmar.2013.10.006>.
- Huang M. H. & Rust R. T. (2021). A strategic framework for artificial intelligence in Marketing. *Journal of the Academy of Marketing Science*, vol. 49, pp. 30-50. DOI: <https://doi.org/10.1007/s11747-020-00749-9>.
- Kanto D. S., de Run E. C. & Hassan A. (2016). The Reputation Quotient as a Corporate Reputation Measurement in the Malaysian Banking Industry: A Confirmatory Factor Analysis. *Procedia – Social and Behavioral Sciences*, vol. 219, pp. 409-415. DOI: <https://doi.org/10.1016/j.sbspro.2016.05.062>.
- Ketron S., Spears N. & Dai B. (2016). Overcoming information overload in retail environments: Imagination and sales promotion in a wine context. *Journal of Retailing and Consumer Services*, vol. 33, pp. 23-32. DOI: <https://doi.org/10.1016/j.jretconser.2016.07.017>.
- Khan S. & Digout J. (2018). The corporate reputation reporting framework (CRRF). *Corporate Reputation Review*, vol. 21, pp: 22-36. DOI: <https://doi.org/10.1057/s41299-017-0041-4>.
- Khemakhem S. & Boujelbene Y. (2015). Credit Risk Prediction: A Comparative Study between Discriminant Analysis and the Neural Network Approach. *Journal of Accounting and Management Information Systems*, The Bucharest University of Economic Studies, vol. 14 (1), pp. 60-78.
- Kosova T., Smerichevskiy S., Yaroshevska O., Smerichevska S. & Zamay O. (2022). Credit Risk Management: Marketing segmentation, Modeling, Accounting, Analysis and Audit. *Scientific Horizons*, vol. 25 (8), pp. 106-116. DOI: [10.48077/scihor.25\(8\).2022.106-116](https://doi.org/10.48077/scihor.25(8).2022.106-116).
- Kosova, T., Smerichevskiy, S., Ivashchenko, A. & Radchenko, H. (2021). Theoretical aspects of risk management models in economics, marketing, finance and accounting. *Financial and Credit Activity: Problems of Theory and Practice*, vol. 3(38), pp. 409-418. DOI: [10.18371/fcaptp.v3i38.237474](https://doi.org/10.18371/fcaptp.v3i38.237474).
- Kou G., Chao X., Peng Y., Alsaadi F.E. & Herrera-Viedma E., (2019). Machine learning methods for systemic risk analysis in financial sectors. *Technological and economic development of economy*, vol.25 (issue 5), pp. 716-742. DOI: <https://doi.org/10.3846/tede.2019.8740>.

- Kumar K. & Bhattacharya S. (2006). Artificial neural network vs linear discriminant analysis in credit ratings forecast. *Review of Accounting and Finance*, vol. 5 (3), pp. 216–227. DOI: [10.1108/14757700610686426](https://doi.org/10.1108/14757700610686426).
- L. Pastor, R. F. Stambaugh & L. A. Taylor. (2020). Sustainable Investing in Equilibrium. *Journal of Financial Economics*, vol. 142 (2), pp. 550-571. DOI: <https://doi.org/10.1016/j.jfineco.2020.12.011>.
- Li Y. & Chen W. (2020). A Comparative Performance Assessment of Ensemble Learning for Credit Scoring. *Mathematics 2020*, vol. 8 (10). DOI: <https://doi.org/10.3390/math8101756>.
- Luciano F., Diogo Ferreira, Julio Cezar & Adiel Teixeira. (2022). Preference Learning Applied to Credit Rating: Applications and Perspectives. *Multiple Criteria Decision Making*, pp. 121-137. DOI: [10.1007/978-3-030-96318-7_7](https://doi.org/10.1007/978-3-030-96318-7_7).
- Luo X. & Bhattacharya C. B. (2006). Corporate Social Responsibility, Customer Satisfaction, and Market Value. *Journal of Marketing*, vol. 70, pp. 1-18. DOI: <https://www.jstor.org/stable/30162111?origin=JSTOR-pdf>.
- Makwana R., Bhatt D., Delwadia K., Shah A. & Chaudhury B. (2022). How to Get Investment Grade Rating in the Age of Explainable Ai?. SSRN. DOI: <http://dx.doi.org/10.2139/ssrn.4163283>.
- Mark W., Kuldeep K. & Adrian G. (2022). Credit rating forecasting using machine learning techniques. *Research Anthology on Machine Learning Techniques, Methods and Applications*, pp. 734-752. DOI: [10.4018/978-1-6684-6291-1.ch039](https://doi.org/10.4018/978-1-6684-6291-1.ch039).
- Markov A., Seleznyova Z. & Lapshin V. (2022). Credit scoring methods: Latest trends and points to consider. *The journal of Finance and Data Science*, vol. 8, pp. 180-201. DOI: <https://doi.org/10.1016/j.jfds.2022.07.002>.
- Mashrur A., Luo W., Zaidi N. A. & Robles-Kelly A. (2020). Machine Learning for Financial Risk Management: A Survey. *IEEE Access*, vol. 8, pp. 203203-203223. DOI: [10.1109/ACCESS.2020.3036322](https://doi.org/10.1109/ACCESS.2020.3036322).
- OuYang Z., Xu J., Wei J & Liu Y. (2017). Information Asymmetry and Investor Reaction to Corporate Crisis: Media Reputation as a Stock Market Signal. *Journal of Media Economics*, vol. 30 (2), pp. 82-95. DOI: <https://doi.org/10.1080/08997764.2017.1364256>.
- Raithel S. & Schwaiger M. (2012). Evaluating Corporate Reputation: The Link with Corporate Financial Performance. *Research Gate*. DOI: [10.1007/978-1-137-29257-5_22](https://doi.org/10.1007/978-1-137-29257-5_22).
- Regolamento (CE) N. 1060/2009 del Parlamento Europeo e del Consiglio del 16 settembre 2009 relativo alle agenzie di rating del credito. (VERIFICARE COME CITARE)
- Ritter J. & Beatty R. P. (1986). Investment banking, reputation, and the underpricing of initial public offerings. *Research Gate*. DOI: [10.1016/0304-405X\(86\)90055-3](https://doi.org/10.1016/0304-405X(86)90055-3).

- Rust R.T. & Huang M.H. (2014). The service revolution and the transformation of Marketing Science. *Marketing Science*, vol. 33(2), pp. 206-221. DOI: <http://dx.doi.org/10.1287/mksc.2013.0836>.
- Shian-Chang H. (2011). Using Gaussian process-based kernel classifiers for credit rating forecasting. *Expert Systems with Applications*, vol. 38 (7), pp. 8607–8611. DOI: [10.1016/j.eswa.2011.01.064](https://doi.org/10.1016/j.eswa.2011.01.064).
- Stepanova M. & Thomas L. C. (2001). PHAB scores: proportional hazards analysis behavioural scores. *Journal of the Operational Research Society*, vol. 52, pp. 1007-1016. DOI: <https://doi.org/10.1057/palgrave.jors.2601189>.
- T. Duan, F. W. Li & R. Michaely. (2022). Consumer Reactions to Corporate ESG Performance: Evidence from Store Visits.
- T. R. Teor, I. A. Ilyna & V. V. Kulibanova. (2022). The Influence of ESG-concept on the Reputation of High-technology Enterprises. *IEEE Xplore*. DOI: [10.1109/ComSDS55328.2022.9769074](https://doi.org/10.1109/ComSDS55328.2022.9769074)
- von Clausewitz C.M., (1997). *On War*. Wordsworth Editions, Ware, p. 373.
- Wang M. & Ku H. (2021). Utilizing historical data for corporate credit rating assessment. *Expert Systems with Applications*, vol. 165. DOI: <https://doi.org/10.1016/j.eswa.2020.113925>.
- Webb E. C. & Shu S. B. (2018). The effect of perceived similarity on sequential risk taking. *Journal of Marketing Research*, vol. 55(2). DOI: [10.1177/0022243718810800](https://doi.org/10.1177/0022243718810800).
- Wu H. C. & Wu Y. T. (2016). Evaluating credit rating prediction by using the KMV model and random forest. *Kybernetes*, vol. 45 (10), pp. 1637–1651. DOI: [10.1108/K-12-2014-0285](https://doi.org/10.1108/K-12-2014-0285).
- Yang X., Bai j. & Wang X., (2022). Construction and risk analysis of Marketing system based on deep neural network. *Security and communication networks*, vol.2022. DOI: <https://doi.org/10.1155/2022/4454283>.
- Žabkar V. & Arslanagić-Kalajdžić M. (2013). The Impact of Corporate Reputation and Information Sharing on Value Creation for Organizational Customers. *South East European Journal of Economics and Business*, vol. 8 (2), pp. 42-52. DOI: <https://doi.org/10.2478/jeb-2013-0009>.
- Zhang S., Xu J., Zhang Q. J. & Root D. E. (2016). Parallel matrix neural network training on cluster systems for dynamic FET modeling from large datasets. 2016 IEEE MTT-S international microwave symposium (IMS), pp. 1-3. DOI: [10.1109/MWSYM.2016.7540387](https://doi.org/10.1109/MWSYM.2016.7540387).
- Zhao Yi, Zhao Ying & Song I. (2009). Predicting New Customers' Risk Type in the Credit Card Market. *Journal of Marketing Research*, vol. 46 (4), pp. 506-517. DOI: <https://doi.org/10.1509/jmkr.46.4.506>.

SITOGRAFIA

- Angelini Industries. (2023). Quando “il prendersi cura” è Passato, Presente e Futuro. <https://www.angeliniindustries.com/storie/unwavering-care/quando-il-prendersi-cura-e-passato-presente-e-futuro/>.
- Bacham D. & Zhao J. (2017). Machine Learning: Challenges, Lessons, and Opportunities in Credit Risk Modeling. <https://www.moodyanalytics.com/risk-perspectives-magazine/managing-disruption/spotlight/machine-learning-challenges-lessons-and-opportunities-in-credit-risk-modeling>.
- Bahillo J. A., Ganguly S., Kremer A. & Kristensen I. (2016). The value in digitally transforming credit risk management. McKinsey&Company, Risk & Resilience. <https://www.mckinsey.com/capabilities/risk-and-resilience/our-insights/the-value-in-digitally-transforming-credit-risk-management>.
- Balaji A., Janardhanan R., Johnston S. & Kaka N. (2018). How predictive analytics can boost product development. McKinsey & Company. <https://www.mckinsey.com/industries/technology-media-and-telecommunications/our-insights/how-predictive-analytics-can-boost-product-development>.
- Bergman M. S. (2020). Introduction to ESG. Harvard Law School Forum on Corporate Governance. <https://corpgov.law.harvard.edu/2020/08/01/introduction-to-esg/>.
- Brea C., Bicanic S., Li Y. & Bhardwaj S. (2020). Predicting Consumer Demand in an Unpredictable World. Harvard Business Review. <https://hbr.org/2020/11/predicting-consumer-demand-in-an-unpredictable-world>.
- Chui M., Henke N. & Miremadi M. (2019). Most of AI’s business uses will be in two areas. <https://www.mckinsey.com/capabilities/quantumblack/our-insights/most-of-ais-business-uses-will-be-in-two-areas>.
- Chui M., Manyika J, Miremadi M., Henke N., et al. (2018). Notes from the AI frontier, insights from hundreds of use cases. McKinsey&Company, McKinsey Global Institute, Discussion paper. <https://www.mckinsey.com/west-coast/~media/McKinsey/Featured%20Insights/Artificial%20Intelligence/Notes%20from%20the%20AI%20frontier%20Applications%20and%20value%20of%20deep%20learning/Notes-from-the-AI-frontier-Insights-from-hundreds-of-use-cases-Discussion-paper.pdf>.
- Consumer Financial Protection Bureau. (2022). What is a credit score?. CFPB. <https://www.consumerfinance.gov/ask-cfpb/what-is-a-credit-score-en-315/>.
- Corporate Finance Institute Staff. (2022). Rating agencies, Evaluating the creditworthiness of debt-issuing companies and organizations. Corporate Finance Institute. <https://corporatefinanceinstitute.com/resources/fixed-income/rating-agency/>.

- Corporate Finance Institute Team. (2023). Credit Risk Analysis Models. Corporate Finance Institute. <https://corporatefinanceinstitute.com/resources/commercial-lending/credit-risk-analysis-models/>.
- Council on Foreign Relations Staff. (2015). The Credit Risk Controversy. Council on Foreign Relations Staff. <https://www.cfr.org/background/credit-rating-controversy>
- D. O'Brien, A. Main, S. Kounkel & Stephan A. R. (2019). Purpose is everything. Deloitte Insights. <https://www2.deloitte.com/us/en/insights/topics/marketing-and-sales-operations/global-marketing-trends/2020/purpose-driven-companies.html>.
- Dash R., Kremer A., Nario L. & Waldron D. (2017). Risk analytics enters its prime. McKinsey&Company. <https://www.mckinsey.com/~media/McKinsey/Business%20Functions/Risk/Our%20Insights/Risk%20analytics%20enters%20its%20prime/Risk-analytics-enters-its-prime.pdf>.
- David E. (2022). Viral chatbot ChatGPT will be overhyped, then overlooked, and then, perhaps, essential. Business Insider. <https://www.businessinsider.com/chatgpt-will-be-overhyped-overlooked-and-then-perhaps-essential-2022-12?r=US&IR=T>.
- Deloitte Access Economics. (2017). Business impacts of machine learning. https://www2.deloitte.com/content/dam/Deloitte/tr/Documents/process-and-operations/TG_Google%20Machine%20Learning%20report_Digital%20Final.pdf.
- Deloitte. (2022). #1 What is ESG? – ESG Explained. Deloitte. <https://www2.deloitte.com/ce/en/pages/global-business-services/articles/esg-explained-1-what-is-esg.html>.
- Diebner R., Malfara D., Neher K., Thompson M. & Vancauwenberghe M. (2021). Prediction: The future of CX. McKinsey Quarterly. <https://www.mckinsey.com/capabilities/growth-marketing-and-sales/our-insights/prediction-the-future-of-cx>.
- Dow Jones. (2022). ESG: The New Dimension of Reputation Management. Dow Jones. <https://www.dowjones.com/professional/resources/blog/the-new-dimension-of-reputation-management>.
- Eccles R. G., Newquist S. C. & Schatz R. (2007). Reputation and Its Risks. Harvard Business Review. <https://hbr.org/2007/02/reputation-and-its-risks>.
- European Economic and Social Committee. (2016). EESC Study on Planned Obsolescence. EESC. <https://www.eesc.europa.eu/sites/default/files/resources/docs/factsheet-en.pdf>.
- Fiorio L., Mau R., Stietz J. & Welander T. (2014). New frontiers in credit card segmentation: Tapping unmet consumer needs. McKinsey. https://www.mckinsey.com/~media/mckinsey/dotcom/client_service/financial%20services/latest%20thinking/payments/mop19_new%20frontiers%20in%20credit%20card%20segmentation.ashx.

- Fortune. (2019). World's most admired companies. <https://fortune.com/ranking/worlds-most-admired-companies/>.
- GDS Link. (2023). 10 Major Challenges of Credit Risk Management in Banks. <https://www.gdslink.com/10-major-challenges-of-credit-risk-management-in-banks/>.
- Harikrishnan N. B. (2019). Confusion Matrix, Accuracy, Precision, Recall, F1 Score. Medium, Analytics Vidhya. <https://medium.com/analytics-vidhya/confusion-matrix-accuracy-precision-recall-f1-score-ade299cf63cd>.
- Hemp P. (2009). Death by Information Overload. Harvard Business Review. <https://hbr.org/2009/09/death-by-information-overload>.
- Hendricks L. (2022). How marketing Teams can tackle the challenge that is ESG. Forbes. <https://www.forbes.com/sites/forbescommunicationscouncil/2022/03/21/how-marketing-teams-can-tackle-the-challenge-that-is-esg/?sh=40a334d61841>.
- Korn Ferry's staff. (2022). FORTUNE World's Most Admired Companies 2022. Korn Ferry. <https://www.kornferry.com/insights/this-week-in-leadership/fortune-worlds-most-admired-companies-2022>.
- Koulouridi E., Kumar S., Nario L., Papanides T. e Vettori M. (2020). Managing and monitoring credit risk after the COVID-19 pandemic. McKinsey & Company. (<https://www.mckinsey.com/capabilities/risk-and-resilience/our-insights/managing-and-monitoring-credit-risk-after-the-covid-19-pandemic>).
- Lutins E. (2017). Ensemble methods in Machine Learning: What are they and why use them? Towards data science. <https://towardsdatascience.com/ensemble-methods-in-machine-learning-what-are-they-and-why-use-them-68ec3f9fef5f>.
- Makhjani C. (2020). Advanced Ensemble Learning Techniques. Towards Data Science. <https://towardsdatascience.com/advanced-ensemble-learning-techniques-bf755e38cbfb>.
- Nielsen (2019). How does The HarrisPoll Reputation Quotient measure corporate reputation?. Twitter. <https://twitter.com/nielsen/status/700738069499142145>.
- Open knowledge team. (2021). Zeneration Time – Work, ambitions and attitudes from A to Gen Z. Harvard Business Review Italia. https://www.open-knowledge.it/wp-content/uploads/2022/02/HBR_Zeneration_time.pdf.
- PWC (2021). Beyond compliance: Consumers and employees want business to do more on ESG - How business can close the expectations gap. <https://www.pwc.com/us/en/services/consulting/library/consumer-intelligence-series/consumer-and-employee-esg-expectations.html>.

- PWC (n.d.). Environmental, Social & Governance - What's it all about?. <https://www.pwc.com/mt/en/publications/sustainability/esg-what-is-it-all-about.html>.
- PWC. (2021). Beyond compliance: Consumers and employees want business to do more on ESG - How business can close the expectations gap. <https://www.pwc.com/us/en/services/consulting/library/consumer-intelligence-series/consumer-and-employee-esg-expectations.html>.
- R. V. Vargas. (2023). Marketing is killing ESG. Here's how we can save it. London School of Economics and Political Science. <https://blogs.lse.ac.uk/businessreview/2023/01/31/marketing-is-killing-esg-heres-how-we-can-save-it/>.
- Rand B. (2023). After High-Profile Failures, Can Investors still Trust Credit Ratings? Harvard Business School. <https://hbswk.hbs.edu/item/after-high-profile-failures-can-investors-still-trust-credit-ratings>.
- 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.
- Silva P. (2021). Speed Is The Most Important Thing For Your Business' Profitability - Here's Why. Forbes. <https://www.forbes.com/sites/piasilva/2021/06/01/speed-is-the-most-important-thing-for-your-business-profitability---heres-why/>.
- Singh A. (2023). A Comprehensive Guide to Ensemble Learning (with Python codes). Analytics Vidhya. <https://www.analyticsvidhya.com/blog/2018/06/comprehensive-guide-for-ensemble-models/>.
- Standard & Poor's. (2011). Guide to Credit Rating Essentials – What are credit ratings and how they work?. S&P. https://img.en25.com/Web/StandardandPoors/SP_CreditRatingsGuide.pdf.
- Standard & Poor's. (n.d.). Intro To Credit Ratings. <https://www.spglobal.com/ratings/en/about/intro-to-credit-ratings>.
- Stobierski T. (2020). 4 Steps to determine the financial health of your company. Harvard Business School. <https://online.hbs.edu/blog/post/how-to-determine-the-financial-health-of-a-company>.

ANNESI

ANNESNO A: Matrici di Correlazione del Dataset Intermedio (Fase 2)

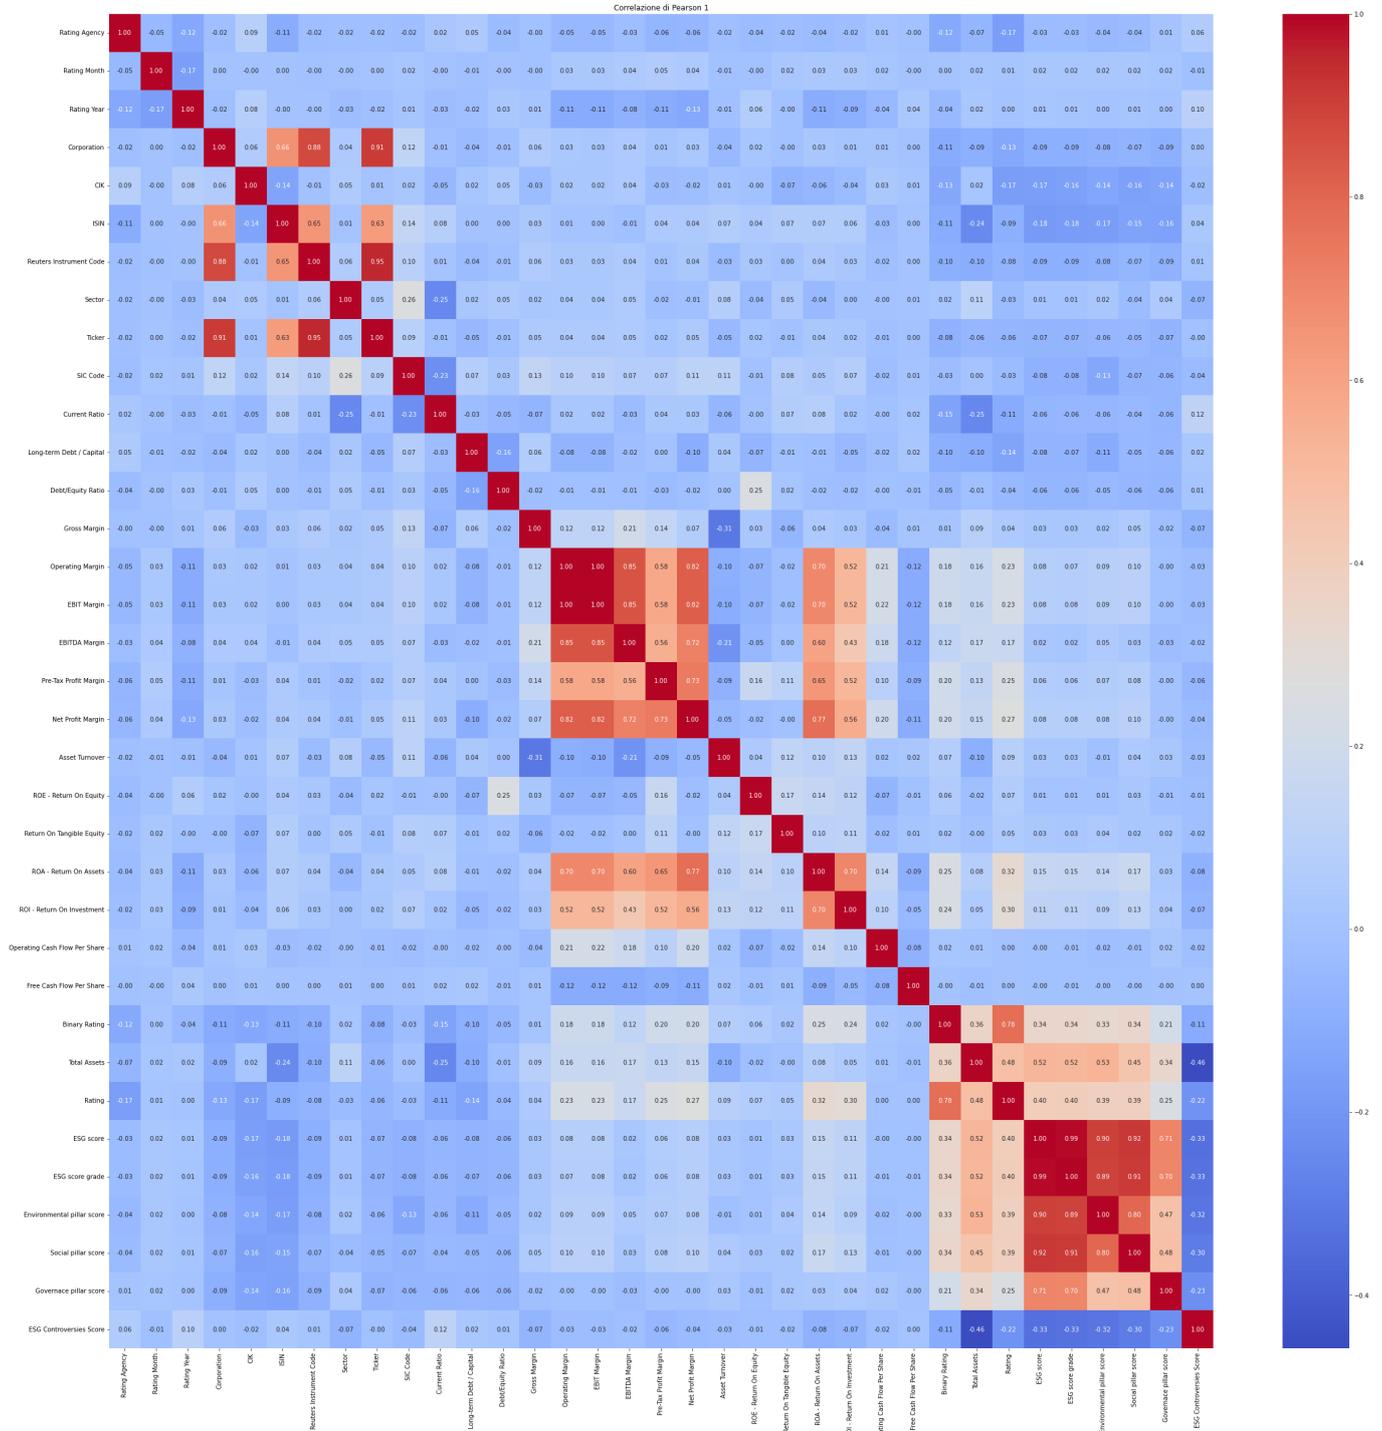
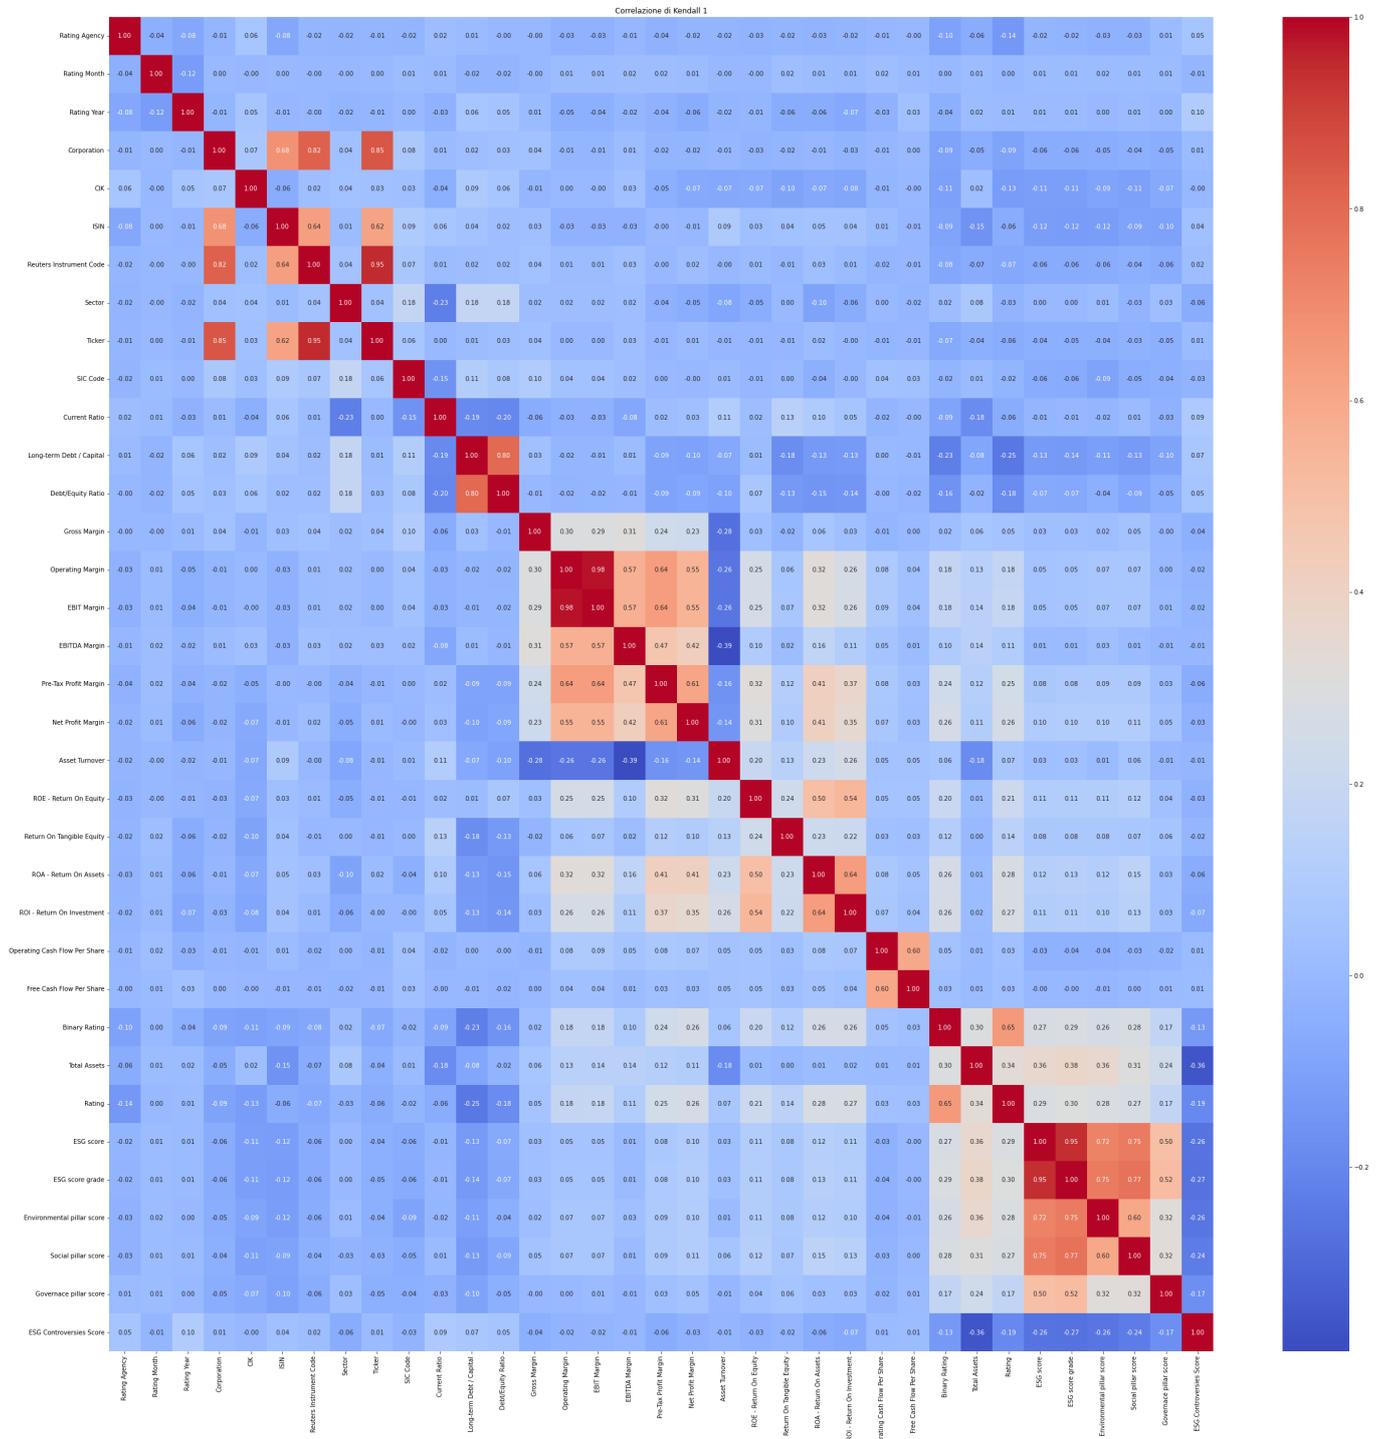
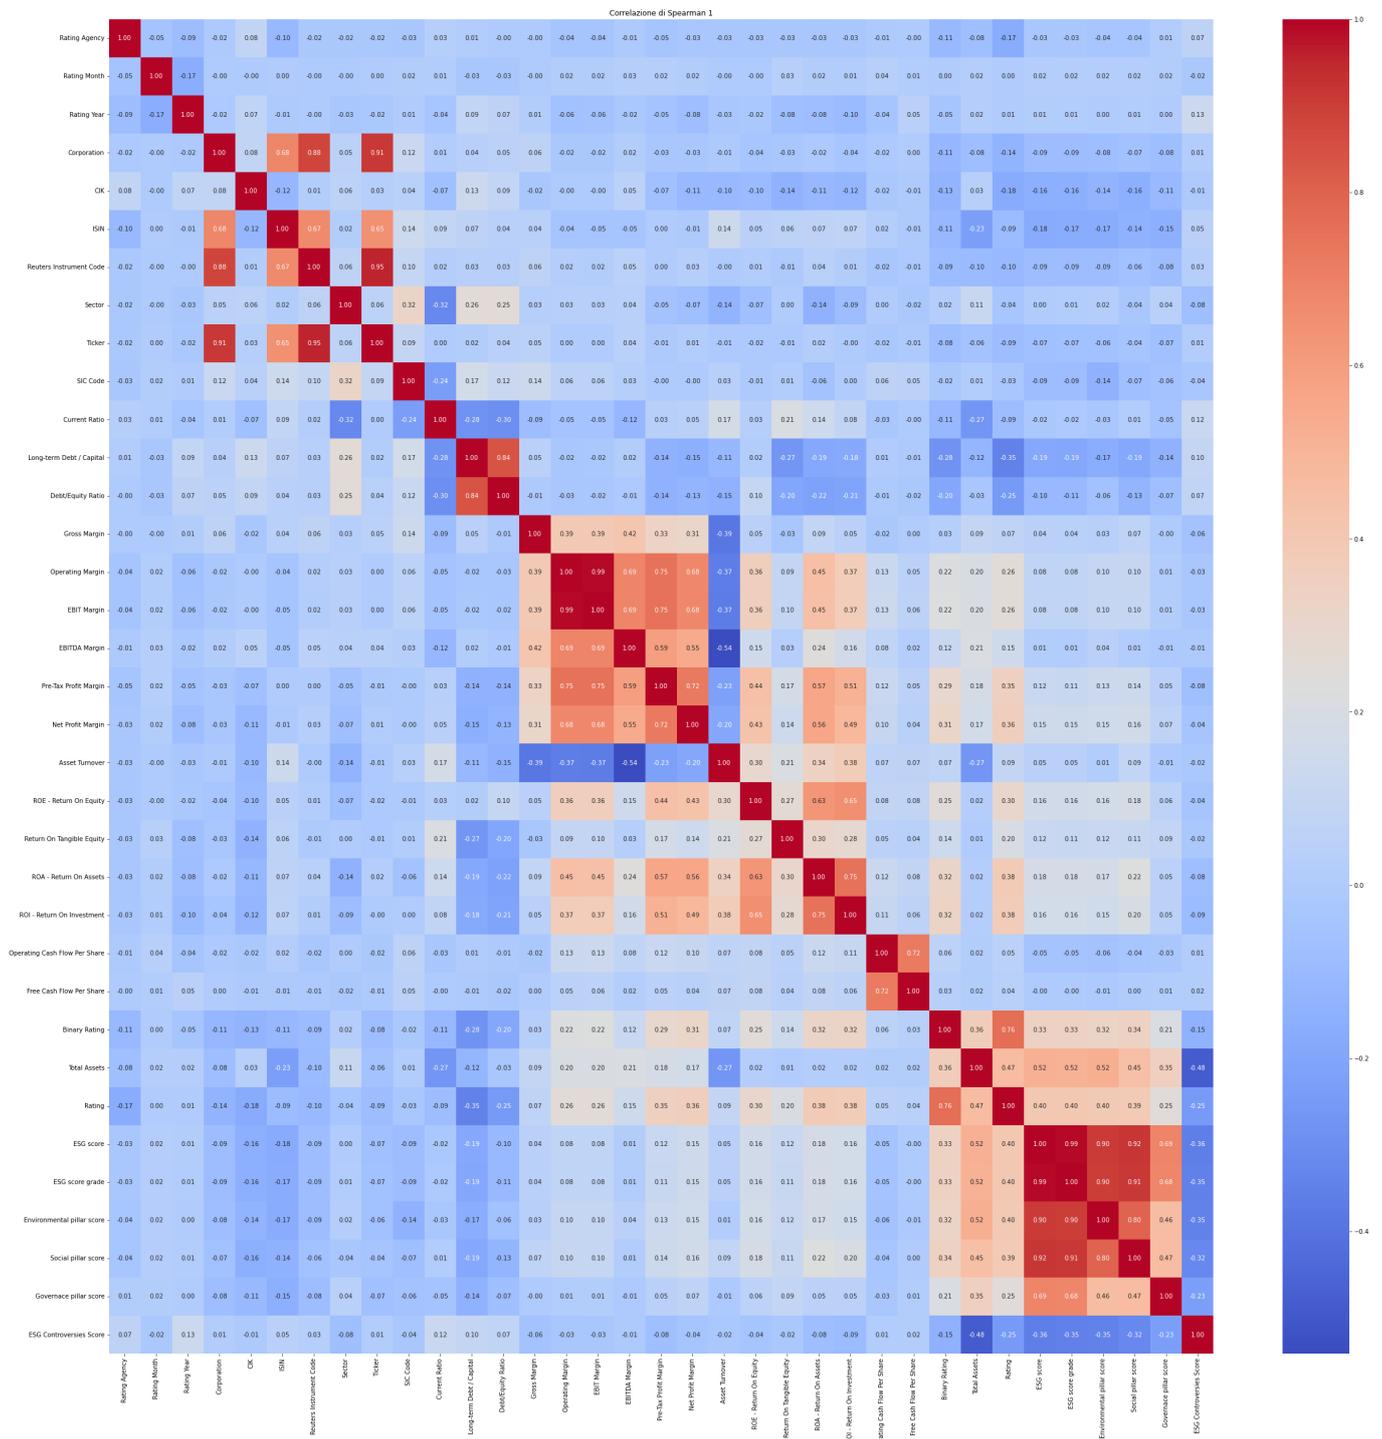
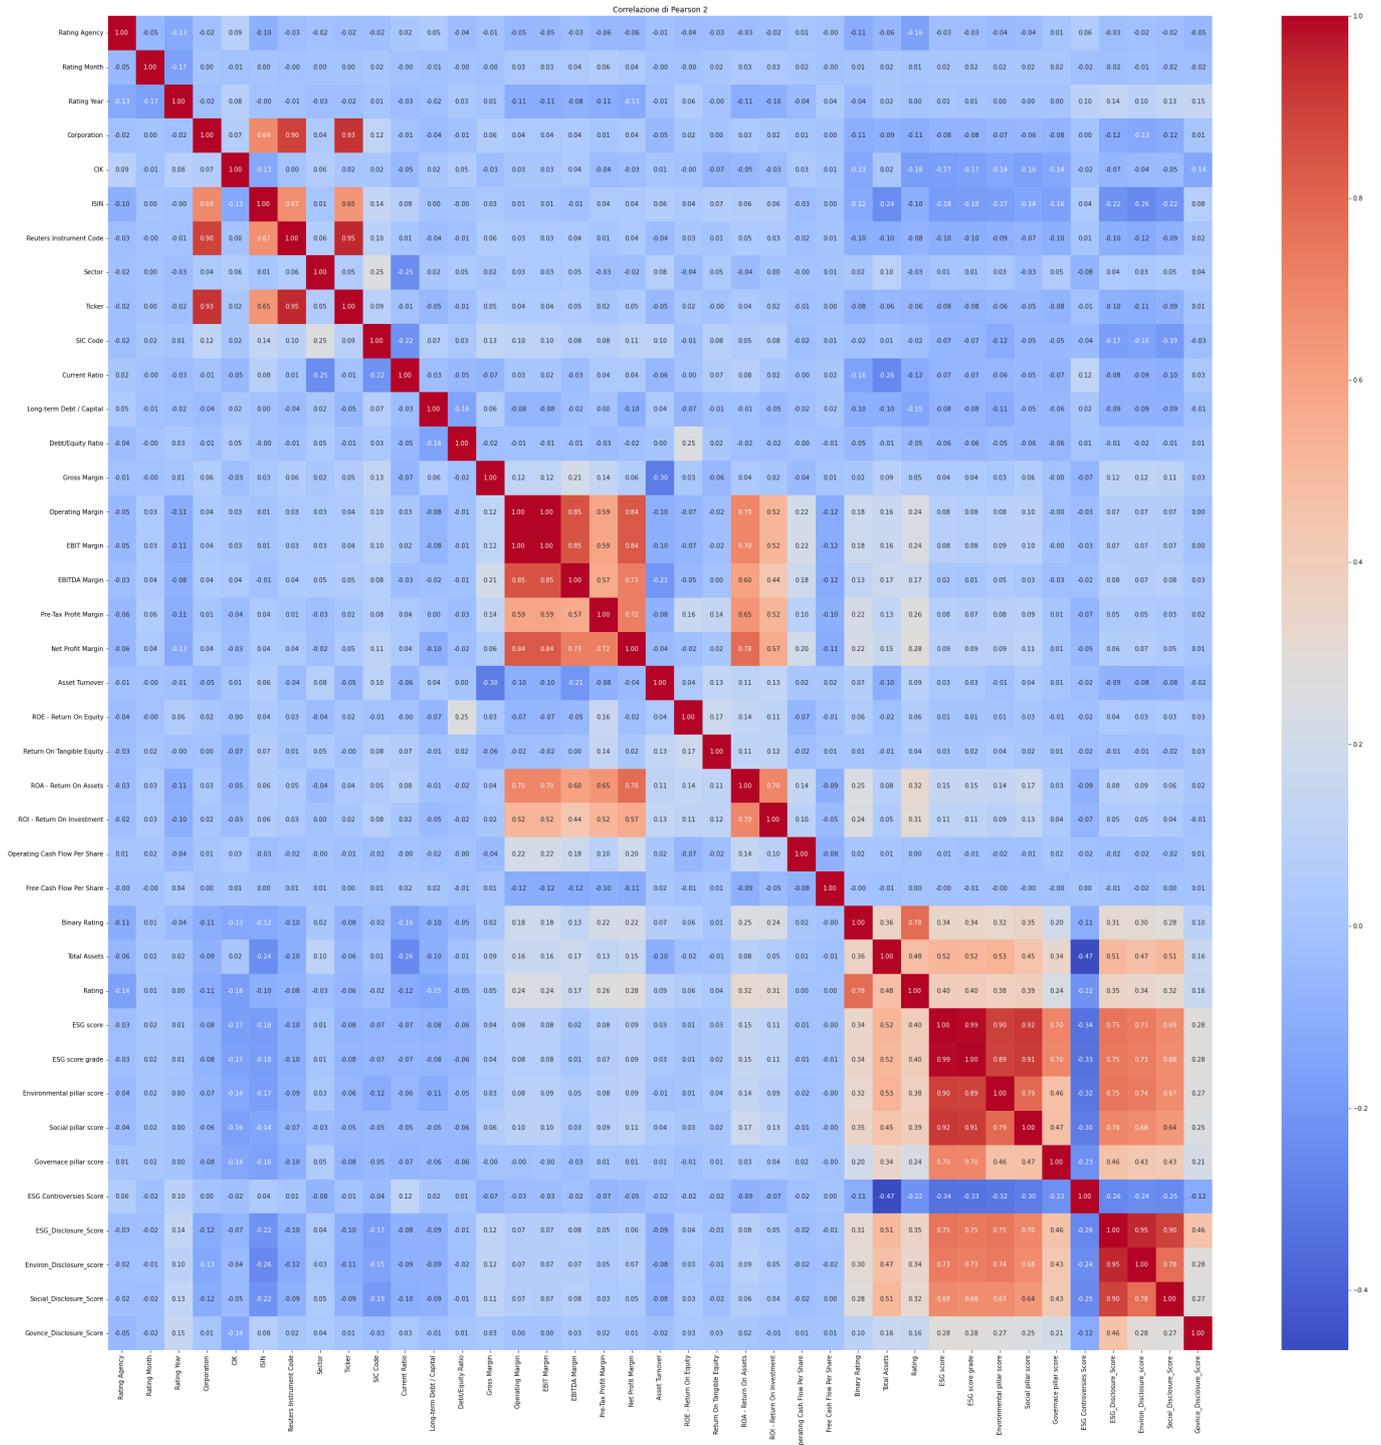


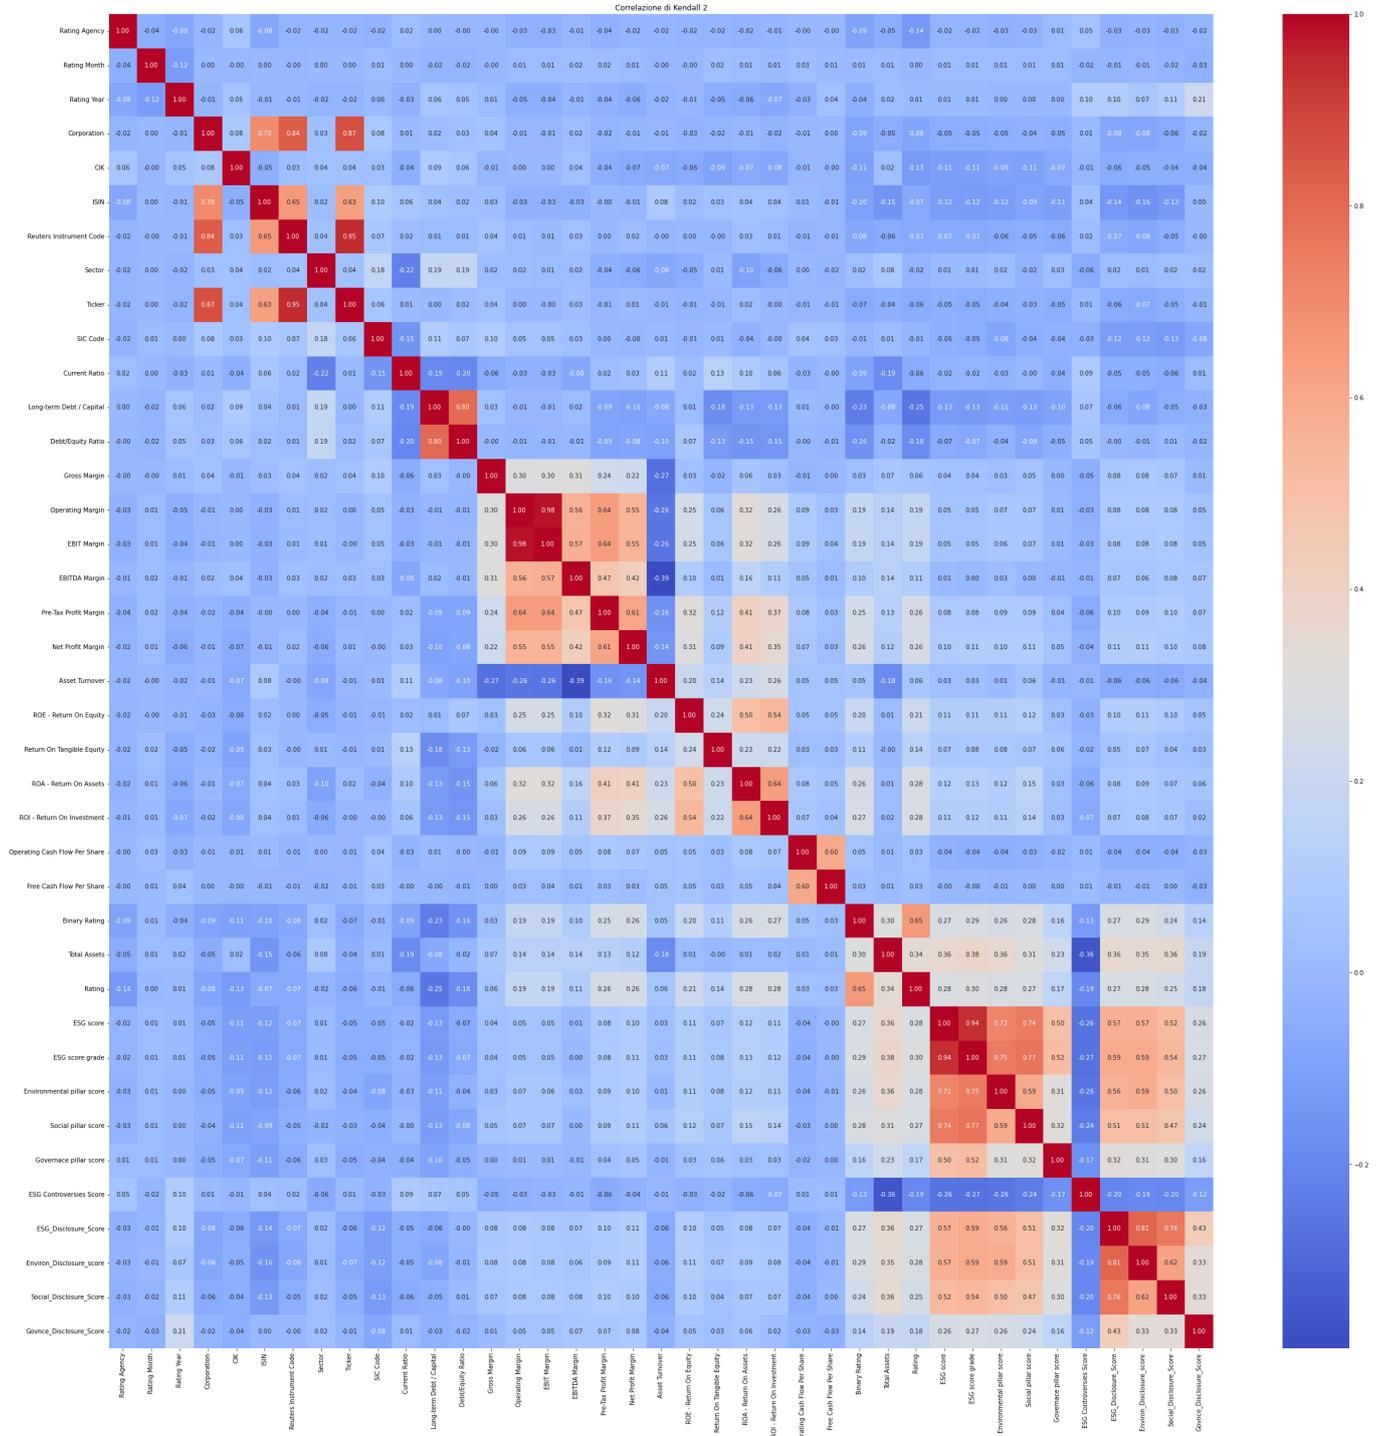
Figura 54 - Matrice di Correlazione di Pearson per dfref





ANNESSE B: Matrici di Correlazione del Dataset Finale (Fase 3)





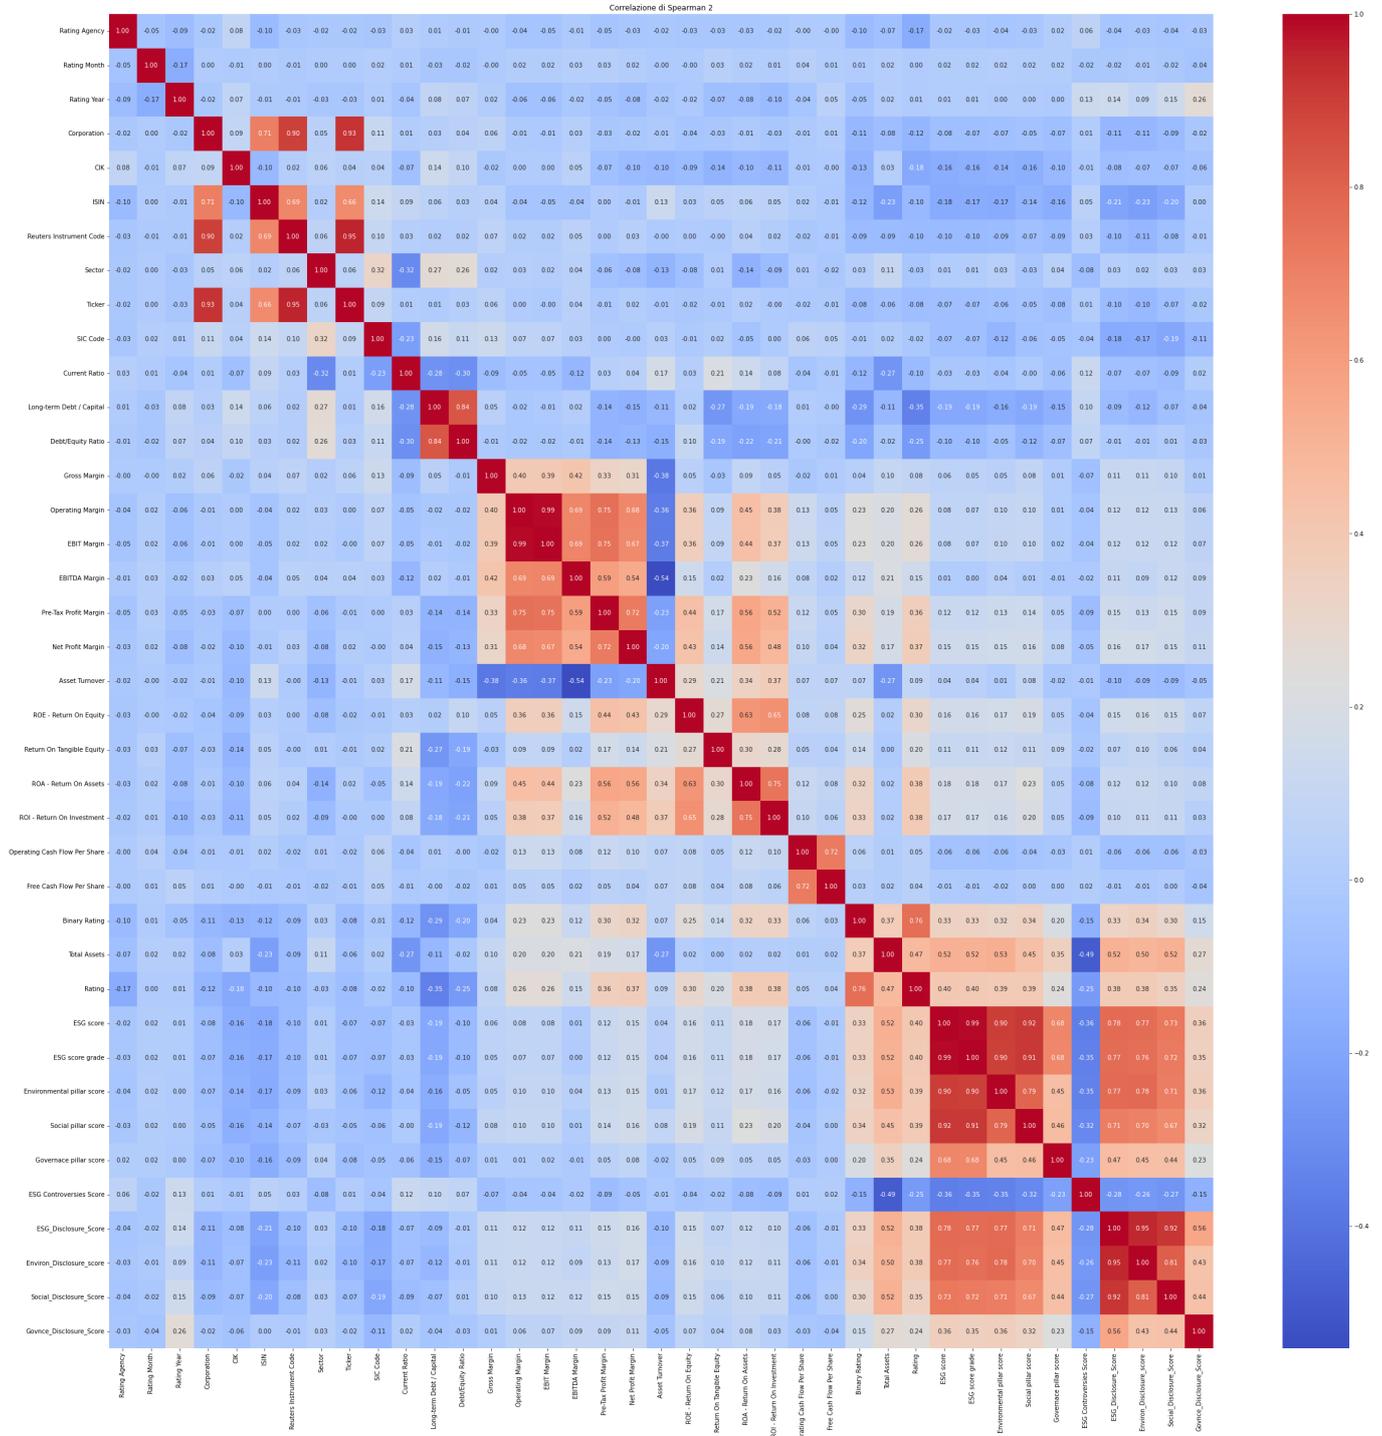


Figura 59 - Matrice di Correlazione di Spearman per dfblo

ANNESSE C: Matrici di Correlazione del Dataset intermedio ridotto con solo le rilevazioni S&P (dfref_sp)

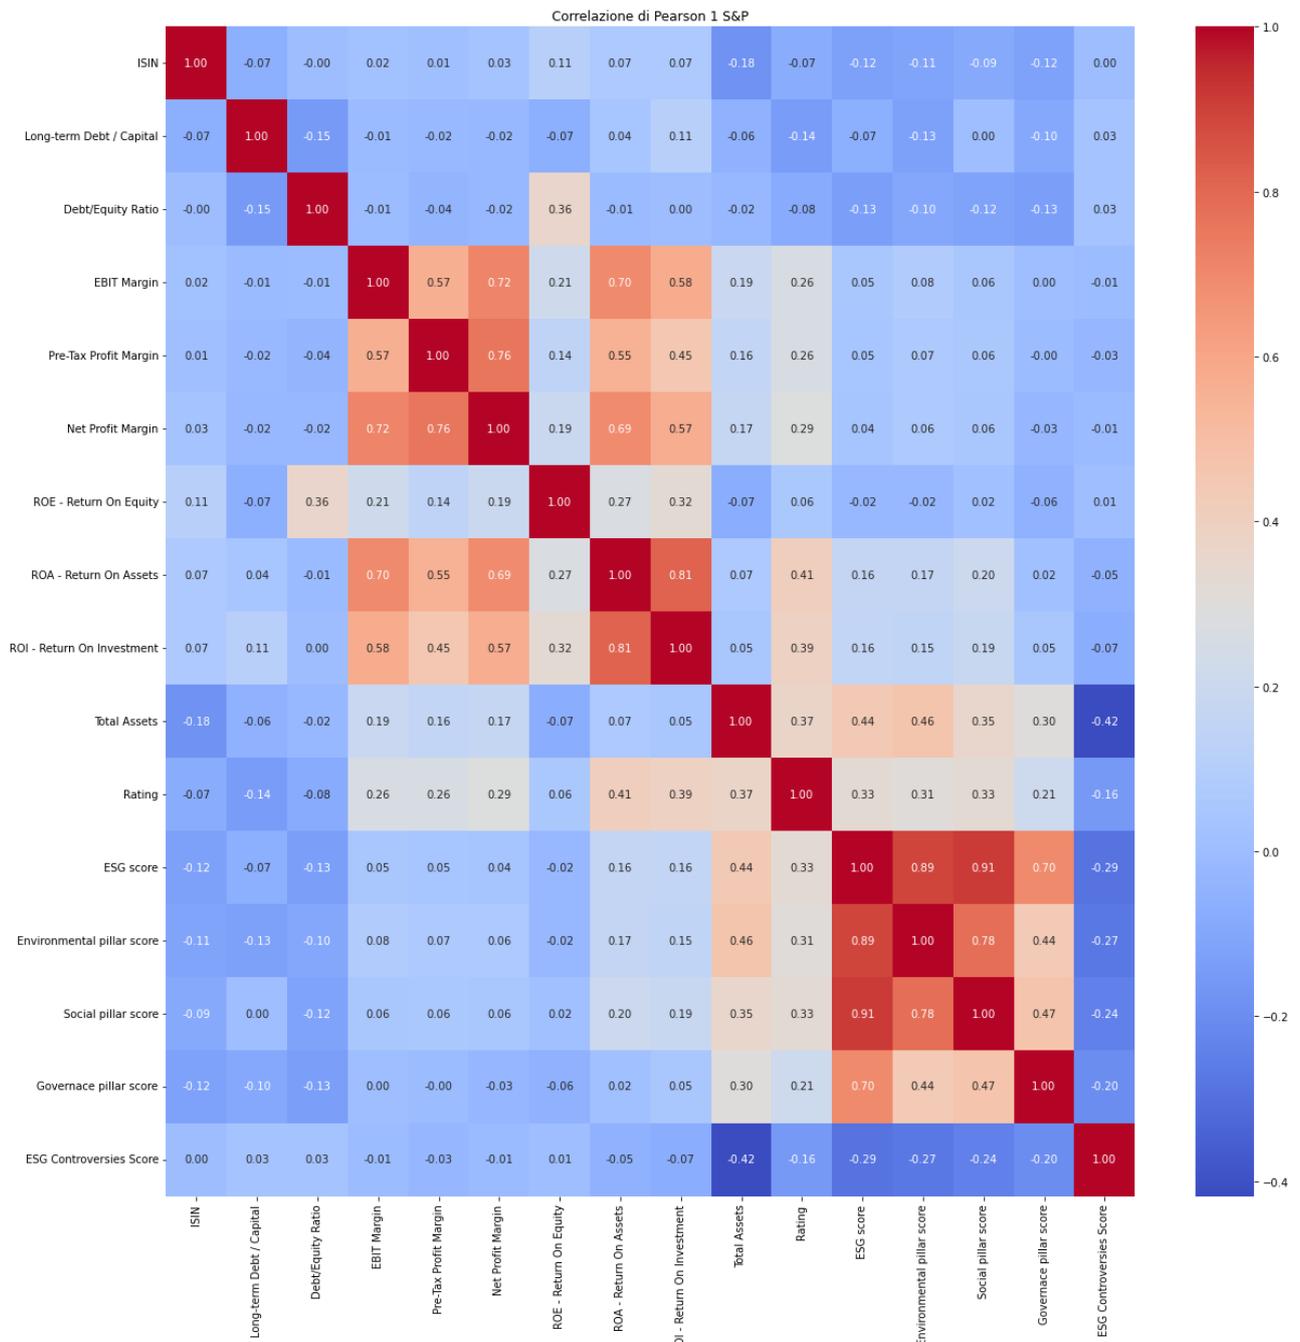


Figura 60 - Matrice di Correlazione di Pearson per dfref_sp

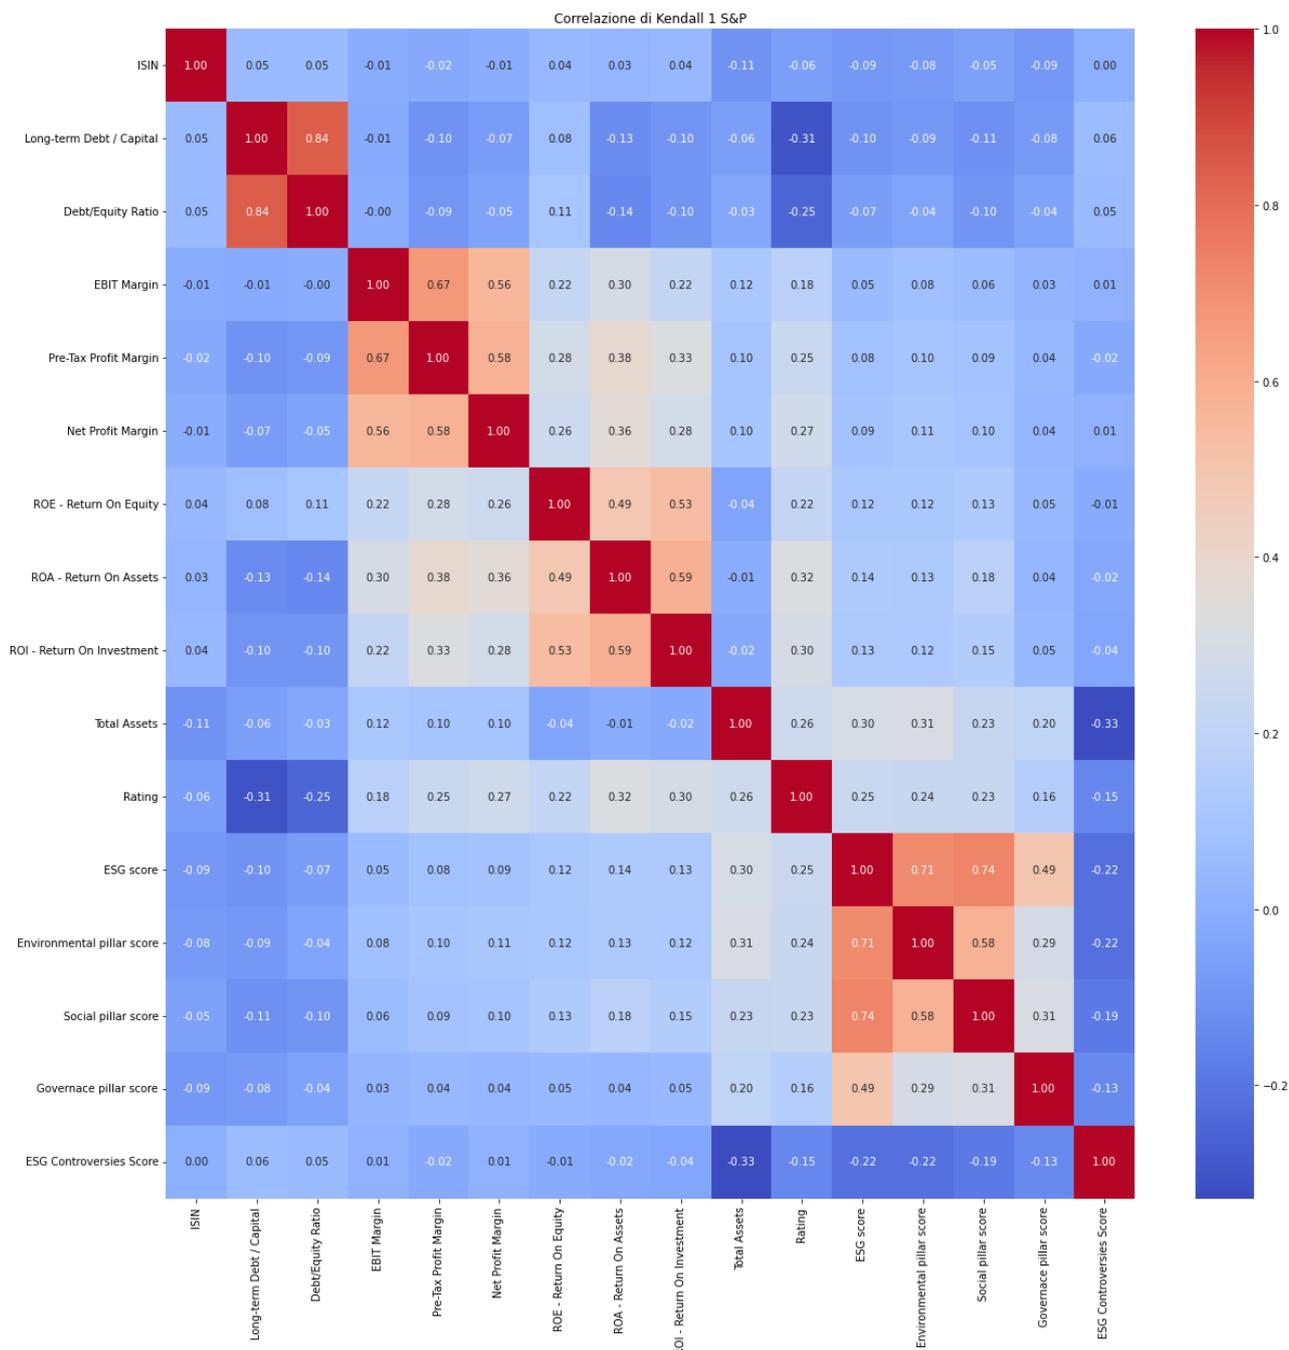


Figura 61 - Matrice di Correlazione di Kendall per dfref_sp

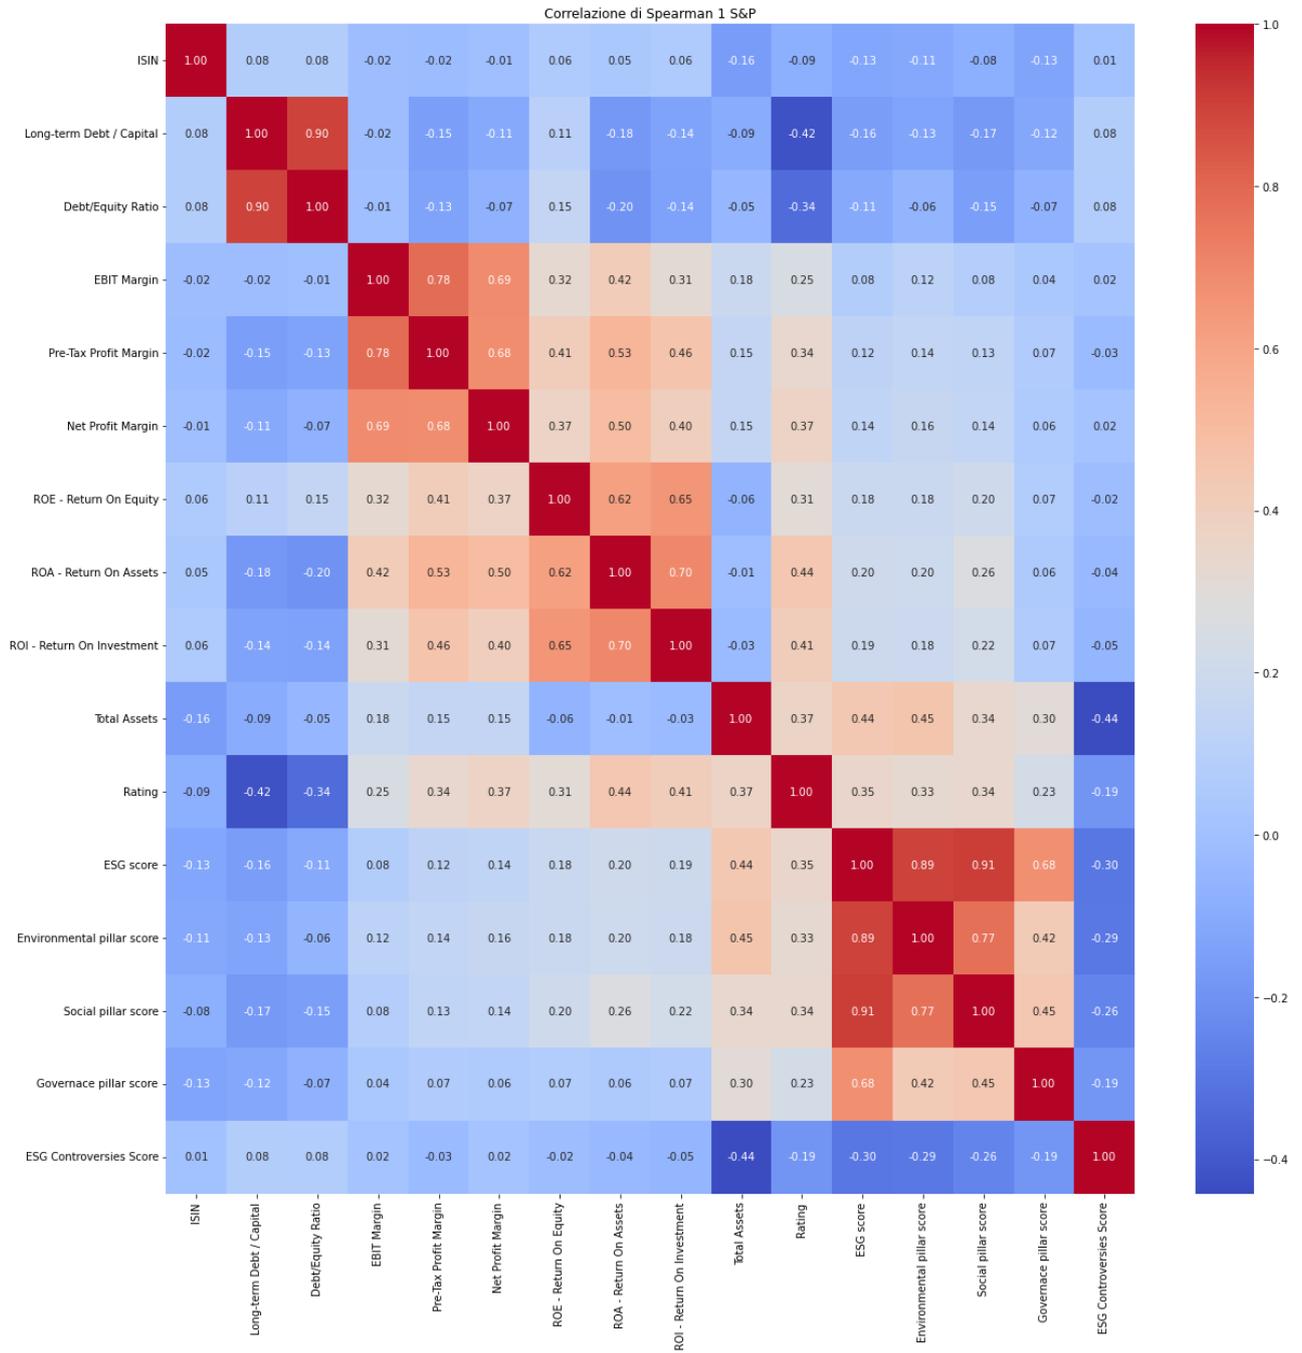


Figura 62 - Matrice di Correlazione di Spearman per dfref_sp

ANNESNO D: Matrici di Correlazione del Dataset intermedio ridotto con solo le rilevazioni Moody's (dfref_moody)

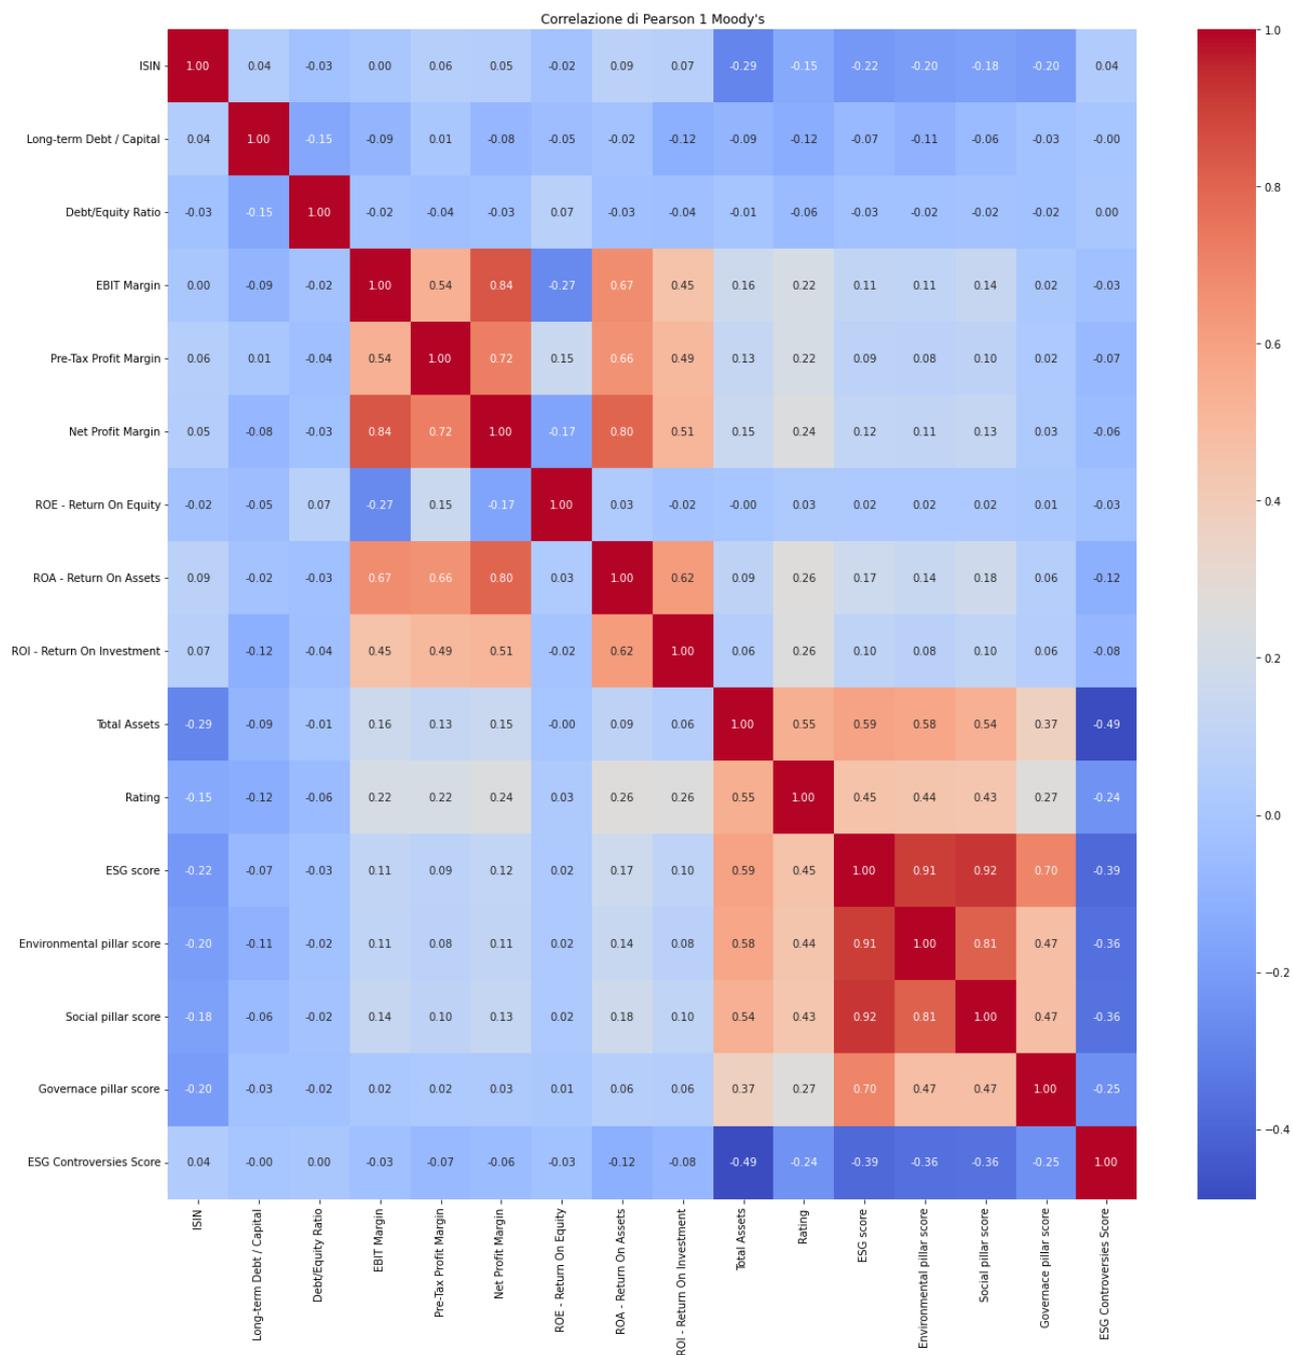


Figura 63 - Matrice di Correlazione di Pearson per dfref_moody

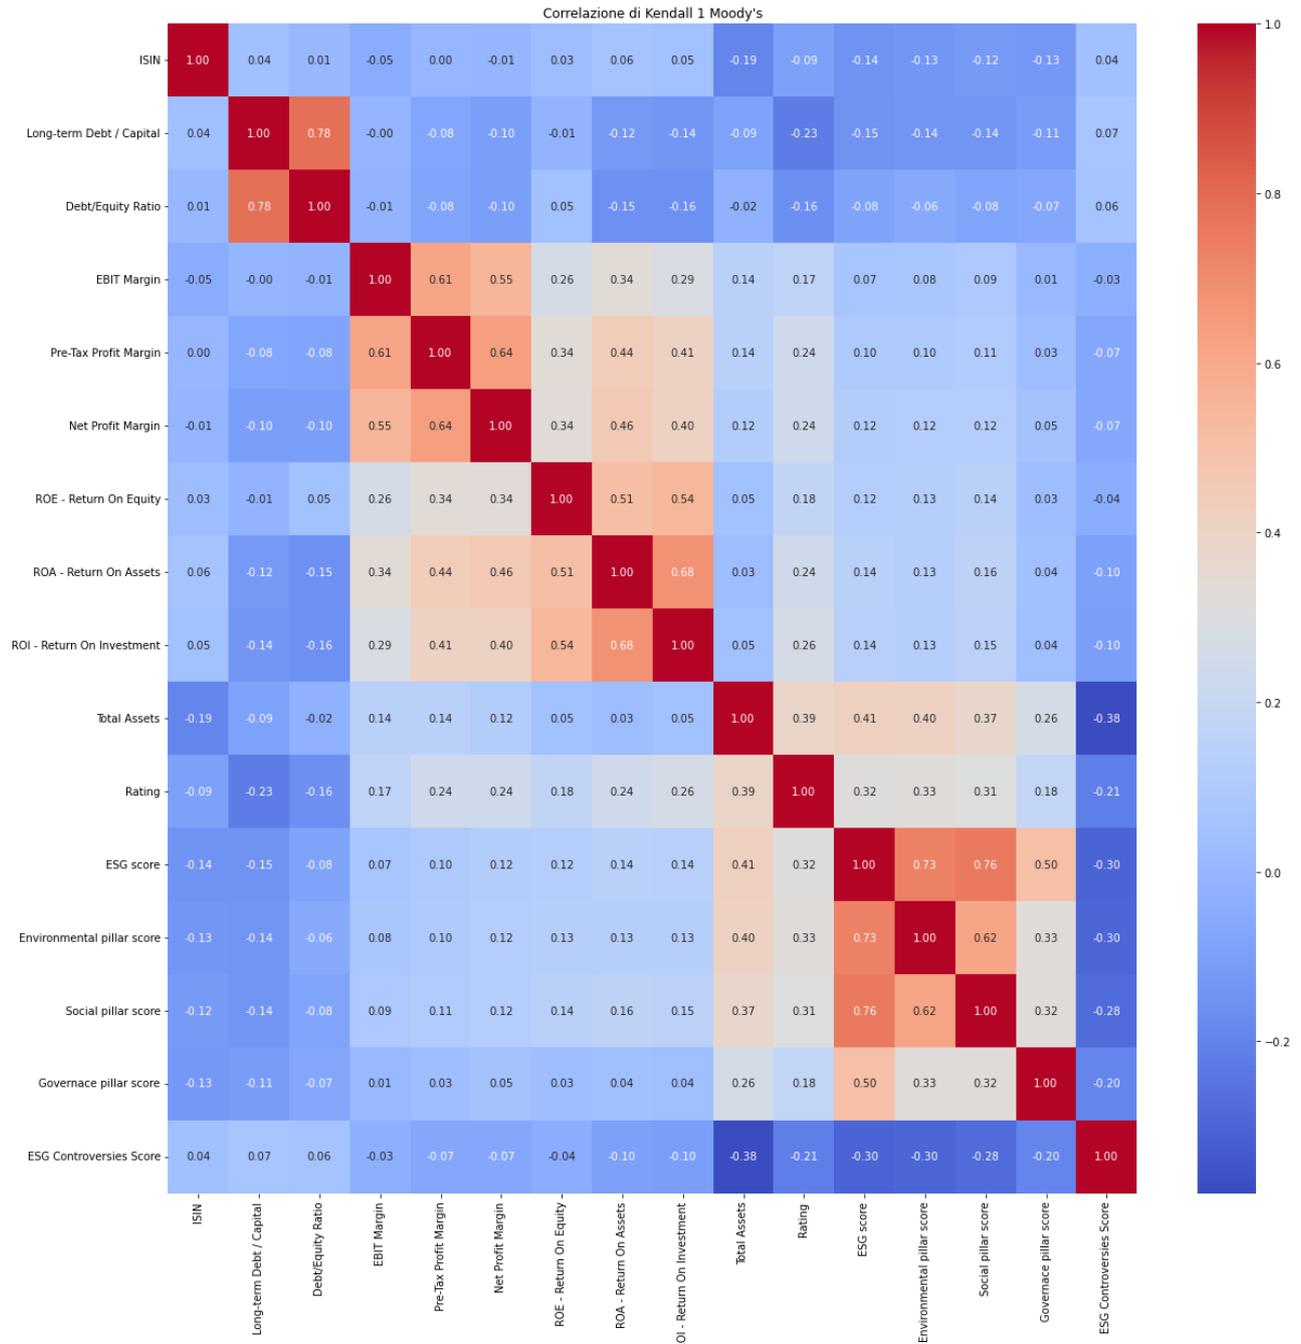


Figura 64 - Matrice di Correlazione di Kendall per dfref_moody

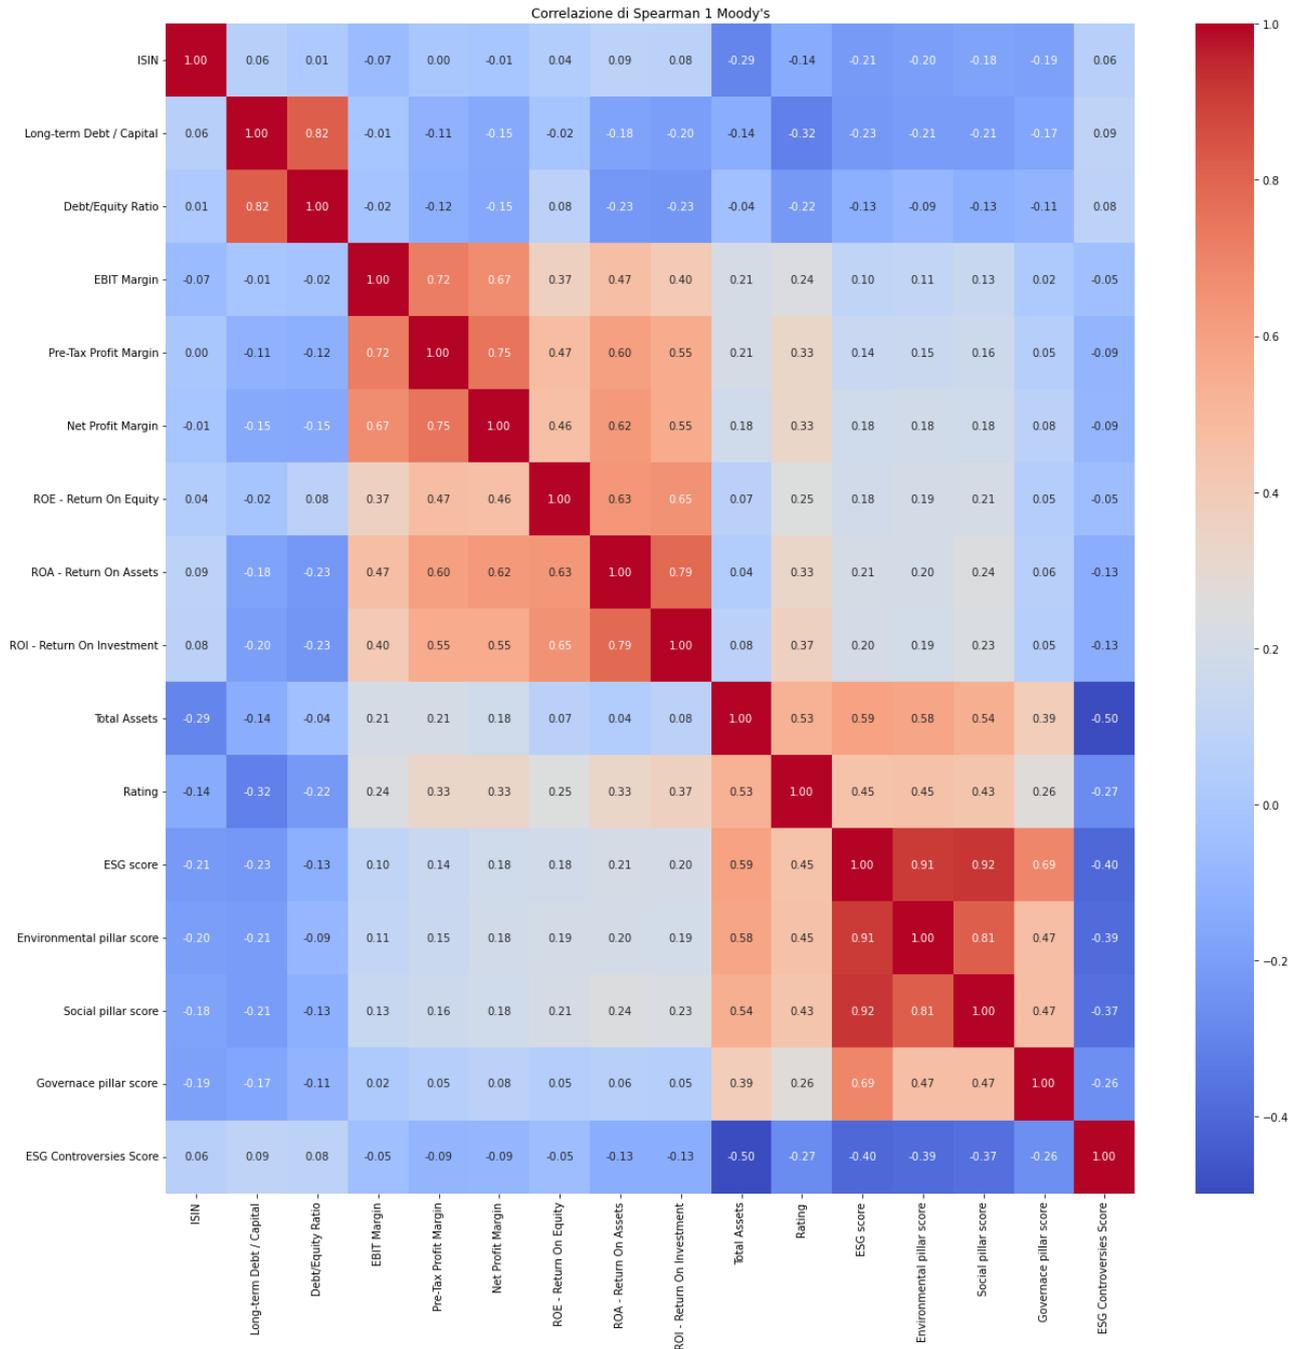


Figura 65 - Matrice di Correlazione di Spearman per dfref_moody

ANNESSE E: Matrici di Correlazione del Dataset intermedio ridotto con solo le rilevazioni Egan-Jones (dfref_egan)

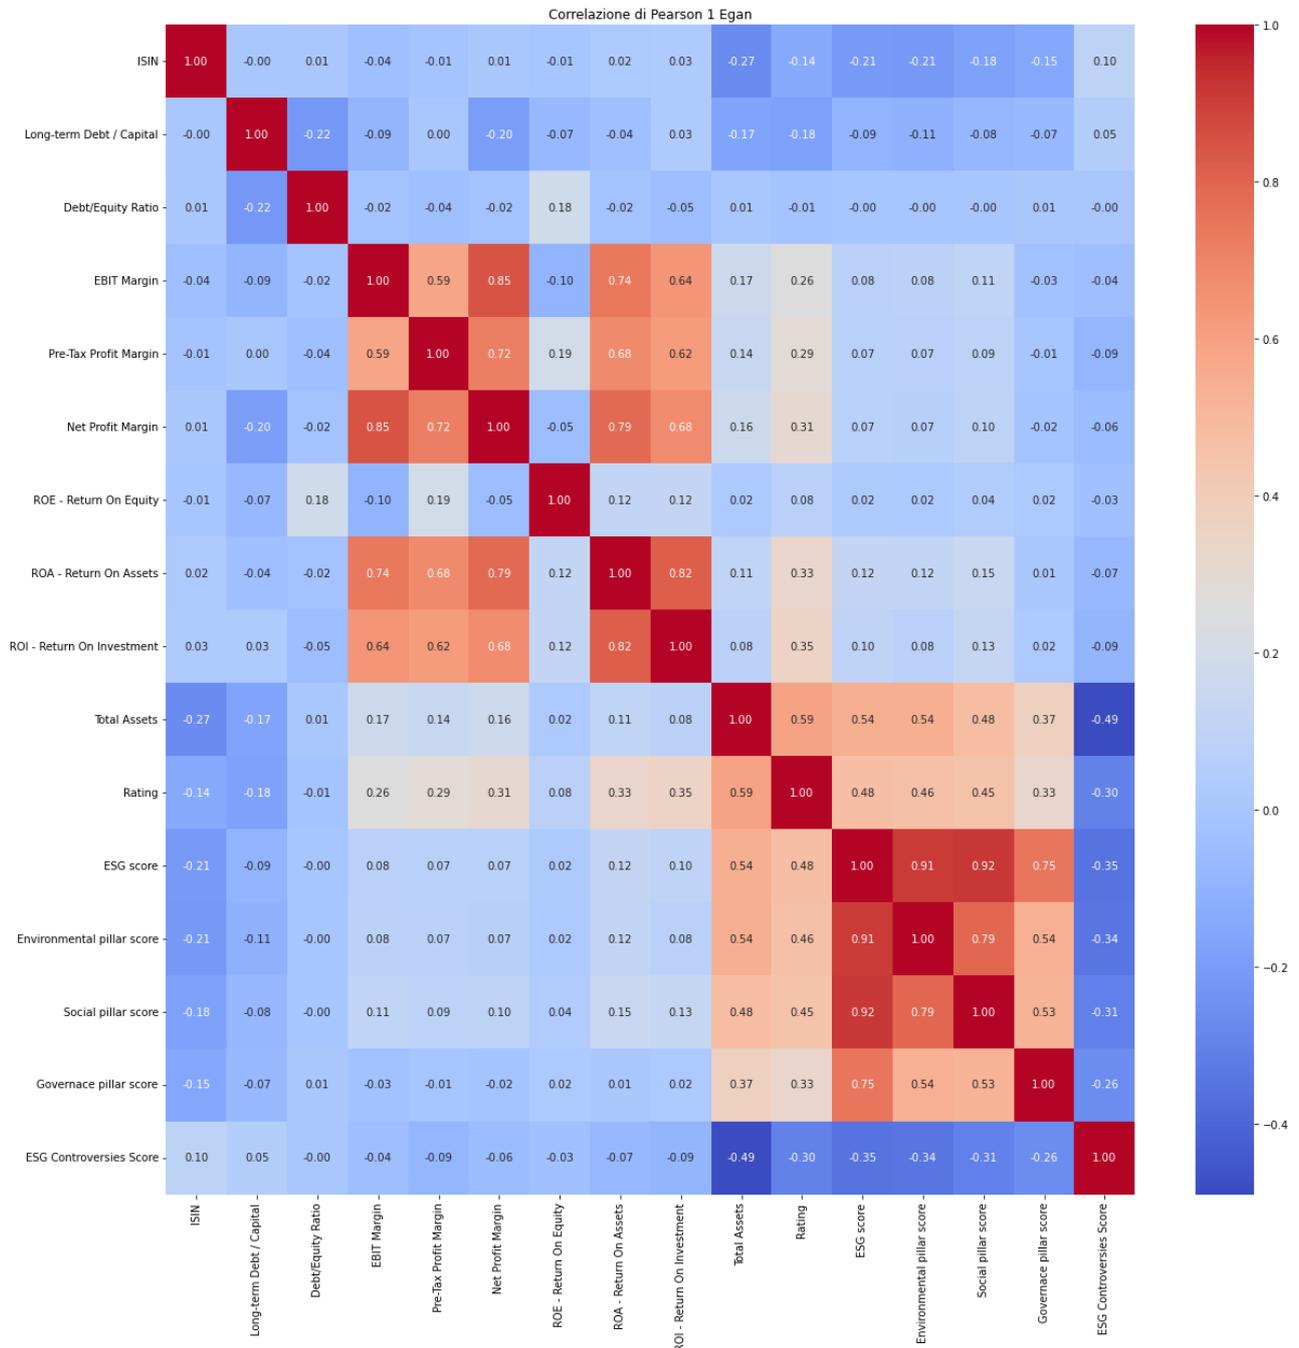


Figura 66 - Matrice di Correlazione di Pearson per dfref_egan

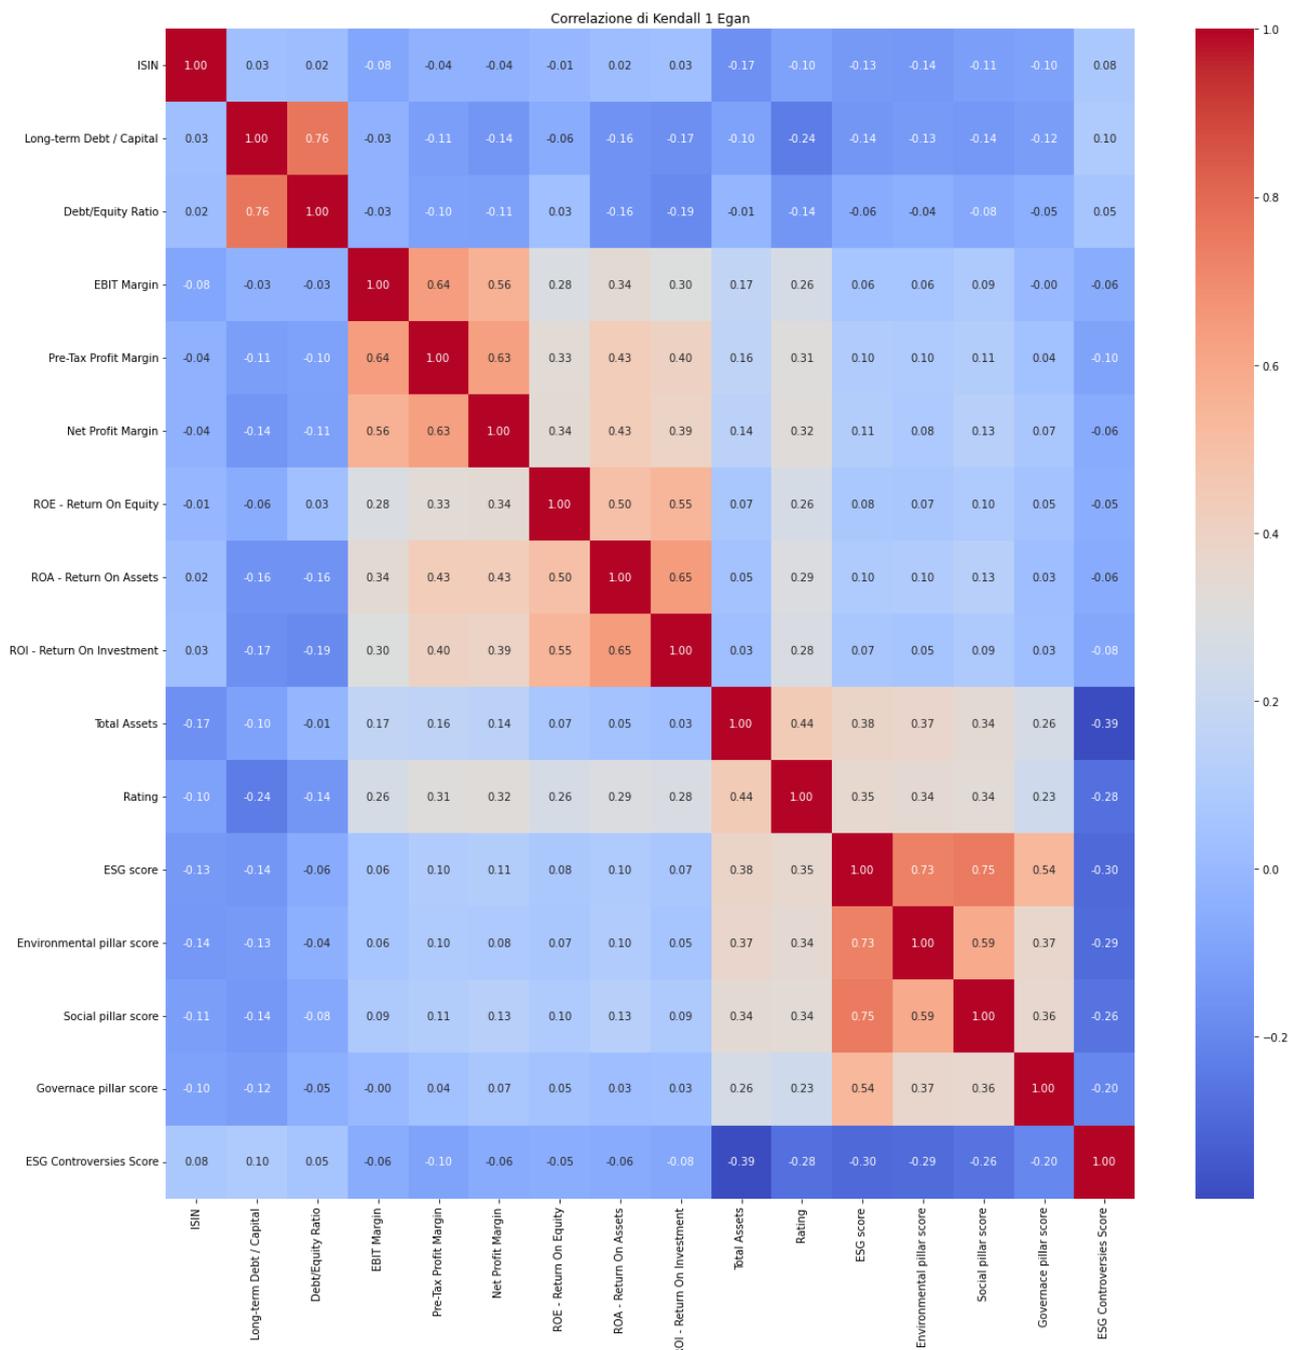


Figura 67 - Matrice di Correlazione di Kendall per dfref_egan

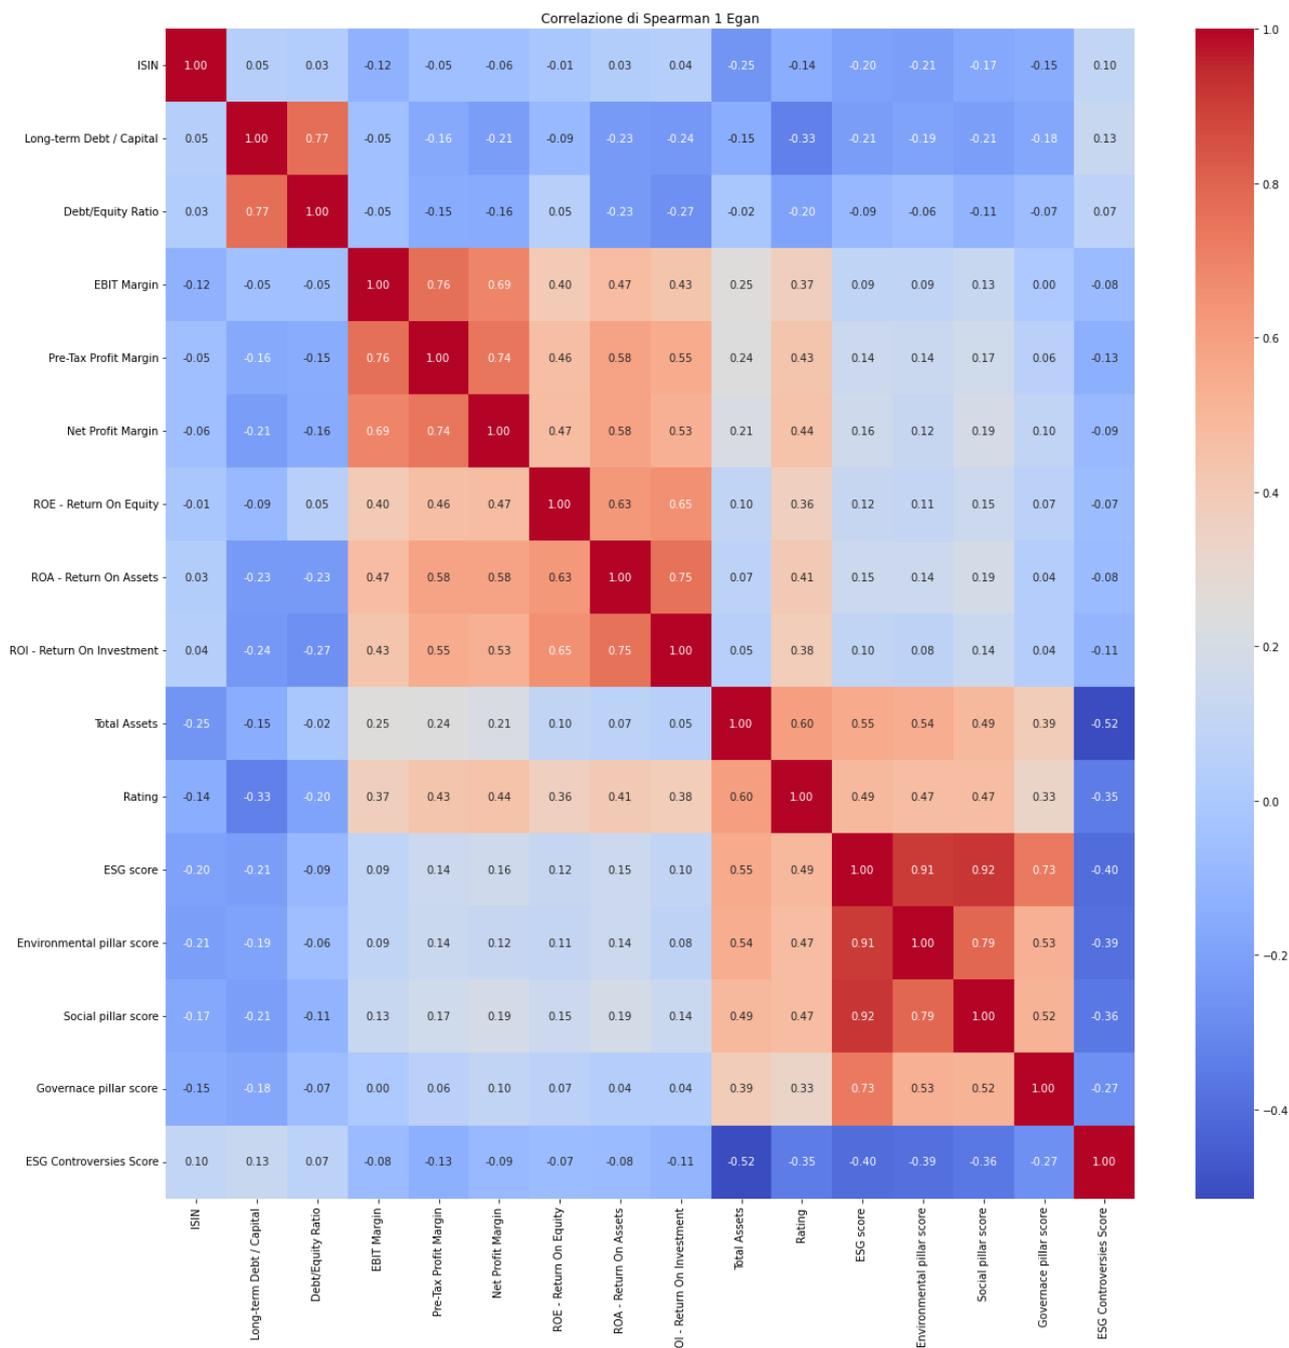


Figura 68 - Matrice di Correlazione di Spearman per dfref_egan

ANNESSE F: Matrici di Correlazione del Dataset finale ridotto con solo le rilevazioni S&P (dfblo_sp)

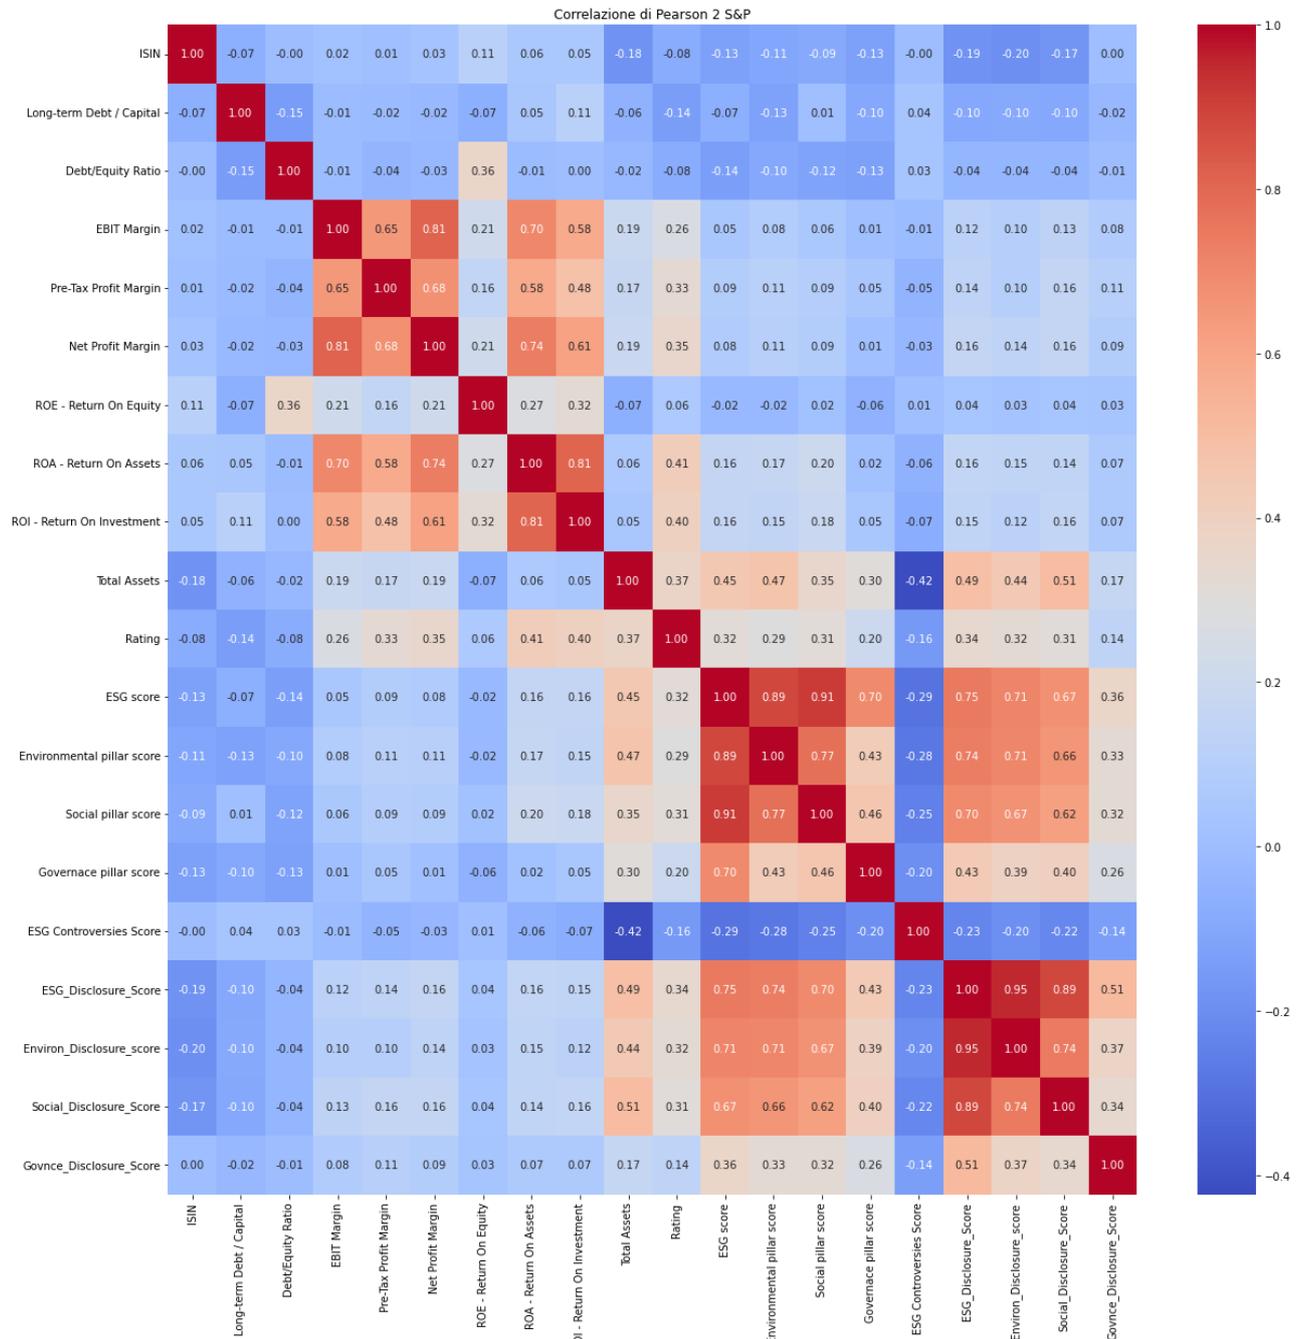


Figura 69 - Matrice di Correlazione di Pearson per dfblo_sp

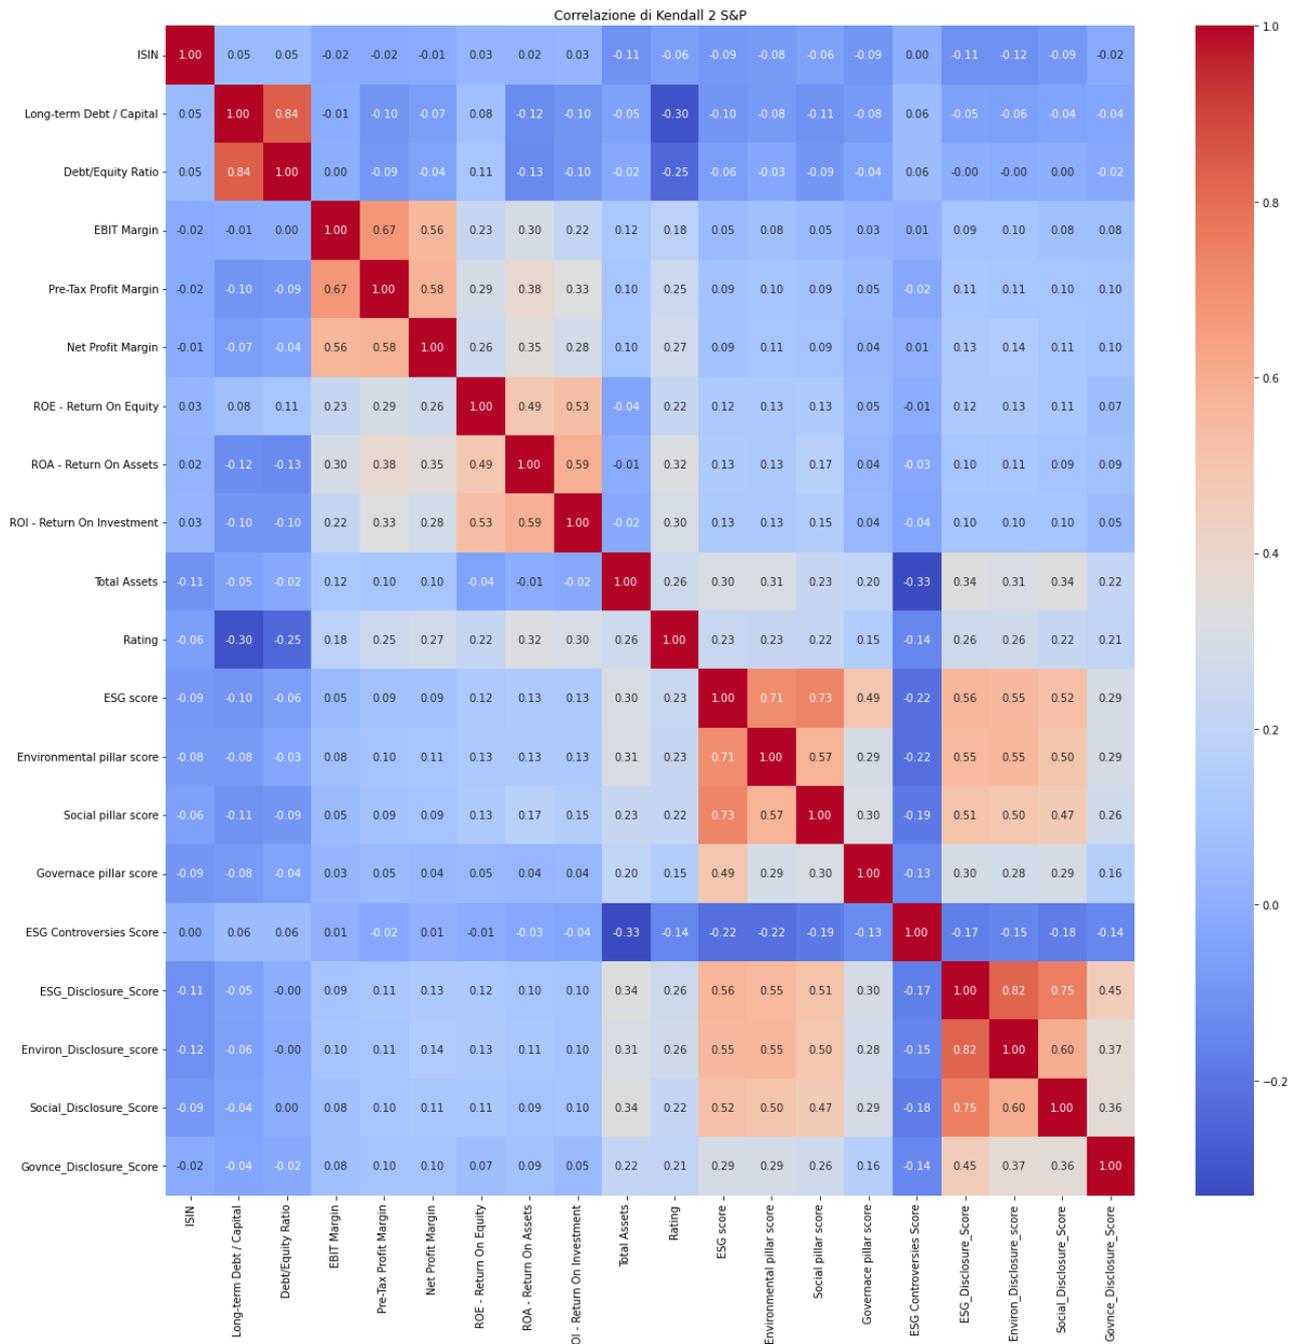


Figura 70- Matrice di Correlazione di Kendall per dfblo_sp

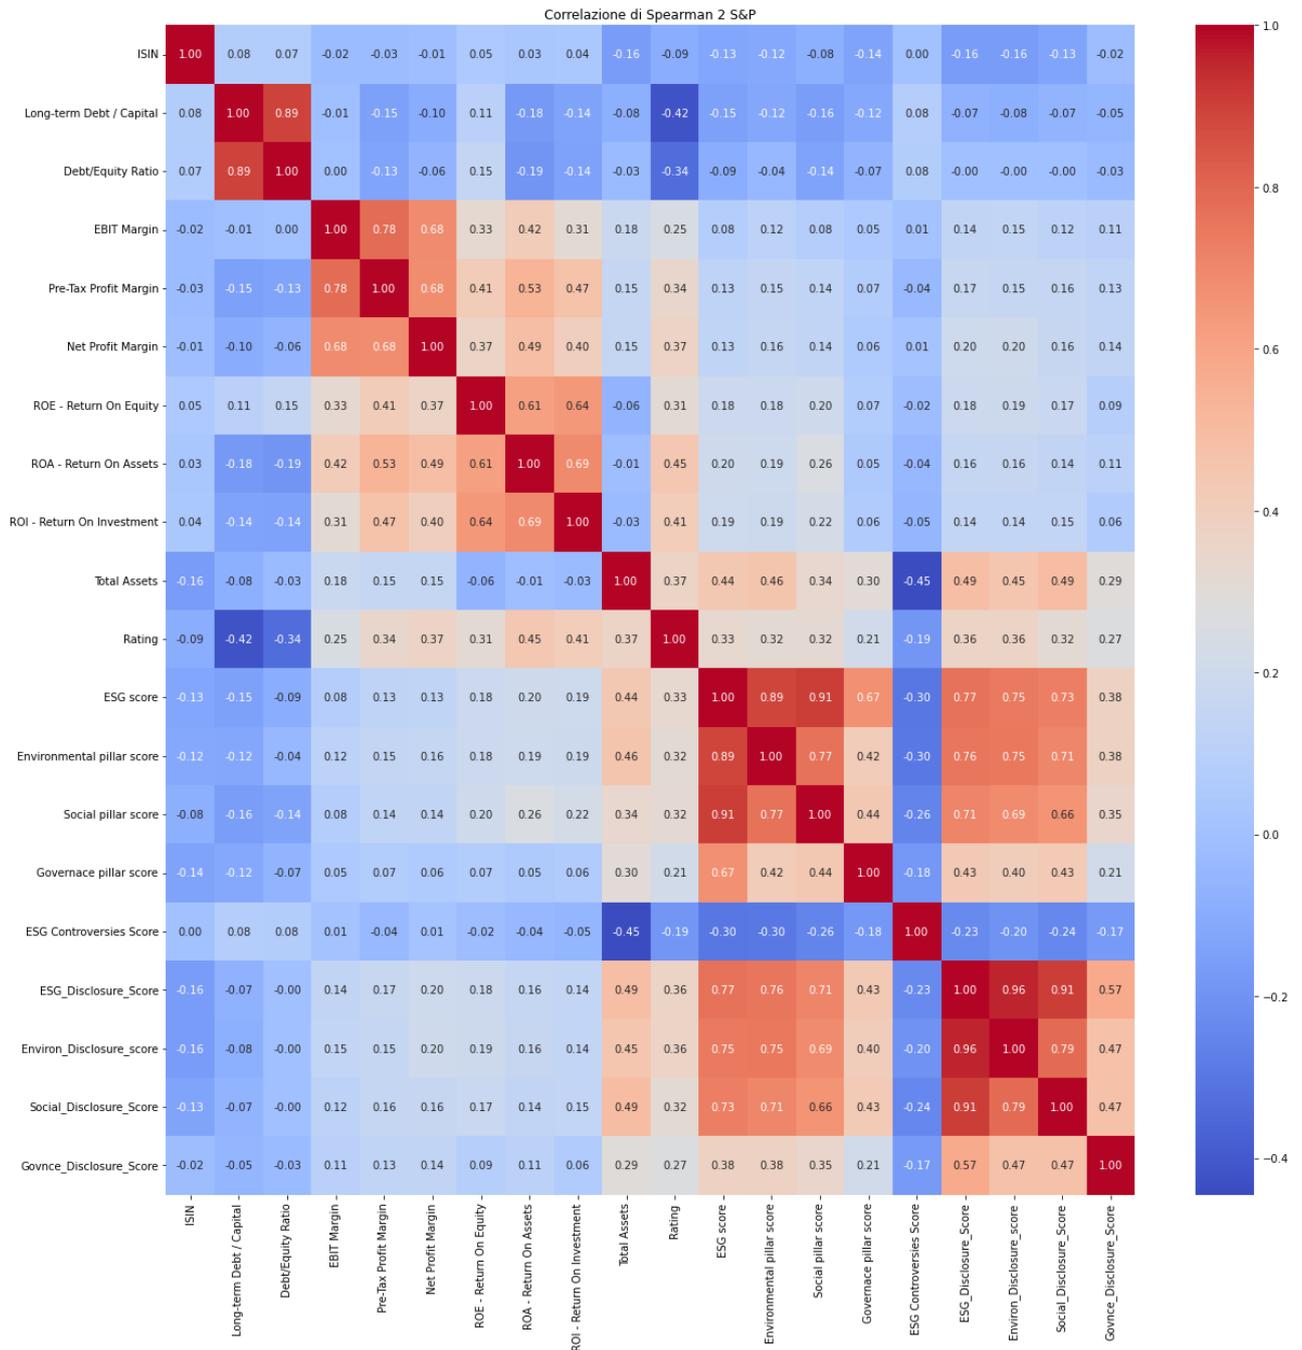


Figura 71- Matrice di Correlazione di Spearman per dfblo_sp

ANNESNO G: Matrici di Correlazione del Dataset finale ridotto con solo le rilevazioni Moody's (dfblo_moody)

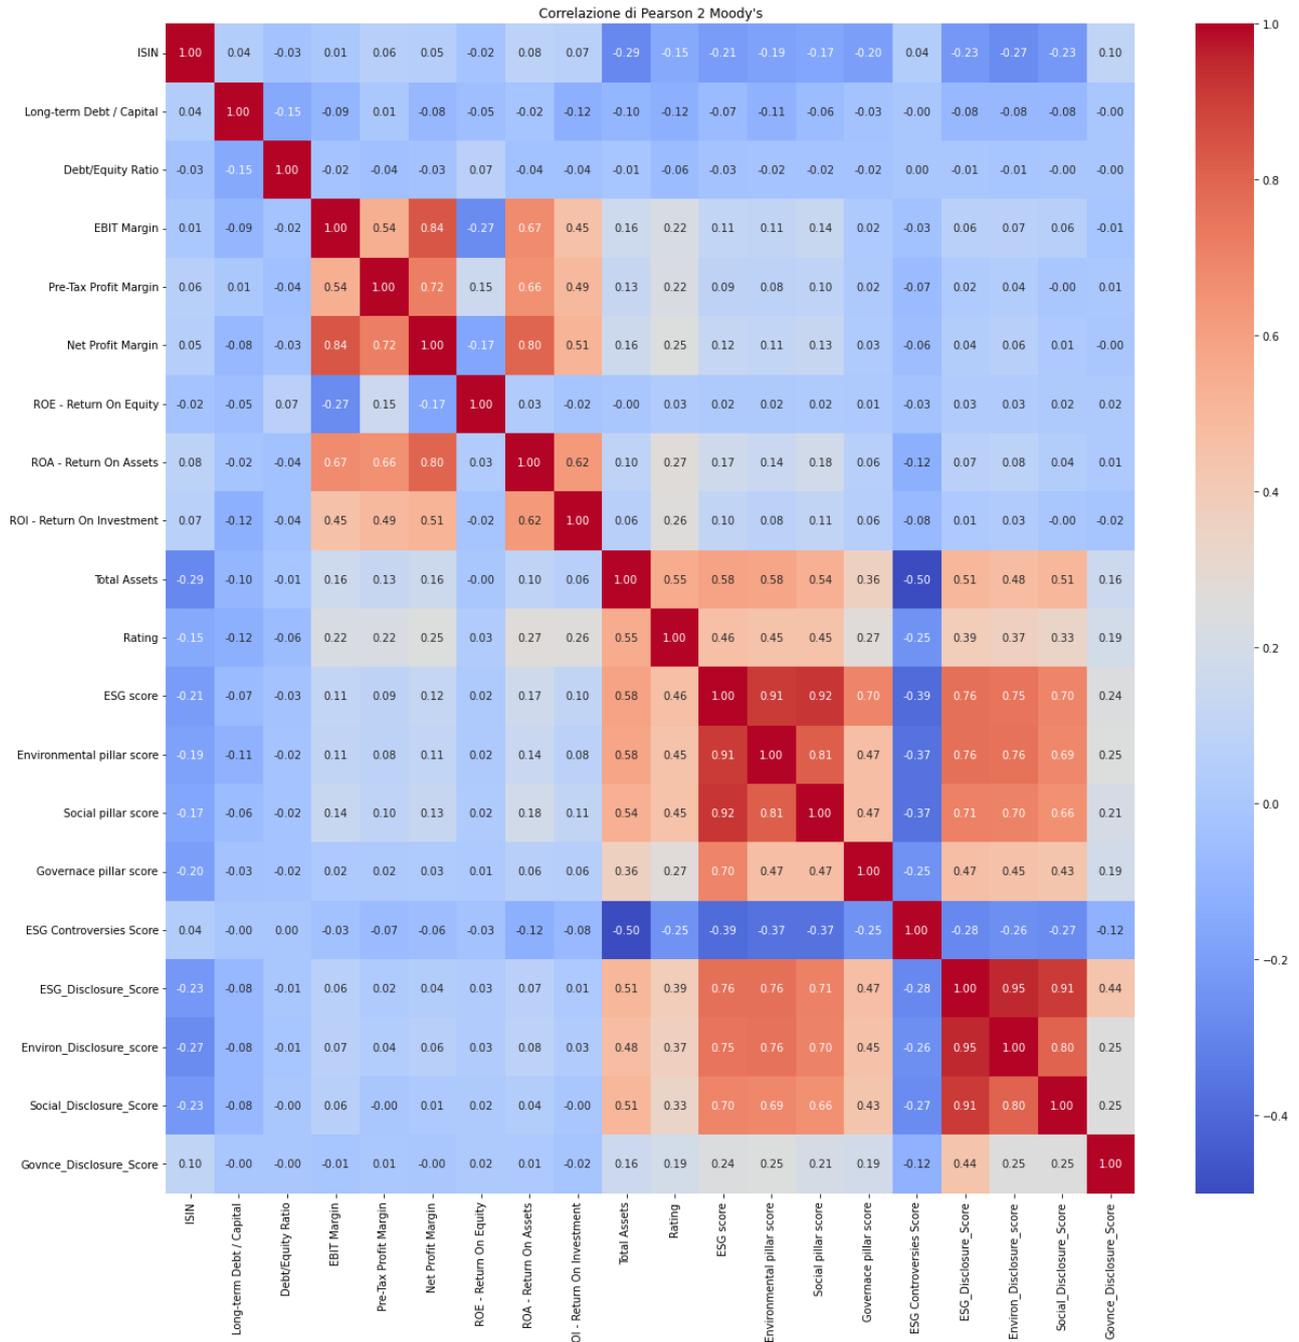


Figura 72 - Matrice di Correlazione di Pearson per dfblo_moody

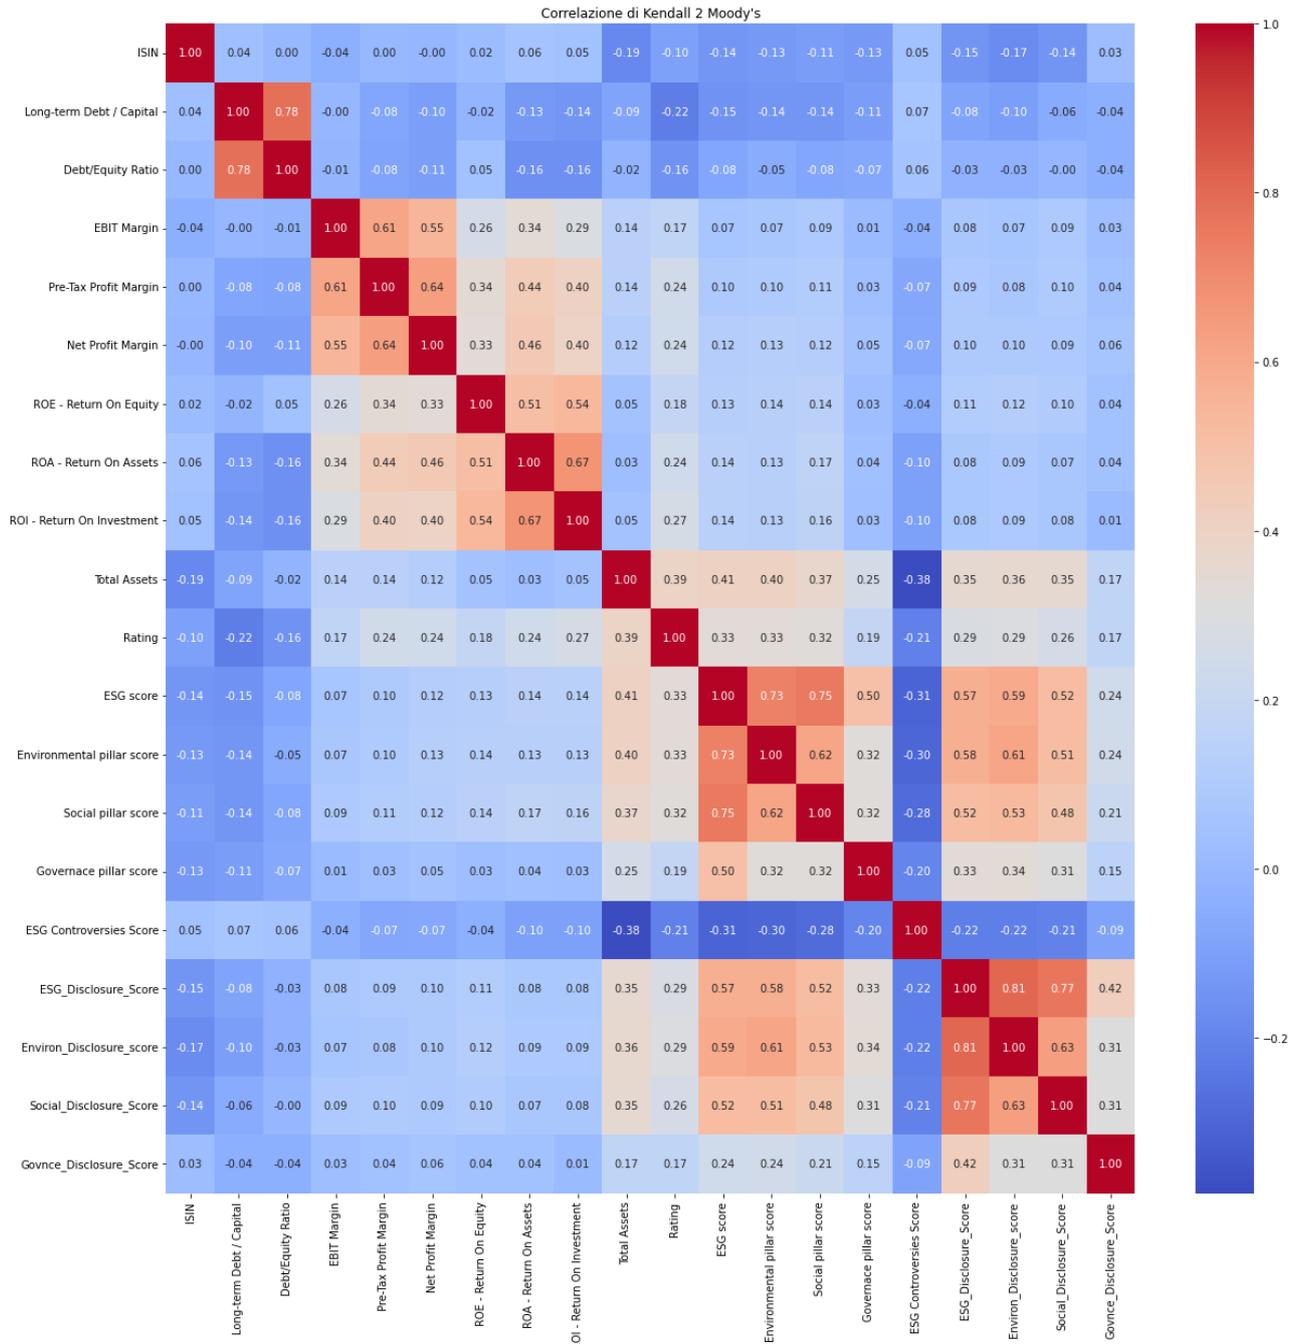


Figura 73 - Matrice di Correlazione di Kendall per dfblo_moody

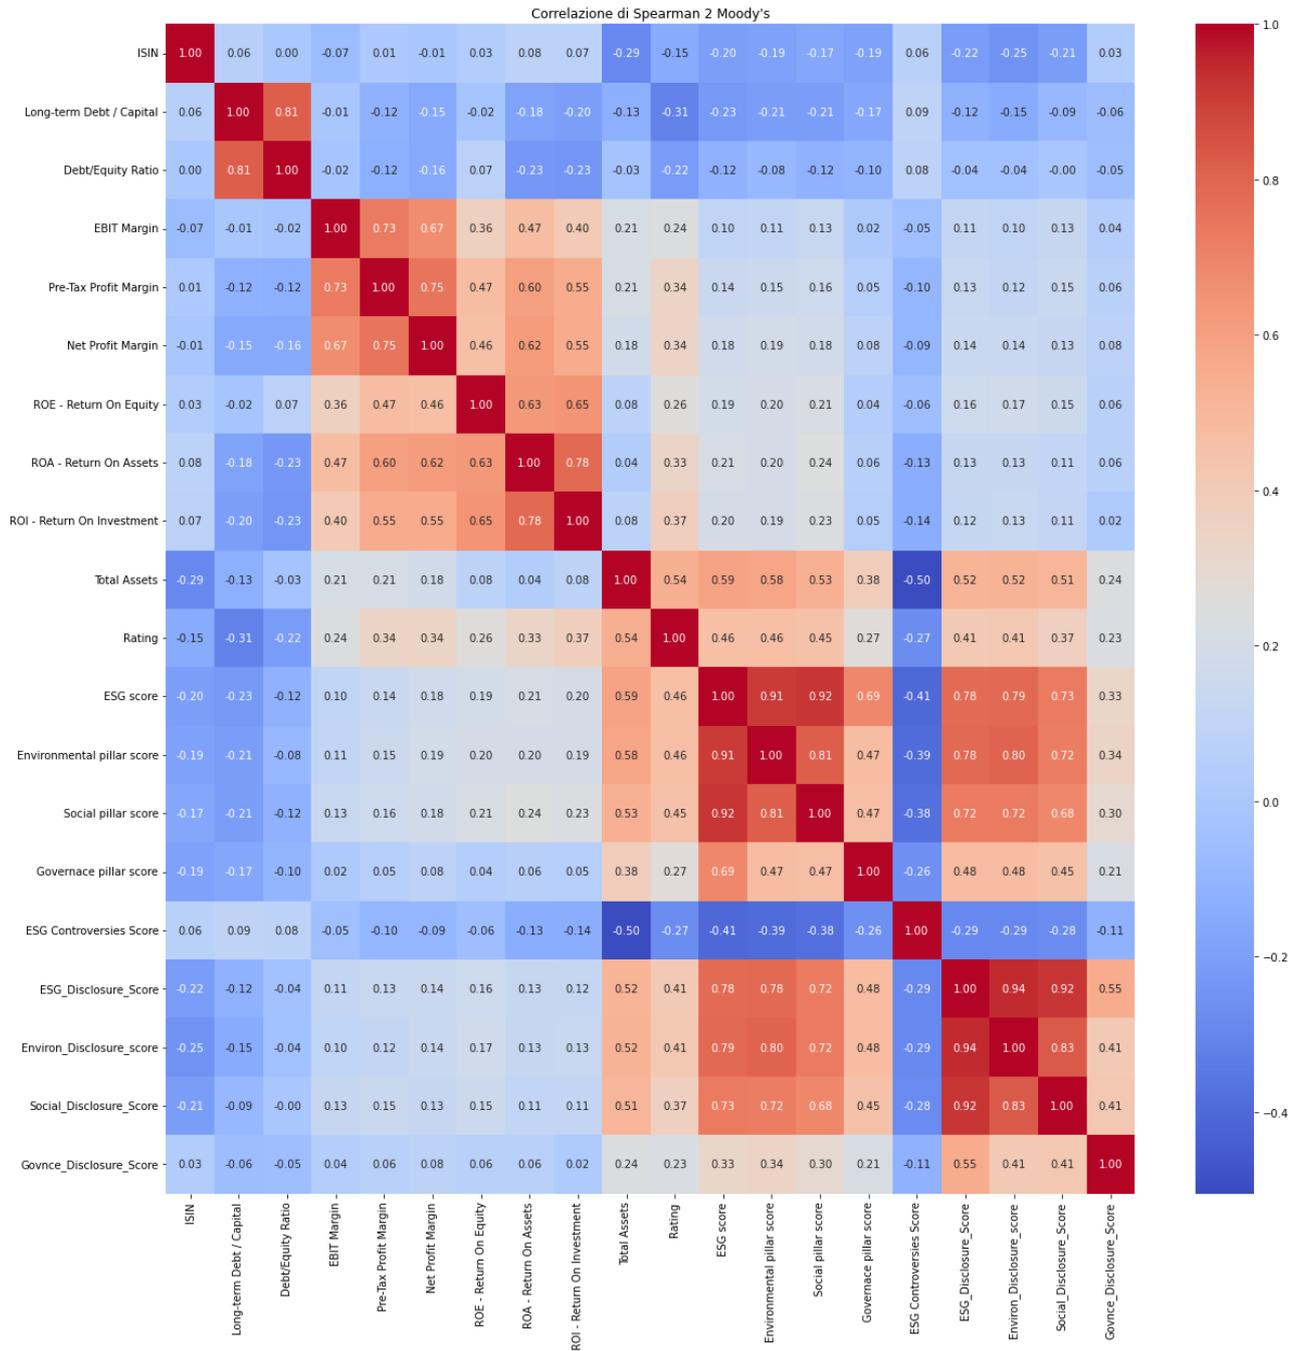


Figura 74 - Matrice di Correlazione di Spearman per dfblo_moody

ANNESSE H: Matrici di Correlazione del Dataset finale ridotto con solo le rilevazioni Egan-Jones (dfblo_egan)

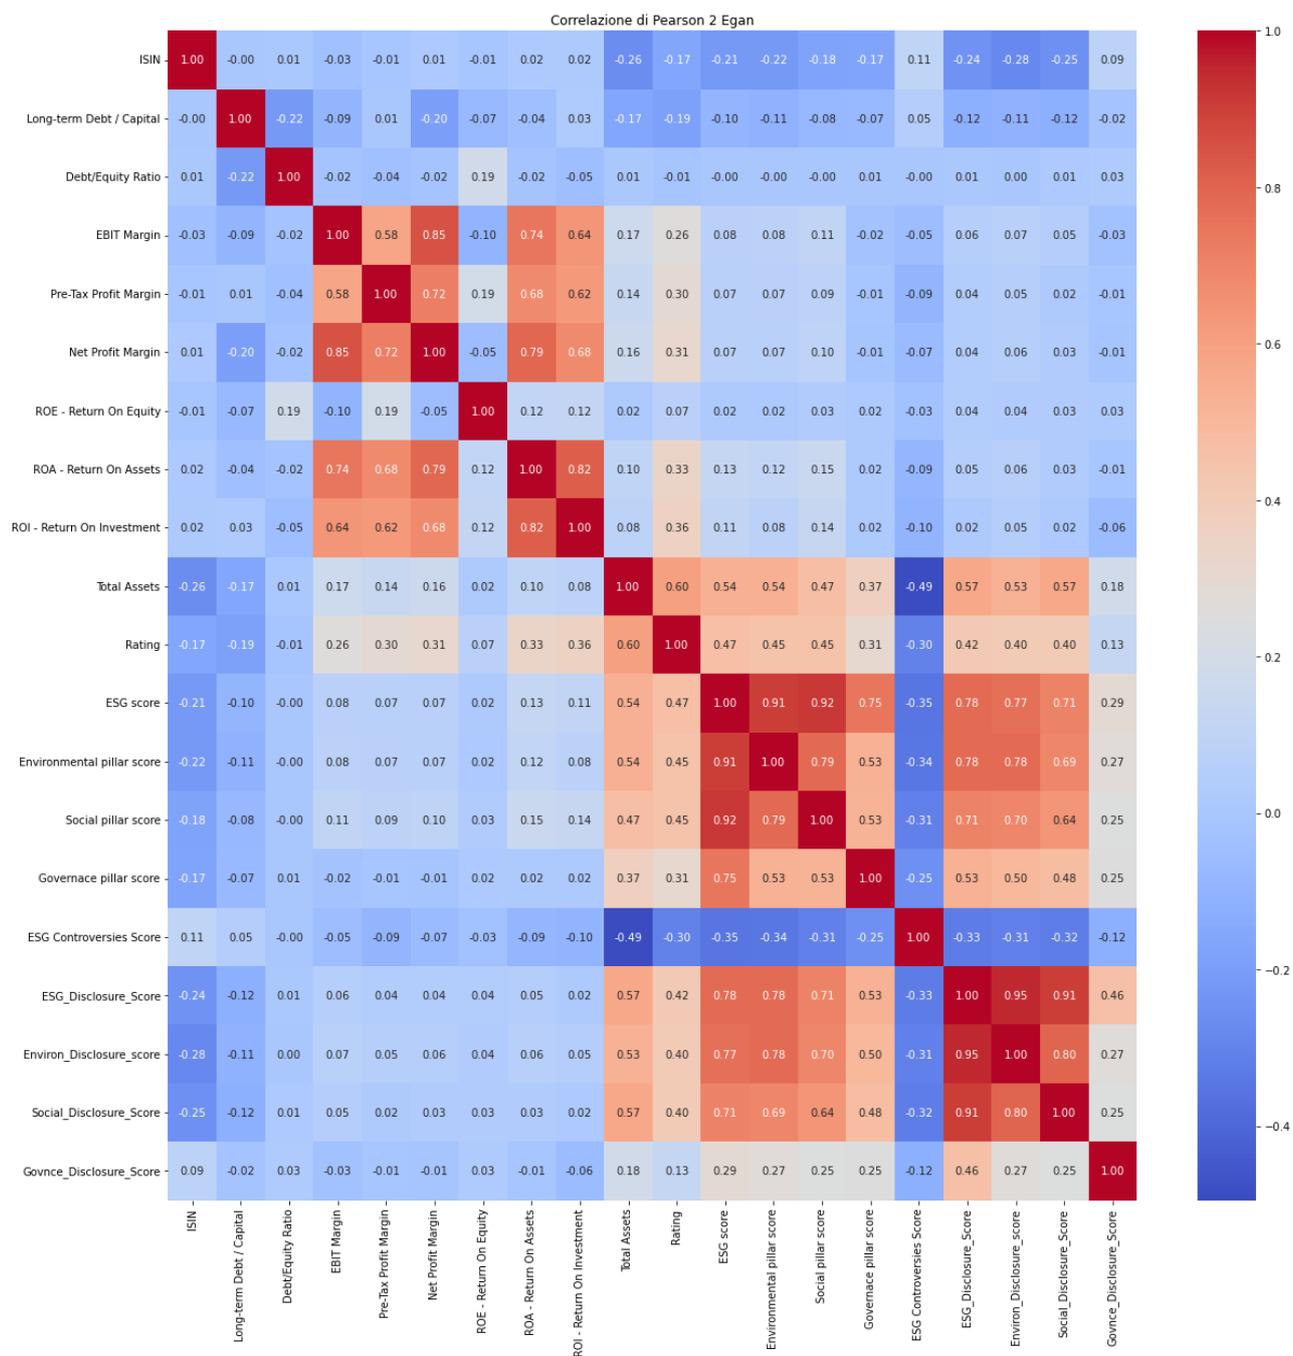


Figura 75 - Matrice di Correlazione di Pearson per dfblo_egan

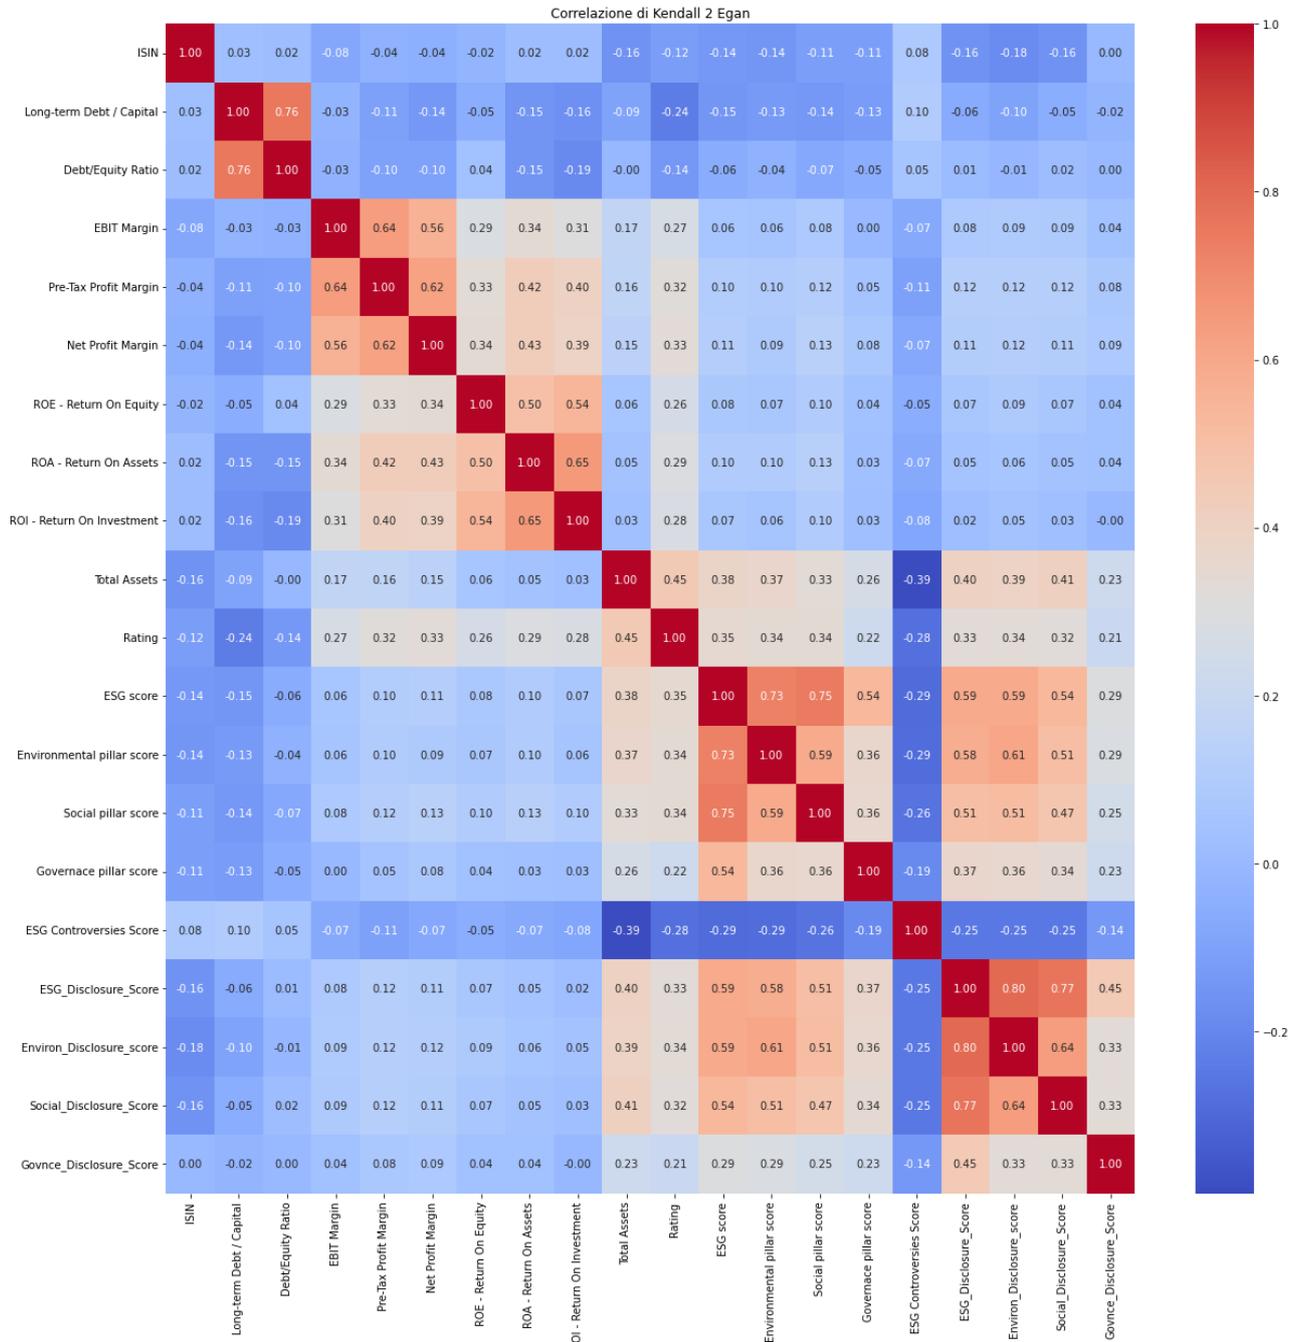


Figura 76 - Matrice di Correlazione di Kendall per dfblo_egan

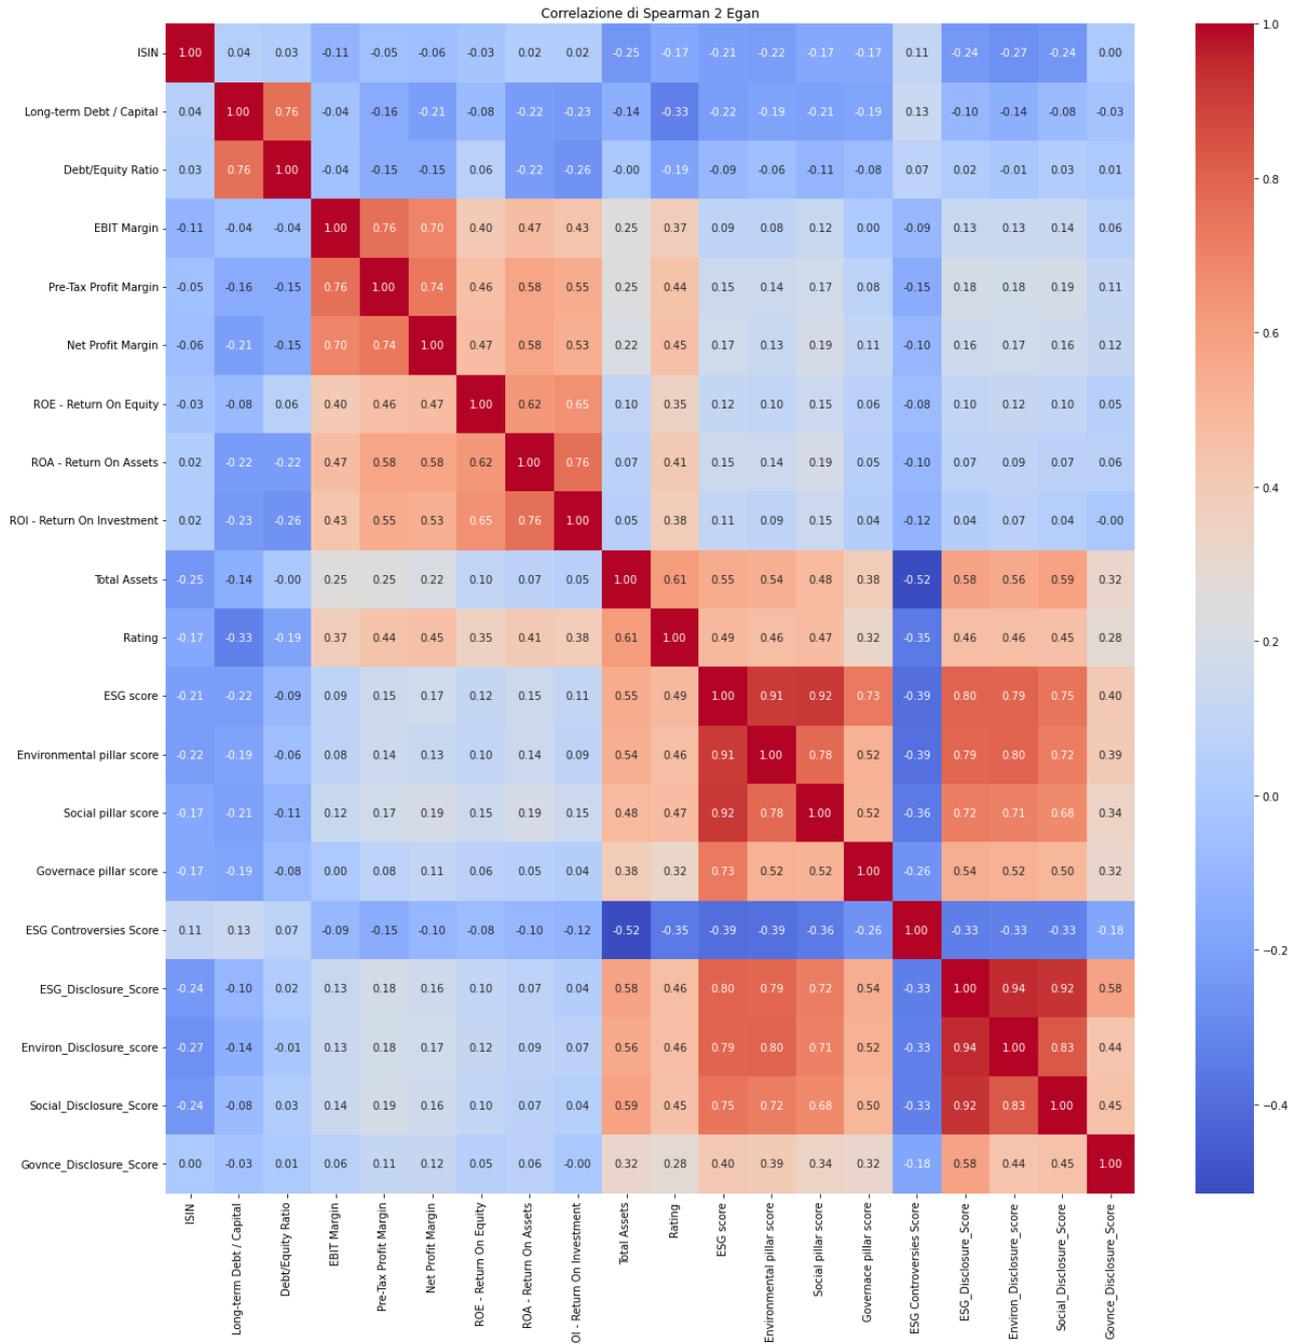


Figura 77 - Matrice di Correlazione di Spearman per dfblo_egan

ANNESSE I: Classification Report e Confusion Matrix per dfr e dfb

Classe	Precision	Recall	f1-score
0	0,81	0,83	0,82
1	0,77	0,71	0,74
2	0,71	0,78	0,74
Accuracy		0,76	

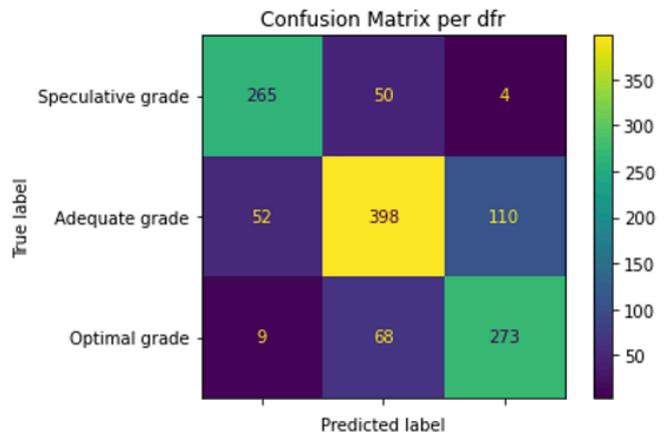


Figura 78 - Classification Report e Confusion Matrix per dfr

Classe	Precision	Recall	f1-score
0	0,88	0,86	0,87
1	0,81	0,77	0,79
2	0,75	0,82	0,78
Accuracy		0,81	

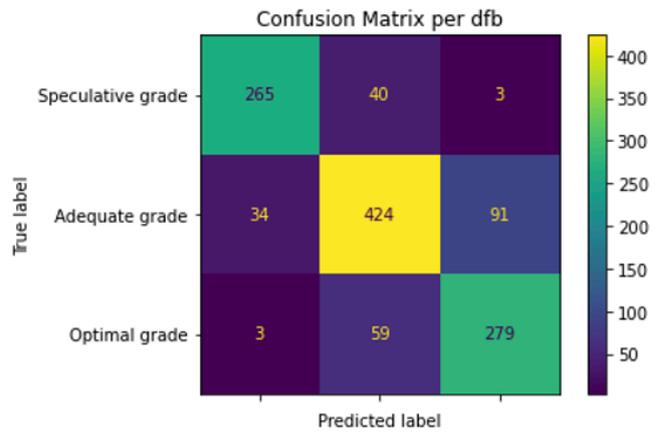


Figura 79 - Classification Report e Confusion Matrix per dfb

ANNESNO L: Classification Report e Confusion Matrix per dfrs, dfrm e dfre

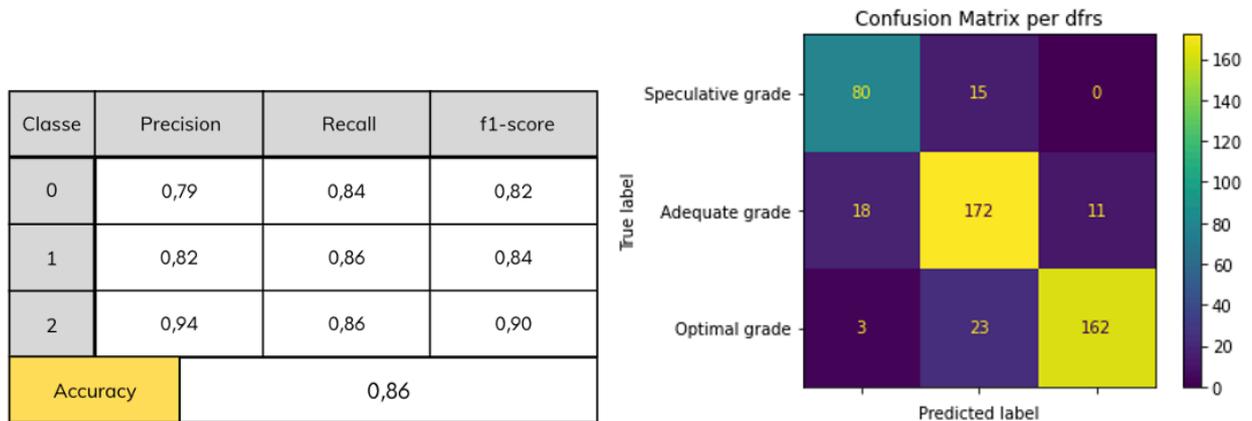


Figura 80 - Classification Report e Confusion Matrix per dfrs

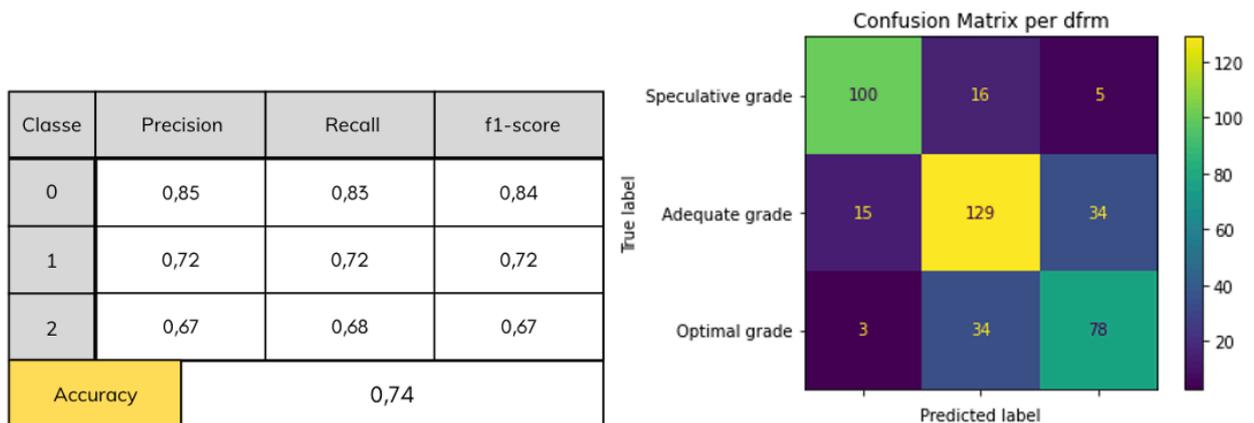


Figura 81 - Classification Report e Confusion Matrix per dfrm

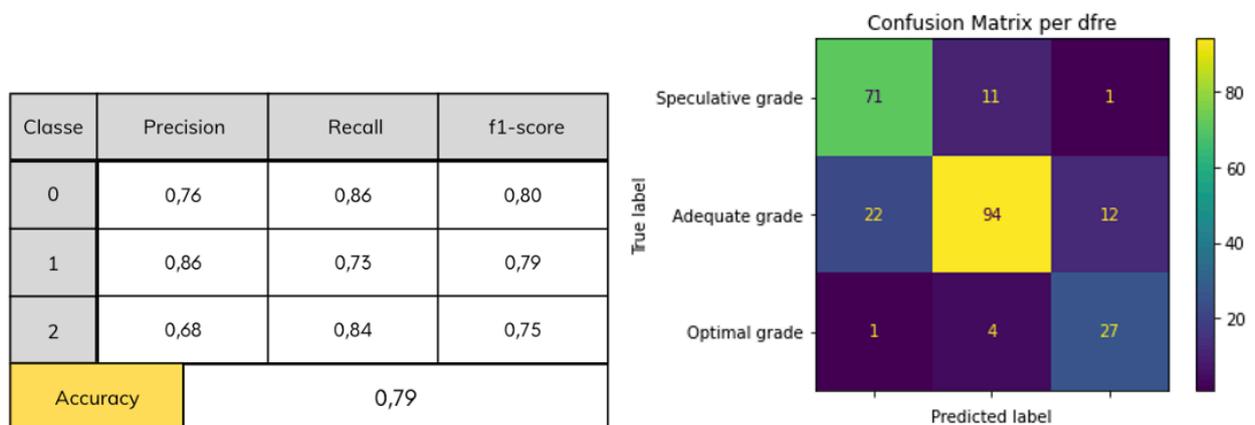


Figura 82 - Classification Report e Confusion Matrix per dfre

ANNESSE M: Classification Report e Confusion Matrix per dfbs, dfbm e dfbe

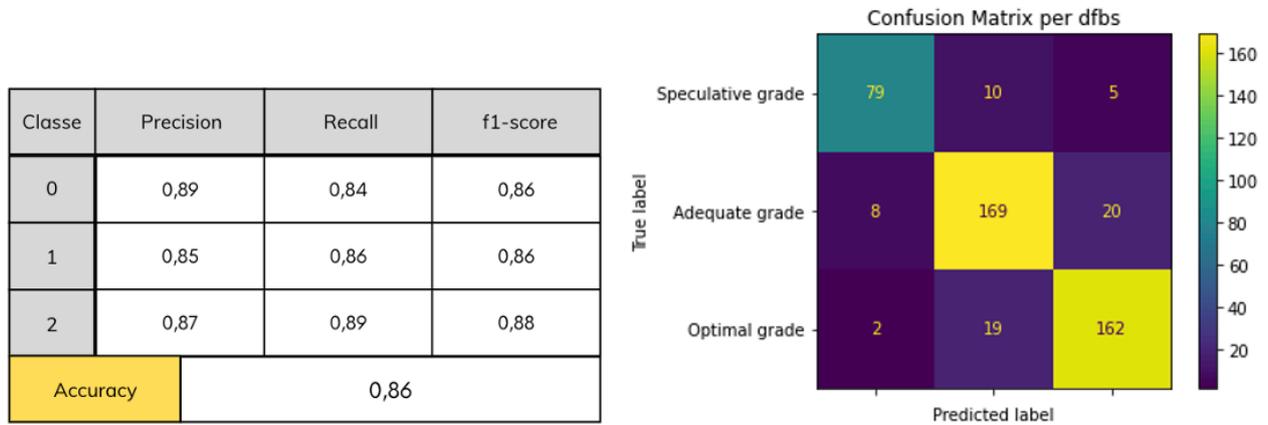


Figura 83 - Classification Report e Confusion Matrix per dfbs

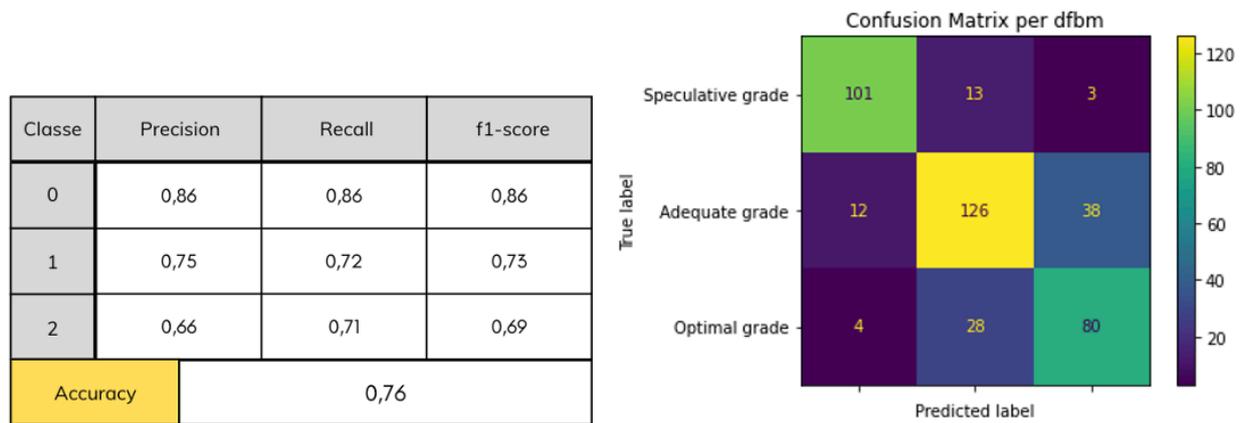


Figura 84 - Classification Report e Confusion Matrix per dfbm

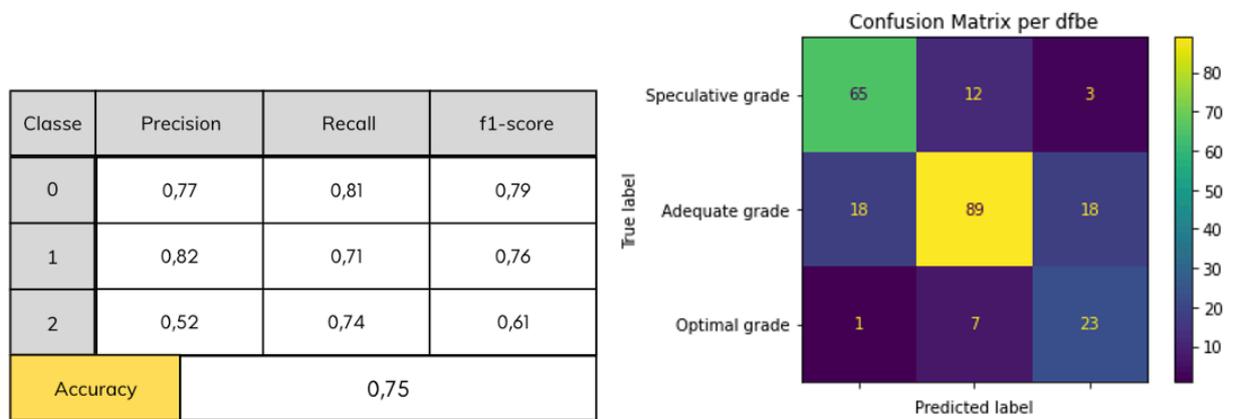


Figura 85 - Classification Report e Confusion Matrix per dfbe

ANNESNO N: Features importance

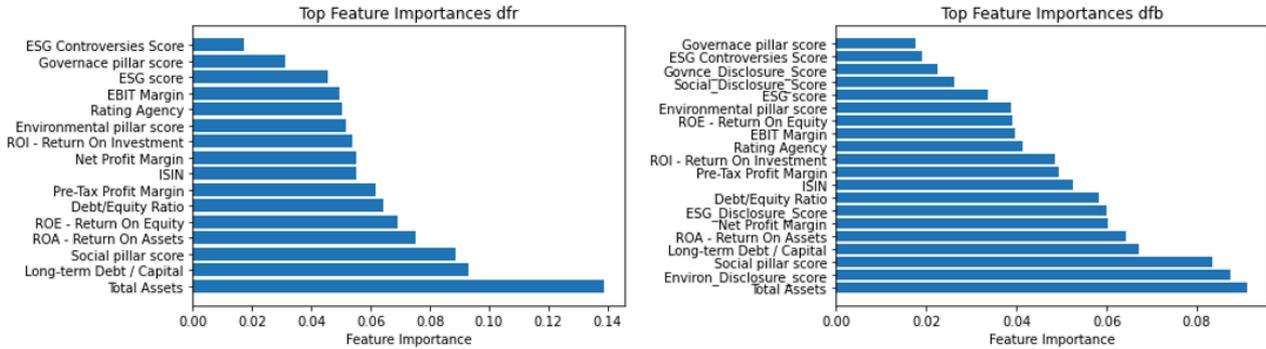


Figura 86 - Importanza delle features per dfr e dfb

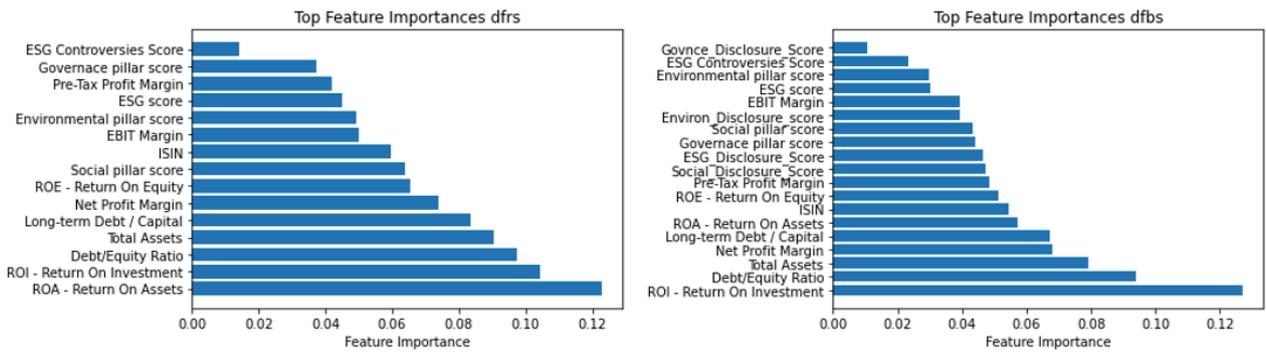


Figura 87 - Importanza delle features per dfrs e dfbs

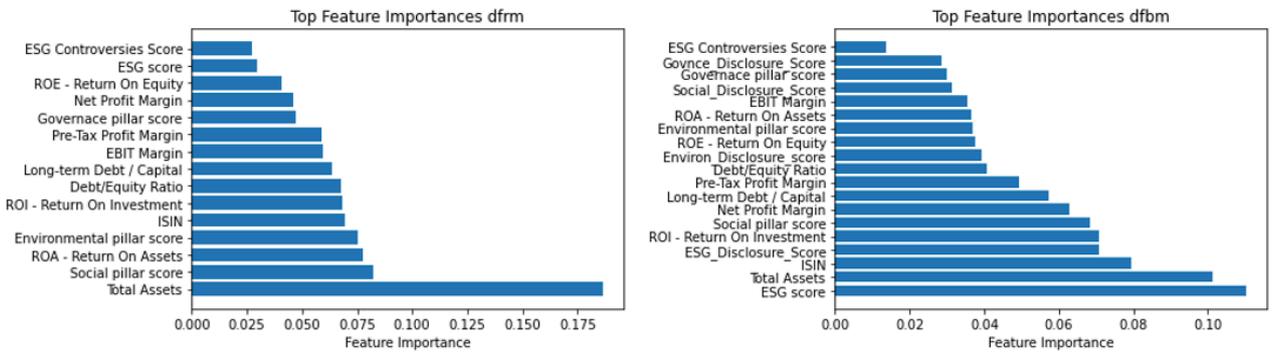


Figura 88 - Importanza delle features per dfmr e dfbm

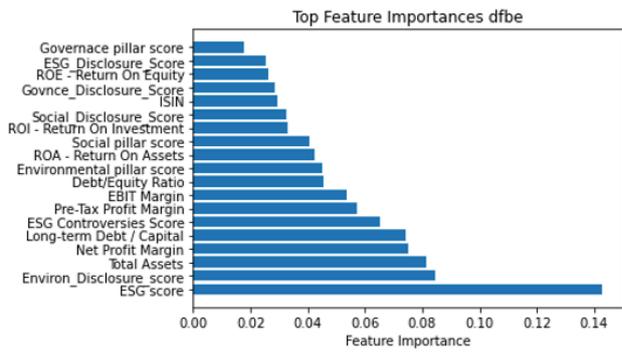
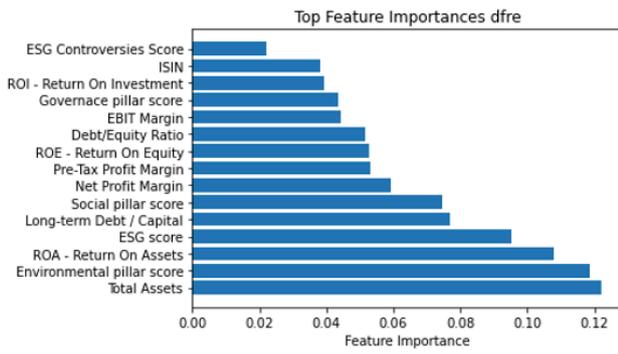


Figura 89 - Importanza delle features per dfre e dfbe

ANNESSO O: Link ai dataset ed allo script

Link cartella drive:

<https://drive.google.com/drive/folders/1wvDY9vzWY8hJECmsoCRuEo3VEEoLodj?usp=sharing>.

QR code cartella drive:



RIASSUNTO

OBIETTIVO DELLA TESI

L'elaborato ha l'obiettivo di indagare come i criteri ESG - ovvero quei criteri rivolti alle sfere ambientale, sociale e di *governance* - colleghino la *corporate reputation* al *credit rating* aziendale, al fine di fornire al manager uno strumento valido con il quale analizzare in maniera olistica le performances dell'azienda sotto un complessivo profilo qualitativo/quantitativo. In particolare, tramite l'applicazione di un algoritmo di Machine Learning, saranno in prima istanza valutati gli impatti delle variabili (ESG e finanziarie) sul *credit rating* e in seconda istanza sarà determinato un algoritmo che partendo da tali variabili potrà prevedere con grande affidabilità le valutazioni di credito delle agenzie di rating più importanti.

INTRODUZIONE AL TEMA

Dopo una parte introduttiva nella quale si è descritto il contesto generale di riferimento, sottolineando l'importanza del Machine Learning per la soluzione di un problema caratterizzato dalla necessità di fare analisi e sintesi di numerosissime variabili di carattere quantitativo (finanziario) e qualitativo, ci si è soffermati sui concetti fondamentali.

In particolare, si è sviluppato il tema del **Credit Risk** la cui analisi permette di studiare la probabilità che un debitore non sia in grado di pagare il proprio debito nei confronti di un creditore. Questo rischio di credito viene preso in esame dalle Agenzie di Credito (CRA), che ricoprono una funzione altamente importante nei mercati finanziari, poiché nascono con l'obiettivo finale di ridurre l'asimmetria informativa che esiste naturalmente fra debitori e creditori sia nelle valutazioni *corporate*, sia nelle valutazioni degli Stati.

Successivamente, si è analizzato il **rapporto tra questo Credit Risk e la reputazione aziendale**, evidenziando come la maggior parte delle aziende non disponga di una struttura adeguata al controllo e dunque al management di questa interazione, limitandosi spesso non tanto alla gestione approssimativa di tale rischio, bensì alla gestione della crisi.

Con il tema della reputazione aziendale si è entrati direttamente nell'ambito di interesse del Marketing. In particolare, negli ultimi anni stiamo assistendo ad una crescente attenzione nei confronti dei criteri ESG, fortemente influenzati dall'opinione pubblica. Si tratta infatti di caratteri intrinsecamente reputazionali ed un numero sempre più elevato di società si trova costretta a fornire quante più informazioni possibili al riguardo, sia a causa delle regolamentazioni sempre più stringenti in materia, sia perché spinte dal mercato stesso. Tale acronimo si riferisce alle dimensioni Ambientale, Sociale e della Governance, laddove, in particolare:

- L'Environmental pillar riguarda tutti quegli aspetti relativi alle emissioni di gas serra o di elementi inquinanti, nonché sull'utilizzo delle risorse e di come queste vengano smaltite o riutilizzate;
- il Social pillar fa invece riferimento a come le aziende gestiscono lo sviluppo dei dipendenti, le pratiche di lavoro, la sicurezza e la qualità dei propri prodotti.
- il Governance pillar, infine, si riferisce ai diritti degli azionisti ai membri del consiglio di amministrazione, nonché alle modalità di retribuzione dei dirigenti.

A questo punto, si è passati ad indagare la **relazione che esiste fra reputazione aziendale e credit rating**, tramite l'utilizzo di questi concetti ESG, mettendoli in sistema con le variabili finanziarie di uso comune. A tale scopo, si è fatto ampio ricorso al linguaggio Python e al *Machine Learning*, in maniera tale da permetterci di utilizzare una vasta gamma di dati in maniera estremamente efficiente e di condurre più analisi simultaneamente.

SVILUPPO DEL TEMA

Creazione dei dataset

A questo punto si entra nello sviluppo vero e proprio del problema, mediante l'analisi dei dati disponibili. Questi devono essere contenuti in un dataset contenente tutti i valori necessari (finanziari e non finanziari) e riferiti alle aziende oggetto dello studio. Questa fase ha rappresentato la prima difficoltà, richiedendo la materiale composizione di dataset che non si limitino, come di norma, a mettere in sistema variabili finanziarie per definire il credit ranking societario, ma che tenga anche conto dei criteri ESG ai quali si è accennato. In particolare, il lavoro, nel suo complesso, ha attraversato tre passaggi principali: [Capitolo 8.1]

4. *Generazione dei dataset*. Si parte da un dataset iniziale creato da Makwana R., Bhatt D., Delwadia K., Shah A. & Chaudhury B. (2022), che ha come obiettivo quello di utilizzare degli algoritmi per ottenere una regola empirica sugli indici finanziari che consenta di prevedere il credit rating aziendale; successivamente, si è integrato questo **dataset iniziale** per addivenire ad un **dataset intermedio** integrato con dati ESG Score estratti da Refinitiv. Infine, si è proceduto a realizzare il **dataset finale** inserendo i dati ESG Disclosure Score estratti da Bloomberg
5. *Correlation Analysis* con la quale si è indagata nello specifico, l'intensità del legame tra le variabili contenute nei dataset intermedio e finale.
6. *Predictive Analysis with machine learning*: con questa fase invece, ci si è posti come obiettivo quello di determinare un algoritmo quanto più efficace ed efficiente possibile per determinare, a partire da una serie di metriche finanziarie ed ESG, il credit rating aziendale futuro.

Svolgimento dell'analisi

Dopo aver costruito i dataset sopra riportati (*Figura 15*), si è cominciata l'analisi vera e propria. Come detto, l'analisi è stata condotta con l'utilizzo del linguaggio Python, il quale ha permesso di analizzare i dati con la massima efficienza.

Per prima cosa si è dunque deciso di condurre un'analisi di Correlazione sui due dataset elaborati, ovvero sia quello intermedio, sia quello finale. L'analisi di correlazione ci è utile a verificare l'esistenza di una relazione significativa tra le variabili indipendenti considerate - *ovvero gli indici finanziari provenienti dal dataset iniziale e dall'extrapolazione via Refinitiv dei Total Assets; gli indici relativi alle performance ESG provenienti dal dataset intermedio (da ora dfref- data frame derivante dall'aggiunta dei dati di Refinitiv); gli indici relativi agli score di pubblicazione riportati nel dataset finale (da ora dfblo - data frame derivante dall'aggiunta dei dati di Bloomberg)* - e la variabile dipendente dell'analisi, ovvero il *Rating creditizio*, proveniente dal dataset iniziale.

Questa analisi di correlazione è stata condotta con tre metodi differenti:

4. *Correlazione di Pearson*, per misurare la forza e la direzione di una relazione lineare tra due variabili continue. Si fa riferimento a variabili continue quando queste possono assumere un qualsiasi valore all'interno del proprio intervallo di riferimento, mentre per relazione lineare si intende una qualsiasi relazione matematica che possa essere rappresentata su un piano cartesiano sotto forma di retta.
5. *Correlazione di Spearman*, per misurare la forza e direzione di una relazione monotona tra due variabili continue o ordinali, laddove per relazione monotona si intende una relazione che all'aumentare o alla diminuzione di una variabile non presenta un aumento o una diminuzione lineare dell'altra, mentre per variabile ordinale si fa riferimento ad una variabile che può assumere un valore stabilito all'interno di un intervallo, come nel caso di una scala di rating in cui si possono assumere solo i valori definiti (AAA, AA+, ecc) fra il valore massimo e quello minimo. Questo tipo di correlazione si calcola come quella di Pearson, con la differenza che i valori vengono convertiti in ranghi prima della misurazione.
6. *Correlazione di Kendall*: questo tipo di correlazione ci permette di misurare forza e direzione della relazione monotona che intercorre tra due variabili ordinali.

L'analisi si è sviluppata attraverso le seguenti fasi:

- **Fase di Exploratory Data Analysis** per esplorare le informazioni generali dei dataset, in modo tale da osservare se ci fossero variabili nulle rimaste a seguito della fase di unione dei dataset e se ci fossero differenze circa il tipo delle informazioni a disposizione (*integer, float, object*, ecc).
- **Fase di Preprocessing** per uniformare le modalità di misurazione all'interno dei dataset, i quali presentavano dati di tipo diverso (*object, float, integer*), mediante due attività di encoding:
 - c. Innanzitutto, si è fatto un *label encoding* per attribuire un numero alle variabili qualitative presenti in analisi. In particolare, questo encoding è stato fatto sulle variabili: “*Corporation*”, “*Rating Agency*”, “*CIK*”, “*ISIN*”, “*Reuters Instrument Code*”, “*Ticker*”, “*Sector*” e “*SIC Code*”.

- d. In secondo luogo, si è fatta un *ordinal encoding* per codificare tutte quelle variabili ordinali presenti nei dataset. Questa attività è stata necessaria sia per la variabile “Rating” proveniente dal dataset iniziale, sia per “*ESG score grade*”, proveniente dal dataset Intermedio *Refinitiv (dfref)*.

Entrambe le attività si sono ripetute sia per *dfref* che per *dfblo*.

Correlation Analysis per *dfref* e *dfblo* (Annesso A e Annesso B)

Lo studio è stato condotto su entrambi i dataset di cui si è parlato sopra in maniera del tutto speculare. La differenza principale è dovuta alle dimensioni delle matrici di correlazione ottenute che, nel primo caso, sono 35x35 e nel secondo caso 39x39. Il commento si è condotto esclusivamente sulla matrice di Spearman poiché è indicata per l’analisi di tutte quelle relazioni monotone fra variabili ordinali o continue.

Innanzitutto, si è osservata la **ridondanza delle variabili**, evidenziabile per le variabili identificative (*Corporation, CIK, ISIN, Reuters Instrument Code* e *Ticker*), per le **variabili di settore** (*Sector* e *SIC Code*), per **Variabili finanziarie** (*Operating Margin* ed *EBIT Margin*) e per le **Variabili ESG**, con riferimento a *ESG score* e *ESG score grade*.

Si è poi considerata l’**irrilevanza di alcune relazioni**, verificandola per le variabili temporali *Rating Year* e *Rating Month*, ma anche *Binary Rating* che potrebbero essere dunque trascurate. Infine, si è presa in considerazione la forza dei legami presenti in matrice, analizzando la **rilevanza delle rilevazioni misurate**. Tutto ciò, ovviamente, ci spinge verso una fase di *feature selection* con la finalità di snellire l’analisi. Questi risultati sono stati ottenuti sia nell’analisi di *dfref* che nell’analisi di *dfblo*.

Inoltre, si segnalano i risultati più importanti che queste due analisi hanno generato.

Osservando le *figure 18 e 19* dell’elaborato, si può facilmente vedere come in entrambe le analisi di correlazione, le variabili ESG inserite abbiano una grande rilevanza per il Rating. In particolare, si ha che i legami presenti all’interno del dataset sono spesso più forti fra variabili ESG *-che siano relative alla performance o che siano relative ai livelli di pubblicazione-* e Rating che fra indici finanziari e Rating, confermando l’importanza dell’analisi effettuata. Questo risultato ci spinge verso un’analisi più approfondita dell’output, che si è tradotta in un’analisi di correlazione per singole agenzie. Questa successiva analisi di correlazione è stata ripetuta sui subset generati da *dfref* e da *dfblo* a seguito di una fase di ***features selection*** condotta sulla base dei risultati ottenuti in termini di ridondanza, rilevanza *-in particolare si sono mantenute solo le variabili con legame maggiore a 0,2 o minore a -0,2-* ed irrilevanza delle variabili. Nello specifico, si è fatto riferimento alle 3 agenzie più frequenti all’interno dei dataset di origine. In particolare, queste sono Standard & Poor’s, Moody’s ed Egan-Jones.

[per un’analisi più approfondita, vedere capitoli 9, 9.1, 9.2 e 9.3]

Riguardo la *features selection*, diciamo che le variabili mantenute nell'analisi successiva, si possono vedere nelle figure 20 e 21 dell'elaborato generale, ovvero a pagina 66 e 67. Queste sono rispettivamente 16 per *dfref_red* (che è *dfref* ridotto) alle quali se ne aggiungono 4 per *dfblo_red* (che è *dfblo* ridotto).

Le matrici così ottenute sono dunque composte sia da variabili finanziarie particolarmente rilevanti, sia da quelle ESG inserite in analisi. Dunque, i subset generati (*Figura 22*) sono: 1) *dfref_sp* (2420x16): *dfref* con solo le rilevazioni di S&P; 2) *dfref_moody* (2069x16): *dfref* con solo le rilevazioni di Moody's; 3) *dfref_egan* (1215x16): *dfref* con solo le rilevazioni di Egan-Jones; 4) *dfblo_sp* (2370x20): *dfblo* con solo le rilevazioni S&P; 5) *dfblo_moody* (2023x20): *dfblo* con solo rilevazioni di Moody's; 6) *dfblo_egan* (1179x20): *dfblo* con solo le rilevazioni di Egan-Jones.

Correlation Analysis per *dfref_sp*, *dfref_moody* e *dfref_egan* (Annesso C, Annesso D e Annesso E)

Lo studio sui tre subset è stato condotto in maniera equivalente a quello condotto sulla matrice generale *dfref*. Questo ha garantito comparabilità fra i risultati ed affidabilità.

Il primo risultato interessante, si è ottenuto per *dfref_sp*, in quanto si evidenzia una leggera controtendenza rispetto a quanto visto nelle matrici generali *dfref* e *dfblo*. In questo caso, infatti, si ha che, per la matrice composta dalle sole rilevazioni Standard & Poor's, a livello di intensità, la correlazione fra Rating e variabili finanziarie risulta essere tendenzialmente più importante rispetto a quella fra Rating e variabili ESG (*Figura 24*). Le osservazioni che si possono fare invece sulla matrice di correlazione di *dfref_moody* e *dfref_egan*, per quanto riguarda la tendenza generale dell'intensità dei legami fra le variabili, si allineano ai risultati ottenuti nello studio di *dfref* e *dfblo*: la forza dei legami fra le variabili ESG e Rating creditizio, risulta essere tendenzialmente più impattante rispetto a quella fra Rating e variabili finanziarie.

In tutti i casi analizzati, infine, si sottolinea la grande incidenza fra variazioni del livello di controversie dovute a questioni ESG (*ESG controversies score*) e *Total Assets*, a testimonianza di quanto danno può generarsi dal coinvolgimento in situazioni conflittuali (scandali) e problematiche dovute a queste questioni. Dunque, le buone pratiche di marketing devono andare a braccetto con l'etica aziendale. Questa deve essere messa in risalto dal marketing, il quale svolge senz'altro un ruolo chiave nell'evitare un'esposizione scriteriata a media e pubblico su alcune questioni che potrebbero generare effetti estremamente negativi per l'azienda, non solo dal punto di vista reputazionale, ma anche da quello finanziario e strutturale. Come si vedrà, questa considerazione, vale anche per le altre agenzie. [Capitoli 9.4, 9.5 e 9.6].

Concludendo, risulta estremamente evidente, per *dfref*, che si hanno differenze, talvolta importanti, fra agenzia ed agenzia. Questa tesi, se sostenuta anche dallo studio condotto su *dfblo*, giustificherebbe concretamente la rilevanza dello studio condotto su diverse agenzie di rating, e aprirebbe l'interrogativo su cosa potrebbe succedere nella fase di analisi predittiva. Inoltre, si è avuta chiara testimonianza di come alcune relazioni siano più importanti di altre a seconda dell'agenzia alla quale ci si riferisce. Dunque, se

l'obiettivo manageriale è quello di ottenere dei benefici particolari da una valutazione di credito di un'agenzia specifica, si potrebbe pensare di focalizzarci su alcune variabili particolari.

Correlation Analysis per *dfblo_sp*, *dfblo_moody* e *dfblo_egan* (Annesso F, Annesso G e Annesso H)

L'analisi condotta sui subset di *dfblo_red*, ha seguito la stessa impostazione logica di quella descritta nel paragrafo precedente.

Le osservazioni riguardo alle tendenze generali ottenute in questo studio, si allineano di fatto a quelle rilevate nello studio precedente. Infatti, si nota come, in presenza del subset *dfblo_sp*, ci sia una leggera inversione di tendenza. Nello specifico, anche in questo caso, nonostante la rilevanza dei legami delle variabili ESG -*con le quali ora facciamo riferimento anche a quelle che misurano il livello di pubblicazione in materia*- con il Rating, abbiamo ora una leggera prevalenza della rilevanza dei legami fra variabili finanziarie e Rating. Anche in questo caso assistiamo ad un riallineamento della tendenza generale per *dfblo_moody* e *dfblo_egan*.

Si va poi nel merito più specifico di quanto accade riguardo l'impatto delle variabili ESG relative al livello di pubblicazione -*ESG disclosure score, Environmental disclosure score, Social Disclosure score e Governance disclosure score*- con il Rating creditizio. Infatti, è interessante andare a vedere come ci sia un'altra differenza fra le varie agenzie. In primo luogo, per *dfblo_sp*, quindi per l'agenzia Standard & Poor's, si nota come la forza del legame fra Rating e score di pubblicazione risulti spesso maggiore o uguale agli score ESG estratti nella fase relativa alla costruzione della matrice intermedia. In particolare, la correlazione fra *ESG score e Rating* risulta essere meno rilevante di quella fra *ESG disclosure score e Rating*, così come quelle fra *Environmental pillar score e Rating* e fra *Governance pillar score e Rating* rispettivamente con quelle fra *Environmental disclosure score e Rating* e fra *Governance disclosure score e Rating*. [Per maggiori dettagli guardare capitolo 9.7]. Questi risultati sottolineano ancora una volta l'importanza da parte delle organizzazioni di saper rivolgersi agli stakeholder esterni ed interni all'azienda, anche agendo con un buon livello di pubblicazioni a sostegno delle tematiche ESG. Tutto ciò, ovviamente, agisce insieme a buone prestazioni finanziarie e ESG, senza le quali non si potrebbe puntare ad ottimizzare i benefici ottenibili. Quanto detto per *dfblo_sp* però non vale del tutto per *dfblo_moody* e *dfblo_egan*. Infatti, in questi due casi, anche se gli impatti delle variabili relative alle pubblicazioni rimangono elevati e si allineano a quelle relative alle performance, rimangono leggermente meno rilevanti. [Più informazioni a capitoli 9.8 e 9.9].

Conclusioni Correlation Analysis

I risultati ottenuti hanno suggerito come le variabili ESG siano estremamente correlate alle metriche finanziarie ed al Rating stesso, il quale sembra essere più influenzato dalle prime che dalle seconde, almeno

in linea generale. Questo ha delle conseguenze importanti per le decisioni che devono essere prese dalle organizzazioni, sia in funzione del pubblico ed in generale degli stakeholders esterni, sia in funzione di quelli interni. L'analisi generale ha messo in risalto come il focus non debba dunque concentrarsi su una visione parziale del problema, anche se di più facile approccio, bensì su una visione quanto più olistica possibile. Le metriche ESG rappresentano l'attualità ed il futuro aziendale, non solo dal punto di vista reputazionale, bensì anche dal punto di vista della salute finanziaria aziendale.

Quanto detto anche nei capitoli precedenti, può essere così sintetizzato facendo un recap delle tendenze che si sono ottenute in queste analisi: 1) **Tendenze generali delle analisi di correlazione di dfref sp e dfblo sp:** leggermente disallineate da quanto visto su *dfref* e *dfblo*. Infatti, si ha uno spostamento tendenziale dell'importanza verso le relazioni fra Rating e variabili finanziarie, anche se i legami fra Rating e variabili ESG rimangono molto rilevanti; 2) **Tendenze generali delle analisi di correlazione di dfref moody e dfblo moody:** in queste analisi abbiamo un totale allineamento a quanto mostrato nelle analisi generali su *dfref* e *dfblo*. 3) **Tendenze generali delle analisi di correlazione di dfref egan e dfblo egan:** nei casi riportati, si ha allineamento alle analisi su *dfref* e *dfblo* per quanto concerne la rilevanza delle correlazioni fra Rating e variabili finanziarie e fra Rating e variabili ESG. Infatti, queste ultime relazioni risultano, così come in Moody's, più rilevanti, ma abbiamo un innalzamento generale dei valori della rilevanza di tutte le variabili scelte per comporre le matrici ridotte sulle quali l'analisi è svolta.

Infine, si possono fare anche delle osservazioni generali su tutte queste analisi riferite ai subset generati:

- 3) Innanzitutto, si ha una grandissima rilevanza della correlazione fra **total assets e variabili ESG** (sia *Refinitiv* che *Bloomberg*), a testimonianza dell'importanza dal punto di vista finanziario di quest'ultime;
- 4) Con focus alle variabili ESG, quelle legate alla **Governance** mostrano i legami più deboli con il Rating, anche se rimangono sempre interessanti ed impattanti.

Quindi, un risultato senz'altro interessante è stato quello secondo cui tramite un'analisi più di dettaglio sulle rilevazioni dei dataset, filtrandole per le agenzie più importanti, si ottengono dei risultati leggermente diversi l'un con l'altra. Questo ci pone davanti alla questione relativa a: cosa succederebbe in un'analisi predittiva e come cambierebbe il livello di importanza delle varie features se non ci si fermasse ad un'analisi generale, ma si conducesse tale studio anche per i subset analizzati in questo caso?

A queste domande, unite alle informazioni estrapolate in letteratura, si risponderà tramite un'analisi predittiva condotta con il *machine learning*, garantendoci una visione olistica del fenomeno.

Predictive Analysis

La seconda tipologia di analisi svolta è stata quella predittiva. In primo luogo, si tratta di **inquadrare lo scopo ultimo della nostra analisi**, ovvero prevedere - *a partire da tutte quelle variabili identificate come più impattanti nella fase di analisi della correlazione* - la valutazione di credito che sarebbe poi stata fatta

dalle agenzie prese in esame. Questo problema, quindi, poteva essere affrontato come una classificazione multi-classe. Questa scelta è stata fatta per molteplici ragioni, fra cui, le più importanti, sono state:

1. Offrire un'analisi che possa essere indicativa anche per quelle classi di Rating che non presentano un numero di rilevazioni sufficiente allo sviluppo di un algoritmo efficace. In *figura 35*, è possibile osservare la distribuzione delle rilevazioni in *dfr* (*dfref_red*) per ogni classe di Rating presente nello studio.
2. Allinearsi agli studi precedenti presi in esame e dai quali lo studio in questione si sviluppa (molti casi, come quello da cui il Dataset di partenza è stato preso, affrontano il problema come una classificazione binaria), sviluppando un'analisi più dettagliata ed approfondita;
3. Allinearsi anche alle informazioni presenti sul sito di S&P riguardo alla classificazione utilizzata - che ricordiamo essere alla base delle valutazioni di Rating impiegate dagli autori dello studio del nostro dataset di partenza - che hanno ridotto alla stessa scala di valutazione di credito tutte le scale utilizzate dalle diverse agenzie presenti nel dataset.

Per quest'ultima ragione, citando la pagina ufficiale di Standard & Poor's ([link](#)), siamo partiti dalla distinzione binaria effettuata dall'agenzia stessa, ovvero *Speculative grade* per i Rating da D a BB e *Investment grade* per quelli da BBB a AAA.

Per far fronte alle necessità di un primo bilanciamento delle classi dei nostri dataset finale ed intermedio, si è deciso di mantenere la classe relativa a *Speculative grade* e di andare più nel dettaglio per quanto riguarda quella chiamata *Investment grade*.

Si è deciso di creare la variabile dipendente **Rating quality grade** da sostituire all'interno dell'analisi predittiva alla variabile dipendente chiamata **Rating**. Le classi generate sono quindi, a salire: **Speculative grade investment** (classe 0 con Rating da D a BB+), **Adequate grade investment** (classe 1 con Rating da BBB- ad A-) e **Optimal grade investment** (classe 2 con Rating da A, ad AAA).

Una volta inquadrato il problema di classificazione, si è scelta la tecnica con cui condurre l'analisi, ovvero la metodologia di *ensemble learning* chiamata **Random Forest**, che è basata su un'altra tecnica di machine learning, ovvero il *Decision Tree Classifier*. Il *Random Forest Classifier*, nello specifico, è una tecnica di Bagging che sviluppa dei modelli predittivi (*Decision Trees*) parallelamente, per poi decidere a votazione quali sono i risultati più ricorrenti (*Figura 36*).

Il passo successivo è stato quello dell'alleggerimento della nomenclatura utilizzata. Ci si riferisce ora con *dfr* a *dfref_red*, con *dfb* a *dfblo_red* (ovvero i dataset intermedio e finale ridotti alle variabili con correlazioni con il Rating maggiori), a *dfrs* e *dfbs* per *dfref_sp* e *dfblo_sp*, a *dfrm* e *dfbm* per *dfref_moody* e *dfblo_moody* e a *dfre* e *dfbe* per *dfref_egan* e *dfblo_egan*.

Successivamente si è analizzato il bilanciamento del dataset, valutando il numero delle rilevazioni appartenenti alle 3 nuove classi create. Si è notato come, seppur in maniera minore a prima, persisteva

ancora un determinato grado di sbilanciamento, al quale avremmo dovuto far fronte in sede di analisi predittiva (Figura 37). Inoltre, si sono definite le altre caratteristiche necessarie e che avremmo poi utilizzato per tutte le analisi predittive svolte. In primo luogo, si è deciso di dividere i dataset in **training set** e **test set** rispettivamente per l'80% del dataset totale e per il 20%. In seguito, si sono ottimizzati gli iperparametri (**hyperparameters tuning**), attraverso una strategia **Grid Search**. Gli iperparametri su cui si è fatta l'ottimizzazione sono stati: 1) **n_estimators** (1, 2 o 5); 2) **max_depth** (1, 5 o 10); 3) **max_features** (2 o 4). Terminata dunque la descrizione dei processi preliminari messi in atto per l'utilizzo del *Random Forest Classifier*, si passano ora in rassegna i principali risultati dello studio. Si risponderà, dunque, alla domanda: "è possibile effettuare un'analisi predittiva con buone performance, utilizzando le variabili emerse come più impattanti durante la fase di correlazione e valutando l'importanza di ogni singola feature?". Si sottolinea che nelle prossime analisi, si sono tenute in conto le misure di performance relative a: **precision**, **recall**, **f-1 score** e **accuracy**, con particolare attenzione alle ultime due. In tutti i casi, dunque, ci è utile conoscere i concetti di *True Positive*, *True Negative*, *False Positive* e *False Negative*. I risultati delle analisi condotte si sono letti con l'ausilio di *confusion matrix* e *classification report*. [Per maggiori informazioni, vedere capitolo 10 e 10.1 e per le metriche Figura 38, 39, 40 e 41].

Predictive Analysis per dfr e dfb (Annesso I)

Il principale risultato che è possibile notare in questa analisi generale, è che le performance del modello applicato a *dfb* siano migliori rispetto a quelle per *dfr*. In particolare, si ha un'accuracy pari a 0,81 per *dfb* e a 0,76 per *dfr*, ma anche gli f1-score, superano in tutti i casi quelli di *dfr*. Nonostante ciò, entrambe le applicazioni mostrano risultati altamente soddisfacenti. Dunque, ampliando l'analisi ad un dataset con valori ESG sia relativi alla performance, sia relativi al livello di pubblicazioni ESG da parte dell'azienda, si ottengono dei risultati predittivi migliori rispetto a quelli ottenuti sul dataset con solo le variabili ESG legate alle performance. Questo risultato è estremamente interessante, soprattutto in ottica di programmazione. [Capitolo 10.1 per approfondire i vari risultati]

Predictive Analysis per dfrs, dfrm e dfre (Annesso L)

L'analisi predittiva è stata replicata in maniera del tutto equivalente a quanto fatto per *dfr* e *dfb*, al fine di ottenere dei risultati confrontabili e di facile lettura. Osservando i risultati ottenuti (Figura 44, 45 e 46) è evidente come il modello si applichi in maniera estremamente più precisa all'agenzia Standard & Poor's, mentre risulta più debole con il dataset che fa riferimento alle rilevazioni di Moody's. In linea generale, si può dunque dire che esistono differenze in termini di predittività fra le varie agenzie, nonostante le performance del modello così costruito rimangano ottime. Infine, per quanto riguarda le analisi svolte su *dfr*, *dfrs*, *dfrm* e *dfre*, si può concludere dicendo che: 1) L'analisi predittiva svolta su *dfrs* risulta di gran

lunga la più affidabile in termini di performance registrate, con un' **Accuracy** complessiva di 0,86 e con degli **f1-score** elevati per tutte le classi (si segnala un 0,90 per la classe 2); 2) Il modello si comporta meglio per **dfrs** e **dfre** rispetto a quanto faccia per **dfr**; 3) Nonostante l'analisi compiuta su **dfr** presenti **Accuracy** e **f1-score** tendenzialmente migliori rispetto all'analisi svolta su **dfre**, sarebbe comunque da preferirsi un'analisi capillare sui vari subset delle agenzie, in quanto non si avrebbero dei benefici eccezionali. [Capitolo 10.2 per una lettura più esaustiva dei risultati].

Predictive Analysis per dfbs, dfbm e dfbe (Annesso M)

Con lo stesso modus operandi dello studio precedente, si è condotta l'analisi per i subset di dfb. Come ottenuto per i subset di dfr, si ottengono dei risultati ottimi quando si va ad applicare il modello predittivo sul dataset con solo rilevazioni di Standard & Poor's, mentre si può parlare di risultati sufficientemente buoni per l'analisi effettuata sulle altre due agenzie. Bisogna però sottolineare come, nel caso di **dfbe**, si abbia un risultato non propriamente soddisfacente, in quanto l' **f1-score** relativo alla classe 2, e quindi alla classe relativa agli "**optimal grade investment**", risulti solo pari a 0,61. Questo score rappresenta dunque il risultato più basso in termini di **f1-score** di tutta l'analisi. Per questo motivo, l'analisi condotta sul dataset comprensivo degli score ESG di pubblicazione della sola Egan-Jones dovrebbe quanto meno esser ponderato e calato in un'analisi più accurata. In linea generale, nonostante gli ottimi risultati, si sottolinea come, eccezion fatta per **dfbs**, gli score ottenuti in termini di **Accuracy** e di **f1-score** per **dfbm** e **dfbe**, ci pongono davanti ad una questione. Infatti, questi presentano dei valori inferiori, non trascurabili, rispetto allo studio generale condotto su **dfb**, il quale presenta delle performance più elevate in tutti i casi. Questo ci porta a dire che l'analisi così condotta ci può portare a cogliere varie differenze all'interno delle metodologie utilizzate dalle agenzie, in termini di pesi utilizzati per le features ed in termini di accuratezza dei modelli. Se per questo secondo aspetto già si sono viste le varie discordanze, per il discorso relativo alla differenza di importanza delle features, sarà necessaria un'analisi ad hoc. Detto questo, è consigliabile effettuare per questa tipologia di dataset (quello composto dalle rilevazioni Egan-Jones), entrambe le analisi. Infine, si sottolinea, facendo un paragone fra le performance del modello su **dfb**, **dfbs** e **dfbm** e su **dfr**, **dfrs** e **dfrm**, come nel caso dell'analisi condotta sui dataset comprensivi anche delle variabili ESG di Bloomberg, si ottengano risultati migliori (eccezion fatta per **dfbe** rispetto a **dfre**). Questo conferma il delta delle performance delle analisi condotte su **dfb** e **dfr** e ci suggerisce che per aumentare la capacità predittiva del nostro modello, sia utile immettere all'interno dello studio gli **score** di pubblicazione in questione. [Capitolo 10.3 per ulteriori dettagli].

Features importance (Annesso N)

A termine dell'analisi predittiva è stata indagata l'importanza delle features all'interno del modello predittivo, per ogni singolo caso esaminato. Questo è stato possibile con l'ausilio dell'attributo adattato "**feature_importances_**" con Python. In particolare, si analizza la media e la deviazione standard dell'accumulo della diminuzione delle impurità presenti all'interno di ogni albero decisionale del modello utilizzato. Per commentare i risultati, è interessante mettere a paragone *dfr* con *dfb*, *dfrs* con *dfbs*, *dfrm* con *dfbm* e *dfre* con *dfbe*. Si premette che questo tipo di analisi, ci permette di fare delle osservazioni accessorie sulle *features* che abbiamo individuato nella fase di analisi della correlazione come più importanti. In particolare, è utile per una eventuale ulteriore selezione di *features* e per comprendere il funzionamento sottostante alla performance di un modello. Quindi, visti gli ottimi risultati ottenuti all'interno degli algoritmi implementati nelle varie singole analisi, è sicuramente interessante andare ad analizzare come le discordanze fra le varie performance si siano create e come le variabili ESG abbiano influito su tale processo. Questo rappresenta l'ultima analisi importante dello studio; analisi che dovrebbe garantire maggiore interpretabilità alle conclusioni finali di cui si parlerà nel prossimo capitolo.

Cominciando da *dfr* e *dfb* (Figura 50), si nota la grande importanza della variabile **total assets** inserita in fase di costruzione dei dataset. A seguire, è interessante sottolineare la grande rilevanza in entrambe le analisi del **Social Pillar score** è la grande importanza di **Environmental disclosure score** nel caso di *dfb*. Questo, ovviamente, non fa altro che confermare la grande importanza in ambito Credit Risk di questa tipologia di variabili. In particolare, si evidenzia come, le strategie di marketing rivolte al sociale, ma anche quelle che effettivamente puntano ad un aumento delle pubblicazioni lato ambientale, garantiscano grande importanza all'interno del modello. In conclusione, ogni metrica all'interno del modello contribuisce alla performance globale e non si hanno metriche con incidenza vicina allo zero. Si sostiene dunque che si possa pensare di mantenere la totalità di queste, per evitare perdite di informazioni.

Proseguendo con *dfrs* e *dfbs* (Figura 51), in maniera coerente con quanto osservato nelle altre analisi, si sottolinea una leggera inversione di tendenza rispetto all'analisi generale. Infatti, per il subset con rilevazioni di Standard & Poor's (anche se di poco), total assets non rappresenta più la variabile più importante e la prima metà di features, guardando all'importanza nel modello, è rappresentata dagli indici finanziari. Questa maggiore importanza non giustifica tuttavia il trascurare le variabili ESG che mostrano in entrambi i casi importanza abbastanza adeguata ad essere rilevata. Infatti, *Social pillar score*, *Social disclosure score* e *ESG disclosure score*, rappresentano anche in questo caso variabili ESG molto importanti. A queste, si aggiunge nell'analisi in *dfbs* *Governance pillar score*, con un impatto maggiore al 4%.

Si passa poi ai risultati dell'analisi condotta su *dfrm* e *dfbm* (Figura 52). In questo caso ci riallinea alla tendenza evidenziata nell'analisi di *dfb* e *dfr*, in cui Total Assets rappresentavano una variabile estremamente rilevante. Si ha comunque una leggera controtendenza anche in questo caso, poiché

nell'analisi svolta su *dfbm* si ha ora una prevalenza della variabile *ESG score*, anche rispetto a *Total Assets*. Inoltre, si segnala la grande importanza del livello di pubblicazioni relative ai criteri ESG. Anche in questi casi, si assiste anche a grande importanza della variabile *Social pillar score*.

Infine, si commentano i risultati per *dfre e dfbe* (Figura 53). Si nota subito come l'ESG score nello studio su *dfbe* rappresenti la variabile nettamente più importante e che rimanga anche fondamentale nell'analisi su *dfre*. Inoltre, ricopre grande importanza, per *dfre* soprattutto, l'*environmental pillar score*, mentre per *dfbe* si ha l'*environmental disclosure score* come seconda variabile più importante.

Per concludere questa ultima fase di analisi, si sottolinea come tutte le variabili ESG indagate nell'elaborato, svolgano il loro ruolo anche all'interno della prevedibilità del Rating aziendale.

È interessante senz'altro osservare le variazioni che esistono fra le varie agenzie e fra le due analisi condotte su dataset intermedio (fase 2) e dataset finale (fase 3). Questo aggiunge senz'altro spirito critico nella valutazione dei singoli casi che si trova ad affrontare l'azienda durante la sua attività. I manager, dunque, possono utilizzare tale strumento per approfondire in maniera elaborata ciò che deve sottostare alla definizione della strategia messa in atto. Come risultato principale, però, va sottolineato come tutte le situazioni abbiano presentato un apporto equilibrato fra variabili finanziarie e variabili ESG, che testimonia ancora una volta la tesi sostenuta all'interno dell'elaborato in questione. Includere dunque questa tipologia di informazioni e sforzarsi di avere un approccio olistico alla questione, porta dunque a benefici quantificabili e misurabili in termini di prevedibilità e programmazione aziendale.

[Per maggiori informazioni, vedere capitolo 10.4].

CONCLUSIONI

Questo elaborato si propone di analizzare il *fil rouge* che connette la realtà che spesso viene considerata come prettamente qualitativa del marketing, a quella che per definizione viene vista come più quantitativa della finanza, al fine di consentire alle organizzazioni oggetto di valutazioni da parte delle CRA di indirizzarle preventivamente in linea coi propri interessi, adeguando il proprio comportamento, anziché limitarsi a rispondere a posteriori alle stesse.

Il relativo strumento operativo è stato individuato in questo studio nell'applicazione di un modello di *Ensemble Learning* ed in particolare nel *Random Forest Classifier*, che è risultato uno degli algoritmi più utilizzati e con migliori performance nel panorama attuale.

Inoltre, lo studio propone di utilizzare misurazioni ESG pratiche ed affidabili che coprano quanti più ambiti possibile, per rappresentare nell'analisi la *Corporate Reputation*, dei quali essi sono parte integrante.

In particolare, con la scelta delle misurazioni di *Refinitiv* circa le performance aziendali riguardo ai criteri ESG e con la scelta delle misurazioni Bloomberg circa gli score di pubblicazione ESG, si ha una visione completa del quadro, che ci permette di trarre anche importanti conclusioni su ciò che debba essere fatto dall'azienda in fase di attuazione della strategia di marketing aziendale.

Infatti, come è stato dimostrato tramite le matrici di correlazione, queste variabili impattano in maniera estremamente concreta sulla valutazione di credito che viene fatta dalle agenzie (CRA), sia che si guardi al complesso, sia che si guardi alle rilevazioni relative alle singole agenzie stesse. Ciò comporta che i vertici aziendali e le varie funzioni coinvolte debbano apprendere in profondità cosa questi criteri cerchino di comunicare e cosa cerchino di raggiungere, per far sì che gli *score* analizzati possano avere effetti benefici sostanziali. Infatti, si è visto come queste variabili abbiano un impatto paragonabile e in alcune occasioni superiore a quelle variabili finanziarie tradizionalmente considerate principali fautrici delle valutazioni effettuate dalle agenzie.

Perciò, trascurare una qualsiasi di queste variabili, considerando anche il profondo legame che le variabili ESG in questione hanno l'un l'altra, potrebbe compromettere la reputazione aziendale e dunque la valutazione di credito successiva fatta su di essa, compromettendo a sua volta la salute aziendale ed a cascata tutte le funzioni interne alle organizzazioni.

La concretezza dei risultati ottenuti, suggerisce anche come ad un determinato buon livello di pubblicazioni, debba corrispondere un buon livello di performance effettivamente raggiunta in campo ESG dall'azienda, in quanto si vede come queste due tipologie di variabili impattino pressoché nella stessa maniera sul *rating* effettuato.

Limitarsi ad una comunicazione estremamente spinta su queste tematiche senza poi far seguito con azioni concrete a quanto detto, dunque, non porterebbe ai benefici sperati, in quanto si avrebbe un impatto positivo solo parziale, con il possibile *tradeoff* negativo riguardo ad un aumento del rischio di controversie legate a queste materie, come il caso di un'accusa di *green washing*, che ora sappiamo avere una relazione estremamente negativa con il Rating.

Tutto ciò, quindi, deve spingere ulteriormente i manager all'interno delle organizzazioni ad affrontare le questioni in maniera assolutamente bilanciata.

Un'altra importante conclusione ottenuta sempre da questa analisi di correlazione, è stata senz'altro quella di quantificare l'impatto delle questioni *Environment*, *Social* e *Governance*, che, alla luce di quanto osservato, devono essere tutte affrontate in maniera estremamente seria. Trascurare anche solo una di esse – che sia la *Governance*, ovvero quella con impatto positivo minore, anche se non trascurabile - o che sia qualsiasi altra componente, comprometterebbe direttamente l'impatto positivo sul Rating, ma anche indirettamente andando a diminuire quello generato dalla variabile ESG score complessiva. Un duplice effetto negativo che basta a incoraggiare le aziende a comportarsi di conseguenza.

E ancora, tutto ciò può e deve essere letto come possibilità concreta di porre il proprio focus su alcune variabili chiave, come effettuato nella fase di analisi predittiva in questo studio. Questo potrebbe portare ad

applicare un algoritmo predittivo volto a identificare la qualità dell'investimento sull'azienda, percepita dalle varie agenzie di rating (*Rating quality grade*).

In questa maniera, il management, viste le proprie performance in ambito finanziario ed in ambito ESG, potrebbe essere in grado di prevedere con una buona accuratezza quale potrebbe essere la valutazione di credito effettuata dalle agenzie nei propri confronti e nei confronti dei suoi competitor.

Inoltre, dalla stessa analisi, emerge come l'impatto degli score relativi alle pubblicazioni aziendali in materia ESG, ovvero quelle variabili inserite a seguito dell'estrazione delle stesse da Bloomberg, generi un effetto positivo in termini di capacità predittiva dell'algoritmo. Si hanno, infatti, benefici diffusi sia in termini di *accuracy* che in termini di *f1-score*, che devono portare ad attente riflessioni in materia.

Quindi, data la forte interconnessione tra gli elementi di questo studio, per ottenere migliori previsioni si potrebbe puntare a fare aumentare il proprio score di pubblicazione, comportando impatti positivi sia sul Rating che sulle altre variabili ESG. Variabili che, però, ancora una volta dovranno essere trattate in maniera egualitaria, per permettere all'azienda di godere di un beneficio concreto.

Questo dovrebbe indirizzare le mosse aziendali verso scelte strategiche adeguate, migliorando così la comunicazione interna all'azienda circa lo scopo che questa deve perseguire, attraverso collaborazioni, iniziative positive, *advertising*, ecc.

L'obiettivo dell'azienda deve essere dunque quello di migliorare ed ampliare la conoscenza e la consapevolezza delle varie tematiche ESG all'interno di tutte le funzioni aziendali, evidenziando rischi e benefici di scelte programmate nell'una o nell'altra direzione. Si dovrebbe comprendere che ogni funzione deve andare a braccetto con l'altra, poiché dalle decisioni dell'una dipendono le sorti dell'altra e viceversa. L'azienda, dunque, mostra così di poter essere vista come una scacchiera, dove ogni mossa ha una conseguenza in termini di possibilità e soprattutto di rischi; muovendosi in una direzione, si rischia di lasciare scoperta una pedina fondamentale della nostra organizzazione e di comprometterne la salute stessa.

LIMITAZIONI E RICERCHE FUTURE

Per concludere l'elaborato, parliamo infine delle limitazioni riscontrate.

Sicuramente le limitazioni più grandi alle quali è stato necessario far fronte sono quelle relative ai dati ed alla loro tipologia.

In primo luogo, la costruzione del dataset, non è stato un processo lineare in quanto in letteratura non si trovano, ad oggi, dataframe con le caratteristiche ricercate in questo studio. Il dataset di partenza (Fase 1), ha tuttavia rappresentato un ottimo inizio per la ricerca e l'analisi condotta, grazie anche al lavoro effettuato con l'estrazione dei dati ESG.

Altra limitazione sempre al riguardo dei dati, è senz'altro stata quella relativa alla mancanza di tutte le rilevazioni temporali per le aziende appartenenti al dataset di partenza. Infatti, quest'ultimo, fa riferimento ad un arco temporale che va dal 2010 al 2016, ovvero gli anni in cui i criteri ESG hanno cominciato ad affermarsi davvero. Per questo, le banche dati utilizzate che, come detto, rappresentano le migliori fonti dalle quali estrarre i dati ricercati, hanno rappresentato un'ottima soluzione anche se non hanno potuto evitare una relativamente piccola perdita di informazioni che si è convertita in una diminuzione delle rilevazioni totali del dataset intermedio (Fase 2) e del dataset finale (Fase 3).

In ultima istanza, sempre riguardo ai dati, connesso a quanto abbiamo appena detto si ha il fatto che le rilevazioni fanno riferimento ad un arco temporale relativamente breve. Ciò è causato dal fatto che la materia, seppur studiata, lo è ancora oggi soprattutto con metodi tradizionali, che non prevedono l'analisi e lo studio dei Big Data. Si pronostica che, nei prossimi anni, con l'aumento delle attenzioni attorno alle questioni relative al *Machine Learning* e con l'aumento dei corsi universitari multidisciplinari che vanno ad istruire il mondo economico in questo ambito, saranno disponibili archi temporali più ampi ed un numero sicuramente maggiore di dataset al quale fare riferimento.

Quindi, le ricerche future vanno nella stessa direzione intrapresa dalla società e dalle istituzioni accademiche. Sarebbe dunque interessante sviluppare nuovi dataframe che permettano un bilanciamento maggiore all'interno delle classi scelte, in modo da poter andare ad analizzare ancora più nel dettaglio le previsioni possibili. Con questo si potrebbe, dunque, andare ancor più in profondità alla classificazione attualmente proposta che già rappresenta un passo in avanti rispetto a quella proposta dalla letteratura di partenza.

A seguito di ciò, si potrebbe poi pensare di aumentare ancor di più il numero delle variabili ESG ed in generale di variabili relative alla reputazione aziendale, senza andar in contro ad una perdita di dati ulteriore, testando nuovi classificatori e nuovi approcci al problema.

Tutto ciò garantirebbe quell'approccio olistico la cui l'importanza si è ampiamente discussa nel testo elaborato, permettendo così grande programmabilità al management aziendale riguardo a campagne marketing particolari per la propria reputazione e riguardo a questioni finanziarie legate alla valutazione di credito.