

JOÃO PEDRO FERREIRA VELOSO
BRUNO SOUTO NÔGA

Impacto do ESG via Machine Learning no Valuation de uma empresa do setor
Fitness: Um estudo de caso da SmartFit

PROJETO DE GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO
APRESENTADO AO DEPARTAMENTO DE ENGENHARIA INDUSTRIAL
DA PUC-RIO, COMO PARTE DOS REQUISITOS PARA OBTENÇÃO
DO TÍTULO DE ENGENHEIRO DE PRODUÇÃO

Orientador: Rodrigo Goyannes Gusmão Caiado
Coorientador: Renan Silva Santos

Departamento de Engenharia Industrial
Rio de Janeiro, 12 de Junho de 2024.

RESUMO

Baseado no cenário atual, de grande influência de fatores ESG na tomada de decisões nos investimentos, este trabalho investiga o impacto das práticas Ambiental, Social e de Governança no *valuation* de empresas do setor fitness, com foco na SmartFit. Utilizando técnicas de *machine learning*, o estudo avalia como variáveis ESG influenciam o valor de mercado da companhia. A pesquisa coleta dados de empresas do *S&P 500* e do IBOVESPA, aplicando modelos de regressão para identificar correlações significativas. A partir das iniciativas ESG da SmartFit, projeções de crescimento foram realizadas, demonstrando a importância de práticas sustentáveis no desempenho financeiro. Apesar das limitações do modelo, que simplifica a influência de fatores ESG, o estudo destaca a relevância das práticas sustentáveis no valor de mercado das empresas. A partir da pesquisa, espera-se que os participantes do mercado, que buscam uma correlação entre práticas sustentáveis e resultado, sejam capazes de utilizar a metodologia proposta para mensurar o impacto de fatores ESG em suas análises, auxiliando na tomada de decisão e a visualizar os benefícios que tais práticas representam na geração de valor da companhia.

Palavras-Chave: ESG, *valuation*, *machine learning*, SmartFit, sustentabilidade, setor *fitness*

ABSTRACT

Based on the current scenario, where ESG factors have huge influence in the decision-making process of companies, this work investigates the impact of Environmental, Social and Governance practices on the valuation of companies in the fitness sector, with a focus on SmartFit. Using machine learning techniques, the study evaluates how ESG variables influence the company's market value. The research collects data from companies in the S&P 500 and IBOVESPA, applying regression models to identify significant correlations. Based on SmartFit's ESG initiatives, growth projections were made, demonstrating the importance of sustainable practices in financial performance. Despite the limitations of the model, which simplifies the influence of ESG factors, the study highlights the relevance of sustainable practices in the market value of companies. With the present research, it is expected that market participants, who seek a correlation between sustainable practices and financial results, will be able to use the proposed methodology to measure the impact of ESG factors in their analyses, assisting in decision making and visualizing the benefits that such practices represent in generating value for the company.

Keywords: ESG, *valuation*, *machine learning*, SmartFit, sustainability, *fitness* sector

SUMÁRIO

1 INTRODUÇÃO	8
2 FUNDAMENTAÇÃO TEÓRICA	11
2.1 Valuation	11
2.1.1 <i>Fundamentos do Valuation</i>	11
2.1.2 <i>Modelos de Valuation</i>	12
2.1.3 <i>Taxas de Desconto e Custo de Capital</i>	13
2.1.4 <i>Fluxo de Caixa Descontado</i>	14
2.2 ESG	15
2.3 Machine Learning	16
3 METODOLOGIA DE PESQUISA	18
3.1 Etapas de Pesquisa	18
3.2 Dados, variáveis e algoritmo	19
3.2.1 <i>Coleta de dados</i>	19
3.2.2 <i>Clusterização a partir das variáveis categóricas</i>	20
3.2.3 <i>Retirada de outliers</i>	22
3.2.4 <i>Modelo de Machine Learning</i>	23
3.2.5 <i>Modelo de Regressão</i>	23
3.3 Estudo de Caso SmartFit	26
3.3.1 <i>Apresentação</i>	26
3.3.2 <i>Setor Fitness na América Latina</i>	26
3.3.3 <i>SmartFit</i>	28
3.3.3.1 <i>Breve Histórico</i>	28
3.3.3.2 <i>Modelo de Negócios</i>	28
3.3.3.3 <i>Estrutura Societária</i>	29
3.3.3.4 <i>Vantagens Competitivas & Riscos</i>	30
3.3.3.5 <i>Relatório de Sustentabilidade</i>	32
3.4 Value Driver Adjustment (VDA)	33

4 APLICAÇÃO DO MÉTODO E RESULTADOS	35
4.1 Premissas da Tese de Investimento	35
4.1.1 <i>Número de Unidades</i>	35
4.1.2 <i>Número de Membros</i>	36
4.1.3 <i>Premissas de Ticket Médio</i>	38
4.1.4 <i>Premissas Macroeconômicas</i>	38
4.2 Projeções Financeiras	40
4.2.1 <i>Demonstrativo de Resultado de Exercício (DRE)</i>	40
4.2.1.1 Premissas de Receita	40
4.2.1.2 Premissas de Custos & Despesas	41
4.2.1.3 Resultado Líquido	43
4.2.2 <i>Demonstrativo de Fluxo de Caixa (DFC)</i>	46
4.2.2.1 Fluxo de Caixa Operacional (FCO)	46
4.2.2.2 Fluxo de Caixa de Investimentos (FCI)	47
4.2.2.3 Fluxo de Caixa de Financiamento (FCF)	48
4.2.3 <i>Balanço Patrimonial (BP)</i>	50
4.3 Cálculo da Taxa de Desconto	51
4.4 Resultados do Modelo de Valuation	52
4.4.1 <i>Fluxo de Caixa Descontado para a Firma (DCFF)</i>	52
4.4.2 <i>Fluxo de Caixa Descontado para o Acionista (DCFE)</i>	52
4.5 Aplicação do Modelo de Machine Learning	53
4.5.1 <i>Clusters</i>	53
4.5.2 <i>Modelo de Regressão</i>	54
4.5.3 <i>Equação de Regressão</i>	55
4.6 Aplicação do modelo na Smartfit e possíveis cenários	55
4.6.1 <i>Expectativa de crescimento</i>	55
4.6.2 <i>Integração no Valuation</i>	57
4.6.3 <i>Cenários</i>	57
5 CONCLUSÃO	59
REFERÊNCIAS BIBLIOGRÁFICAS	60

LISTA DE TABELAS

Tabela 1 - Descrição estatística do preço e ESG Score das 428 empresas.	20
Tabela 2 - Projeção do Número de Academias por Nível de Maturidade	36
Tabela 3 - Número de Unidades Projetadas	36
Tabela 4 - Projeção do Número de Clientes por Nível de Maturidade das Academias	37
Tabela 5 - Projeção do Número de Membros	37
Tabela 6 - Evolução do Ticket-Médio Projetado	38
Tabela 7 - Inflação Ponderada Projetada	39
Tabela 8 - Projeção de Receita Bruta	40
Tabela 9 - Projeção de Despesas Operacionais	42
Tabela 10 - Projeção de Depreciação & Amortização	43
Tabela 11 - Projeção do Resultado Financeiro	44
Tabela 12 - Demonstrativo de Resultado de Exercício Projetado	45
Tabela 13 - Projeção da Necessidade de Capital de Giro da Companhia	46
Tabela 14 - Projeção do CAPEX Imobilizado	47
Tabela 15 - Projeção do Ativo de Direito de Uso	48
Tabela 16 - Projeção da Estrutura de Capital da Companhia	48
Tabela 17 - Projeção do Passivo de Arrendamento da Companhia	48
Tabela 18 - Demonstrativo de Fluxo de Caixa Projetado	49
Tabela 19 - Balanço Patrimonial Projetado da Companhia	50
Tabela 20 - Cálculo do Valor da Empresa	50
Tabela 21 - Componentes do CAPM	51
Tabela 22 - Componentes do WACC	51
Tabela 23 - Sensibilidade do Crescimento na Perpetuidade e Valor da Firma	52
Tabela 24 - Sensibilidade do Crescimento na Perpetuidade e Valor do Acionista	52
Tabela 25 - Desempenho dos 5 melhores modelos de Machine Learning	55
Tabela 26 - Crescimento na Perpetuidade em Cenários ESG	58

LISTA DE FIGURAS

Figura 1 - Modelo de Mensuração do FCLF	12
Figura 2 - Fluxo de Caixa Livre do Acionista (Forma Indireta)	13
Figura 3 - Fluxograma da análise dos dados e integração no valuation	19

Figura 4 - Gym Members as % of Total Population	27
Figura 5 - Atuação da SmartFit na América Latina	29
Figura 6 - Composição Acionária	30
Figura 7 - Ecossistema do Grupo SmartFit	31
Figura 8 - Planos SmartFit	32

LISTA DE GRÁFICOS

Gráfico 1 - Evolução dos Custos na Projeção	42
Gráfico 2 - Evolução da Margem Bruta na Projeção	42
Gráfico 3 - Evolução da Margem EBITDA na Projeção	43
Gráfico 4 - Evolução do ROIC no Período Projetado	44
Gráfico 5 - Identificação do número ideal de clusters utilizando o Método do Cotovelo	53
Gráfico 6 - Mapa de dispersão dos Clusters formados	54

LISTA DE EQUAÇÕES

Equação 1 - Custo Médio Ponderado de Capital (WACC)	13
Equação 2 - Capital Asset Pricing Model (CAPM)	14
Equação 3 - Beta of Asset i	14
Equação 4 - Discounted Cashflow	15
Equação 5 - Z-score	23
Equação 6 - Regressão Linear Múltipla	26
Equação 7 - Preço da Ação pela Regressão Linear Múltipla	55
Equação 8 - Fluxo de Caixa na Perpetuidade	57

1 INTRODUÇÃO

No contexto atual, as empresas estão sendo vistas não somente pela sua capacidade de gerar lucros e entregar resultados aos acionistas, como também pela preocupação que a companhia possui com problemas relacionados ao meio ambiente, ao social e à política. Uma das visões aceitas na literatura é de que, a maioria dos investidores valoriza quando a gestão de uma companhia incorpora suas práticas em relatórios de sustentabilidade (Friske et al, 2022). Segundo relatório da *Global Sustainable Investment Alliance* (2022), trinta trilhões de dólares são investidos em ativos sustentáveis ao redor do mundo e, fora dos Estados Unidos, o crescimento em investimentos desse tipo foi de 20% desde 2020.

Devido aos acontecimentos recentes como a pandemia da COVID-19, a fraude contábil das Americanas. S.A e as catástrofes ambientais de Brumadinho, o tema ESG (*Environmental, Social and Governance*) está ganhando ainda mais destaque no mundo corporativo. Estudos recentes apontam que a gestão de risco de companhias que adotam práticas sustentáveis, as torna mais resilientes em períodos de crise (Phang et al, 2022). Segundo uma pesquisa realizada pelo IBM *Institute for Business Value*, o tema está sendo tratado como prioridade máxima por 48% dos CEOs brasileiros (EXAME, 2022). No entanto, estudos empíricos que examinam o desempenho ambiental, social, de governança, e financeiro das empresas, forneceram resultados contraditórios (DASGUPTA, 2023). Pesquisas teóricas ainda não encontraram um consenso em relação ao ESG e o risco retorno de empresas (BAX,2024), entretanto, o número de fundos de investimento e profissionais focados no assunto vem aumentando cada vez mais. Em 2020, fundos de investimento ESG receberam US\$542 bilhões em investimentos, seguidos por US\$649 bilhões em 2021 (FORBES, 2022).

No mercado, não é diferente, com o aumento da pressão social em torno do assunto, incluindo investidores vigilantes, gestores tornaram-se obrigados a implementar as melhores práticas (Bertão, 2023). A partir disso, surgiu a GRI (*Global Reporting Initiative*), organização internacional responsável por guiar empresas, governos e outras organizações, a divulgarem seus principais indicadores ambientais e sociais, seguindo princípios de transparência e clareza (Dumay; Guthrie; Farneti, 2010).

Valuation é, por definição, a técnica de “reduzir a subjetividade” de algo que é subjetivo por natureza (PÓVOA, 2012). Dessa forma, compreender como o método é aplicado e quais variáveis, dependendo de cada empresa, influenciam no valor final, possui intrínseca importância no mundo corporativo hoje. Entretanto, há uma dificuldade do investidor em prever

indicadores futuros dentro de diferentes cenários. Para isso, uma abordagem *utilizando machine learning* pode ser útil, uma vez que é voltada para tarefas de previsão e pode ser projetada para analisar informações contidas nas demonstrações financeiras (ROBERTS, 2020). O método clássico de realizar um *valuation* possui dificuldade ao lidar com uma determinada quantidade de dados extensa e de alta complexidade e, por isso, nos últimos anos, métodos de *machine learning* utilizando redes neurais demonstraram enorme potencial em resolver problemas não-lineares (Zhang et al, 2022).

O setor *fitness* no Brasil é um dos maiores do mundo, com enorme potencial, gerando 225,4 mil empregos diretos e indiretos em 2021 (ACAD Brasil, 2022). Apesar disso, é bastante granular, sendo sua base composta principalmente por academias regionais e independentes, com apenas uma delas listada em bolsa de valores, segundo dados da B3. Portanto, por ser um setor que proporciona enorme capacidade de expansão, e por ter sido pouco explorado, é interessante compreender como esse setor busca crescer de maneira sustentável. Além do Brasil, o setor é o segundo que mais cresce no mundo, e por isso, com altas taxas de desenvolvimento, a indústria atrai investimentos e um alto volume de mercado, que aumenta a cada ano (Chekhovska, 2017).

O cenário atual mostra o ESG saindo de um subsetor pouco conhecido, para o centro das discussões, e o motivo é o reconhecimento de que os fatores de sustentabilidade possuem relevância no longo-prazo de uma companhia (Edmans, 2023). Esta pesquisa possui como principal objetivo, investigar e avaliar o impacto quantitativo das variáveis ESG com o valor final da empresa. Para isso, será utilizado uma análise fundamentalista da empresa *Smartfit Escola de Ginástica e Dança S.A.*, onde serão estabelecidas premissas de crescimento futuro e o *valuation* para encontrar o valor final a partir de um FCF (Fluxo de Caixa Livre).

Será estabelecido uma extensa base de empresas de capital aberto sujeitas a *ESG Scores*, métrica que avalia a performance em relação a governança ambiental, social e corporativa, segundo definição do *Corporate Finance Institute* (CFI). Esta pesquisa utilizará técnicas avançadas de análise de dados, incluindo regressões lineares e algoritmos de *machine learning*, para estabelecer uma correlação entre o valor das empresas e suas métricas ESG. A utilização de *machine learning* permite a análise de grandes volumes de dados e a identificação de padrões complexos que podem não ser facilmente detectáveis por métodos tradicionais. A relação entre demonstrações financeiras e lucros futuros de companhias vem de transações frequentemente não-lineares que apresentam uma complexidade que pode ser beneficiada pelo uso de *machine learning* para processar dados e, capturar os efeitos e padrões dessas transações (Cao et al,

2024), oferecendo a capacidade de lidar com variáveis multidimensionais e dinâmicas, proporcionando uma análise mais robusta e precisa. Baseado nisso, o presente estudo visa elucidar os possíveis benefícios que uma companhia pode obter ao adotar padrões de sustentabilidade e boas práticas de governança, refletindo em seus lucros e principalmente, no valor final da empresa.

O trabalho está estruturado da seguinte forma: o primeiro capítulo apresenta uma breve introdução dos temas a serem explorados, sua relevância e objetivo. No segundo capítulo há a fundamentação teórica do *valuation*, das questões ESG abordadas e a técnica de *machine learning* utilizada. O terceiro capítulo possui a metodologia de pesquisa, descrevendo a abordagem escolhida para introduzir o ESG no *valuation* e a maneira na qual as técnicas de *machine learning* e regressão linear participam do processo. No quarto capítulo é aplicado a metodologia e explorado os resultados para que, no quinto e último capítulo, seja feita a conclusão do trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Valuation

2.1.1 *Fundamentos do Valuation*

Valor é a métrica definitiva em uma economia de mercado. Pessoas investem na expectativa de que ao vender, o valor do seu investimento haverá crescido o suficiente para recompensar o risco tomado (Copeland; Koller; Murrin, 2002). Dessa forma, é imprescindível no mercado de capitais, fundamentos para determinar o valor de um ativo, de maneira a encontrar seu valor justo. Por isso, o processo de *valuation* é o mais utilizado por investidores, principalmente o de fluxo de caixa descontado, onde o valor de um ativo é determinado pelo valor presente de fluxos de caixa futuros (Damodaran, 2012).

Entre 1994 e 2000, a bolsa *Nasdaq* dos Estados Unidos foi alvo de fortes especulações acerca de empresas denominadas “ponto com”, na medida que investidores consideravam empresas ligadas a internet como anticíclicas e de crescimento ilimitado (Reis, 2019a). Com isso, diversas companhias começaram a abrir seu capital sem ao menos registrar lucros, em um momento que os investidores questionavam os métodos tradicionais de mensurar valor, como o *valuation*. O episódio chegou a ser referido como “exuberância irracional” por Alan Greenspan, ex-presidente do Banco Central dos Estados Unidos. Antes da bolha estourar, os acadêmicos notaram um declínio na relevância do valor como métrica essencial pelos investidores e, após a crise, o efeito foi reverso, com mais investidores focando em mensurar o valor correto dos ativos antes de investirem (Morris; Alam, 2012).

Diante disso, a ferramenta do *valuation* se disseminou ainda mais no mercado financeiro, a fim de evitar a irracionalidade e permitir que investidores analisem suas decisões em cenários de curto, médio e longo prazo (Luisa, 2023). Existem duas escolas de pensamento dentro da precificação de ativos, a Escola Gráfica e Técnica, e a Escola Fundamentalista, que será abordada neste estudo. A primeira aceita a teoria da “eficiência dos mercados” e, por isso, utiliza de gráficos como principais instrumentos para se definir preços futuros. Por outro lado, a Escola Fundamentalista trabalha com fundamentos macroeconômicos, setoriais e relativos de cada empresa para determinar seu “valor justo” (Póvoa, 2012).

2.1.2 Modelos de Valuation

Existem diversas definições na literatura acerca do Fluxo de Caixa Livre, segundo Jensen (1986), é todo o fluxo de caixa em excesso utilizado para financiar os projetos com valor presente positivo e, descontados por um custo de capital relevante (Risman, 2021). Dessa forma, o Fluxo de Caixa Livre é o saldo de caixa após a empresa realizar todos os pagamentos necessários para seu funcionamento (Reis, 2017). Para chegar ao fluxo de caixa esperado, projetam-se demonstrações de resultado e balanços patrimoniais, estimando desempenhos econômicos e financeiros (Cunha; Martins; Neto, 2014). Com isso, existem dois possíveis fluxos de caixa: para firma e para o acionista.

O Fluxo de Caixa Livre para a Firma (FCFF) abrange todo o fluxo de caixa da empresa a ser distribuído entre os credores (*debtholders*) e acionistas (*stockholders*), sob a forma de juros e dividendos (Póvoa, 2012). O conceito de EBITDA (lucros antes de juros, impostos, depreciação e amortização) é similar ao do (FCFF), acrescido dos impostos a serem pagos sobre o lucro, os investimentos de capital e as necessidades de capital de giro (Damodaran, 2012).

Figura 1 - Modelo de Mensuração do FCLF

Lucro antes de juros, impostos e amortizações (Ebitda)
(-) Impostos sobre Ebitda
= Lucro líquido operacional menos impostos ajustados (Noplat)
(+) Depreciação
Fluxo de caixa bruto
(+/-) Mudança de capital de giro
(-) Investimento no ativo fixo
(+/-) Aumento líquido de outros ativos
(-) Investimento bruto
= Fluxo de caixa operacional livre
(+/-) Fluxo de caixa de investimentos não operacionais
(+) Receita de juros após impostos
(+/-) Títulos negociáveis
= Fluxo de caixa livre disponível para investidores

Fonte: (Copeland; Koller; Murrin, 2002)

O Fluxo de Caixa Livre para o Acionista (FCFE) representa o fluxo de caixa líquido, após computados os efeitos de todas as dívidas para complementar o financiamento da empresa (Shrieves; Wachowicz, 2001). Dessa forma, o fluxo de caixa livre para o acionista é o fluxo de

caixa livre para a firma, acrescentado da amortização ou aquisição do capital de terceiros (empréstimos líquidos), de maneira que representa o caixa da empresa disponível para pagar dividendos aos seus investidores (Reis, 2019b).

Figura 2 - Fluxo de Caixa Livre do Acionista (Forma Indireta)

Fluxo de caixa livre da firma
(-) Pagamento de juros líquido após impostos
(-) pagamento do principal da dívida
(+) novas captações de dívidas
= Fluxo de caixa livre do acionista

Fonte: Fernández (2002)

2.1.3 Taxas de Desconto e Custo de Capital

Uma parte intrínseca da avaliação por Fluxo de Caixa Descontado, é a taxa de desconto utilizada. A mensuração correta desta taxa está intimamente ligada a escolha do fluxo de caixa (Machado, 2007). A taxa de desconto dentro da avaliação de uma empresa, busca representar a quantia que tantos os credores como os acionistas almejam ganhar ao optar pelo custo de oportunidade de um investimento em uma determinada empresa ao invés de outra (Silva, 2023).

A taxa de desconto utilizada para descontar o Fluxo de Caixa Livre para a Firma é o WACC (*weighted average cost of capital*), conhecido como custo médio ponderado de capital. O custo de capital é definido pelas condições na qual a empresa obtém seus recursos financeiros no mercado, a partir de uma média dos custos de oportunidade do capital próprio, e de terceiros, ponderados pelas respectivas proporções utilizadas de capital, líquidas do imposto de renda (Assaf Neto, 2004).

$$WACC = \left(\frac{E}{(E + D)} \right) \cdot K_e + \left(\frac{D}{(E + D)} \right) \cdot K_D \cdot (1 - T_c) \quad (1)$$

Onde:

E é o montante de capital próprio;

D é o montante de capital de terceiros;

K_e é o custo de capital próprio;

K_D é o custo de capital de terceiros; e

T_c é a alíquota do imposto de renda.

O CAPM (*Capital Asset Pricing Model*), é um modelo de precificação de ativos que estabelece uma relação entre o retorno esperado e sua parcela de risco não diversificável, encontrando assim um retorno exigido pelos acionistas. Desenvolvido por *William Sharpe*, *Jack Treynor*, *Jonh Lintner* e *Jan Mossin*, com base no trabalho de *Harry Markowitz* sobre a Teoria do Portfólio (Kumar *et al.*, 2023), o CAPM é utilizado para calcular o custo de capital (k_e) de um ativo, ou seja, o retorno exigido do ativo.

$$\text{CAPM} = \text{RF} + (\beta \times (1 - T_c) \times \frac{D}{D+E} \times \text{Prêmio de Risco}) \quad (2)$$

Onde:

RF = Retorno do Ativo Livre de Risco (*risk free rate*); e

β = Risco sistêmico inerente à empresa;

O beta (β) é o coeficiente de risco específico de uma empresa em relação ao índice de mercado e mede a tendência de variação de uma ação em relação ao mercado (Campos *et al.*, 2010). Sendo um β maior que 1 mais volátil e, um menor que 1 menos volátil do que o mercado (Póvoa, 2012).

$$\beta = \frac{\text{Covariância do ativo com o mercado}}{\text{Variância do mercado}} = \frac{\sigma_{im}}{\sigma_m^2} \quad (3)$$

A taxa de livre de risco (*risk free rate*) leva em conta o retorno no qual um ativo com risco associado quase zero oferece, com o retorno de ativos arriscados mensurados a partir dessa taxa livre de risco, com o risco criando um prêmio adicional (Damodaran, 2012).

2.1.4 Fluxo de Caixa Descontado

Segundo Alexandre Póvoa (2012), “o valor de uma companhia equivale ao somatório de todo o caixa gerado no médio-longo prazo, trazido a valor presente por uma taxa de desconto que representa o chamado retorno exigido pelo investidor.” Dessa forma, pode-se definir dois

fluxos de caixa descontados, o do investidor e da firma, cada um com uma taxa de desconto diferente, dado que os dois fluxos de caixa representam diferentes tipos de investidor.

$$Valor = \sum_{t=1}^{t=n} \frac{CF_t}{(1 + WACC)^t} \quad (4)$$

Onde:

CF_t = Fluxo de Caixa esperado no período t ;

WACC = Taxa de Desconto apropriada.

2.2 ESG

A Sigla ESG surgiu em 2005 no relatório “*Who Cares Wins: Connecting Financial Markets to a Changing World*”, em uma iniciativa liderada pela Organização das Nações Unidas (ONU). O objetivo do relatório era propor diretrizes e recomendações sobre como contemplar questões ambientais, sociais e de governança na gestão de ativos, serviços de corretagem de títulos e pesquisas sobre o tema (Eccles, 2022).

A abordagem ESG é um conjunto de padrões e boas práticas que visa definir se uma empresa é socialmente consciente, sustentável e corretamente gerenciada. (Equipe Totvs, 2023). Segundo uma pesquisa feita pela ONU em parceria com a *Stilingue*, em 2019, havia 4 mil menções ao termo “ESG” na internet. Em 2023, esse número saltou para 109 mil (Redação Exame, 2023). Os últimos acontecimentos, como as guerras na Ucrânia e no Oriente Médio, além de escândalos contábeis, como o das Americanas S.A, trouxe o tema ao centro das atenções, na medida que os investidores ficam cada vez mais preocupados com as empresas que investem.

Investidores institucionais do internacionalmente reconhecido PRI (*Principles for Responsible Investment*), que em 2021 contabilizava por 121 trilhões de dólares em ativos sobre gestão, estão integrando fatores ESG dentro de suas análises de investimento e tomada de decisões em níveis nunca vistos (PRI, 2024). Empresas são vistas cada vez mais como causadoras de problemas sociais, econômicos e ambientais, dado que na percepção pública, lucram à custa da comunidade (Abramovay, 2012). Nesse sentido, a *Generation Investment Management*, de *Al Gore*, publicou o manifesto Capitalismo Sustentável, onde é reivindicado um paradigma em que “*procure maximizar a criação de valor econômico no longo prazo,*

reformando os mercados para que respondam a reais necessidades, levando em conta todos os custos e todos os stakeholders”.

Para compreender como algumas práticas ESG tornaram-se comuns no cotidiano corporativo recente, houve a “#nãodemita”, compromisso liderado por 40 grandes empresas nacionais no sentido de manter seus colaboradores empregados no início da pandemia, além das doações feitas a fim de mitigar os impactos causados pela Covid-19 (Redecker; Trindade, 2021). Visto um crescimento importante do contexto ESG nas empresas, deve-se compreender como a adoção de tais práticas ajudam na valorização de determinada companhia. Wong *et al.* (2021), afirma que um dos motivos é o sinal positivo que a empresa emite ao mercado, atraindo mais investidores em potencial (Macedo *et al.*, 2022).

2.3 Machine Learning

Segundo a IBM (2024), *Machine Learning* (ML) é um componente importante do crescente campo da ciência de dados. Por meio do uso de métodos estatísticos, os algoritmos são treinados para fazer classificações ou previsões, revelando os principais *insights* em projetos de mineração de dados. Em outras palavras, os algoritmos de ML aprendem a partir de experiências anteriores e, fornecem previsões para resultados futuros. Os benefícios da ML incluem, a melhoria do desempenho de algoritmos iterativos por meio do armazenamento temporário dos conjuntos de dados acessados anteriormente (Ja’afar; Mohamad; Ismail, 2021). Os principais métodos de ML utilizados hoje são: redes neurais, regressão linear, árvores de decisão e floresta aleatórias.

Hoje, os tomadores de decisão do mercado têm acesso a uma infinidade de fontes como *Bloomberg*, *Thomson Reuters* e *RavenPack*. No entanto, métodos de econometria clássica não funcionam com esses conjuntos de dados, porque muitas vezes são baseados em álgebra linear e geram erro, se o número de variáveis exceder o número de observações (Karachun; Vinnichek; Tuskov, 2021). Essa é a lacuna na qual o *Machine Learning* busca preencher, oferecendo poder numérico e flexibilidade funcional para identificar padrões complexos em um espaço multidimensional.

A modelagem de precificação de ativos está se desenvolvendo em uma direção empírica. Conjuntos extensivos de características das empresas e muitos fatores são usados para descrever e entender as diferenças no retorno esperado dos ativos e para modelar a dinâmica do prêmio de risco de investimento. Em essência, medir o prêmio de risco é um problema de

previsão, uma vez que o prêmio de risco é uma expectativa condicional de lucros excedentes realizados no futuro. Metodologias que podem correlacionar de forma confiável os retornos excedentes com anomalias de negociação são altamente valorizados. Métodos de *Machine Learning* fornecem uma abordagem empírica não linear para modelar retornos reais com base nas características das empresas (Karachun; Vinnichuk; Tuskov, 2021). Yao, Xia e Liu (2024) utilizaram um modelo de memória de longo curto prazo (LSTM) para prever retornos de ações, destacando o potencial dos algoritmos de aprendizado profundo na precificação de ativos.

Portanto, em um cenário competitivo e imprevisível, em que “velocidade” e precisão são essenciais para identificar assimetrias no mercado, modelos mais avançados e poder computacional suficiente são imperativos (McKinsey, 2020). Estudos recentes demonstram que a aplicação de *machine learning* em finanças, como no caso de redes neurais para previsão de preços de ações e modelos de florestas aleatórias para identificar padrões de mercado, está se tornando cada vez mais comum e eficaz (Fischer; Krauss, 2018; Gu; Kelly; Xiu, 2020). Drobetz e Otto (2021) mostraram que, na previsão de retornos de ações europeias, redes neurais e máquinas de vetor de suporte superam os modelos lineares tradicionais, destacando a importância dos métodos não lineares em finanças

3 METODOLOGIA DE PESQUISA

3.1 Etapas de Pesquisa

Primeiro, utilizou-se o *Yahoo Finanças* para coletar os dados utilizados na pesquisa. Foram coletadas informações diárias do preço (volume, alta, baixa, fechamento e abertura) e indicadores ESG, separados em cada vertente (*Environmental, Social, and Governance*), e um *score* total obtido pela soma das notas separadas. A fonte dos dados ESG disponíveis no *Yahoo Finance* é o *Sustainalytics*, uma empresa holandesa focada em fornecer *ratings* e dados ESG para investidores e empresas. Além das variáveis contínuas, foram coletadas variáveis categóricas, o setor das empresas, capitalização de mercado (*market caps*), país de origem e, foram separados em intervalos os preços das ações e os *market caps*.

A escolha do *Yahoo Finance* como fonte de dados é justificada pelo seu uso comum em pesquisas relacionadas ao mercado financeiro. Gupta, Gupta e Chaturvedi (2020) utilizaram dados do *Yahoo Finance* para desenvolver e testar modelos de *machine learning* que preveem o comportamento dos preços das ações. Hasan, Popp e Oláh (2020) destacam que o *Yahoo Finance* é frequentemente utilizado para analisar o impacto de grandes volumes de dados financeiros na hipótese de mercado eficiente, explorando a relação entre a frequência de menções de nomes de ações e os sentimentos extraídos do conteúdo.


Após coletar e pré-processar os dados, detalhados no próximo tópico, uma variedade de modelos de *machine learning* foi aplicada para identificar o melhor modelo preditivo para os padrões dos dados. Santos (2020) menciona que diversos algoritmos têm sido empregados para prever as tendências das ações, incluindo *random forest*, redes neurais artificiais, regressão linear, KNN (*K-Nearest Neighbors*) e o classificador *Naive Bayes* (Santos, 2020). No entanto, a aplicação desses modelos desafia diretamente a Hipótese do Mercado Eficiente de Fama (1970), que postula que os preços das ações refletem todas as informações relevantes disponíveis e, portanto, são imprevisíveis (Fama, 1970). Em contraste, a Hipótese do Mercado Adaptativo, descrita por Lo (2017), sugere que os preços das ações podem ser previstos por meio de modelos estatísticos e matemáticos, desafiando a ideia de eficiência do mercado. Essa perspectiva oferece uma nova abordagem para entender o comportamento do mercado financeiro e pode fornecer *insights* valiosos para a tomada de decisões de investimento.

Em um segundo momento, com o modelo de *machine learning* definido, foi decidido qual empresa seria utilizada como base para a pesquisa. A escolhida foi a SmartFit, por estar inserida em um setor com enorme capacidade de expansão, que é o *fitness*, e possuir relatório

de sustentabilidade e compromissos ESG já implementados em sua cultura. A partir dela, é feito um estudo de caso do setor e da empresa, compreendendo a fundo o ambiente competitivo no qual ela se insere, suas vantagens e o modelo de negócios da companhia. Dessa forma, com um bom embasamento acerca da empresa, pode-se estabelecer premissas e criar um modelo de *valuation*, utilizando os dados disponibilizados no seu site de relação com investidores, para assim calcular seu preço justo.

Por fim, serão analisados dois cenários, o primeiro considerando apenas o *valuation* tradicional e no segundo cenário será considerado o modelo de *machine learning* no *valuation*. O *output* final do modelo de ML será o preço da empresa, considerando as iniciativas ESG propostas em seu último relatório de sustentabilidade. A partir desse *output* e do preço da ação da companhia antes da divulgação do relatório, será calculado o crescimento percentual que a empresa pode alcançar com tais iniciativas. Tal crescimento será usado como taxa de crescimento na perpetuidade, para analisar como o valor da empresa pode ser impactado. Todas as etapas foram realizadas através de um código em *Python*.

Figura 3 – Fluxograma da análise dos dados e integração no *valuation*.



Fonte: Elaborado pelos Autores

3.2 Dados, variáveis e algoritmo

3.2.1 Coleta de dados

Por meio do *Application Programming Interface* (API) do *Yahoo Finance* foram coletados os dados de 428 empresas que compõem o *S&P 500* e 30 empresas do Ibovespa. Foram coletados dados diários dos preços das empresas, alta, baixa, abertura, fechamento e volume de ações negociadas e *scores* ESG de cada empresa, também diários. Os *scores* ESG são separados em cada vertente e há um *score* total que é a soma dos 3 indicadores separados. Como mencionado no tópico 3.1, foi necessário coletar 5 variáveis categóricas que serão usadas

para agrupar as empresas que mais se assemelham a SmartFit a partir de características comuns (Clusterização). As variáveis categóricas escolhidas foram o setor das empresas analisadas, *market cap*, país de origem e os intervalos de preço de cada ação e de *market cap*. Os intervalos de preço definidos foram: menor que R\$50,00, entre R\$50,00 e R\$200,00 e maior que R\$200,00. Os intervalos de *market cap* definidos foram: menor que 10 bilhões de reais, entre 10 e 30 bilhões de reais, entre 30 e 50 bilhões de reais, entre 50 e 100 bilhões de reais e maior do que 100 bilhões de reais.

Tabela 1 - Descrição estatística do preço e ESG Score das 428 empresas.

Variáveis	Valor Máximo	Valor Mínimo	Média	Desvio Padrão
Total-Score	76,96	6,99	37,85	10,57
E-Score	25,68	0,00	11,86	4,10
S-Score	34,74	1,11	12,43	3,38
G-Score	26,99	3,08	13,56	4,82
Preço de Fechamento	5.365,27	2,78	100,72	173,63

Fonte: Autoria Própria

Para tratar a diferença cambial, foi utilizada a cotação do Dólar de 19 de abril de 2024 para converter os preços de Dólar para Real. De acordo com o *Refinitiv*, a cotação nesta data era de 5,20. Além do ajuste do câmbio, foi necessário tratar da mudança de pontuação do *Sustainalytics*. Antes de Novembro de 2019, as notas, que podiam variar de 0 a 100, eram interpretadas como quanto maior a nota, mais iniciativas ESG a empresa apresentava. Após Novembro de 2019, houve a inversão da interpretação da pontuação, portanto, quanto menor a nota, mais sustentável a empresa. Para tratar essa inversão da interpretação dos *scores*, foi feito um ajuste nas notas “pré novembro de 2019” para que todas tenham a mesma interpretação, quanto menor a nota, mais sustentável a companhia.

3.2.2 Clusterização a partir das variáveis categóricas

Segundo Castro (2023), a clusterização é um tipo de aprendizado não supervisionado em que o objetivo é agrupar objetos semelhantes formando *clusters*. Um *cluster* é essencialmente um conjunto de dados que são similares entre si e distintos de dados em outros *clusters*. Essa etapa é fundamental para garantir a eficiência do modelo, pois as empresas analisadas possuem diferenças intrínsecas que precisam ser consideradas como a liquidez das ações, número de ações disponíveis no mercado, *market cap* das empresas e economia que estão inseridas.

Na literatura de aprendizado de máquina, Oyewole e Thopil (2023) destacam que as principais técnicas de clusterização incluem *K-Means*, *Hierarchical Clustering*, DBSCAN (*Density-Based Spatial Clustering of Applications with Noise*) e *Gaussian Mixture Models* (GMM). O método de clusterização escolhido neste trabalho foi o *K-Means* devido à sua simplicidade e eficiência, além de ser amplamente utilizado em pesquisas financeiras. Rodriguez et al. (2024) aplicaram o *K-Means* para agrupar dados do *S&P 500* em três *clusters* com base em características como dias consecutivos de alta ou baixa e a média móvel absoluta de 5 dias, apresentando uma precisão de 85% na classificação da mudança percentual absoluta, sendo particularmente eficaz em prever mudanças significativas no índice.

A aplicação do *K-Means* segue várias etapas específicas. Inicialmente, escolhe-se o número k de *clusters* e inicializam-se os k centróides de forma aleatória ou utilizando métodos como o *K-Means++* para melhorar a escolha inicial (Ikotun et al., 2023). Cada ponto de dados é então atribuído ao centróide mais próximo, e as posições dos centróides são recalculadas como a média dos pontos atribuídos a cada cluster. Esse processo de atribuição e recálculo é repetido até que os centróides não mudem significativamente ou até que um número máximo de iterações seja alcançado.

As justificativas para a escolha do *K-Means* incluem a simplicidade e eficiência do algoritmo, sua facilidade de implementação, e sua flexibilidade para ser ajustado e otimizado para diferentes tipos de dados e aplicações. Além disso, o *K-Means* é computacionalmente eficiente e funciona bem com o aumento do tamanho do conjunto de dados, sendo adequado para os dados financeiros coletados. Zhang et al. (2025) demonstraram a eficácia do *K-Means* na segmentação de dados ambientais complexos, enquanto Ooi et al. (2025) destacaram sua precisão e robustez na segmentação de imagens médicas de COVID-19.

Para definir o número de *clusters* ideal, utilizou-se o Método do Cotovelo (*Elbow Method*). Este método é amplamente utilizado para determinar o número ótimo de *clusters* em uma análise de clusterização. O processo começa com a execução do algoritmo *K-Means* para uma série de valores de k (número de *clusters*), variando de 1 a um número máximo predefinido. Para cada valor de k , calcula-se a soma dos quadrados das distâncias (*Sum of Squared Errors, SSE*) entre os pontos de dados e os centróides dos *clusters* aos quais pertencem. O SSE é uma medida de compactação dentro dos *clusters*, com valores menores indicando *clusters* mais compactos e homogêneos.

A próxima etapa envolve a plotagem dos valores de SSE em relação aos diferentes valores de k . O gráfico resultante geralmente apresenta uma curva decrescente, onde a SSE

diminui rapidamente com o aumento de k inicialmente, e depois a taxa de diminuição se torna mais lenta. O ponto onde essa curva começa a se nivelar e formar um "cotovelo" é considerado o número ideal de *clusters*. Esse ponto de inflexão indica que a adição de mais *clusters* além desse ponto não resulta em uma redução significativa na SSE, sugerindo que a estrutura interna dos dados foi bem capturada pelos *clusters* formados até ali (Nainggolan et al., 2019). Após determinar o número ideal de *clusters* com o Método do Cotovelo, o algoritmo *K-Means* foi implementado para particionar os dados nos *clusters* definidos.

3.2.3 Retirada de outliers

Remover *outliers* é uma etapa crucial no processo de análise de dados e modelagem estatística. Em seu livro, "*Identification of Outliers*" publicado em 1980, Hawkins define outliers como uma observação que se desvia tanto das outras observações que é suspeitável que tenha sido gerada por um mecanismo diferente. A presença desses *outliers* pode distorcer a análise estatística, afetar negativamente a precisão dos modelos e influenciar as conclusões tiradas a partir dos dados. Portanto, a eliminação cuidadosa dos *outliers* é uma etapa essencial no pré-processamento de dados para garantir a qualidade e a confiabilidade das análises estatísticas.

Segundo Iglewicz e Hoaglin (1993), "*a remoção de outliers é essencial para garantir a integridade das análises estatísticas, pois a presença de valores atípicos pode levar a resultados enganosos e interpretações incorretas.*" Ao remover os *outliers*, é possível obter uma visão mais precisa e representativa do comportamento dos dados, permitindo que os modelos estatísticos capturem melhor os padrões subjacentes e façam previsões mais precisas. Barnett e Lewis (1994) destacam que "*a identificação e remoção de outliers são passos fundamentais para melhorar a qualidade e a confiabilidade das análises, especialmente em conjuntos de dados grandes e complexos.*"

Em 1988, Shiffler trouxe o *Z-score* como uma solução para detectar *outliers*. O *Z-score* é uma medida estatística que indica quantos desvios padrão um ponto de dados está da média do conjunto de dados. Para cada observação, o *Z-score* é calculado subtraindo a média do conjunto de dados e dividindo pelo desvio padrão. Assim, um *Z-score* alto indica que o ponto de dados está longe da média, enquanto um *Z-score* baixo indica que está próximo da média. Wu et al. (2023) utilizam o *Z-score* para melhorar a precisão na detecção de falhas em baterias

de veículos elétricos, combinando-o com a distância de *Hausdorff* para identificar e localizar falhas internas de curto-circuito com maior precisão.

$$Z = \frac{(X - \mu)}{\sigma} \quad (5)$$

Ao usar o *Z-score* para identificar *outliers*, geralmente define-se um limite de corte, além do qual os pontos são considerados *outliers*. Este limite pode ser arbitrário, como, por exemplo, considerar como *outliers* os pontos com *Z-score* acima de 3 ou abaixo de -3. Uma vez identificados os *outliers*, eles podem ser removidos do conjunto de dados, o que ajuda a garantir que as análises subsequentes sejam mais robustas e confiáveis (Vu et al., 2023; Udandara & Gupta, 2024). Aggarwal (2017) explica que técnicas como o *Z-score* são amplamente utilizadas devido à sua simplicidade e eficácia na identificação de pontos de dados atípicos, permitindo uma análise mais robusta e confiável. Barbiroli e Fuschini (2024) demonstram a importância de lidar com *outliers* na modelagem de propagação sem fio, destacando como a remoção de valores atípicos pode melhorar significativamente a precisão dos modelos.

Darné, Levy-Rueff e Pop (2024) também enfatizam a importância da remoção de *outliers* em testes de estresse bancário, demonstrando que a calibração correta de choques iniciais em cenários financeiros depende significativamente da identificação e exclusão de valores atípicos. Eles destacam que *"a detecção precisa de outliers pode melhorar significativamente a robustez das simulações de estresse, garantindo que os cenários considerados sejam plausíveis e adequados às condições de mercado"*.

3.2.4 Modelo de Machine Learning

A utilização do *LazyRegressor* (Pandala, 2020) representa uma contribuição significativa no processo de modelagem de regressão, ao simplificar a tarefa de seleção do modelo mais apropriado dentre uma vasta gama de opções disponíveis. O *LazyRegressor* é uma biblioteca em *Python* que automatiza a etapa de ajuste e avaliação de múltiplos modelos de regressão, proporcionando uma comparação eficaz do desempenho de cada um. A biblioteca ajusta automaticamente diversos modelos de regressão aos dados de entrada e calcula métricas comuns de avaliação, tais como R^2 , R^2 ajustado e RMSE (Erro Quadrático Médio). Isso permite aos profissionais economizar consideravelmente tempo e esforço, uma vez que não precisam

ajustar manualmente cada modelo de regressão e calcular suas respectivas métricas de desempenho. Kalantari et al. (2024) destacam a importância do uso dessas métricas para avaliar a qualidade dos modelos de regressão. Eles utilizaram R^2 , MAE e MSE para comparar o desempenho de diferentes modelos de aprendizado de máquina na previsão de dados de concentração de PM10, que são partículas inaláveis com diâmetro de 10 micrômetros ou menos, geralmente associadas à poluição do ar e que podem causar sérios problemas de saúde.

A biblioteca *LazyRegressor* inclui uma ampla gama de algoritmos de regressão, como Regressão Linear, *Random Forest*, *XGBRegressor*, *Gradient Boosting*, *K-Nearest Neighbors* (KNN), *Support Vector Regression* (SVR), *XGBoost*, *LightGBM*, *Decision Tree* e *ElasticNet*.

A Regressão Linear, por exemplo, ajusta uma linha reta que minimiza a soma dos quadrados das diferenças entre os valores observados e os valores previstos. Suas vantagens incluem simplicidade e interpretabilidade, sendo adequada para dados com uma relação linear entre as variáveis independentes e dependentes. Já o *Random Forest* constrói múltiplas árvores de decisão em diferentes subamostras do conjunto de dados e utiliza a média para melhorar a precisão preditiva e controlar o *overfitting*, tornando-o robusto contra *overfitting* e capaz de capturar relações complexas nos dados. Esse algoritmo é utilizado para dados com muitas variáveis independentes e interações complexas.

O *Gradient Boosting* combina múltiplos modelos fracos (geralmente árvores de decisão) de forma sequencial, onde cada novo modelo tenta corrigir os erros dos modelos anteriores. Ele é altamente preciso e pode lidar com diferentes tipos de dados, sendo adequado para problemas onde a precisão é crucial e há necessidade de capturar relações não lineares. O *K-Nearest Neighbors* (KNN), por sua vez, prediz o valor de uma observação com base nos valores dos seus k vizinhos mais próximos. Este método é simples e eficaz em conjuntos de dados de pequena escala, especialmente quando a relação entre as variáveis não é linear e os dados possuem uma estrutura clara de vizinhança.

Outro algoritmo importante é o *ExtraTreeRegressor*, que faz parte do conjunto de algoritmos de árvores de decisão. O *ExtraTreeRegressor*, ou *Extremely Randomized Trees*, constrói várias árvores de decisão de forma independente usando amostras aleatórias do conjunto de dados. A principal diferença entre o *ExtraTreeRegressor* e outras técnicas de árvores de decisão, como o *Random Forest*, é a forma como os splits (divisões) nos dados são feitos. Enquanto o *Random Forest* seleciona os melhores splits com base em critérios como a redução de impureza, o *ExtraTreeRegressor* faz os splits de forma totalmente aleatória. Esta

abordagem aleatória pode levar a uma maior diversidade entre as árvores, o que pode melhorar a generalização do modelo.

As métricas desempenham um papel fundamental na avaliação da qualidade do modelo de regressão. O coeficiente de determinação (R^2) oferece uma medida da proporção da variabilidade dos dados que é explicada pelo modelo. Quanto mais próximo de 1 for o valor de R^2 , melhor será o ajuste do modelo aos dados. Já o R^2 ajustado leva em conta o número de variáveis independentes no modelo, penalizando modelos mais complexos que podem estar superestimando o ajuste devido à inclusão de variáveis desnecessárias. O RMSE representa uma medida da discrepância entre os valores observados e os valores previstos pelo modelo, sendo uma métrica crucial para avaliar a precisão das previsões.

Segundo Nevasalmi (2020), o uso dessas métricas é fundamental para avaliar a eficácia de modelos preditivos em finanças, onde a precisão das previsões impacta diretamente nas decisões de investimento e estratégias de *trading*. Em outro estudo, Zhong e Enke (2019) mostram que a utilização dessas métricas em seus modelos híbridos de aprendizado de máquina resulta em previsões mais precisas do retorno diário do índice *SPDR S&P 500 ETF*. Eles utilizaram uma combinação de redes neurais artificiais (ANN) e técnicas de análise de componentes principais (PCA) para melhorar a precisão das previsões.

Dessa forma, a adoção do *LazyRegressor* em conjunto com métricas como R^2 , R^2 ajustado e RMSE constitui uma abordagem eficaz para a identificação do modelo de *Machine Learning* mais adequado aos dados, possibilitando a geração de previsões precisas. Tal prática capacita os profissionais de análise de dados e aprendizado de máquina a tomarem decisões informadas e a otimizarem o desempenho de seus modelos de regressão, refletindo um avanço significativo na área de ciência de dados.

3.2.5 Modelo de Regressão

Após identificar o modelo de machine learning (ML) mais adequado para os dados do cluster da empresa escolhida, aplicamos um modelo de regressão linear múltipla para ilustrar e simplificar a relação entre os valores de entrada (ESG Scores) e a variável de saída (preço da ação). Este método é frequentemente utilizado para prever preços de ativos financeiros devido à sua simplicidade e interpretabilidade (Fama & French, 1992). A linearização do modelo facilita a análise de cenários variando as métricas ESG, permitindo uma avaliação quantitativa do impacto potencial de diferentes estratégias ESG nos preços das ações.

$$y = \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_0 \quad (6)$$

Onde:

y é o preço previsto;

β é o intercepto;

$\beta_1, \beta_2, \beta_3$ são os coeficientes de regressão;

X_1, X_2, X_3 são os ESG Scores.

3.3 Estudo de Caso SmartFit

3.3.1 Apresentação


Conforme mencionado na introdução, uma das etapas essenciais da pesquisa é a escolha de uma empresa para projetar, com o uso de machine learning e regressões lineares, seu valor com base nas práticas ESG desempenhadas por ela hoje. Para isso, foi escolhido a SmartFit, que além de ser líder do seu setor, foi a primeira a ingressar no segmento de Novo Mercado (empresas com alto nível de governança corporativa) da B3, segundo seu portal de Relacionamento com Investidores (RI). Será realizado um estudo de caso sobre a empresa e o setor no qual ela se insere, discorrendo sobre os principais pontos analisados e levados em conta em sua análise. Dessa forma, pode-se compreender as premissas utilizadas dentro do valuation para encontrar um valor justo de sua ação, utilizando o método de FCF.

3.3.2 Setor Fitness na América Latina

Nos dias de hoje, a sociedade possui responsabilidade e, conhecimento da importância da atividade física praticada com regularidade, como um método de melhorar a qualidade de vida (Barros; Gonçalves, 2009). Para melhor compreender a companhia, deve-se primeiro adentrar sobre o ambiente no qual ela está inserida, que é o setor *fitness* da América Latina. A indústria na região apresentou uma forte expansão, com taxa de crescimento anual composta de 7.1% no número de membros nos últimos nove anos. Entretanto, no que se refere a penetração do mercado, apenas 4% do total da população nos países em que a SmartFit está inserida,

frequentam academias e centros de saúde, enquanto em países desenvolvidos, essa média alcança 15%, segundo relatório da IHRSA (2020).

Figura 4 - Gym Members as % of Total Population



Fonte: IHRSA 2020 Global Report

A indústria *fitness* possui segmentos distintos: academias multisserviço, de musculação e especialistas, aulas coletivas, escola de esportes, clubes, condomínios e hotéis. O Brasil é o segundo país do mundo em número de centros de atividades físicas, com cerca de 30 mil academias, representando 48% do total de academias na América Latina e, mesmo assim, é o 13º em faturamento, com 12 bilhões de reais (Fitness Brasil, 2023). Dito isso, o setor é granular, formado por poucas academias regionais e apenas uma empresa listada na bolsa de valores. O impacto da pandemia no setor foi considerável, nos Estados Unidos houve a perda de três milhões de empregos e mais de 50% do faturamento da indústria, com players consolidados no país como a *Gold's Gym* entrando em recuperação judicial (Guanais; Disselli; Rogatis, 2021). Por outro lado, as tendências apresentadas após esse período, como plataformas digitais e, uma maior priorização da saúde e bem-estar, beneficiaram uma recuperação acelerada do setor nos últimos anos.

A SmartFit se posiciona como a líder do setor fitness na América Latina, com uma escala cinco vezes maior que o segundo colocado no Brasil, e seis vezes maior que o segundo colocado no México. Apesar disso, no que se refere ao *market-share* da companhia, a SmartFit possui 13% do mercado na América Latina, enquanto em países com mercados mais desenvolvidos, os líderes do setor alcançam mais de 20% do *market-share* (Giordano; Vilela; Larrain, 2024). Dessa forma, pode-se dizer que o setor possui enorme capacidade de expansão a ser explorada na região, por ser um mercado pouco penetrado e fragmentado, e pela posição ocupada pela empresa, existe *market-share* a ser incorporado.

3.3.3 *SmartFit*

3.3.3.1 Breve Histórico

A SmartFit foi fundada em 1996 por Edgard Corona. Inicialmente designada como BioRitmo, foi alterada em 2009, quando já havia adquirido experiência no setor, para o nome atual, com mudança em seu modelo de negócios: academias com baixo custo e alto valor agregado. Entre 2010 e 2011, a companhia recebeu aporte do *Pátria Investimentos*, renomada gestora de fundos alternativos, que possibilitou o começo do plano de expansão da marca, que adentrou o mercado da América Latina através de franquias. Durante a pandemia, a empresa lançou iniciativas digitais para se manter atualizada no mercado e consolidou um ecossistema ao redor da marca. Em 2021, para financiar sua estratégia de expansão, a SmartFit fez seu IPO (oferta pública inicial) na bolsa de valores brasileira, sendo a primeira e única do setor até o momento. A empresa hoje, a maior rede de academias fora dos Estados Unidos, opera 1,459 unidades e atende 4.5 milhões de membros em 15 países. Sua estrutura é composta 80% por academias próprias e 20% franquias (SmartFit, 2024).

Figura 5 - Atuação da SmartFit na América Latina



Fonte: Apresentação (RI) 4T2023

3.3.3.2 Modelo de Negócios

Durante a recessão de 2008 nos Estados Unidos, consumidores se viram diante da difícil tarefa de lidar com um orçamento apertado sem sacrificar a sua saúde. Desse desafio, surgiu em centros de saúde e *fitness*, o modelo de alto valor e preço baixo, onde os usuários das


academias trocaram seus planos de alto e médio valor por outros que custavam uma fração do preço (IHRSA, 2020). O modelo de negócios da companhia, inspirado na americana *Planet Fitness*, busca otimizar o uso do espaço, concentrando sua operação em equipamentos de força e cárdio, sem prover estruturas mais elaboradas, como piscinas ou cafeterias.

A partir disso, a SmartFit é capaz de ofertar seu serviço com um custo 50% a 80% abaixo da média de outras academias, como a própria BioRitmo, que faz parte do grupo (Giordano; Vilela; Larrain, 2024). Introduzido junto ao nome da marca, o modelo de alto volume e custo baixo, é o principal consolidador do setor em mercados desenvolvidos, onde os principais *players* utilizam da estratégia para expandir e capturar *market-share*. A ideia do modelo de negócios é permitir que os processos sejam automatizados, fazendo com que as unidades possam funcionar com um número reduzido de colaboradores, permitindo uma fácil expansão no número de academias, que visam cortes de custo com ganho de escala.

3.3.3.3 Estrutura Societária

O fundador da companhia, Edgard Corona, ainda desempenha o papel de CEO e membro do conselho, com sua família sendo uma das acionistas controladoras da empresa com 14.8% das ações. Como mencionado no histórico da empresa, antes de fazer o IPO, a SmartFit recebeu diversas rodadas de investimento do *Pátria Investimentos* para financiar seu crescimento e estratégia de expansão em 2010. Atualmente, o fundo também é um dos acionistas controladores e possui 32.7% das ações. Em 2018, o fundo soberano de Singapura (GIC) investiu aproximadamente 100 milhões de reais, e em 2019 um fundo de pensão canadense (CPPIB) investiu cerca de 1 bilhão de reais na empresa. Ambos ainda mantêm suas posições e, hoje possuem respectivamente 9% e 12.1% da companhia. Dessa forma, a empresa possui um *free float*, termo que se refere às ações destinadas à livre negociação no mercado, de 31.4%, cerca de 184 milhões de ações (SmartFit, 2024).

Figura 6 - Composição Acionária



Fonte: Elaborado pelos Autores


3.3.3.4 Vantagens Competitivas & Riscos

Segundo Warren Buffet (2007): “Um negócio verdadeiramente excelente deve ter um “*moat*” duradouro, que proteja os retornos sobre o capital investido.” O investidor americano popularizou o termo *moat*, inspirado no fosso feito na era medieval para dificultar o acesso de inimigos a uma fortificação, e que no mercado de capitais se refere às vantagens competitivas que permitem uma empresa proteger seu valor e gerar lucros no longo prazo (Collins, 2014).

Uma das vantagens criadas pela empresa, foi o desenvolvimento de um ecossistema ao redor da marca. O objetivo da companhia é se manter próxima ao cliente ao longo de toda sua jornada *fitness*, por meio de iniciativas de bem-estar que vão além dos treinos ou academias. Por isso, além da marca SmartFit, o grupo é dono da BioRitmo, que possui um modelo de academias mais premium, entrou no ramo de estúdios em 2018, que são clubes com espaço menor, e um ticket médio maior, voltados para atividades mais específicas, como boxe e yoga. E para completar, no contexto da pandemia, a empresa investiu em serviços B2B e plataformas digitais, como as seguintes marcas:

- Queima Diária: adquirida pela companhia com o objetivo de impulsionar serviços digitais, com foco em conteúdo fitness e de bem-estar, a partir de vídeos na plataforma.
- SmartNutri e SmartCoach: em uma parceria com uma startup, são *marketplaces* de nutrição e treinos que oferecem consultas online personalizadas com o objetivo do cliente.
- TotalPass: a SmartFit é acionista da empresa, uma plataforma B2B2C feita para empresas disponibilizarem a seus colaboradores um benefício de utilizar diversas academias e centros de saúde.

Figura 7 - Ecossistema do Grupo SmartFit



Fonte: Relatório de Sustentabilidade (2023)

A estratégia de expansão agressiva da academia possui relação com o aumento do seu ticket-médio a partir dos planos oferecidos por ela. Com uma maior rede de academias disponível, seu Plano Black, que possui o benefício de utilizar qualquer academia da rede, ganha maior adesão dos seus membros, que podem ver no alcance da marca, um maior benefício de pagar mais caro em outro plano. Somado a isso, uma maior rede de academias diminui o custo de investimentos em equipamentos, visto que seus fornecedores oferecem um desconto de cerca de 10% por conta da escala e, um menor custo de aluguel devido ao grande fluxo que uma academia da SmartFit conhecidamente gera (Giordano; Vilela; Larrain, 2024). Dessa forma, torna-se praticamente impossível que *players* regionais consigam competir com os valores e qualidade da empresa.

Figura 8 - Planos SmartFit

	O mais vantajoso		
	Plano Black Treine em mais de 1.400 academias Smart Fit!	Plano Fit Pague menos para treinar o quanto quiser na sua unidade.	Plano Smart Treine quando quiser na sua unidade
Acesso ilimitado a +1.400 academias da rede	☑	×	×
Leve amigos para treinar com você	☑	×	×
Cadeira de massagem	☑	×	×
Smart Fit GO (treinos online) no app	☑	☑	☑
Área de musculação e aeróbicos	☑	☑	☑
Smart Fit App	☑	☑	☑
Confira as condições da academia escolhida	A PARTIR DE R\$ 9,90* no 1º mês, depois R\$ 139,90/mês 12 meses de fidelidade	A PARTIR DE R\$ 9,90* no 1º mês, depois R\$ 99,90/mês 12 meses de fidelidade	A PARTIR DE R\$ 9,90* no 1º mês, depois R\$ 119,90/mês

Fonte: SmartFit (2024)

Apesar de inicialmente ser uma vantagem competitiva, existe o risco de a expansão agressiva da companhia afetar seus resultados. Uma das métricas essenciais para a companhia gerar valor é o número de membros que uma academia madura possui. Com uma maior rede de academias disponíveis, uma unidade pode ‘canibalizar’ a outra, roubando clientes, diminuindo a métrica e, portanto, afetando o resultado daquelas unidades. Além disso, na medida que a companhia deseja ganhar mercado, existe o risco de que ao adentrar mercados com uma população menor, essa média não irá se sustentar (Giordano; Vilela; Larrain, 2024).

A *GymPass*, com a mesma proposta da *TotalPass* na qual a SmartFit possui participação, está mirando um IPO e pode ameaçar a estratégia B2B da empresa, assim como seu *market-share* e seus serviços de *marketplace*. A startup já presente em 11 países e com 2.7 milhões de assinantes, oferece benefícios ligados ao *fitness* (Fleischmann, 2024) e, como o benefício corporativo que a empresa oferece disponibiliza diferentes academias e estúdios para os colaboradores, a competição da SmartFit pode usufruir de um eventual aumento de escala da *GymPass* e ameaçar sua fatia do mercado.

No modelo de negócios no qual a SmartFit atua, de alto valor agregado e baixo custo, a taxa de cancelamento é mais alta, variando de 20% a 10% ao ano entre 2015 e 2021 (IHRSA, 2021). Por oferecer um serviço de baixo custo, a empresa possui uma base de membros, principalmente na América Latina, com uma disponibilidade de renda menor e mais suscetível a pressões inflacionárias. Dessa forma, a adesão de membros pode não ser acelerada como a abertura de academias e, no longo prazo, pode resultar em menores médias de membros por unidade, afetando o resultado.

3.3.3.5 Relatório de Sustentabilidade

A empresa divulgou em 2023, seu primeiro e único, até o momento, relatório de sustentabilidade do grupo referente ao ano de 2022 e com base no GRI (*Global Reporting Initiative*), uma linguagem comum no mundo corporativo para divulgar os impactos ESG. No relatório, a companhia divulga as principais iniciativas de desenvolvimento sustentável e, como a empresa pretende incorporar suas melhores práticas ambientais, sociais e de governança alinhadas aos Objetivos de Desenvolvimento Sustentável (ODS) da Organização das Nações Unidas (ONU). O relatório também apresenta uma matriz de materialidade que visa nortear a empresa acerca dos temas mais relevantes aos negócios e direciona na elaboração do relatório.

Segundo a ONU, os Objetivos de Desenvolvimento Sustentável são: “um apelo global à ação para acabar com a pobreza, proteger o meio ambiente e o clima e garantir que as pessoas, em todos os lugares, possam desfrutar de paz e de prosperidade.” Para o Brasil em específico, a organização divulgou 17 objetivos, no qual a SmartFit busca priorizar 7, entre eles: saúde e bem-estar, energia acessível e limpa, trabalho decente e crescimento econômico, redução das desigualdades, consumo e produção responsáveis, ação contra a mudança global do clima e paz, justiça e instituições eficazes.

Antes da divulgação do relatório, em 2021, a empresa ingressou no Novo Mercado da B3, segmento que reúne empresas do mais alto nível de governança corporativa da bolsa. Atualmente, a companhia possui mais de 200 campanhas de arrecadação, para o suporte do desenvolvimento social local, e 148 unidades atuando no Mercado Livre de energia, ambiente no qual consumidores podem escolher livremente seu fornecedor de energia (Oliveira, 2017).

3.4 Value Driver Adjustment (VDA)

O desenvolvimento do tema sustentabilidade nas últimas décadas, e sua integração na decisão de investimento, se tornará cada vez mais relevante e discutido (Efimova, 2018). Entretanto, a maioria dos analistas e profissionais do mercado ainda sentem dificuldade em conciliar ESG com modelos clássicos de modelagem financeira. O desafio é identificar o impacto que uma prática sustentável possui dentro do valor da empresa.

A *Robeco Asset Management*, gestora de recursos holandesa, foi responsável por introduzir um método de avaliar o impacto que as práticas de sustentabilidade possuem no modelo de negócios e na posição de mercado da empresa. O *Value-Driver Adjustment* (VDA), desenvolvido por *Willem Schramade*, busca identificar os principais indicadores de valor de uma companhia, seu setor e principais participantes a fim de verificar se existe alguma vantagem competitiva, do ponto de vista ESG, e como isso afeta suas premissas de crescimento (Schramade, 2016).

Para sintetizar como a métrica funciona: são definidas quatro principais premissas (*value drivers*): crescimento de receita, evolução da margem, uso do capital investido e a taxa de desconto. Dentro de um modelo, definido como o *Value Dynamic Framework* (VDF), os fatores são combinados na forma de um fluxo de caixa descontado que leva em conta o capital investido, uma maneira de avaliar o retorno sobre capital investido (ROIC) da companhia. O VDF então leva em conta os fatores ESG mais importantes da empresa e introduz nas premissas

de maneira a ajustar o valor de saída. Porém, para isso, são seguidos alguns passos: foco nas principais variáveis ESG que podem afetar o resultado da companhia, analisar o impacto desses fatores na empresa e, por último, traduzir as vantagens e desvantagens competitivas acerca desses fatores em ajustes nas premissas do *valuation* (Schramade, 2016).

4 APLICAÇÃO DO MÉTODO E RESULTADOS

4.1 Premissas da Tese de Investimento

Conforme foi detalhado no estudo de caso da companhia, a SmartFit possui como principal vantagem competitiva seu modelo de negócios de baixo custo e alto valor agregado, permitindo que a marca consiga alcançar uma expansão robusta. A partir disso, a rede é capaz de reduzir custos operacionais e alavancar receita não apenas pelo aumento do número de alunos, como também pelo aumento na adesão de um *ticket-médio* mais caro. Dessa forma, as premissas contábeis pensadas para a companhia foram estruturadas de maneira que refletissem aquilo que o seu modelo de negócios pode atingir no mercado inserido.

4.1.1 Número de Unidades

O estudo de caso do setor *fitness* na América Latina serve como base teórica para justificar a expansão no número de academias. O mercado na região ainda possui espaço para expandir e, a marca ainda pode ganhar *market-share*, se igualando a líderes do setor em outros países. A companhia divulgou, através do seu canal de Relacionamento com Investidores (RI), um *guidance*, que é uma estimativa interna, para o número de academias que pretende abrir em 2024, entre 240 e 260 unidades.

No modelo, considera-se que no primeiro ano, a empresa irá abrir 240 academias e 3 *studios*, buscando uma premissa mais conservadora. Além disso, com base no histórico da SmartFit, e na premissa de expansão, foi projetado que a companhia irá abrir 180 academias e 3 *studios* por ano até 2028, estabilizando o número de 2,434 unidades na perpetuidade, um crescimento de 67% do número atual.

Visto que o faturamento de academias franqueadas e próprias é feito de maneira diferente, o modelo busca manter a divisão atual de franquias e unidades próprias, que é 20% e 80% respectivamente, conforme divulgado pelo demonstrativo da empresa (4T23). A partir disso, na perpetuidade, a SmartFit teria uma base composta por 1.889 academias próprias e 481 franquias. Além dessa categoria, é necessário dividir as academias pela maturidade. Considera-se uma academia madura a que possui 3 anos ou mais, as de até 1 ano são recém-inauguradas e, entre 1 e 3 anos estão em desenvolvimento. Elas diferem no número de clientes que cada uma possui e, influenciam diretamente na mensalidade escolhida pelos seus membros.

Apesar de ser essencial no seu modelo de negócios, a expansão agressiva no número de unidades não necessariamente é sinônimo de rentabilidade. O capital investido por unidade é aproximadamente cinco milhões de reais e, existe um custo de manutenção e inovação feitos nas unidades. Além disso, o aumento na base de unidades faz com que haja um aumento no passivo de arrendamento e no ativo de direito de uso da companhia, que por representarem contratos arrendatários, são sensíveis a inflação e podem afetar o resultado da companhia no longo prazo.

Tabela 2 - Projeção do Número de Academias por Nível de Maturidade

Número de Unidades	2023	2024E	2025E	2026E	2027E	2028E	2029E
Novas Unidades - Unidades 1 ano	215	240	180	180	180	180	-
Unidades 2 anos	158	215	240	180	180	180	180
Unidades Maduras - Unidades 3 ou + anos	1.065	1.223	1.438	1.678	1.858	2.038	2.218
Total	1.438	1.678	1.858	2.038	2.218	2.398	2.398

Fonte: Autoria Própria

A premissa de expansão no número de unidades levou em conta apenas um aumento no número de academias da SmartFit e *Studios*. No que diz respeito a *Bio Ritmo e O2*, visto que no histórico recente da companhia, existem mais academias da rede fechando do que abrindo, foi projetado, conforme a Tabela 3, o modelo mantendo o número atual de academias dessa marca.

Tabela 3 - Número de Unidades Projetadas

Número de Unidades	2023	2024E	2025E	2026E	2027E	2028E	2029E
Unidades	1.459	1.702	1.885	2.068	2.251	2.434	2.434
YoY (%)	18,0%	16,7%	10,8%	9,7%	8,8%	8,1%	0,0%
Academias	1.438	1.678	1.858	2.038	2.218	2.398	2.398
SmartFit	1.410	1.650	1.830	2.010	2.190	2.370	2.370
Próprias	1.121	1.313	1.457	1.601	1.745	1.889	1.889
Franquias	289	337	373	409	445	481	481
Bio Ritmo e O2	28	28	28	28	28	28	28
Próprias	23	23	23	23	23	23	23
Franquias	5	5	5	5	5	5	5
Studios	21	24	27	30	33	36	36

Fonte: Autoria Própria

4.1.2 Número de Membros

Em relação ao número de membros, a premissa foi baseada no número médio de clientes que cada academia atinge, dependendo do seu nível de maturidade. Baseado no número de

novos membros por novas unidades em 2023, divulgado pelo Relacionamento com o Investidor (RI) da empresa, foi estimado que a SmartFit atinge cerca de 3,2 mil clientes na maturidade, em seu primeiro ano chega a aproximadamente 60% desse valor, um pouco mais da metade de uma unidade madura e, durante seu desenvolvimento, atinge em média 2,9 mil clientes, que representa 90% do valor na maturidade. A partir disso, e com uma base de unidades bem categorizada de acordo com o nível de maturidade, foi possível projetar um número de clientes baseado no número de academias em cada ano.

Tabela 4 - Projeção do Número de Clientes por Nível de Maturidade das Academias

Número de Clientes (000')	2023	2024E	2025E	2026E	2027E	2028E	2029E
Novas Unidades - Unidades 1 ano		461	346	346	346	346	-
Unidades 2 anos		619	691	518	518	518	518
Unidades Maduras - Unidades 3 ou + anos		3.914	4.602	5.370	5.946	6.522	7.098
Total	4.089	4.994	5.638	6.234	6.810	7.386	7.616

Fonte: Autoria Própria

O número de clientes no canal digital da SmartFit foi projetado conforme o fechamento do ano de 2023, onde o número de membros na plataforma representou cerca de 8% do número total de membros nas academias. Nos *studios*, também foi mantida a média de 2023, com 230 clientes por *studio* na projeção, enquanto a *Bio Ritmo e O2* não sofreram com alteração no número de membros. Assim como o número de unidades, a relação de clientes em franquias e unidades próprias se manteve, sendo a divisão 79% clientes em lojas próprias e 21% em franqueados.

Tabela 5 - Projeção do Número de Membros

Número de Clientes	2023	2024E	2025E	2026E	2027E	2028E	2029E
Membros	4.455.778	5.429.944	6.124.448	6.765.583	7.386.058	8.006.534	8.254.443
YoY (%)	17,2%	21,9%	12,8%	10,5%	9,2%	8,4%	3,1%
Academias	4.140.126	5.044.837	5.689.637	6.284.837	6.860.837	7.436.837	7.667.237
SmartFit	4.088.889	4.993.600	5.638.400	6.233.600	6.809.600	7.385.600	7.616.000
Próprias	3.224.033	3.947.802	4.463.642	4.939.802	5.400.602	5.861.402	6.045.722
Franquias	864.856	1.045.798	1.174.758	1.293.798	1.408.998	1.524.198	1.570.278
Bio Ritmo e O2	51.237	51.237	51.237	51.237	51.237	51.237	51.237
Studios	4.925	5.629	6.332	7.036	7.739	8.443	8.443
Digital	310.727	379.479	428.479	473.710	517.482	561.254	578.763

Fonte: Autoria Própria

4.1.3 Premissas de Ticket Médio

No estudo de caso da companhia, foram detalhados os planos oferecidos e as vantagens que cada um oferece, assim como a maneira que os benefícios de cada plano fazem parte da estratégia de crescimento inerente ao modelo de negócios da empresa. O Plano Black, que possui o preço mais alto e, como vantagem, o acesso a qualquer academia da rede, é um dos principais vetores de crescimento da companhia. O motivo é que, membros de academias maduras aderem mais a esse plano, além de que a expansão da rede de academias da marca aumenta a relevância do benefício oferecido.

Pensando nisso, foi feito um cálculo do ticket-médio atual a partir da aderência que cada plano possui na base total de membros, divulgada na última apresentação da companhia (1T24). Com um maior número de academias maduras na perpetuidade, e algumas poucas ainda em desenvolvimento, a ideia é que a adesão do Plano Black aumente consideravelmente, aumentando o ticket-médio da companhia de maneira que a base de representação dos planos seja 90% Black e 10% Smart. Com isso, foi calculado um crescimento anual do ticket-médio para atingir o valor nesse cenário e, acrescido da inflação, foi utilizado para projetar a evolução do faturamento da companhia.

Tabela 6 - Evolução do Ticket-Médio Projetado

Planos Disponíveis	2023	2024E	2025E	2026E	2027E	2028E	2029E
Plano FIT	4%	3,3%	2,7%	2,0%	1,3%	0,7%	0%
Plano SMART	29%	25,8%	22,7%	19,5%	16,3%	13,2%	10%
Plano BLACK	67%	70,8%	74,7%	78,5%	82,3%	86,2%	90%
Ticket Médio	132,5	133,4	134,3	135,2	136,1	137,0	137,9
<i>Variação Ticket Médio (%)</i>		0,7%	0,7%	0,7%	0,7%	0,7%	0,7%
Variação Ticket Médio - Inflacionado		4,3%	4,2%	4,1%	4,1%	4,1%	4,1%

Fonte: Autoria Própria

4.1.4 Premissas Macroeconômicas

A SmartFit é uma empresa que atua não somente no mercado brasileiro, como em grande parte de América Latina. Sua base, de acordo com o site de Relacionamento com Investidores (RI), é composta por 15 países e os clientes estão 47% no Brasil, 22% no México e 31% em outras regiões da América Latina. Pensando nisso, foi necessário calcular uma inflação ponderada dos países que compõem essa base para aplicar no modelo, levando em consideração o peso que cada um possui na base de clientes da empresa.

Os dados de inflação (IPCA) e juros (taxa SELIC) do Brasil aplicados, foram coletados e revisados utilizando o Relatório *FOCUS* do Banco Central, enquanto a inflação mexicana foi coletada no portal do Banco Central do México. Por outro lado, para evitar revisões exaustivas, nos demais países no qual a SmartFit opera, foi coletado a projeção de *consumer prices* do FMI (*International Monetary Fund*) no relatório *World Economic Outlook*, de abril de 2024. Entretanto, vale ressaltar que, por estar muito defasada das demais, a inflação projetada para a Argentina foi descartada do modelo.

Tabela 7 - Inflação Ponderada Projetada

Inflação Ponderada	2024E	2025E	2026E	2027E	2028E	2029E
Inflação Ponderada	3,7%	3,5%	3,4%	3,4%	3,4%	3,4%
Brasil	3,8%	3,7%	3,5%	3,5%	3,5%	3,5%
México	3,3%	3,2%	3,1%	3,1%	3,1%	3,1%
Outros	3,7%	3,5%	3,5%	3,5%	3,5%	3,5%
Argetina	249,8%	59,6%	59,6%	59,6%	59,6%	59,6%
Uruguai	5,8%	5,5%	5,5%	5,5%	5,5%	5,5%
Colombia	6,4%	3,6%	3,6%	3,6%	3,6%	3,6%
Chile	3,2%	3,0%	3,0%	3,0%	3,0%	3,0%
Peru	2,3%	2,0%	2,0%	2,0%	2,0%	2,0%
Panamá	3,0%	3,3%	3,3%	3,3%	3,3%	3,3%
Costa Rica	3,0%	3,3%	3,3%	3,3%	3,3%	3,3%
Paraguai	3,8%	4,0%	4,0%	4,0%	4,0%	4,0%
El Salvador	3,0%	3,3%	3,3%	3,3%	3,3%	3,3%
Equador	1,4%	1,5%	1,5%	1,5%	1,5%	1,5%
Guatemala	3,0%	3,3%	3,3%	3,3%	3,3%	3,3%
República Dominicana	6,8%	5,6%	5,6%	5,6%	5,6%	5,6%
Honduras	3,0%	3,3%	3,3%	3,3%	3,3%	3,3%

Fonte: Autoria Própria

Em relação aos juros aplicados no modelo, utilizamos a taxa SELIC. Segundo o Banco Central, a taxa SELIC é a taxa básica de juros da economia que influencia as outras e, é o principal instrumento monetário utilizado pelo Banco Central para controlar a inflação. Como a empresa é sediada no Brasil, e possui suas obrigações e aplicações financeiras no país, utilizou-se como base de juros apenas a taxa referência nacional.

4.2 Projeções Financeiras

4.2.1 *Demonstrativo de Resultado de Exercício (DRE)*

A demonstração de resultado de exercício ou DRE, fornece informações sobre as receitas e despesas da empresa, e o lucro resultante durante um determinado período, podendo ser trimestral ou anual (Damodaran, 2012). Dentro do demonstrativo do modelo, foram calculadas as premissas de faturamento, custos e despesas da companhia utilizando a tese de investimentos, de maneira a chegar em um valor para o EBITDA e lucro líquido que façam sentido com o modelo de negócios da empresa.

4.2.1.1 Premissas de Receita

A partir das premissas da tese de investimento detalhadas no capítulo 4.1, pode-se calcular as projeções de faturamento da companhia baseado no aumento da base de clientes e no aumento de adesão de um plano mais caro por seus membros. A receita bruta da SmartFit é composta por quatro componentes:

- Mensalidade: Pagamento mensal feito pelos membros pelos planos disponíveis, assim como o valor extra pago por serviços oferecidos dentro do ecossistema da empresa, como o *QueimaDiária* e *SmartNutri*.
- Anuidade: Referente ao pagamento completo da mensalidade do ano feito por alguns membros.
- Adesões: Receita proveniente da taxa de adesão paga quando um novo aluno ingressa em alguma academia da rede.
- Outras: Receitas das franquias em forma de *royalties* por utilizarem a marca da SmartFit.

Cada componente da receita foi projetado de maneira diferente, com base nos clientes que compõem o cálculo daquele faturamento. No caso da mensalidade e anuidade, apenas membros de unidades próprias da SmartFit fazem parte do cálculo, enquanto adesões apenas considera novos membros de unidades próprias, e “outras” considera apenas os membros de franquias. Entretanto, todas consideraram o crescimento de suas projeções de acordo com a

evolução inflacionada do ticket-médio calculado, dado que todas as modalidades de faturamento possuem como base principal de cálculo o valor pago pelos alunos nos planos.

Tabela 8 - Projeção de Receita Bruta

Receita Bruta	2023	2024E	2025E	2026E	2027E	2028E	2029E
Receita Bruta	4.539	5.802	6.802	7.818	8.881	10.020	10.726
YoY%		27,8%	17,2%	14,9%	13,6%	12,8%	7,0%
Mensalidade	4.027	5.142	6.050	6.961	7.913	8.931	9.583
Mensalidade / Membros Unidades Próprias	1,12	1,17	1,22	1,27	1,32	1,38	1,43
Anuidade	303	387	456	524	596	673	722
Anuidade / Membros Unidades Próprias	0,08	0,09	0,09	0,10	0,10	0,10	0,11
Adesões	33	52	38	37	37	38	16
Adesões / Novos Membros Unidades Próprias	0,06	0,06	0,07	0,07	0,07	0,08	0,08
Outras	177	221	258	296	335	378	405
Royalties / Membros (Franquias)	0,20	0,21	0,22	0,23	0,24	0,25	0,26

Fonte: Autoria Própria


Para chegar na receita líquida da empresa, foi mantida a porcentagem do faturamento de 2023, pago em impostos e devoluções. O valor abatido da receita bruta foi de 6,5% na projeção, de maneira que a receita líquida apresentasse a mesma evolução previamente calculada pela premissa de faturamento.

4.2.1.2 Premissas de Custos & Despesas

Os custos dos serviços prestados pela companhia são compostos principalmente pelos custos de ocupação, custos com pessoal, consumo, entre outros custos dos serviços prestados pela SmartFit. No modelo de negócios da empresa, espera-se que ela consiga, a partir de sua expansão, reduzir alguns custos de aluguel e pessoal a partir do seu ganho de escala e, com base em seu Relatório de Sustentabilidade (2023), corte gastos em relação ao consumo de água e energia elétrica.

A premissa de crescimento no número de unidades leva em conta principalmente que, com o amadurecimento das academias, os custos considerados diminuam, ou seja, quanto mais academias maduras na base, menor o custo de serviços prestados. Uma prova disso é que no 4T23 vs 1T24, segundo demonstrativo da empresa, as academias maduras apresentaram um crescimento de custos inferior ao crescimento de receita. Pensando nisso, a premissa calculada para os custos é feita a partir da evolução *year-over-year* da receita líquida descontada para que, nos primeiros anos de projeção, onde existe um crescimento elevado de faturamento, não haja alavancagem operacional, com os custos variando conforme a variação de receita líquida apenas na perpetuidade.


Gráfico 1 - Evolução dos Custos na Projeção



Fonte: Autoria Própria

O resultado é o crescimento de margem bruta de maneira estável, com um acréscimo considerável entre 2023 e 2024, principalmente pelo notável aumento de faturamento no período, para depois na projeção manter uma evolução praticamente estável da métrica.

Gráfico 2 - Evolução da Margem Bruta na Projeção



Fonte: Autoria Própria

Nas despesas operacionais, as projeções foram feitas com base na evolução da receita líquida. Dessa maneira, conforme o faturamento evoluiu no período, as despesas aumentaram na mesma magnitude. As despesas operacionais são compostas por despesas com vendas, despesas gerais e administrativas, outras despesas e receitas e equivalência patrimonial. Com uma representação quase desprezível e variações constantes, desconsidera-se a projeção de outras despesas e receitas, e equivalência patrimonial no modelo. Mesmo assim, a porcentagem de despesas operacionais em função da receita líquida manteve o valor de 2023 na perpetuidade. A premissa pode ser considerada conservadora uma vez que o histórico da companhia mostrava um aumento mais agressivo da margem bruta.

Tabela 9 - Projeção de Despesas Operacionais


Despesas Operacionais	2023	2024E	2025E	2026E	2027E	2028E	2029E
Despesas Operacionais	(813)	(1.039)	(1.218)	(1.400)	(1.591)	(1.795)	(1.921)
YoY%		27,8%	17,2%	14,9%	13,6%	12,8%	7,0%
Despesas com Vendas	(345)	(441)	(517)	(594)	(675)	(761)	(815)
YoY%		27,8%	17,2%	14,9%	13,6%	12,8%	7,0%
Despesas Gerais e Administrativas	(468)	(599)	(702)	(807)	(916)	(1.034)	(1.107)
YoY%		27,8%	17,2%	14,9%	13,6%	12,8%	7,0%
Outras (Despesas)/Receitas	148	-	-	-	-	-	-
Equivalência Patrimonial	(1)	-	-	-	-	-	-

Fonte: Autoria Própria

Com o cálculo dos custos dos serviços prestados e das despesas operacionais, pode-se chegar em uma métrica importante para compreender a rentabilidade da empresa, que é o EBITDA (lucro antes dos juros, impostos, depreciação e amortização). A sigla é uma medida de rentabilidade da companhia que, além de não considerar os juros atribuídos ao financiamento da dívida, não considera a depreciação e amortização, que não representam desembolso de caixa, ou seja, o EBITDA é uma aproximação do potencial de geração de caixa operacional de uma companhia (Macedo *et al.*, 2012).

O EBITDA resultante das projeções de receita, custos e despesas feito, foi praticamente o mesmo do fechamento do ano de 2023, com uma variação de margem pequena.

Gráfico 3 - Evolução da Margem EBITDA na Projeção



Fonte: Autoria Própria

4.2.1.3 Resultado Líquido

O lucro líquido da empresa, após descontados as despesas e custos da receita, deve ser calculado descontando a depreciação e amortização, impostos e resultado financeiro da companhia. Primeiro, desconsidera as despesas de depreciação e amortização, que foi dividida

em depreciação do imobilizado, intangível e do direito de uso. Cada um foi importante no cálculo do ativo fixo da companhia na perpetuidade e, na projeção, todas as depreciações mantiveram o valor que representavam do seu respectivo ativo fixo no balanço.


Tabela 10 - Projeção de Depreciação & Amortização

Depreciação & Amortização	2023	2024E	2025E	2026E	2027E	2028E	2029E
Depreciação & Amortização	(1.157)	(1.460)	(1.629)	(1.829)	(2.009)	(2.193)	(2.377)
<i>YoY%</i>	28,3%	26,1%	11,5%	12,3%	9,9%	9,1%	8,4%
Depreciação Imobilizado	(549)	(709)	(860)	(941)	(1.016)	(1.084)	(1.146)
<i>Imobilizado BoP (%)</i>	17,5%	17,5%	17,5%	17,5%	17,5%	17,5%	17,5%
Amortização Intangível	(48)	(65)	(65)	(65)	(65)	(65)	(65)
<i>Intangível BoP (%)</i>	3,4%	3,4%	3,4%	3,4%	3,4%	3,4%	3,4%
Depreciação Direito de Uso	(560)	(685)	(704)	(822)	(928)	(1.044)	(1.166)
<i>Direito de Uso (%)</i>	18,2%	18,2%	18,2%	18,2%	18,2%	18,2%	18,2%

Fonte: Autoria Própria

Descontada a depreciação e amortização, é possível calcular o NOPAT (*Net Operating Profit After Taxes*) da companhia, que é o lucro operacional da companhia depois dos impostos, e é utilizado para calcular o ROIC (*Return Over Invested Capital*) da empresa. O ROIC é o retorno que a companhia possui por cada centavo investido no negócio, auxiliando na análise de geração de valor de uma empresa (Mckinsey, 2010). O indicador apresentou boa evolução no período, muito por conta do aumento da sua rentabilidade ao mesmo tempo que houve menos capital investido na abertura de unidades, principalmente por conta de um amadurecimento das academias abertas e, por consequência, do ticket-médio praticado, que ilustra bem o modelo de negócios da companhia.

Gráfico 4 - Evolução do ROIC no Período Projetado



Fonte: Autoria Própria

O próximo passo foi projetar o resultado financeiro da companhia, que é composto pela soma das receitas financeiras geradas e despesas financeiras pagas no período. A receita financeira de uma companhia são os rendimentos obtidos através de aplicações financeiras, portanto, na projeção, foi calculado com base no caixa da companhia no período, uma porcentagem condizente com as aplicações financeiras feitas no Brasil, que geralmente rendem a taxa SELIC acrescido de um prêmio. Para as despesas financeiras, foi mantido o valor pago sobre a dívida bruta em 2023, contabilizado os juros e encargos.

Tabela 11 - Projeção do Resultado Financeiro

Resultado Financeiro	2023	2024E	2025E	2026E	2027E	2028E	2029E
Resultado Financeiro	(473)	(568)	(647)	(679)	(664)	(615)	(529)
<i>YoY%</i>		20,0%	13,9%	5,0%	-2,3%	-7,3%	-14,1%
Receita Financeira	461	366	287	254	270	319	405
<i>Caixa BoP (%)</i>	17,6%	14,0%	13,0%	13,0%	13,0%	13,0%	13,0%
Despesa Financeira	(934)	(934)	(934)	(934)	(934)	(934)	(934)
<i>Dívida Bruta (%)</i>	24,4%	24,4%	24,4%	24,4%	24,4%	24,4%	24,4%

Fonte: Autoria Própria

Para chegar no lucro líquido, foi descontado o imposto de renda e contribuição social, utilizando como premissa uma alíquota de 27,5% do lucro antes do imposto de renda. Descontado o imposto, o modelo calcula o lucro líquido da companhia e é projetado um demonstrativo de resultado completo da SmartFit.

Tabela 12 - Demonstrativo de Resultado de Exercício Projetado

SMFT3 - Overview	2018	2019	2020	2021	2022	2023	2024E	2025E	2026E	2027E	2028E	2029E
Receita Bruta	1.290	2.148	1.362	1.841	3.152	4.539	5.802	6.802	7.818	8.881	10.020	10.726
(-) Impostos & Devoluções	(130)	(164)	(105)	(134)	(221)	(295)	(376)	(441)	(507)	(576)	(650)	(696)
Receita Líquida	1.160	1.984	1.256	1.707	2.930	4.245	5.425	6.361	7.310	8.305	9.369	10.030
(-) Custo Serviços Prestados	(623)	(1.250)	(1.267)	(1.593)	(2.018)	(2.534)	(3.027)	(3.445)	(3.882)	(4.331)	(4.803)	(5.141)
(-) Depreciação & Amortização	(184)	(544)	(707)	(791)	(902)	(1.157)	(1.460)	(1.629)	(1.829)	(2.009)	(2.193)	(2.377)
Lucro Bruto	537	734	(10)	114	912	1.711	2.398	2.916	3.428	3.974	4.567	4.889
<i>Margem Bruta (%)</i>	46,3%	37,0%	-0,8%	6,7%	31,1%	40,3%	44,2%	45,8%	46,9%	47,9%	48,7%	48,7%
(-) SG&A	(231)	(614)	(346)	(462)	(640)	(813)	(1.039)	(1.218)	(1.400)	(1.591)	(1.795)	(1.921)
(-) Despesas Com Vendas	(81)	(153)	(133)	(186)	(292)	(345)	(441)	(517)	(594)	(675)	(761)	(815)
(-) Despesas Gerais e Administrativas	(149)	(460)	(214)	(276)	(348)	(468)	(599)	(702)	(807)	(916)	(1.034)	(1.107)
EBITDA	689	634	314	432	1.168	2.202	2.819	3.326	3.857	4.392	4.965	5.344
<i>Margem EBITDA (%)</i>	59,4%	32,0%	25,0%	25,3%	39,8%	51,9%	52,0%	52,3%	52,8%	52,9%	53,0%	53,3%
EBIT	321	90	(394)	(360)	265	1.045	1.359	1.697	2.028	2.383	2.772	2.967
NOPAT	294	88	(415)	(368)	257	1.004	1.332	1.718	2.034	2.434	2.823	2.966
<i>ROIC</i>	9,6%	1,5%	-5,7%	-4,8%	2,9%	9,0%	10,4%	12,0%	13,0%	14,2%	15,2%	16,2%
<i>Margem EBIT (%)</i>	27,7%	4,5%	-31,3%	-21,1%	9,1%	24,6%	25,0%	26,7%	27,7%	28,7%	29,6%	29,6%
Lucro Líquido	173	(339)	(604)	(633)	(86)	1.044	573	761	978	1.246	1.564	1.768
<i>Margem Líquida (%)</i>	14,9%	-17,1%	-48,1%	-37,1%	-2,9%	24,6%	10,6%	12,0%	13,4%	15,0%	16,7%	17,6%

Fonte: Autoria Própria

4.2.2 Demonstrativo de Fluxo de Caixa (DFC)

Para desenvolver um fluxo de caixa descontado, para a firma e acionista, deve-se primeiro projetar o demonstrativo de fluxo de caixa da companhia. O fluxo de caixa consiste em três tipos diferentes, o de operações que computa toda a saída e entrada de recursos do dia a dia da empresa, o de investimentos, que apresenta o fluxo da compra e venda de ativos não fixos, e o de financiamento, que representa a variação da estrutura de capital, envolvendo dívida e dividendos (Póvoa, 2012).

4.2.2.1 Fluxo de Caixa Operacional (FCO)

No caso da SmartFit, foi considerado o EBITDA gerado no período, descontado do resultado financeiro e impostos, ou seja, o lucro líquido sem contabilizar a depreciação, que se refere ao lucro caixa que a empresa gera. Além disso, foi descontado a variação de capital de giro da companhia, que representa a liquidez da empresa e facilita a análise das operações de maneira a compreender a habilidade que a mesma possui de gerar caixa para pagar suas obrigações de curto-prazo (Alvarez; Sensini; Vazquez, 2021).

Na projeção da variação da Necessidade de Capital de Giro (NCG), foi considerado a quantidade de dias que, em função da receita líquida nos últimos 12 meses, um ativo será recebido e, a quantidade de dias que, em função dos custos dos serviços, um passivo será pago. Dessa forma, para cada linha do capital de giro, foi mantido o número de dias de 2023 de maneira que os prazos de pagamento e recebimento não variassem.

Tabela 13 - Projeção da Necessidade de Capital de Giro da Companhia

Necessidade de Capital de Giro	2023	2024E	2025E	2026E	2027E	2028E	2029E
Necessidade de Capital de Giro	(375)	(387)	(408)	(435)	(459)	(482)	(516)
Variação de NCG	(160)	(12)	(21)	(27)	(25)	(22)	(34)
WKC Ativo	733	937	1.098	1.262	1.434	1.618	1.732
Clientes	349	446	523	601	683	770	825
dias Receita Líquida	30	30	30	30	30	30	30
Outros Ativos Circulantes	384	491	575	661	751	847	907
dias Receita Líquida	33	33	33	33	33	33	33
WKC Passivo	1.108	1.323	1.506	1.697	1.893	2.099	2.247
Receita diferida	399	477	543	612	682	757	810
dias Custos	58	58	58	58	58	58	58
Fornecedores	206	246	280	316	352	391	418
dias Custos	30	30	30	30	30	30	30
Salários, provisões e contribuições sociais	96	115	131	147	164	182	195
dias Custos	14	14	14	14	14	14	14
Contas a pagar CP	185	221	252	284	317	351	376
dias Custos	27	27	27	27	27	27	27
Outros Passivos Circulantes CP	221	264	300	339	378	419	448
dias Custos	32	32	32	32	32	32	32

Fonte: Autoria Própria

4.2.2.2 Fluxo de Caixa de Investimentos (FCI)

Conforme mencionado na tese de investimentos, o crescimento da base de unidades da SmartFit nem sempre é sinônimo de rentabilidade, dado que o custo de abrir uma nova unidade é de R\$5,1 milhões, existe um custo de 7% do imobilizado gasto em manutenção todo ano e, foram projetados gastos com capex de inovação e corporativo da unidade crescendo cerca de 10% ao ano. Como foi explicado na seção de demonstrativo de resultado de exercício, a depreciação foi calculada, em parte, com base no imobilizado do período de maneira constante e, o resultado foi um capex que variou conforme a abertura de unidades. O capex nada mais é do que os investimentos em bens de capital da companhia, como equipamentos e renovação das unidades.

Tabela 14 - Projeção do CAPEX Imobilizado

CAPEX (Imobilizado)	2023	2024E	2025E	2026E	2027E	2028E	2029E
Capex	1.326	1.565	1.326	1.365	1.402	1.438	556
Expansão	1.093	1.220	915	915	915	915	-
Capex Expansão / Novas Unidades	5,1	5,1	5,1	5,1	5,1	5,1	5,1
Manutenção	186	283	343	376	405	432	457
% Imobilizado BoP	5,9%	7,0%	7,0%	7,0%	7,0%	7,0%	7,0%
Corporativo / Inovação	56	61	68	74	82	90	99
Variação Anual (%)	35%	10%	10%	10%	10%	10%	10%
Ajuste Capex	(10)	-	-	-	-	-	-
Imobilizado BoP	3.132	4.045	4.900	5.366	5.790	6.177	6.531
(+) Adições	1.326	1.565	1.326	1.365	1.402	1.438	556
(-) Depreciação	(549)	(709)	(860)	(941)	(1.016)	(1.084)	(1.146)
(+/-) Outros	136	-	-	-	-	-	-
Imobilizado EoP	4.045	4.900	5.366	5.790	6.177	6.531	5.941
Novas Unidades	223	243	183	183	183	183	-

Fonte: Autoria Própria

O Ativo de Direito de Uso, que representa o direito de utilizar um ativo subjacente durante determinado período, que no caso da SmartFit se refere aos aluguéis das academias, variou conforme a base de unidades aumentava. Nesse caso, como a maioria dos contratos arrendatários variam com a inflação, a variação dos ativos de direito de uso veio não somente com o aumento da base de unidades, como também com um ajuste pela inflação para que refletisse uma valorização desses contratos.

Tabela 15 - Projeção do Ativo de Direito de Uso

Ativo de Direito de Uso	2023	2024E	2025E	2026E	2027E	2028E	2029E
Ativo de Direito de Uso BoP	3.067	3.755	3.856	4.504	5.086	5.721	6.391
(+/-) Variação Direito de Uso	1.247	786	1.352	1.404	1.564	1.713	1.297
Ativo de Direito de Uso/ Unidades	2,6	2,7	2,8	2,9	3,0	3,1	3,2
(-) Depreciação do Direito de Uso	(560)	(685)	(704)	(822)	(928)	(1.044)	(1.166)
Ativo de Direito de Uso EoP	3.755	3.856	4.504	5.086	5.721	6.391	6.522

Fonte: Autoria Própria

4.2.2.3 Fluxo de Caixa de Financiamento (FCF)

Primeiro passo para calcular o fluxo de caixa de financiamento foi projetar a variação da dívida da companhia, onde a premissa utilizada foi manter o valor da dívida bruta durante o período, fazendo com que a SmartFit aumentasse sua base de unidades de maneira orgânica, sem recorrer ao aumento de sua dívida. O resultado foi um $D/(D+E)$ menor do que o de 2023, saindo de 43% para 30%. Os juros pagos sobre os empréstimos e debêntures, que é a base para calcular o custo da dívida (K_d) na taxa de desconto, foi mantido em 12% da dívida bruta.

Tabela 12 - Projeção da Estrutura de Capital da Companhia

Estrutura de Capital	2023	2024E	2025E	2026E	2027E	2028E	2029E
Dívida Bruta	3.820	3.820	3.820	3.820	3.820	3.820	3.820
Empréstimos de Curto Prazo BoP	488	594	594	594	594	594	594
(-) Amortização	-	(643)	(557)	(653)	(715)	(618)	(432)
(+) Captação	-	643	557	653	715	618	432
(+/-) Variação Empréstimo CP	106	-	-	-	-	-	-
Empréstimos de Curto Prazo EoP	594	594	594	594	594	594	594
Empréstimos de Longo Prazo BoP	2.932	3.225	3.225	3.225	3.225	3.225	3.225
(+/-) Variação Empréstimo LP	294	-	-	-	-	-	-
Empréstimos de Longo Prazo EoP	3.225	3.225	3.225	3.225	3.225	3.225	3.225
Juros Pagos sobre Empréstimos e Debêntures	(453)	(458)	(458)	(458)	(458)	(458)	(458)
Juros (%)	12%	12%	12%	12%	12%	12%	12%
D/(D+E)	0,43	0,41	0,38	0,36	0,33	0,30	0,27

Fonte: Autoria Própria

O passivo de arrendamento, segundo os demonstrativos financeiros da companhia, é composto pelos contratos que as unidades possuem para locar espaço físico, equipamentos e outras instalações da sua operação e, por isso, é bastante sensível a inflação e ao número de unidades abertas. A variação do passivo de arrendamento é feita com base na adição de contratos arrendatários, juros incorridos que foram projetados com base na taxa SELIC, contraprestações que são descontos obtidos junto ao locatário e foram projetadas com base no histórico, e “outros”, que na projeção, serviram para anular o efeito dos juros cobrados em cima

do contrato, para que a variação do passivo fosse feita principalmente sobre o número de unidades e a inflação.

Tabela 17 - Projeção do Passivo de Arrendamento da Companhia

Passivo de Arrendamento	2023	2024E	2025E	2026E	2027E	2028E	2029E
Passivo de Arrendamento BoP	3.329	4.107	4.477	4.960	5.538	6.199	6.937
(+) Adições e Remensurações	1.161	1.404	1.610	1.826	2.055	2.298	2.377
Adições / Unidades	0,80	0,82	0,85	0,88	0,91	0,94	0,98
(+) Juros Incorridos	343	411	403	446	498	558	624
Juros Incorridos / Passivo de Arrendamento BoP	10%	10%	9%	9%	9%	9%	9%
(-) Contraprestações	(838)	(1.034)	(1.127)	(1.249)	(1.394)	(1.560)	(1.746)
Contraprestações / Passivo de Arrendamento BoP	0,25	0,25	0,25	0,25	0,25	0,25	0,25
(+/-) Outros	112	(411)	(403)	(446)	(498)	(558)	(624)
Passivo de Arrendamento EoP	4.107	4.477	4.960	5.538	6.199	6.937	7.567
Variação do Passivo de Arrendamento	778	370	483	578	662	738	630

Fonte: Autoria Própria

Por último, foram projetados os dividendos pagos pela companhia no período. Como a primeira vez que a SmartFit pagou juros sobre capital próprio (JCP) ao seu investidor foi no 4T23, foi utilizado como base a porcentagem do valor pago sobre o lucro líquido, de 25%, para projetar o pagamento.

Tabela 18 - Demonstrativo de Fluxo de Caixa Projetado

Demonstrativo de Fluxo de Caixa (DFC)	2023	2024E	2025E	2026E	2027E	2028E	2029E
Fluxo de Caixa Operacional	2.361	2.045	2.411	2.833	3.280	3.779	4.179
EBITDA	2.202	2.819	3.326	3.857	4.392	4.965	5.344
(+/-) Variação de Capital de Giro	160	12	21	27	25	22	34
(-) Impostos	473	(217)	(289)	(371)	(473)	(593)	(671)
(+/-) Resultado Financeiro	(473)	(568)	(647)	(679)	(664)	(615)	(529)
Fluxo de Caixa de Investimento	(2.118)	(2.416)	(2.743)	(2.834)	(3.031)	(3.216)	(1.919)
(-) Imobilizado	(1.326)	(1.565)	(1.326)	(1.365)	(1.402)	(1.438)	(556)
(-) Ativos de direito de uso	(688)	(786)	(1.352)	(1.404)	(1.564)	(1.713)	(1.297)
(-) Intangível	(501)	(65)	(65)	(65)	(65)	(65)	(65)
(-) Outros	395	-	-	-	-	-	-
Fluxo de Caixa de Financiamento	(552)	(37)	83	120	125	105	36
(+/-) Empréstimos LP	294	-	-	-	-	-	-
(+/-) Empréstimos CP	106	-	-	-	-	-	-
(-) Variação Passivo de Arrendamento	778	370	483	578	662	738	630
(+/-) NWC	(770)	(261)	(206)	(208)	(219)	(234)	(143)
(-) Dividendos	(266)	(146)	(194)	(249)	(318)	(398)	(450)
(+/-) Outros	(694)	-	-	-	-	-	-
Variação de Caixa	(310)	(408)	(249)	119	374	668	2.297
Caixa BoP	2.923	2.613	2.205	1.956	2.076	2.450	3.118
Caixa EoP	2.613	2.205	1.956	2.076	2.450	3.118	5.415

Fonte: Autoria Própria

4.2.3 Balanço Patrimonial (BP)

Com o objetivo de avaliar, controlar e gerenciar as atividades de uma entidade, o Balanço Patrimonial é uma demonstração contábil que pode ser utilizada para simples análises das atividades desenvolvidas por determinada empresa (Costa *et al.*, 2016). Segundo Montibeller (2012), o balanço patrimonial é uma demonstração constituída por ativos que representam os bens e direitos, passivo que representa as obrigações e o patrimônio líquido, que é a diferença entre os dois e, possui a finalidade de demonstrar quantitativamente e qualitativamente a situação de uma empresa no final de um determinado período. A partir da projeção do demonstrativo de fluxo de caixa, pode-se estruturar o balanço patrimonial projetado da companhia e analisar o desempenho do caixa e sua variação de patrimônio com mais detalhe.

Tabela 19 - Balanço Patrimonial Projetado da Companhia

Balanço Patrimonial	2023	2024E	2025E	2026E	2027E	2028E	2029E
Ativo	14.230	15.288	16.555	18.089	19.913	22.062	24.184
Ativo Circulante	3.346	3.142	3.054	3.338	3.884	4.735	7.147
Caixa e equivalentes de caixa	2.613	2.205	1.956	2.076	2.450	3.118	5.415
Clientes	349	446	523	601	683	770	825
Outros Ativos Circulantes	384	491	575	661	751	847	907
Ativo Não Circulante	10.884	12.146	13.501	14.751	16.029	17.326	17.037
Ativos por imposto diferido	798	1.020	1.196	1.375	1.562	1.762	1.886
Depósitos judiciais	101	129	151	174	197	223	238
Outros Ativos Não Circulantes	191	246	289	332	377	425	455
Imobilizado	4.045	4.900	5.366	5.790	6.177	6.531	5.941
Ativos de direito de uso	3.755	3.856	4.504	5.086	5.721	6.391	6.522
Intangível	1.913	1.913	1.913	1.913	1.913	1.913	1.913
Outros Ativos Fixos	81	81	81	81	81	81	81
Passivo	9.135	9.739	10.421	11.207	12.082	13.045	13.836
Passivo Circulante	2.244	2.460	2.642	2.833	3.030	3.236	3.384
Empréstimos CP	594	594	594	594	594	594	594
Passivos de arrendamentos CP	542	542	542	542	542	542	542
Fornecedores	399	246	280	316	352	391	418
Receita diferida	206	477	543	612	682	757	810
Outros Passivos Circulantes CP	502	600	683	770	859	952	1.019
Passivo Não Circulante	6.890	7.280	7.779	8.373	9.053	9.809	10.453
Empréstimos LP	3.225	3.225	3.225	3.225	3.225	3.225	3.225
Passivos de arrendamentos LP	3.565	3.935	4.418	4.995	5.657	6.395	7.025
Outros Passivos Não Circulantes LP	100	119	135	153	170	189	202
Patrimônio Líquido	5.096	5.548	6.134	6.882	7.830	9.017	10.348
Capital social	2.970	2.970	2.970	2.970	2.970	2.970	2.970
Reserva de capital	953	953	953	953	953	953	953
Reserva de Lucro	771	1.198	1.765	2.494	3.423	4.588	5.906
Outros	401	427	445	464	483	505	518

Fonte: Autoria Própria

4.3 Cálculo da Taxa de Desconto

Para calcular os resultados do modelo, é imprescindível uma taxa de desconto que corresponda a realidade e possua premissas atualizadas. Primeiro item a ser introduzido no modelo é o seu valor de mercado hoje, calculado com o preço mais recente da ação, multiplicado pelas ações negociadas pela empresa. A partir disso, para chegar no valor da empresa, deve-se descontar o valor de mercado pelo dado mais recente de dívida líquida.

Tabela 20 - Cálculo do Valor da Empresa

Preço da Ação	21,86
Ações Negociadas	586.242.000
Valor de Mercado	12.815.250.120
(+) Dívida Líquida 4T23	1.500.851.633
Valor da Empresa	14.316.101.753

Fonte: Autoria Própria

A primeira taxa de desconto a ser calculada é o CAPM (modelo de precificação de ativos financeiros), que servirá também para calcular o custo médio ponderado de capital (WACC). Para isso, foi definido como ativo livre de risco (R_f) a taxa pré-longa de dez anos do Brasil de 11,6%, um prêmio de risco do país de 4,4%, segundo Damodaran e, uma alíquota corporativa de 34% segundo a consultoria *PwC*. O beta da companhia foi calculado separadamente, a partir do histórico de preços de fechamento disponibilizados pela *InfoMoney*, do índice IBOVESPA e da ação SMFT3. Com os dados obtidos, foi possível calcular a variância do mercado e covariância entre o mercado e a ação, para chegar em um beta desalavancado.

Tabela 21 - Componentes do CAPM

CAPM	18,9%
Retorno do Ativo Livre de Risco	11,6%
Prêmio de Risco	4,4%
Imposto de Renda	34,0%
Beta	1,40

Fonte: Autoria Própria

Com o CAPM calculado, e os juros da dívida projetados, o modelo possui o custo do capital de terceiros (K_b) e custo de capital próprio (K_e) a serem utilizados no WACC.

Tabela 22 - Componentes do WACC

WACC	2024E	2025E	2026E	2027E	2028E	2029E
IPCA	3,7%	3,5%	3,4%	3,4%	3,4%	3,4%
Cost of Equity (Real) - CAPM	18,9%	18,9%	18,9%	18,9%	18,9%	18,9%
Cost of Equity (Nominal)	22,5%	22,4%	22,3%	22,3%	22,3%	22,3%
Cost of Equity (E/D+E)	0,59	0,62	0,64	0,67	0,70	0,73
Cost of Debt (Nominal)	12,0%	12,0%	12,0%	12,0%	12,0%	12,0%
Cost of Debt (D/D+E)	0,41	0,38	0,36	0,33	0,30	0,27
Corporate Income Tax	34%	34%	34%	34%	34%	34%
WACC	16,6%	16,9%	17,2%	17,6%	18,0%	18,4%

Fonte: Autoria Própria

4.4 Resultados do Modelo de Valuation

4.4.1 Fluxo de Caixa Descontado para a Firma (FCDF)

Com o fluxo de caixa e as taxas de desconto da companhia, pode-se projetar um fluxo de caixa livre para a firma, com a inflação e crescimento na perpetuidade (g). No caso do fluxo de caixa da firma, é utilizado o custo médio ponderado de capital (WACC) para refletir o custo do capital investido por credores e acionistas na firma.

O valor final da ação calculada por esse método é sensível a uma taxa de crescimento na perpetuidade (g) que, junto a inflação, aumenta o valor do fluxo de caixa da empresa ao longo dos anos. Dessa forma, foi feita uma análise de sensibilidade do valor da ação resultante do fluxo de caixa descontado pela firma, e do crescimento na perpetuidade considerado para a SmartFit.

Tabela 33 - Sensibilidade do Crescimento na Perpetuidade e Valor da Firma

	0%	0,5%	1,0%	1,5%	2,0%	2,5%	3,0%	3,5%	4,0%	4,5%	5,0%
DCFF	26,6	27,4	28,2	29,1	30,0	31,0	32,1	33,3	34,6	36,0	37,6

Fonte: Autoria Própria

4.4.2 Fluxo de Caixa Descontado para o Acionista (DCF)

O fluxo de caixa livre para o acionista, conforme visto na fundamentação teórica, adiciona ao fluxo de caixa livre para a firma, a emissão e amortização de financiamentos, que no modelo foi considerado apenas a valorização dos contratos de arrendamento com a abertura de unidades e inflação. No caso do acionista, o fluxo de caixa é descontado pelo k_e , que é o

custo de capital próprio calculado. Assim como o DCFF, foi calculado a sensibilidade do valor final do modelo em relação a taxa de crescimento na perpetuidade (g) da ação.

Tabela 24 - Sensibilidade do Crescimento na Perpetuidade e Valor do Acionista

	0%	0,5%	1,0%	1,5%	2,0%	2,5%	3,0%	3,5%	4,0%	4,5%	5,0%
DCFE	27,9	28,4	28,9	29,4	30,0	30,6	31,3	31,9	32,7	33,5	34,4

Fonte: Autoria Própria


Considerando que a companhia não possua um crescimento na perpetuidade (g), a ação ficaria em torno de R\$27 em ambos os fluxos de caixa e, apresentaria um *upside* de 25% e 27% no fluxo de caixa descontado para a firma e para o acionista respectivamente.

4.5 Aplicação do Modelo de Machine Learning

4.5.1 Clusters

Para determinar o número de *clusters* e aplicar a técnica de clusterização, foi utilizado o método *K-Means*. O número ideal de *clusters* foi identificado utilizando o Método do Cotovelo (*Elbow Method*). Esse método envolveu a plotagem da soma dos quadrados das distâncias (SSE) para diferentes valores de k e a identificação do ponto onde a redução da SSE começa a se nivelar, formando um "cotovelo" no gráfico. A partir do Gráfico 5 abaixo, foi decidido que o número ideal de clusters é 4.

Gráfico 5 - Identificação do número ideal de clusters utilizando o Método do Cotovelo




Fonte: Autoria Própria

A aplicação do algoritmo *K-Means* aos dados ESG resultou na formação de 4 *clusters* distintos. Cada *cluster* representa um grupo de empresas com características similares. As variáveis utilizadas para formar os *clusters* foram: Setor das empresas, *market cap*, país de origem, intervalos de preço das ações e intervalos de *market cap*.

Essas variáveis categóricas foram selecionadas por suas características distintivas, que permitem agrupar as empresas de maneira a refletir suas similaridades e diferenças nos indicadores ESG e outras variáveis relevantes. A empresa escolhida para o estudo de caso, SmartFit (SMFT3), ficou no *cluster* 0.

Gráfico 6 - Mapa de dispersão dos Clusters formados



Fonte: Autoria Própria

4.5.2 Modelo de Machine Learning

Com os dados limpos e segmentados em clusters, foi aplicado o *LazyRegressor* para identificar o melhor modelo de *Machine Learning* para prever o comportamento dos preços das ações com base nos indicadores ESG. A biblioteca *LazyRegressor* ajustou automaticamente diversos modelos de regressão e calculou métricas comuns de avaliação como R^2 , R^2 ajustado e RMSE.

Tabela 25 - Desempenho com a base completa dos 5 melhores modelos de Machine Learning

Modelo	R2 Ajustado	R2	RMSE	Tempo(s)
ExtraTreeRegressor	0,61	0,87	3,06	0,01
GaussianProcessRegressor	0,61	0,81	20,58	0,01
ExtraTreesRegressor	0,59	0,89	2,94	0,09
DecisionTreeRegressor	0,57	0,8	3,27	0,01
GradientBoostingRegressor	0,56	0,85	3,18	0,06

Fonte: Autoria Própria

O melhor modelo identificado foi o *ExtraTreeRegressor*, que apresentou o R^2 igual a 0,87, indicando que 87% da variabilidade dos dados foi explicada pelo modelo. R^2 ajustado de 0,61. RMSE de 3,06, indicando a média dos erros entre os valores observados e os valores previstos pelo modelo.

4.5.3 Equação de Regressão

A aplicação do *ExtraTreeRegressor* permitiu a avaliação das importâncias das variáveis ESG (Environmental, Social, Governance) na previsão dos preços ajustados das ações. Embora o *ExtraTreeRegressor* não seja um modelo linear, foi fornecido para o modelo todos os dados de ESG *Score* e armazenado os resultados. Em seguida, aplica-se um modelo de regressão linear múltipla sobre essas séries de dados, permitindo chegar a uma equação resultante que permite a criação de cenários e uma maior interpretação. A linearização dos valores resultantes de modelos complexos, como árvores de decisão, é uma prática comum para facilitar a análise e interpretação dos dados (Molnar, 2019).

$$\text{Preço ajustado} = 18,58 \cdot \text{Environment} - 17,41 \cdot \text{Governance} - 19,34 \cdot \text{Social} + 573,86 \quad (7)$$

4.6 Aplicação do modelo na Smartfit e possíveis cenários

4.6.1 Expectativa de crescimento

Em 22/12/2023, a SmartFit (SMFT3) teve um preço de fechamento de R\$25,73 segundo o *Yahoo Finance*. Ao fornecer esse preço para o modelo de Regressão Linear Múltipla foi possível encontrar os ESG *Scores* estimados da companhia nesta data: *Environment Score* 7,91, *Governance Score* 7,91 e *Social Score* 28,82. Em seguida, a partir do último relatório

disponibilizado pela companhia, foram analisadas as iniciativas ESG propostas pela empresa e como elas podem impactar os ESG *Scores* da companhia.

No pilar ambiental, a empresa elaborou sua primeira matriz de materialidade, que define diretrizes de sustentabilidade e iniciativas futuras. A empresa investiu em energia renovável, com 148 unidades operando com Mercado Livre ou Geração Distribuída, e automação de ar-condicionado em 224 unidades, aumentando a eficiência energética.

No pilar social, a SmartFit conduziu mais de 200 campanhas de doações em todos os países onde opera, apoiando o desenvolvimento social local. Em parceria com a UNICEF, as unidades do Grupo SmartFit receberam o selo de “Espaço Solidário à Infância”, destacando seu compromisso com a infância.

No pilar de governança, a SmartFit destaca-se pela elaboração da primeira matriz de materialidade, definindo diretrizes de sustentabilidade e iniciativas para os próximos anos. A empresa iniciou estudos de impacto do seu negócio e avançou no processo de levantamento de dados para temas mais relevantes. Adicionalmente, a SmartFit está no Novo Mercado da B3, o segmento de listagem com os mais altos padrões de governança corporativa no Brasil.

Com a conclusão e aprimoramento dessas iniciativas, a expectativa é que o ESG *Score* da empresa aumente para *Environment Score* 6, *Governance Score* 7,5 e *Social Score* 27,3. Aplicando essas variáveis na equação 7, é encontrado um preço de R\$26,78. Representando um crescimento de 3,99% em relação ao preço base de R\$ 25,76.

Segundo relatório da XP (2023), apesar de ter um IPO recente, os avanços na agenda ESG sinalizam um progresso da companhia no tema. O relatório entra em detalhes, destacando que na esfera ambiental, a empresa é menos intensiva em carbono do que a maioria das empresas e, ainda possui muito espaço para melhorar esse indicador. Em relação ao social, destaca o serviço de baixo custo oferecido pela empresa e nos benefícios à saúde e, no âmbito da governança, um conselho administrativo e estrutura societária composta por *stakeholders* com experiência no mercado. Dessa forma, a premissa de crescimento com base nas práticas ESG da companhia é embasada em suas práticas e na agenda ESG, sendo reconhecida pelo mercado.

Vale reforçar que os preços ajustados pelo modelo não são compatíveis com a realidade do preço da ação atual, pois para fins de análise, os preços da ação são resumidos unicamente pela importância de cada ESG *Score*. Segundo *Alam et Al* (2017), os preços das ações são determinados por uma combinação complexa de fatores internos e externos, incluindo condições econômicas gerais, políticas macroeconômicas, expectativas do mercado, eventos

geopolíticos e alterações regulatórias, que juntos influenciam a oferta e a demanda de ações no mercado. Tais fatores internos e externos não estão sendo tratados nessa pesquisa.

4.6.2 Integração no Valuation

A taxa de crescimento na perpetuidade (g) é subjetiva no modelo. Segundo *Damodaran* (2002), a taxa de crescimento na perpetuidade é uma das variáveis mais difíceis de estimar em avaliações de empresas devido à sua natureza subjetiva e à influência de fatores futuros incertos. Para integrar o modelo de *machine learning* com o *valuation*, será utilizado o crescimento de 3,99% indicado pelo modelo, como taxa de crescimento na perpetuidade (g).

$$Fluxo\ de\ Caixa_{d+1} = Fluxo\ de\ Caixa_d \times (1 + g) \times (1 + inflação) \quad (8)$$

O resultado encontrado com um crescimento de 3,99% na perpetuidade da empresa foi de um *upside* em relação ao preço atual de 48% no fluxo de caixa descontado para o acionista, com uma ação cotada em R\$32,4. No fluxo de caixa descontado para a firma, o *upside* foi de 63% com uma ação cotada em R\$35,7.

4.6.3 Cenários

As mudanças nos parâmetros ESG foram baseadas no Relatório de Sustentabilidade da SmartFit (2022), e nas iniciativas individuais que cada parâmetro apresentou no relatório. Dessa forma, foi possível atribuir uma melhoria diferente em cada ESG *Score* com base no que a empresa visa melhorar e possui como iniciativa. No que se refere às esferas social e de governança, a companhia possui iniciativas já consolidadas, conforme relatado anteriormente, participando de campanhas de doação e, ocupando Novo Mercado da B3, que é apenas concedido para empresas com o mais alto nível de governança, por isso, foi atribuído ao *Social Score* e *Governance Score* uma melhora na nota de mesma proporção.

Por outro lado, as iniciativas de sustentabilidade da companhia parecem promissoras e ainda possuem muita margem de melhora. As práticas de redução de consumo de água e energia, assim como a entrada de algumas unidades no Mercado Livre de energia, aliado ao fato de que o modelo de negócios da SmartFit é pouco intensivo em carbono quando comparado a maioria das empresas, representa uma grande vantagem da empresa nesse parâmetro em

específico. Portanto, foi atribuído uma melhora de magnitude maior no *Environmental Score* da companhia, visando justamente o potencial de melhora, nesse parâmetro, que a SmartFit pode apresentar na perpetuidade.

Tabela 26 - Crescimento na Perpetuidade em Cenários ESG

Cenários	E	S	G	Preço	g
Cenário Base	7,91	28,82	7,91	25,76	0,00%
Cenário Otimista	6,00	27,30	7,50	26,78	3,99%

Fonte: Autoria Própria

O resultado proposto e a metodologia utilizada, introduzem uma maneira mais quantitativo de avaliar o impacto ESG dentro do valor de uma companhia. Diferente de outros estudos, fortemente baseados no *Value Driver Adjustment* (VDA), que exige um maior detalhamento dos fatores ESG dentro do modelo da companhia, o modelo proposto fornece um dado de crescimento na perpetuidade (g) de fácil integração no modelo de *valuation*. Além disso, é possível justificar a partir dos dados da própria companhia, o potencial que a empresa possui em cada variável ESG.

5 CONCLUSÃO

Este trabalho teve como objetivo investigar e avaliar a influência das variáveis ESG (*Environmental, Social, Governance*) no *valuation* de uma empresa do setor *fitness*, utilizando a SmartFit como estudo de caso e aplicando métodos de *machine learning* para esta análise. Por meio de uma análise detalhada das práticas ESG e a implementação de um modelo de regressão com o *ExtraTreeRegressor*, foi possível entender a importância relativa de cada pilar ESG no preço ajustado das ações da SmartFit.

Os resultados demonstraram que, embora o modelo de *machine learning* tenha identificado a importância das variáveis ESG, há uma significativa diferença entre os preços previstos pelo modelo e os preços reais de mercado. Essa discrepância pode ser atribuída à complexidade e à multiplicidade de fatores que influenciam o preço das ações, incluindo liquidez, condições econômicas gerais, políticas macroeconômicas, expectativas do mercado, eventos geopolíticos e alterações regulatórias. Conforme mencionado por Alam et Al. (2017), "*os preços das ações são influenciados por uma vasta gama de fatores externos, tornando impossível representar todos esses fatores em uma única equação.*"

Apesar dessas limitações, este estudo contribui para a área ao demonstrar a relevância das práticas ESG no *valuation* das empresas e, ao utilizar técnicas avançadas de *machine learning* para essa análise. A abordagem metodológica aplicada pode ser replicada e aprimorada em futuras pesquisas, abrangendo outros setores e empresas, para um entendimento mais profundo da relação entre ESG e *valuation*.

Contudo, algumas lacunas permaneceram, como a necessidade de incluir uma análise mais detalhada de outros fatores que influenciam o preço das ações e a potencial melhoria da acurácia do modelo preditivo. Também seria benéfico explorar a interação entre as variáveis ESG e outros indicadores financeiros para uma visão mais holística do impacto ESG. Em futuras pesquisas, pode ser utilizado mais cenários e, análises de mais indicadores financeiros.

O benefício deste trabalho para a área de finanças corporativas e sustentabilidade é significativo. A integração de práticas ESG no *valuation* de empresas oferece uma abordagem mais holística e moderna para a avaliação de ativos, alinhando-se às crescentes demandas de investidores por transparência e responsabilidade socioambiental. Este estudo contribui para o entendimento de como práticas sustentáveis podem ser traduzidas em valor econômico. O avanço dessa linha de pesquisa pode fornecer insights valiosos para investidores e gestores, promovendo práticas empresariais mais sustentáveis e responsáveis.

REFERÊNCIAS BIBLIOGRÁFICAS

ABRAMOVAY, Ricardo. Em busca do capitalismo sustentável. **Folha de S.Paulo**, São Paulo, 31 mar. 2012. Disponível em:

<https://www1.folha.uol.com.br/empreendedorsocial/colunas/1069934-em-busca-do-capitalismo-sustentavel.shtml>. Acesso em: 13 maio 2024.

AGGARWAL, Charu C. **Outlier Analysis**. Berlin: Springer Nature, 2017.

AIELLO, Marianne. How Blink Fitness Is Redefining the Meaning of “Value” in the HVLP Segment: Blink Fitness is living proof that low-price gyms don’t have to come with a bad member experience. *In: HEALTH & Fitness Association*. Boston, Dec. 20, 2016. Disponível em: <https://www.ihrsa.org/improve-your-club/how-blink-fitness-is-redefining-the-meaning-of-value-in-the-hvlp-segment>. Acesso em: 13 maio 2024.

ALAM, Shafiqul; MIAH, Rubel; KARIM, Abdul. An Empirical Study on Microeconomic Factors Affecting Stock Price: A Study on Insurance Companies Listed in Dhaka Stock Exchange. *Research Journal of Finance and Accounting*, v. 7, n. 18, p. 93-105, 2017. Disponível em:

https://www.researchgate.net/publication/339445164_Analysis_on_Factors_that_Affect_Stock_Prices_A_Study_on_Listed_Cement_Companies_at_Dhaka_Stock_Exchange. Acesso em: 13 maio 2024.

ALVAREZ, Thiago; SENSINI, Luca; VAZQUEZ, Maria. Working Capital Management and Profitability: Evidence from an Emergent Economy. **International Journal of Advances in Management and Economics**, Vadodra, v. 11, n. 1, p. 32-39, 2021. Disponível em: https://www.researchgate.net/publication/348944860_Working_Capital_Management_and_Profitability_Evidence_from_an_Emergent_Economy#fullTextFileContent. Acesso em: 26 maio 2024.

AMEL-ZADEH, Amir; CALLIESS, Jan-Peter; KAISER, Daniel; ROBERTS, Stephen. Machine Learning-Based Financial Statement Analysis. **Econometrics: Econometric & Statistical Methods**, Brisbane, Jan. 15, 2020. Disponível em: <https://oxford-man.ox.ac.uk/wp-content/uploads/2020/06/Machine-Learning-Based-Financial-Statement-Analysis.pdf>. Acesso em: 26 maio 2024.

ASSEF NETO, Alexandre. **Contribuição ao estudo da avaliação de empresas no Brasil: uma aplicação prática**. 2004. Tese (Livre Docência em Finanças) – Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, Ribeirão Preto, 2004.

BANCO CENTRAL, do Brasil; **Focus Relatório de Mercado**, 7 de junho 2024. <https://www.bcb.gov.br/content/focus/focus/R20240607.pdf>.

BANCO de MÉXICO; **Quarterly Report October – December 2023**, 28 de fevereiro de 2024. <https://www.banxico.org.mx/publications-and-press/quarterly-reports/%7B33DB1D6A-5B7F-FE2F-5301-A164E1715330%7D.pdf>

BARBIROLI, Marina, FUSCHINI, Franco. A Machine Learning Approach to Wireless Propagation Modeling in Industrial Environment. *IEEE Open Journal of Antennas and Propagation* 2024.

BARNETT, Vic; LEWIS, Toby. **Outliers in statistical data**. Chichester: Wiley, 1994.

BARROS, Catarina; GONCALVES, Lisa. Investigating individual satisfaction in health and fitness training centres. **International Journal of Sport Management and Marketing**, Geneva, v. 5, n. 4, p. 384-395, 2009. Disponível em: https://www.researchgate.net/publication/247834448_Investigating_individual_satisfaction_in_health_and_fitness_training_centres#fullTextFileContent. Acesso em: 13 maio 2024.

BAX, Karoline; BONACCOLTO, Giovanni; PATERLINI, Sandra. Spillovers in Europe: The role of ESG. **Journal of Financial Stability**, New York, v. 72, 2024. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1572308924000068>. Acesso em: 13 maio 2024.

BERTÃO, Naiara. Pressão vinda de reguladores e clientes impulsiona avanço das empresas na agenda ESG. **Valor Econômico**. São Paulo, 15 maio 2023. Disponível em: <https://valor.globo.com/empresas/esg/noticia/2023/05/15/pressao-vinda-de-reguladores-e-clientes-impulsiona-avanco-das-empresas-na-agenda-esg.ghtml>. Acesso em: 13 maio 2024.

CAMPOS, Renato; VITAL, Juliana Tatiane; MORITZ, Gilberto de Oliveira; COSTA, Alexandre Marino. Valor justo da Tractebel Energia: uma avaliação a partir dos principais modelos de precificação de ativos. **Revista de Ciências da Administração**, Florianópolis, v. 12, n. 26, p. 11-47, 2010. Disponível em: <https://periodicos.ufsc.br/index.php/adm/article/view/2175-8077.2010v12n26p11/17401>. Acesso em: 13 maio 2024.

CAO, Kai; YOU, Haifeng. **Fundamental Analysis via Machine Learning**. *Financial Analysts Journal*, vol. 80, no. 2, 21 Mar. 2024, pp. 74–98. Disponível em: <https://doi.org/10.1080/0015198x.2024.2313692>

CASTRO, Lucas Teófilo de. **Análise de Indicadores Financeiros e Clusterização das Principais Empresas do Ibovespa via k-means**. 2023. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Materiais e Manufatura) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2023. Disponível em: https://bdta.abcd.usp.br/directbitstream/d8282d81-317a-4b6f-9726-9c3f49f86ffb/Castro_Lucas_tcc.pdf. Acesso em: 13 maio 2024.

CHEKHOVSKA, Liubov. Fitness industry: state and prospects of development in the countries of the world. **SlobozhanSkyi herald of Science and Sport**, Kharkiv, v. 58, n. 2, p. 19-24, 2017. Disponível em: https://journals.uran.ua/sport_herald/article/view/104259/pdf_179. Acesso em: 13 maio 2024.

COLLINS, Elizabeth. What Makes a Moat?. *In: MORNINGSTAR*, New York, Jul. 21, 2014. Disponível em: <https://www.morningstar.com/articles/656426/what-makes-a-moat>. Acesso em: 13 maio 2024.

COPELAND, Tom; KOLLER, Tim; MURRIN, Jack. **Avaliação de Empresas - Valuation: calculando e gerenciando o valor das empresas**. São Paulo: Makron Books, 2002.

COSTA, Robson Antonio Tavares; MANSO, Rodrigo Semblano; GOMES, Marcos Antônio Damasceno; FIGUEIREDO, Artur Ricardo. Balanço patrimonial como ferramenta para tomada de decisão. **Revista de Empreendedorismo e Gestão de Micro e Pequenas Empresas**, Belém, v. 1, n. 1, p. 57-67, 2016. Disponível em: <https://revistas.editoraenterprising.net/index.php/regmpe/article/view/74/53>. Acesso em: 26 maio 2024.

CUNHA, Moisés Ferreira da; MARTINS, Eliseu; NETO, Alexandre Assaf. Avaliação de empresas no Brasil pelo fluxo de caixa descontado: evidências empíricas sob o ponto de vista dos direcionadores de valor nas ofertas públicas de aquisição de ações. **Revista de Administração**, São Paulo, v. 49, n. 2, p. 251-266, 2014. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0080210716303442>. Acesso em: 26 maio 2024.

DAMODARAN, Aswath. **Investment valuation: Tools and techniques for determining the value of any asset**. 3. ed. Hoboken: Wiley, 2012.

DARNÉ, Olivier; LEVY-RUEFF, Guy; POP, Adrian. The calibration of initial shocks in bank stress test scenarios: An outlier detection based approach. **Economic Modelling**, Amsterdam, v. 136, p. 106744, 2024. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0264999324001007>. Acesso em: 26 maio 2024.

DASGUPTA, Ranjan; ROY, Arup. Firm environmental, social, governance and financial performance relationship contradictions: Insights from institutional environment mediation. **Technological Forecasting and Social Change**, Amsterdam, v. 189, 2023. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0040162523000264?pes=vor>. Acesso em: 19 maio 2024.

DROBETZ, Wolfgang; OTTO, Tizian. Empirical asset pricing via machine learning: evidence from the European stock market. **Journal of Asset Management**, Oxford, v. 22, p. 507-538, 2021. Disponível em: <https://link.springer.com/article/10.1057/s41260-021-00237-x>. Acesso em: 13 maio 2024.

DUMAY, John; GUTHRIE, James; FARNETI, Federica. Gri Sustainability Reporting Guidelines For Public And Third Sector Organizations. **Public Management Review**, Phoenix, v. 12, n. 4, p. 531-548, 2010. Disponível em: <https://www.tandfonline.com/doi/epdf/10.1080/14719037.2010.496266?needAccess=true>. Acesso em: 13 maio 2024.

DUNLOP, Amelia. New Data Reveals The Chief Experience Officer's Top Five Challenges. **Forbes: Deloitte BrandVoice**. New York, Feb. 8, 2024. Disponível em: <https://www.forbes.com/sites/deloitte/2024/02/08/new-data-reveals-the-chief-experience-officers-top-five-challenges/?sh=a47e69c6671b>. Acesso em: 13 maio 2024.

ECCLES, Robert G. From “Who Cares Wins” To Pernicious Progressivism: 18 Years Of ESG. **Forbes**, New York, Nov. 5, 2022. Disponível em: <https://www.forbes.com/sites/bobeccles/2022/11/05/from-who-cares-wins-to-pernicious-progressivism-18-years-of-esg/>. Acesso em: 13 maio 2024.

EDMANS, Alex. The end of ESG. **Financial Management**, Tampa, v. 52, n. 1, p. 3-17, 2023. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1111/fima.12413>. Acesso em: 13 maio 2024.

EFIMOVA, Olga V. Integrating Sustainability Issues into Investment Decision Evaluation. **Journal of Reviews on Global Economics**, Montreal, v. 7, p. 668-681, 2018. Disponível em: <https://core.ac.uk/download/pdf/493037841.pdf>. Acesso em: 13 maio 2024.

ESG: o que é, como funciona, vantagens e características. *In*: EQUIPE TOTVS. **Blog Gestão de Negócios**, São Paulo, 16 out. 2023 [Atualizado em 26 jan. 2024]. Disponível em: <https://www.totvs.com/blog/negocios/esg/>. Acesso em: 13 maio 2024.

EXPERT XP. **Radar ESG | Smart Fit (SMFT3): O segredo para progredir é dar o primeiro passo**. Rio de Janeiro: XP, 2023. Disponível em: <https://conteudos.xpi.com.br/esg/radar-esg-smartfit-smft3-o-segredo-para-progredir-e-dar-o-primeiro-passo/>. Acesso em: 13 maio 2024.

FAMA, Eugene F. **Efficient Capital Markets: a Review of Theory and Empirical Work**. The Journal of Finance, Bethlehem, v. 25, n. 2, p. 383-417, 1970.

FAMA, Eugene; FRENCH, Kenneth. **The Cross-Section of Expected Stock Returns**. The Journal of Finance, 1992. <https://doi.org/10.1111/j.1540-6261.1992.tb04398.x>

FERNÁNDEZ, Pablo. **Valuation Methods and Shareholder Value Creation**. Amsterdam: Elsevier, 2002.

FISCHER, Thomas; KRAUSS, Christopher. Deep learning with long short-term memory networks for financial market predictions. **European Journal of Operational Research**, Amsterdam, v. 270, n. 2, p. 654-669, 2018. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0377221717310652?via%3Dihub>. Acesso em: 13 maio 2024.

FITNESS BRASIL. **Panorama Setorial Fitness Brasil**. São Paulo: Fitness Brasil, 2023.

FLEISCHMANN, Isabela. De olho em IPO, Gympass muda nome para Wellhub com foco no mercado de bem-estar. **Bloomberg Línea**, 4 abr. 2024. Disponível em: <https://www.bloomberglinea.com.br/startups/de-olho-em-ipo-gympass-muda-nome-para-wellhub-para-atender-o-mercado-de-bem-estar/>. Acesso em: 13 maio 2024.

FRIEDMAN, Jerome H. Greedy function approximation: A gradient boosting machine. **The Annals of Statistics**, v. 29, n. 5, p. 1189-1232, 2001.

FRISKE, Wesley; HOELSCHER, Seth ; NIKOLOV, Atanas. **The impact of voluntary sustainability reporting on firm value: Insights from signaling theory**. Journal of the Academy of Marketing Science, 2022. 51. 10.1007/s11747-022-00879-2.

GU, Shihao; KELLY, Bryan; XIU, Dacheng. Empirical Asset Pricing via Machine Learning. **The Review of Financial Studies**, Oxford, v. 33, n. 5, p. 2223-2273, 2020. Disponível em: <https://academic.oup.com/rfs/article/33/5/2223/5758276>. Acesso em: 13 maio 2024.

GUERRA FILHO, Ricardo Wagner Correia. **Deteção de outliers em curvas de demanda de energia baseado no algoritmo TEDA Recursivo**. 2023. Dissertação (Mestrado em Engenharia Elétrica) – Centro de Energias Alternativas e Renováveis, Universidade Federal da Paraíba, João Pessoa, 2023. Disponível em: https://repositorio.ufpb.br/jspui/bitstream/123456789/30134/1/RicardoWagnerCorreiaGuerraFilho_Dissert.pdf. Acesso 13 maio 2024.

GUPTA, Anish; GUPTA, Manish; CHATURVEDI, Prateek. Investing Data with Machine Learning Using Python. **Asset analytics**, Berlin, p. 1-9, Jun. 20, 2020.

HASAN, Morshadul Md.; POPP, József; OLÁH, Judit. Current Landscape and Influence of Big Data on Finance. **Journal of Big Data**, Berlin, v. 7, n. 21, p. 1-17, 2020. Disponível em: <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-020-00291-z>. Acesso em: 25 maio 2024.

HAWKINS, D. M. **Identification of outliers**. London: Chapman and Hall, 1980.

HEATON, J. B.; POLSON, N.; WITTE, J. Deep learning for finance: deep portfolios. **Applied Stochastic Models in Business and Industry**, Hoboken, v. 33, n. 1, p. 3-12, 2016.

HERNG, Wei; NASIR, Aimi Salihah Abdul; SUKOR, Abdul Syafiq Abdull. Robust Segmentation of COVID-19 Chest X-Ray Images: Analysis of Variant k-Means Based Clustering Algorithms. **Journal of Advanced Research in Applied Sciences and Engineering Technology**, Kajang, v. 44, n. 1, p. 77-93, 2024. Disponível em: https://semarakilmu.com.my/journals/index.php/applied_sciences_eng_tech/article/view/2047. Acesso em: 26 maio 2024.

IGLEWICZ, Boris; HOAGLIN, David Caster. **How to Detect and Handle Outliers**. Milwaukee: ASQ Quality Press, 1993.

IKOTUN, Abiodun; EZUGWU, Absalom; ABUALIGAH, Laith; ABUHAIJA, Belal; HEMING, Jia. **K-means clustering algorithms: A comprehensive review, variants analysis, and advances in the era of big data**. Information Sciences 2023, 622, 178-210.

INTERNATIONAL MONETARY FUND; **World Economic Outlook – Steady But Slow: Resilience amid Divergence**, abril de 2024. <https://www.imf.org/en/Publications/WEO/Issues/2024/04/16/world-economic-outlook-april-2024>

JA'AFAR, Nur Shahirah; MOHAMAD, Junainah; ISMAIL, Suriatini. Machine learning for property price prediction and price valuation: a systematic literature review. **Planning Malaysia: Journal of Malaysian Institute of Planners**, Petaling Jaya, v. 19, n. 3, p. 411-422, 2021. Disponível em: <https://planningmalaysia.org/index.php/pmj/article/view/1018/714>. Acesso em: 13 maio 2024.

JENSEN, Michael C. Agency Costs of Free Cash Flow, Corporate Finance, and Takeovers. **The American Economic Review**, Pittsburgh, v. 76, n. 2, p. 323-329, 1986. Disponível em: <https://www.jstor.org/stable/1818789>. Acesso em: 13 maio 2024.

KALANTARI, Elham; GHOLAMI, Hamid; MALAKOOTI, Hossein; EFTEKHARI, Mahdi; SANEI, Poorya; ESFANDIARPOUR, Danya; MOOSAVI, Vahid; NAFARZADEGAN, Ali Reza. Evaluating traditional versus ensemble machine learning methods for predicting missing data of daily PM₁₀ concentration. **Atmospheric Pollution Research**, v. 15, n. 5, 2024. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S130910422400028X>. Acesso em: 26 maio 2024.

KARACHUN, Irina; VINNICHEK, Lyubov; TUSKOV, Andrey. Machine learning methods in finance. **SHS Web of Conferences**, Les Ulis, v. 110, 05012, p. 1-6, 2021. Disponível em: https://www.shs-conferences.org/articles/shsconf/pdf/2021/21/shsconf_icemt2021_05012.pdf. Acesso em: 13 maio 2024.

KITE-POWELL, Jennifer. ESG é uma estratégia de investimento ou o caminho para um mundo sustentável?. **Forbes Brasil**. São Paulo, 23 dez. 2022. Disponível em: <https://forbes.com.br/forbesesg/2022/12/esg-e-uma-estrategia-de-investimento-ou-o-caminho-para-um-mundo-sustentavel/>. Acesso em: 13 maio 2024.

KUMAR, Santosh; KUMAR, Ankit; SINGH, Kamred Udham; PATRA, Sujit Kumar. The Six Decades of the Capital Asset Pricing Model: A Research Agenda. **Journal of Risk Financial Management**, Basel, v. 16, n. 8, p. 356, 2023. Disponível em: <https://www.mdpi.com/1911-8074/16/8/356>. Acesso em: 13 maio 2024.

KUMARI, Roopa; GUPTA, Neena; KUMAR, Narender. Segmentation of Covid-19 Affected X-Ray Image using K-means and DPSO Algorithm. **International Journal of Mathematical Engineering and Management Sciences**, Jamnipur, v. 6, n. 5, p. 1255-1275, 2021. Disponível em: https://www.researchgate.net/publication/355135919_Segmentation_of_Covid-19_Affected_X-Ray_Image_using_K-means_and_DPSO_Algorithm. Acesso em: 13 maio 2024.

LO, Andrew W. **Adaptive markets**: Financial evolution at the speed of thought. Princeton: Princeton University Press, 2017.

LUISA. Valuation: saiba calcular o valor da sua empresa!. In: EXPERT XP. Rio de Janeiro, 31 maio 2023 [Atualizado em 3 out. 2023]. Disponível em: <https://conteudos.xpi.com.br/aprenda-a-investir/relatorios/valuation/>. Acesso em: 26 maio 2024.

MACEDO, Marcelo Alvaro da Silva; MACHADO, Márcia Reis; MURCIA, Fernando Dal-Ri; MACHADO, Márcio André Veras. Análise da relevância do EBITDA versus fluxo de caixa operacional no mercado brasileiro de capitais. **Advances in Scientific and Applied Accounting**, São Paulo, v. 5, n. 1, p. 99-130, 2012. Disponível em:

<http://www.atena.org.br/revista/ojs-2.2.3-08/index.php/ASAA/article/viewFile/1846/1702>. Acesso em: 26 maio 2024.

MACEDO, Paula de Souza; ROCHA, Pedro Serezani; ROCHA, Edgar Teixeira; TAVARES, Gabriel Frias; JUCÁ, Michele Nascimento. O impacto do ESG no Valor e Custo de Capital das Empresas. **Revista Contabilidade, Gestão e Governança**, Brasília, v. 25, n. 2, p. 159-175, 2022. Disponível em: <https://revistacgg.org/index.php/contabil/article/view/2802>. Acesso em: 26 maio 2024.

MACHADO, Michele Rílany Rodrigues. Fluxo de Caixa Descontado: metodologias e critérios adotados na determinação da taxa de desconto. 2007. Disponível em: <https://sistema.semead.com.br/10semead/sistema/resultado/trabalhosPDF/198.pdf>. Acesso em: 26 maio 2024.

MOLNAR, Christoph. **Interpretable Machine Learning: A Guide for Making Black Box Models Explained**. 2024. <https://christophm.github.io/interpretable-ml-book/>

MONTIBELLER, B.H. **Análise das Demonstrações Contábeis de Empresa Agroindustrial que Atua nos Seguintes de Compra e Venda de Insumos e Cereais**. 2012. Trabalho de Conclusão de Curso (Bacharelado em Ciências Contábeis) – Faculdade Assis Gurgacz, Toledo, PR, 2012.

MORRIS, John; ALAM, Pervaiz. Value relevance and the dot-com bubble of the 1990s. **The Quarterly Review of Economics and Finance**, Amsterdam, v. 52, n. 2, p. 243-255, 2012. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1062976912000245>. Acesso em: 13 maio 2024.

NAINGGOLAN, Rena; PERANGIN-ANGIN, Resianta; SIMARMATA, Reinhard; TARIGAN, Astuti Feriani. Improved the Performance of the K-Means Cluster Using the Sum of Squared Error (SSE) optimized by using the Elbow Method. **Journal of Physics: Conference Series**, Bristol, v. 1361, 012015, 2019. Disponível em: <https://iopscience.iop.org/article/10.1088/1742-6596/1361/1/012015/pdf>. Acesso em: 13 maio 2024.

NEVASALMI, Lauri. Forecasting multinomial stock returns using machine learning methods. **The Journal of Finance and Data Science**, Amsterdam, v. 6, p. 86-106, 2020. Disponível em: https://www.researchgate.net/publication/346916165_Forecasting_multinomial_stock_returns_using_machine_learning_methods. Acesso em: 26 maio 2024.

OLIVEIRA, Yasmin Martins de. **O mercado livre de energia no brasil**: aprimoramentos para sua expansão. 2017. Trabalho de Conclusão de Curso (Bacharelado em Ciências Econômicas) – Faculdade de Economia, Administração e Contabilidade, Universidade de Brasília, Brasília, 2017. Disponível em: https://bdm.unb.br/bitstream/10483/18148/1/2017_YasminMartinsDeOliveira_tcc.pdf. Acesso em: 13 maio 2024.

OYEWOLE, Gbeminiyi; THOPIL, George. **Data clustering: application and trends**. Artificial Intelligence Review 2023. <https://doi.org/10.1007/s10462-022-10325-y>

PANDALA, Shankar Rao. LazyPredict. *In*: GITHUB Repository. [San Francisco, 2020]. Disponível em: <https://github.com/shankarpandala/lazypredict>. Acesso em: 26 maio 2024.

PHANG, Soon-Yeow; ADRIAN, Christofer; GARG, Mukesh; TRUONG, Cameron. **COVID-19 pandemic resilience: an analysis of firm valuation and disclosure of sustainability practices of listed firms**. *Managerial Auditing Journal* 2022. 38. 10.1108/MAJ-06-2021-3183.

PÓVOA, Alexandre. **Valuation**: Como Precificar Ações. Rio de Janeiro: Gen Atlas, 2012.

PRI. **Principles for Responsible Investment**, 2024. Página Inicial. Disponível em: <https://www.unpri.org/>. Acesso em: 26 maio 2024.

REDAÇÃO EXAME. ESG: Por que a busca pelo termo cresceu 1200% em 2 anos. **Exame**, São Paulo, 12 set. 2022 [Atualizado em 13 set. 2022]. Disponível em: <https://exame.com/esg/esg-por-que-a-busca-pelo-termo-cresceu-1200-em-2-anos/>. Acesso em: 13 maio 2024.

REDAÇÃO EXAME. Termo ESG cresceu 2.600% nas redes; descubra como aproveitar a tendência e começar carreira na área. **Exame**, São Paulo, 20 mar. 2023 [Atualizado em 6 abr. 2023]. Disponível em: <https://exame.com/carreira/termo-esg-cresceu-2600-nas-redes-descubra-como-aproveitar-a-tendencia-e-comecar-carreira-na-area/>. Acesso em: 13 maio 2024.

REDECKER, Ana Cláudia; TRINDADE, Luiza de Medeiros. Práticas de ESG em sociedades anônimas de capital aberto: um diálogo entre a função social instituída pela lei nº6.404/76 e a geração de valor. **RJLB**, ano 7, n. 2, p. 59-125, 2021. Disponível em: https://www.cidp.pt/revistas/rjlb/2021/2/2021_02_0059_0125.pdf. Acesso em: 13 maio 2024.

REIS, Tiago. Bolha da internet: entenda as causas e consequências desse evento. *In*: SUNO. São Paulo, 16 maio 2019a. Disponível em: <https://www.suno.com.br/artigos/bolha-da-internet/>. Acesso em: 13 maio 2024.

REIS, Tiago. FCFE: entenda o que é e como funciona o Fluxo de Caixa do Acionista. *In*: SUNO. São Paulo, 13 jun. 2019b [Atualizado em 5 abr. 2023]. Disponível em: <https://www.suno.com.br/artigos/fcfe/>. Acesso em: 13 maio 2024.

REIS, Tiago. Fluxo de caixa livre: aprenda como compreendê-lo numa análise. *In*: SUNO. São Paulo, 17 out. 2017. Disponível em: <https://www.suno.com.br/artigos/fluxo-caixa-livre/>. Acesso em: 13 maio 2024.

RISMAN, Asep. The Mediating Role of Firm's Performance on The Relationship between Free Cash Flow and Capital Structure. **Psychology and Education Journal**, v. 58, n. 1, p. 1209-1216, 2021. Disponível em: https://www.researchgate.net/publication/349388794_The_Mediating_Role_of_Firm%27s_Performance_on_The_Relationship_between_Free_Cash_Flow_and_Capital_Structure. Acesso em: 13 maio 2024.

RODRIGUEZ, F. S.; NOROUZZADEH, P.; ANWAR, Z.; SNIR, E.; RAHMANI, B. A machine learning approach to predict the S&P 500 absolute percent change. **Discover Artificial Intelligence**, San Francisco, v. 4, n. 8, 2024. Disponível em: <https://link.springer.com/content/pdf/10.1007/s44163-024-00104-9.pdf>. Acesso em: 26 maio 2024.

SANTOS, Gustavo. **Algoritmos de Machine Learning para previsão de ações da B3**. 2020. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, 2020. Disponível em: <https://repositorio.ufu.br/bitstream/123456789/29897/7/AlgoritmosMachineLearning.pdf>. Acesso em: 13 maio 2024.

SCHRAMADE, Willem. Integrating ESG into Valuation Models and Investment Decisions: The Value Driver Adjustment Approach. *In*: SSRN, Rochester, Feb. 22, 2016. Disponível em: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2749626. Acesso em: 13 maio 2024.

SHIFFLER, Ronald E. Maximum Z Scores and Outliers. **The American Statistician**, Boston, v. 42, n. 1, p. 79-80, 1988.

SHRIEVES, R. E.; WACHOWICZ JR., J. M. Free cash flow (FCF), economic value added (EVA™), and net present value (NPV): A reconciliation of variations of discounted-cash-flow (DCF) valuation. **The Engineering Economist**, London, v. 46, n. 1, p. 33-52, 2001. Disponível em: https://www.researchgate.net/publication/228278940_Free_cash_flow_FCF_economic_value_added_EVA_and_net_present_value_NPV_A_reconciliation_of_variations_of_discounted-cash-flow_DCF_valuation. Acesso em: 13 maio 2024.

SILVA, César Augusto Tibúrcio. Discounted Cash Flow: Theoretical and Practical Aspects of its Use. **Advances in Scientific and Applied Accounting**, São Paulo, v. 16, n. 3, p. 199-209, 2023. Disponível em: <https://asaa.emnuvens.com.br/asaa/article/view/1100>. Acesso em: 13 maio 2024.

SMARTFIT, SmartFit RI, 2023. **Central de Resultados e Informações Financeiras da SmartFit (Relação com Investidores)**. <https://investor.smartfit.com.br/informacoes-financeiras/central-de-resultados/>

THE 2021 IHRSA Global Report. *In*: HEALTH & Fitness Associaton. Boston, 2021. Disponível em: <https://www.healthandfitness.org/publications/the-2021-ihrsa-global-report/>. Acesso em: 13 maio 2024.

THE 2020 IHRSA Health Club Consumer Report. *In*: HEALTH & Fitness Associaton. Boston, 2020. Disponível em: <https://www.healthandfitness.org/publications/the-2020-ihrsa-health-club-consumer-report/>. Acesso em: 13 maio 2024.

UDANDARAO, Vikranth; GUPTA, Pratyush. **Movie Revenue Prediction using Machine Learning Models**. 2024. <https://arxiv.org/pdf/2405.11651>

VU, Tung; THIRUNAVUKKARASU, Gokul; SEYEDMAHMOUDIAN, Mehdi. **Comparative Analysis of Regression Models for Household Appliance Energy**

Consumption Prediction using Extreme Gradient Boosting. In 33rd Australasian Universities Power Engineering Conference (AUPEC) 2023.

WONG, Woei Chyuan; BATTEN, Jonathan A.; AHMAD, Abd Halim; MOHAMED-ARSHAD, Shamsul Bahrain; NORDIN, Sabariah; ADZIS, Azira Abdul. Does ESG certification add firm value?. **Finance Research Letters**, v. 39, 2021. Disponível em: https://www.sciencedirect.com/science/article/abs/pii/S1544612319312735?casa_token=4c0aTa1ot7kAAAAA:3B5J91QntZKQpjldrTPvUxe0J5N1HJ-RGWh4GLXYfUA4HevfZxQdLU80rkbDCVC8yj5XHuov5g. Acesso em: 13 maio 2024.

WU, Minghu; SUN, Meng; ZHANG, Fan, WANG, Lujun. **A fault detection method of electric vehicle battery through Hausdorff distance and modified Z-score for real-world data.** Journal of Energy Storage, 2023.

YAO, Haixiang; XIA, Shenghao; LIU, Hao. Return predictability via an long short-term memory-based cross-section factor model: Evidence from Chinese stock market. **Journal of Forecasting**, Hoboken, Feb. 29, 2024. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/for.3096>. Acesso em: 25 maio 2024.

ZHANG, Qiang; LI, Xin; YU, Long; WANG, Lingxiao; WEN, Zhiqing; SU, Pengchen; SUN, Zhenli; WANG, Suhua. Machine learning-assisted fluorescence visualization for sequential quantitative detection of aluminum and fluoride ions. **Journal of Environmental Sciences**, Amsterdam, v. 149, p. 68-78, 2024. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1001074224000342>. Acesso em: 26 maio 2024.

ZHANG, Ruling, et al. **Application of Machine Learning Techniques to Predict Entrepreneurial Firm Valuation.** Journal of Forecasting, vol. 42, no. 2, 6 Oct. 2022, pp. 402–417, <https://doi.org/10.1002/for.2912>.

ZHONG, Xiao; ENKE, David. Predicting the daily return direction of the stock market using hybrid machine learning algorithms. **Financial Innovation**, Berlin, v. 5, n. 4, p. 1-20, 2019. Disponível em: https://www.researchgate.net/publication/333804204_Predicting_the_daily_return_direction_of_the_stock_market_using_hybrid_machine_learning_algorithms. Acesso em: 26 maio 2024.