

DETERMINANTES DAS CLASSIFICAÇÕES DE CRÉDITO CORPORATIVO

Resumo

O principal objetivo desta pesquisa é identificar os determinantes das classificações de crédito corporativo (Ratings) para empresas listadas no S&P500. As classificações de crédito servem como uma fonte crucial de informações de risco para instituições financeiras, permitindo-lhes avaliar o risco e determinar os custos de empréstimos para os gestores corporativos antes de tomar decisões de empréstimos e financiamento. Para alcançar esse objetivo, um modelo de Equações de Estimativas Generalizadas (GEE) foi empregado, que considera uma estrutura de painel com uma variável dependente categórica classificação de crédito (Ratings) e dez variáveis independentes agrupadas em categorias como alavancagem, liquidez, cobertura de juros, lucratividade, mercado, sobrevivência e macroeconômicas. A amostra compreende 2398 observações abrangendo um período de nove anos, de 2013 a 2021, com 292 empresas públicas operando no mercado dos Estados Unidos. O estudo revela que a cobertura de juros, lucratividade, Q de Tobin, TSR (Retorno Total para Acionistas) e Z-score de Altman foram fatores significativos na explicação das classificações de crédito a um nível de 1%. No geral, o estudo fornece entendimentos valiosos sobre os fatores que afetam as classificações de crédito corporativo, o que pode auxiliar instituições financeiras e empresas a tomarem decisões informadas sobre empréstimos e financiamento.

Palavras-chave: classificações de crédito, risco de crédito, determinantes, risco de gestão

Introdução

Para auxiliar credores e investidores em suas tomadas de decisão, a avaliação do risco de crédito tornou-se uma ferramenta vital no mercado financeiro. Ela mede a probabilidade de inadimplência ou da incapacidade de uma empresa em pagar suas obrigações financeiras.

Segundo Ganguin e Bilardello (2005), a avaliação do risco de crédito é mais uma arte do que uma ciência e envolve a monitorização constante de vários fatores essenciais para a tomada de decisões no mercado financeiro global. Assim, identificar e explicar os fatores que afetam significativamente as decisões de crédito é crucial para mitigar o risco de inadimplência e aumentar a transparência e a credibilidade no mercado.

As agências de classificação de crédito oferecem uma opinião prospectiva sobre a capacidade e disposição de um devedor de cumprir suas obrigações financeiras, de acordo com a S&P Global Ratings. O mercado amplamente utiliza as classificações de crédito, uma vez que elas afetam o custo da dívida de uma empresa, sua estrutura de financiamento e capacidade de negociação, conforme apontado por (Gray et al., 2006).

Revisão da Literatura

O risco é definido por Crouhy et al. (2006) como a compreensão intuitiva de prever custos orçamentários e a ameaça de excessos de custos inesperados devido a fatores de custo crescentes e não controlados previamente contabilizados em um período determinado. Para gerenciar efetivamente o risco, as empresas devem desenvolver as ferramentas e a mentalidade necessárias para identificar e gerenciar dimensões de risco relacionadas às atividades e oportunidades de mercado.

Markowitz (1952) introduziu a teoria da fronteira eficiente, que maximiza os retornos e minimiza os riscos de investimento simultaneamente, diversificando a carteira de ativos. As instituições financeiras têm aplicado amplamente esse conceito de diversificação e retorno de risco de investimento para reduzir a exposição aos riscos de crédito e maximizar os retornos, expandindo a diversificação de suas carteiras de empréstimos, atendendo a uma ampla gama de clientes com diferentes perfis de risco.

Modigliani e Miller (1958) enfatizaram a importância de incorporar fatores de risco de crédito, como a probabilidade de inadimplência e o risco de perda esperado, no custo da dívida. Gray et al. (2006) também observaram que o risco de crédito afeta o custo da dívida de uma empresa, sua estrutura financeira e capacidade de continuar operando. Conseqüentemente, o perfil de risco de crédito de uma empresa pode impactar as decisões de gestão relacionadas a novos empréstimos e transações de financiamento. Ali e Javid (2015) sugeriram ainda que as classificações de crédito podem ajudar as empresas a reduzir os custos da dívida e obter acesso mais fácil aos mercados de capitais.

Pinches e Singleton (1978) argumentam que as classificações de crédito desempenham um papel crucial ao fornecer informações sobre a qualidade das emissões de títulos, uma vez que têm acesso a informações confidenciais que não estão disponíveis no mercado. Poon e Chan (2008) sugerem que as classificações de crédito têm dois propósitos: primeiro, certificar a

condição financeira atual de uma empresa e monitorar e indicar mudanças na classificação; segundo, avaliar a disposição e capacidade do emissor de cumprir suas obrigações financeiras.

De acordo com a S&P Global (2022), cada agência de classificação tem sua própria metodologia para atribuir classificações e utiliza uma escala específica para informar o mercado financeiro geral sobre suas opiniões de classificação. As classificações são expressas como notas de letras variando de 'AAA' a 'D' para disseminar a opinião da agência sobre o nível de risco de crédito.

Em resumo, as classificações de crédito são a opinião das agências de classificação sobre a probabilidade de uma empresa cumprir suas obrigações financeiras (Milidonis, 2013).

Tabela 1

Escala Global de Credit Ratings

S&P Global Ratings		Descrição
Grau de Investimento	AAA	A capacidade do obrigado de cumprir suas obrigações financeiras na obrigação é extremamente forte.
	AA	A capacidade do obrigado de cumprir suas obrigações financeiras na obrigação é muito forte.
	A	A capacidade do obrigado de cumprir suas obrigações financeiras na obrigação é forte.
	BBB	Uma obrigação classificada como 'BBB' apresenta parâmetros de proteção adequados. No entanto, condições econômicas adversas ou circunstâncias mutáveis são mais propensas a enfraquecer a capacidade do obrigado de cumprir suas obrigações financeiras na obrigação.
Grau Especulativo	BB	Uma obrigação classificada como 'BB' é menos vulnerável ao não pagamento do que outras emissões especulativas. No entanto, ela enfrenta incertezas significativas em curso ou exposição a condições comerciais, financeiras ou econômicas adversas que poderiam levar à capacidade inadequada do obrigado de cumprir suas obrigações financeiras na obrigação.
	B	Uma obrigação classificada como 'B' é mais vulnerável ao não pagamento do que obrigações classificadas como 'BB', mas o obrigado atualmente tem a capacidade de cumprir suas obrigações financeiras na obrigação. Condições comerciais, financeiras ou econômicas adversas provavelmente prejudicarão a capacidade ou disposição do obrigado de cumprir suas obrigações financeiras na obrigação.
	CCC	Uma obrigação classificada como 'CCC' é atualmente vulnerável ao não pagamento e depende de condições comerciais, financeiras e econômicas favoráveis para que o obrigado cumpra suas obrigações financeiras na obrigação.
	CC	Uma obrigação classificada como 'CC' é atualmente altamente vulnerável ao não pagamento. A classificação 'CC' é usada quando um inadimplemento ainda não ocorreu, mas é praticamente esperado, independentemente do tempo previsto para o inadimplemento.
	C	Uma obrigação classificada como 'C' é atualmente altamente vulnerável ao não pagamento, e espera-se que a obrigação tenha uma prioridade relativa inferior ou uma recuperação final inferior em comparação com obrigações com classificação mais alta.
	D	Uma obrigação classificada como 'D' está em situação de inadimplência. A classificação 'D' também será usada ao se apresentar um pedido de falência ou a realização de uma ação semelhante e quando o inadimplemento de uma obrigação for praticamente certo. A classificação de uma obrigação é rebaixada para 'D' se estiver sujeita a uma reestruturação de dívida em situação de crise.

*Ratings from 'AA' to 'CCC' may be modified by the addition of a plus (+) or minus (-) sign to show relative standing within the rating categories.

Nota. Fonte: S&P Global Ratings>S&P Global Ratings Definitions Nov 10. 2021
<https://www.capitaliq.com/CIQDotNet/CreditResearch/SPResearch.aspx?ArtObjectId=504352>

Metodologia

A metodologia deste estudo é apresentada em três partes. A primeira parte delinea as hipóteses e suas justificativas teóricas subjacentes. A segunda parte detalha o modelo, técnica estatística, variáveis e proxies empregadas no estudo. A parte final descreve os procedimentos de coleta de dados e a amostra utilizada no estudo.

Hipóteses

Para avaliar a influência das variáveis independentes nas classificações de crédito, foram formuladas dez hipóteses da seguinte forma:

Alavancagem

H1: Empresas com maior Razão Dívida Total sobre Ativos Totais (TDTA) têm piores classificações de crédito.

De acordo com Hayes (2023), a razão Dívida Total sobre Ativos Totais é usada para avaliar a capacidade financeira de uma empresa de cobrir suas obrigações de dívida, comparando o montante da dívida ao valor de seus ativos. Uma proporção maior indica um maior risco de investimento para a empresa.

Rentabilidade

H2: Empresas com maior Retorno sobre Ativos (ROA) têm melhores classificações de crédito.

A rentabilidade é um fator crucial na capacidade de uma empresa de gerar dinheiro e cumprir suas obrigações financeiras. Nishanthini e Nimalathan (2014) enfatizam que a rentabilidade é a principal medida do sucesso de uma empresa e é importante para várias partes interessadas.

Cobertura de Juros

H3: Empresas com maior cobertura de juros EBITDA têm melhores classificações de crédito.

Tomasett (2023) define a relação de cobertura de juros como uma proporção usada pelas empresas para determinar sua capacidade de pagar despesas de juros relacionadas ao nível de dívida pendente, enquanto I.

Liquidez

H4: Empresas com maior Razão Rápida têm melhores classificações de crédito.

De acordo com Yameen et al. (2019), as empresas devem ter liquidez adequada para cumprir suas obrigações de dívida de curto prazo.

Mercado

H5: Empresas com Retorno Total para Acionistas (TSR) mais alto ou com Tobin's Q mais alto têm melhores classificações de crédito.

Ganti (2021) explica que o Retorno Total para Acionistas (TSR) é uma medida que reflete como o mercado percebe o desempenho de uma empresa. Tobin's Q é uma relação de valor de mercado que compara o valor de mercado de uma empresa ao custo de reposição de seus ativos, de acordo com a definição fornecida por (Carton & Hofer, 2006).

Sobrevivência

H6: Empresas com Z-score de Altman mais alto têm melhores classificações de crédito.

Em 1968, Altman (1968) desenvolveu um modelo de análise discriminante que usava um conjunto de índices financeiros para prever a probabilidade de falência de uma empresa. O modelo de Altman, que inclui cinco índices financeiros, como capital de giro/ativos totais, lucros retidos/ativos totais, lucros antes de juros e impostos/ativos totais, valor de mercado do patrimônio líquido/valor contábil do passivo total e vendas/ativos totais, é uma das ferramentas que as agências de classificação usam para avaliar o risco de crédito. Um Z-score de Altman mais alto é esperado ter um impacto positivo nas classificações de crédito devido ao seu alto grau de precisão.

Macroeconômico

H7: As classificações de crédito melhoram com o crescimento do PIB.

O crescimento econômico refere-se ao aumento do valor de bens e serviços, resultando em maiores lucros para empresas e aumento do volume de capital investido em seus negócios (Amadeo, 2022).

H8: As classificações de crédito pioram com o crescimento da inflação.

De acordo com Cantor e Packer (1996), os governos podem enfrentar desafios estruturais na gestão de suas finanças durante períodos de alta inflação. Quando não conseguem cumprir suas obrigações financeiras por meio de impostos e dívida, podem

recorrer ao dinheiro inflacionário, o que pode levar à insatisfação do mercado e à instabilidade política.

H9: As classificações de crédito melhoram com taxas de juros mais baixas.

Ganguin e Bilardello (2005) sugerem que taxas de juros altas podem pressionar os sistemas financeiros locais, levando a maiores custos de empréstimos e maior volatilidade.

Statistical Tecnique

Agresti (2013) destaca a eficácia dos modelos de regressão ordinal na análise de dados com categorias ordenadas, como as classificações de crédito.

De maneira semelhante, Gujarati (2006) sugere que variáveis categóricas com ordem intrínseca, como as classificações de crédito, podem ser tratadas como variáveis ordinais em análise estatística. Isso ocorre porque tratá-las como ordinais preserva a informação de ordenação das categorias. Além disso, se houver uma relação linear entre a variável ordinal e a variável dependente, a variável ordinal pode ser incluída em uma análise de regressão como uma variável contínua. Este mesmo conceito pode ser aplicado às classificações de crédito, que são apresentadas em categorias que variam de D a AAA e podem ser vistas como um resultado de capacidade de solvência contínua.

O método de Equações de Estimação Generalizada (GEE) foi introduzido em 1986 por Liang e Zeger em um artigo seminal publicado na revista *Biometrika*. Desde então, tornou-se um método amplamente utilizado para analisar dados que incluem medidas repetidas ou observações agrupadas. O GEE considera estruturas de correlação de trabalho, que permitem a estimativa da correlação dentro de grupos de observações e entre medidas repetidas ao longo do tempo. Ele também utiliza a função de quasi-verossimilhança para estimar efeitos médios na população, levando em consideração a correlação intra-grupo.

No contexto das classificações de crédito, o GEE pode ser utilizado para analisar a relação entre os preditores e as classificações de crédito, levando em consideração a correlação dentro das classificações de um mutuário ao longo do tempo. Este método é particularmente útil ao analisar dados com observações correlacionadas, como medidas repetidas ou dados agrupados. Ao usar o GEE, é possível estimar efeitos médios na população e considerar a correlação intra-grupo, fornecendo uma análise mais precisa dos dados de classificação de crédito.

Uma abordagem eficaz para analisar dados de classificações de crédito ao longo do tempo é usar regressão em painel em combinação com Equações de Estimação Generalizada (GEE). A regressão em painel é uma técnica estatística que permite examinar as relações entre variáveis dentro de um painel de entidades ao longo do tempo. Ao aplicar o GEE dentro da regressão em painel, a correlação dentro dos painéis e entre observações ao longo do tempo pode ser considerada, produzindo estimativas de coeficientes mais precisas.

Tabela 2

<i>Classe de Variáveis Dependentes</i>		
Grade	S&P	CLASS
Grau de Investimento	AAA	22
	AA+	21
	AA	20
	AA-	19
	A+	18
	A	17
	A-	16
	BBB+	15
	BBB	14
	BBB-	13
Grau Especulativo	BB+	12
	BB	11
	BB-	10
	B+	9
	B	8
	B-	7
	CCC+	6
	CCC	5
	CCC-	4
	CC	3
C	2	
D/SD	1	

Fonte: S&P Global

As classificações de crédito são expressas usando uma escala ordinal que varia de D/SD a AAA, refletindo o risco de crédito relativo do mutuário.

A equação fornecida representa um modelo de painel composto por dez variáveis independentes distintas:

$$Y_{it} = \beta_0 + \beta_1 QR_{it} + \beta_2 TDTA_{it} + \beta_3 EBITDAICOV_{it} + \beta_4 ROA_{it} + \beta_5 QTobinit + \beta_6 TSR_{it} + \beta_7 AZS_{it} + \beta_8 GDP_{it} + \beta_9 CPI_{it} + \beta_{10} FDRlit + \epsilon_{it}$$

Tabela 4

	Ratings	QR	TDTA	EBITDAICOV	ROA	QTobin	TSR	AZS	GDP	CPI	FDRI
Ratings	1										
QR	0.091**	1									
TDTA	-0.336**	-0.085**	1								
EBITDAICOV	0.364**	0.147**	-0.313**	1							
ROA	0.243**	0.079**	0.203**	0.280**	1						
QTobin	-0.333**	-0.083**	0.998**	-0.309**	0.206**	1					
TSR	-0.001	0.033	-0.027	0.064**	0.122**	-0.023	1				
AZS	0.349**	0.182**	-0.174**	0.358**	0.493**	-0.166**	0.063**	1			
GDP	0.007	-0.018	-0.032	0.074**	0.096**	-0.031	0.061**	0.058**	1		
CPI	-0.020	-0.030	0.062**	0.021	0.033	0.063**	0.153**	-0.009	0.634**	1	
FDRI	-0.007	-0.059**	0.045*	-0.037***	0.017	0.045*	-0.101**	0.002	0.133**	0.090**	1

Nota. ** Indica significância ao nível de confiança de 1%. * Indica significância ao nível de confiança de 5%. *** Indica significância ao nível de confiança de 10%.

A multicolinearidade surge quando há uma alta correlação entre os preditores, resultando em compartilhamento de poder preditivo e comprometendo a significância estatística individual das variáveis independentes. Para identificar a multicolinearidade, é avaliada a intercorrelação entre as variáveis independentes. Um valor de correlação de 0,65 ou mais indica a presença de multicolinearidade (Bone, 2011; de Souza Murcia et al., 2014; Grassa, 2016). Na Tabela 4, verificou-se que a correlação entre QTobin e TDTA foi de 99,8%, indicando multicolinearidade. Para lidar com esse problema, excluímos a variável independente TDTA (Total Debt to Total Assets), pois ela já está incorporada no cálculo de QTobin. Não houve outras variáveis independentes com correlações acima de 65%, indicando que a multicolinearidade não é mais um problema. Além disso, modificamos a equação para refletir a exclusão da variável independente TDTA da seguinte forma:

$$Y_{it} = \beta_0 + \beta_1 QR_{it} + \beta_2 EBITDAICOV_{it} + \beta_3 ROA_{it} + \beta_4 QTobin_{it} + \beta_5 TSR_{it} + \beta_6 AZS_{it} + \beta_7 GDP_{it} + \beta_8 CPI_{it} + \beta_9 FDRI_{it} + \epsilon_{it}$$

Dados e Amostra

A amostra é composta por 2398 observações que correspondem a 292 empresas retiradas do índice S&P 500 ao longo de um período de 9 anos, abrangendo de 2013 a 2021.

Estatística Descritiva

No estudo, a classificação de crédito (Ratings) é considerada como a variável dependente, seguida por 9 variáveis independentes agrupadas em 6 subcategorias. As categorias independentes são as seguintes:

- (1) Liquidez: (QR) liquidez,
- (2) Cobertura de juros: (EBITDAICOV) cobertura de juros EBITDA,
- (3) Lucratividade: ROA Retorno sobre Ativos,
- (4) Mercado: (TSR) Retorno Total dos Acionistas e (Tobin's Q),
- (5) Sobrevivência: (AZS) Escore Z de Altman, e
- (6) Macroeconômico: (GDP) Produto Interno Bruto, (CPI) Inflação, (FDRI) Taxa de Juros do Federal Reserve.

Tabela 6

Estatística Descritiva

Variables	Obs	Mean	Std. dev.	Min	Max
QR	2,398	1.13	0.89	0.01	11.67
EBITDAICOV	2,398	15.84	14.68	-22.05	100.11
ROA	2,398	10.75	7.38	-12.91	59.44
QTobin	2,398	0.33	0.18	0.00	2.45
TSR	2,398	15.49	28.05	-89.22	109.90
AZS	2,398	3.41	1.92	0.00	10.83
GDP	2,398	2.14	2.18	-2.77	5.95
CPI	2,398	1.91	1.20	0.12	4.70
FDRI	2,398	0.71	0.77	0.08	2.27

Nota. Cálculo da média, desvio padrão, mínimo e máximo de todas as variáveis independentes.

Análise dos Resultados

Para levar em consideração a heteroscedasticidade em nossa análise, utilizamos a opção robusta no comando Xtgee do Stata 17®. Essa opção nos permite estimar os parâmetros do modelo usando erros padrão robustos, que fornecem inferências mais confiáveis na presença de heteroscedasticidade. Além disso, ela possibilita o ajuste dos erros padrão para heteroscedasticidade dentro de clusters ou painéis, melhorando a precisão de nossos resultados.

Além de abordar a heteroscedasticidade, também consideramos a autocorrelação em nossa análise. Para levar em consideração a autocorrelação dentro da estrutura de painel ou

cluster de nossos dados, utilizamos uma estrutura de correlação "autoregressiva". Essa estrutura de correlação pressupõe um padrão específico de correlação entre observações dentro de cada grupo, onde a correlação entre duas observações diminui à medida que o intervalo de tempo entre elas aumenta.

Como resultado do uso da estrutura de correlação autoregressiva, observamos uma redução no número de observações de 2398 para 2385.

Ao considerar tanto a heteroscedasticidade por meio de erros padrão robustos quanto a autocorrelação por meio da estrutura de correlação autoregressiva, buscamos melhorar a confiabilidade e precisão de nossa análise, ao mesmo tempo em que contabilizamos adequadamente essas questões estatísticas.

Tabela 7

Análise da Significância do Modelo de Painel

GEE population-averaged model	Number of obs	=	2,385
Group variable : id	Number of groups	=	283
Family: Poisson	Obs per group		
Link: Log	min	=	2
Correlation: AR(1)	avg	=	8.4
	max	=	9
	Wald chi2(10)	=	78.19
Scale parameter = 1	Prob>chi2	=	0.0000

Os resultados do modelo de painel inicial são apresentados na Tabela 8, onde a significância e o coeficiente de cada variável são fornecidos.

Tabela 8

Resultados do Modelo de Painel Inicial

Ratings	Robust			
	Coefficient	std. err.	z	P> z
QR	-0.0001422	0.0021134	-0.07	0.946
EBITDAICOV	0.0001441	0.0000646	2.23	0.026
ROA	0.0014462	0.0003036	4.76	0.000
QTobin	-0.1223078	0.0222682	-5.49	0.000
TSR	-0.0000446	0.0000241	-1.85	0.064
AZS	0.0017428	0.0008335	2.09	0.037
GDP	0.0002941	0.0003763	0.78	0.435
CPI	-0.0008198	0.0009196	-0.89	0.373
FDRI	0.000764	0.0012635	0.60	0.545
cons	2.710188	0.0135052	200.68	0.000

O modelo de painel inicial analisou várias variáveis para avaliar seu impacto nas classificações de crédito. Os resultados revelaram descobertas significativas em diferentes níveis de significância. Especificamente, as variáveis de lucratividade (ROA) e mercado (QTobin) demonstraram significância estatística no nível de 1%, enquanto as variáveis de cobertura de juros (EBITDAICOV) e sobrevivência (AZS) foram significativas no nível de 5%. A variável que mede o desempenho do mercado (TSR) apresentou significância no nível de 10%. No entanto, as variáveis macroeconômicas (PIB, CPI e TMR) não exibiram significância estatística, indicando ausência de relação significativa com as classificações de crédito.

Para abordar a multicolinearidade, a variável de alavancagem (TDTA) foi excluída da análise. Como consequência, a hipótese H1, que envolvia a alavancagem, também foi excluída. No entanto, a hipótese H2 foi aceita, uma vez que a lucratividade (ROA) apresentou um impacto estatisticamente significativo nas classificações de crédito no nível de 1%. Essa descoberta está em linha com pesquisas anteriores de Gray et al. (2006), que indicam que índices de lucratividade mais altos estão associados a melhores classificações de crédito.

A hipótese H3 foi aceita, uma vez que a variável de cobertura de juros (EBITDAICOV) mostrou significância estatística no nível de 5%. Isso sugere que a capacidade de uma empresa de cobrir despesas de juros influencia positivamente sua

classificação de crédito. Isso está em consonância com a visão de Noghondari et al. (2022), enfatizando a importância da taxa de cobertura de juros (TCJ) na determinação da solvência.

A hipótese H4 foi rejeitada, pois a variável de liquidez (QR) não apresentou significância estatística. Portanto, pode-se concluir que a liquidez não impacta significativamente as classificações de crédito nesta análise.

Da mesma forma, a hipótese H5 foi rejeitada, apesar de as variáveis Total Shareholder Return (TSR) e desempenho de mercado (QTobin) terem mostrado significância estatística nos níveis de 1% e 10%, respectivamente. No entanto, ambas as variáveis apresentaram coeficientes negativos, indicando que valores mais altos de TSR e QTobin correspondiam a classificações de crédito mais baixas. Essa descoberta está alinhada com o argumento apresentado por Desai et al. (2022) de que um TSR negativo reflete uma queda no valor do investimento, levantando preocupações sobre possível dificuldade financeira. Lindenberg e Ross (1981) também explicam que uma relação QTobin abaixo de 1 sugere possível supervalorização e aumento do risco de instabilidade financeira, fatores considerados pelas agências de classificação de crédito ao avaliar a solvência.

A hipótese H6 foi aceita, uma vez que a variável de sobrevivência (AZS) apresentou significância estatística no nível de 5%. Isso implica que um escore Z de Altman mais alto influencia positivamente as classificações de crédito. O estudo conduzido por Madonna e Cestari (2015) apoia essa aceitação, destacando a eficácia do modelo de escore Z de Altman na detecção de sinais de falha e na distinção entre empresas bem-sucedidas e em declínio.

As hipóteses H7, H8 e H9 foram rejeitadas, pois as variáveis macroeconômicas (PIB, CPI e TMR) não demonstraram significância estatística. Consequentemente, a análise não encontrou uma relação significativa entre esses fatores macroeconômicos e as classificações de crédito.

Prosseguindo, removemos as variáveis não estatisticamente significativas do modelo. Isso incluiu a liquidez (QR) com um nível de significância de 0,946, bem como as variáveis macroeconômicas como PIB, CPI e FDRI, que tinham níveis de significância de 0,435, 0,373 e 0,545, respectivamente. Posteriormente, o modelo foi retestado.

Os resultados finais do modelo de painel inicial, incluindo a significância e o coeficiente de cada variável.

Tabela 9
Significância do Modelo de Painel Final

GEE population-averaged model	Number of obs	=	2,385
Group variable : id	Number of groups	=	283
Family: Poisson	Obs per group		
Link: Log	min	=	2
Correlation: AR(1)	avg	=	8.4
	max	=	9
	Wald chi2(10)	=	76.22
Scale parameter = 1	Prob>chi2	=	0.0000

O modelo de painel final apresentou significância nos níveis de 1% e 5%. A Tabela 10 exibe os resultados do modelo de painel final, indicando a significância e o coeficiente de cada variável.

Tabela 10
Resultado do Modelo de Painel Final

Ratings	Coefficient	Robust		
		std. err.	z	P> z
EBITDAICOV	0.0001482	0.0000655	2.26	0.024
ROA	0.0014633	0.000295	4.96	0.000
QTobin	-0.1227424	0.0223056	-5.50	0.000
TSR	-0.0000471	0.0000232	-2.03	0.043
AZS	0.0017672	0.0008354	2.12	0.034
cons	2.708648	0.0129915	208.49	0.000

O modelo de painel final revelou diferentes níveis de significância. Especificamente, as variáveis de lucratividade (ROA) e mercado (QTobin) apresentaram significância estatística no nível de 1%, enquanto as variáveis de cobertura de juros (EBITDAICOV), mercado (TSR) e sobrevivência (AZS) foram significativas no nível de 5%.

Conclusões

Em um estudo que analisou as classificações de crédito de empresas listadas no índice S&P 500, foram selecionadas 283 empresas classificadas de um total de 2385 observações. O estudo focou em 6 subcategorias, a saber: Liquidez, Cobertura de Juros, Lucratividade, Mercado, Sobrevivência e Macroeconômico. Essas subcategorias consistiram em 9 variáveis independentes: Quick Ratio (QR), Cobertura de Juros EBITDA (EBITDAICOV), Lucratividade (ROA), Retorno Total ao Acionista (TSR), Tobin's Q (QTobin), Altman's Z-score (AZS), Produto Interno Bruto (PIB), Inflação (CPI) e Taxa de Juros do Federal Reserve (FDRI).

A análise estatística utilizou a abordagem Generalized Estimating Equations (GEE) com uma estrutura de dados em painel abrangendo um período de 9 anos, de 2013 a 2021. O objetivo era examinar a relação entre as variáveis independentes e as classificações de crédito.

Das 9 variáveis independentes examinadas, apenas 5 foram consideradas estatisticamente significativas para explicar a variável dependente, que são as classificações de crédito. EBITDAICOV, ROA e AZS exibiram um coeficiente positivo com significância estatística, indicando que um aumento de 1% nessas variáveis tem um impacto positivo nas classificações de crédito. Por outro lado, TSR e QTobin, embora estatisticamente significativos, exibiram um coeficiente negativo, sugerindo que um aumento nessas variáveis leva a uma diminuição na pontuação de classificação de crédito.

Para pesquisas futuras, recomenda-se explorar variáveis adicionais, como participação de mercado, Risco Setorial, Risco País, política financeira e estrutura de custos, para entender melhor sua influência nas classificações de crédito.

Referências

Agresti, A. (2013). *Categorical Data Analysis* (3rd ed).

Agu, S. C., Onu, F. U., Ezemagu, U. K., & Oden, D. (2022). Predicting gross domestic product to macroeconomic indicators. *Intelligent Systems with Applications*, 14. <https://doi.org/10.1016/j.iswa.2022.200082>

Ali Naqvi, P. A., Sulaiman Bagaba, A. S., & Ramzani, S. R. (2018). The consumer price index as a measure of consumer price inflation. *International Journal of Innovative Technology and Exploring Engineering*, 8(2S).

Ali, S., & Javid, A. Y. (2015). Relationship between credit rating, capital structure and earning management behaviour: Evidence from Pakistani listed firms. *PIDE Working Papers*, 1(121).

Altman, E. I. (1968). FINANCIAL RATIOS, DISCRIMINANT ANALYSIS AND THE PREDICTION OF CORPORATE BANKRUPTCY. *The Journal of Finance*, 23(4).
<https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>

Amadeo, K. (2022, July 31). What is Economic Growth?, the balance. *The Balance*.
<https://www.thebalancemoney.com/what-is-economic-growth-3306014>

Azhar, I., & Meutia, T. (2022). The Effect of Return On Asset, Return on Equity, Net Profit Margin and Earning Per Share on Stock Price. In *Proceeding International Seminar of Islamic Studies*, (Vol. 3, N(1)).

Basha, A., Zhang, W., & Hart, C. (2021). The impacts of interest rate changes on US Midwest farmland values. *Agricultural Finance Review*, 81(5). <https://doi.org/10.1108/AFR-11-2020-0163>

Bone, R. B. (2011). DETERMINANTS OF CORPORATE RATINGS IN THE OIL INDUSTRY: THE REPSOL-YPF CASE. *Revista Eletrônica de Administração (READ)*, 24(3).

Cantor, R., & Packer, F. (1996). Determinants and Impact of Sovereign Credit Ratings. *The Journal of Fixed Income*, 6(3). <https://doi.org/10.3905/jfi.1996.408185>

Carton, R. B., & Hofer, C. W. (2006). Measuring organizational performance: Metrics for entrepreneurship and strategic management research. In *Measuring Organizational Performance: Metrics for Entrepreneurship and Strategic Management Research*.

Crouhy, M., Galai, D., & Mark, R. (2006). THE ESSENTIALS OF RISK MANAGEMENT. McGraw-Hill. <https://doi.org/DOI: 10.1036/0071429662>

de Souza Murcia, F. C., Murcia, F. D. R., Rover, S., & Borba, J. A. (2014). The determinants of credit rating: Brazilian evidence. *BAR - Brazilian Administration Review*, 11(2).
<https://doi.org/10.1590/S1807-7692201400020005>

Demirtas, K. O., & Rodgers Cornaggia, K. (2013). Initial credit ratings and earnings management. *Review of Financial Economics*, 22(4).
<https://doi.org/10.1016/j.rfe.2013.05.003>

Desai, M. A., Egan, M., & Mayfield, S. (2022). A Better Way to Assess Managerial Performance. *Harvard Business Review*.

Fauzi, M., Hade Chandra Batubara, R., & Anisah, N. (2022). CURRENT RATIO, QUICK RATIO, DEBT TO ASET RASIO AND DEBT TO EQUITY RATIO TO RETUR ON EQUITY IN FOOD AND BEVERAGE COMPANIES LISTED ON THE INDONESIA STOCK EXCHANGE. *Proceeding International Seminar on Islamic Studies*, 3.

- Foss, G. W. (1995). Quantifying Risk in the Corporate Bond Markets. *Financial Analysts Journal*, 51(2). <https://doi.org/10.2469/faj.v51.n2.1878>
- Franco Modigliani; Merton H. Miller. (1958). The cost of capital, corporation finance and theory of investment. *Journal of Craniomandibular Disorders : Facial & Oral Pain*, 5(1).
- Frost, C. A. (2007). Credit rating agencies in capital markets: A review of research evidence on selected criticisms of the agencies. *Journal of Accounting, Auditing and Finance*, 22(3). <https://doi.org/10.1177/0148558X0702200306>
- Fu, L., Parkash, M., & Singhal, R. (2017). Tobin's q Ratio and Firm Performance. *International Research Journal of Applied Finance*. <https://doi.org/10.0704/article-2>
- Gaertner, F. B., Kausar, A., & Steele, L. B. (2020). Negative accounting earnings and gross domestic product. *Review of Accounting Studies*, 25(4). <https://doi.org/10.1007/s11142-020-09536-x>
- Ganguin, B., & Bilardello, J. (2005). *Fundamentals of Corporate Credit Analysis*. McGraw-Hill.
- Ganti, A. (2021, May 29). Total Shareholder Return (TSR): Definition and Formula. Investopedia. <https://www.investopedia.com/terms/t/tsr.asp>
- Grassa, R. (2016). Corporate governance and credit rating in Islamic banks: Does Shariah governance matters? *Journal of Management and Governance*, 20(4). <https://doi.org/10.1007/s10997-015-9322-4>
- Gray, S., Mirkovic, A., & Rangunathan, V. (2006). The Determinants of Credit Ratings: Australian Evidence. *Australian Journal of Management*, 31(2). <https://doi.org/10.1177/031289620603100208>
- Gujarati, D. (2006). *Econometria básica* .
- Hayes, A. (2023, January 21). Total Debt to Total Assets Ratio. Investopedia. <https://www.investopedia.com/terms/t/totaldebttotalassets.asp>
- Hoang, T. T., Thi, V. A. N., & Minh, H. D. (2020). The impact of exchange rate on inflation and economic growth in Vietnam. *Management Science Letters*, 10(5). <https://doi.org/10.5267/j.msl.2019.11.004>
- Hung, K., Cheng, H. W., Chen, S. S., & Huang, Y. C. (2013). Factors that affect credit rating: An application of ordered probit models. *Romanian Journal of Economic Forecasting*, 16(4).
- Kablan, A. (2020). Altman s Z"-Score to Predict Accounting Based Financial Distress of Municipalities: Bankruptcy Risk Map for Metropolitan Municipalities in Turkey. *Journal of Business Research - Turk*, 12(1). <https://doi.org/10.20491/isarder.2020.858>
- Kurniawan, A. (2021). Analysis of the effect of return on asset, debt to equity ratio and total asset turnover on share return. *Journal of Industrial Engineering & Management Research*, 2(1).

- Lindenberg, E. B., & Ross, S. A. (1981). Tobin's Q Ratio and Industrial Organization. *The Journal of Business*, 54(1). <https://doi.org/10.1086/296120>
- Madonna, S., & Cestari, G. (2015). the Accuracy of Bankruptcy Prediction Models: a Comparative Analysis of Multivariate Discriminant Models in the Italian Context. *European Scientific Journal*, 11(34).
- Makhija, H., & Trivedi, P. (2020). An empirical investigation of the relationship between TSR, value-based and accounting-based performance measures. *International Journal of Productivity and Performance Management*, 70(5). <https://doi.org/10.1108/IJPPM-05-2019-0231>
- Milidonis, A. (2013). Compensation incentives of credit rating agencies and predictability of changes in bond ratings and financial strength ratings. *Journal of Banking and Finance*, 37(9). <https://doi.org/10.1016/j.jbankfin.2013.04.032>
- Nelissen, L. M. (2018). Predicting bankruptcy among U.S. companies : a study based on Altman's Z-score and Almany's J-UK model. 11th IBA Bachelor Thesis Conference,.
- Nishanthini, A., & Nimalathasan, B. (2014). Determinants of profitability: a case study of listed manufacturing companies in Sri Lanka. *Journal of Management*, 8(1). <https://doi.org/10.4038/jm.v8i1.7556>
- Noghondari, A. T., Zeinali, H., & Beytollahi, A. (2022). The Effect of Company's Interest Coverage Ratio on the Structural and Reduced-Form Models in Predicting Credit Derivatives Price. *Iranian Journal of Management Studies*, 15(1). <https://doi.org/10.22059/IJMS.2021.313368.674295>
- Pinches, G. E., & Singleton, J. C. (1978). THE ADJUSTMENT OF STOCK PRICES TO BOND RATING CHANGES. *The Journal of Finance*, 33(1). <https://doi.org/10.1111/j.1540-6261.1978.tb03387.x>
- Poon, W. P. H., & Chan, K. C. (2008). An empirical examination of the informational content of credit ratings in China. *Journal of Business Research*, 61(7). <https://doi.org/10.1016/j.jbusres.2007.08.001>
- Selection, P., & Markowitz, H. (1952). American Finance Association. In Source: *The Journal of Finance* (Vol. 7, Issue 1).
- S&P Global. (n.d.). Guide to Credit Rating Essentials. Retrieved May 28, 2023, from https://www.spglobal.com/ratings/_division-assets/pdfs/guide_to_credit_rating_essentials_digital.pdf
- Tang, T. T. (2009). Information asymmetry and firms' credit market access: Evidence from Moody's credit rating format refinement. *Journal of Financial Economics*, 93(2). <https://doi.org/10.1016/j.jfineco.2008.07.007>
- Tomasett, B. (2023, May 30). Interest Coverage Ratio. carbon collective. Carbon Collective. <https://www.carboncollective.co/sustainable-investing/interest-coverage-ratio>

- Wang, I. (2023, February 14). What is the EBITDA Coverage Ratio. FinancialEdge.
- Wijaya, D. P., & Sedana, I. B. P. (2020). Effects of Quick Ratio, Return on Assets and Exchange Rates on Stock Returns. *American Journal of Humanities and Social Sciences Research*, 4(1).
- Yahya, A., & Hidayat, S. (2020). The Influence of Current Ratio, Total Debt to Total Assets, Total Assets Turn Over, and Return on Assets on Earnings Persistence in Automotive Companies. *Journal of Accounting Auditing and Business*, 3(1).
<https://doi.org/10.24198/jaab.v3i1.24959>
- Yameen, M., Farhan, N. H. S., & Tabash, M. I. (2019). The impact of liquidity on firms' performance: Empirical investigation from Indian pharmaceutical companies. *Academic Journal of Interdisciplinary Studies*, 8(3). <https://doi.org/10.36941/ajis-2019-0019>
- Yang, B., & Gan, L. (2021). Contingent capital, Tobin's q and corporate capital structure. *North American Journal of Economics and Finance*, 55.
<https://doi.org/10.1016/j.najef.2020.101305>