

Universidade Federal de Alfenas - UNIFAL
Instituto de Ciências Sociais Aplicadas - ICSA

MATHEUS SARAIVA ALCINO

**Retorno anormal acumulado no setor bancário: uma
análise empírica no período de 1986 a 2017**

Varginha

2017

MATHEUS SARAIVA ALCINO

Retorno anormal acumulado no setor bancário: uma
análise empírica no período de 1986 a 2017

Trabalho apresentado como fase final do Programa Integrado de Ensino, Pesquisa e Extensão para a obtenção do título de Bacharel Interdisciplinar em Ciência e Economia pela Universidade Federal de Alfenas.

Orientador: Professor Dr. Gabriel Rodrigo Gomes Pessanha

MATHEUS SARAIVA ALCINO

Retorno anormal acumulado no setor bancário: uma
análise empírica no período de 1986 a 2017

Varginha, 20 de dezembro de 2017:

Aprovado: _____

Professor Dr. Gabriel Rodrigo Gomes Pessanha

Aprovado: _____

Professor Dr. Lincoln Thadeu Gouvêa de Frias

Aprovado: _____

Professora Dra. Patrícia de Siqueira Ramos

Varginha
2017

Resumo

As decisões que ocorrem nos mercados financeiros impactam diretamente a vida cotidiana na sociedade. Isto porque as decisões tomadas nos mercados financeiros pelos grandes investidores desempenham um papel importante na qualidade de vida da população. Tais decisões podem ocasionar oscilações de preço, emprego/desemprego, incentivo a políticas públicas etc. Sendo assim, a partir da ótica de investidores, o presente trabalho busca analisar quais são os fatores que afetam o retorno anormal acumulado e de que forma o fazem. Para isto, utilizaram-se dados referentes aos cinco maiores bancos brasileiros, de acordo com o seu total do ativo financeiro, ranqueados pelo Banco Central do Brasil. Os dados foram retirados do programa Economática e estão separados trimestralmente, sob o horizonte temporal 1986 – 2017. A análise consiste em aplicar duas metodologias estatísticas de forma complementar: regressão linear múltipla (RLM) e redes neurais artificiais (RNA). Os resultados sugerem que parte do comportamento do retorno anormal acumulado das instituições financeiras seja explicado pelas variações dos indicadores contábeis e macroeconômicos inclusos no modelo. Além disso, o fato de utilizar a RLM e RNA de forma complementar pode representar uma estratégia de investimento eficaz. Enquanto a primeira foi capaz de desvendar as relações entre as variáveis inclusas no modelo, a segunda atingiu alto poder de previsão. Ambas respeitando seus respectivos pressupostos estatísticos.

Palavras-chave: Retorno anormal acumulado, mercado acionário, previsão, setor bancário.

Lista de Figuras

1	Erro no modelo RLM	20
2	Modelo conceitual-teórico e hipóteses	20
3	Neurônio biológico humano	22
4	Esquema de rede neural	23
5	Análise gráfica da dispersão retorno anormal acumulado	24
6	Análise gráfica do retorno anormal acumulado	26
7	Teste de normalidade dos resíduos.	27
8	Resultados da rede neural.	30
9	Valores estimados e observados.	31

Lista de Tabelas

1	Corte temporal de cada banco	14
2	Variáveis do modelo e sinais esperados.	17
3	Resumo estatístico.	24
4	Matriz de correlação das variáveis.	25
5	Resultados das regressões.	28
6	Sinais Esperados e Observados.	29
7	Erro quadrado médio nos diferentes métodos.	30

Lista de Quadros

1	Resumo dos estudos empíricos apresentados	12
2	Resumo das variáveis utilizadas	13
3	Vantagens e Desvantagens de se utilizar RNA	18

Sumário

1	Introdução	7
2	Referencial teórico	8
2.1	Investimentos: risco e retorno	8
2.2	Ofertas públicas iniciais	9
2.3	Estudos empíricos	10
3	Metodologia	13
3.1	Dados	13
3.2	Modelo conceitual-teórico e hipóteses	15
3.3	Métodos aplicados	17
3.3.1	Modelo de regressão linear múltipla	19
3.3.2	Redes neurais artificiais	22
4	Resultados	23
4.1	Resultados da regressão linear múltipla	26
4.2	Resultados da rede neural	29
5	Considerações finais	31
	Referências	32

1 Introdução

A política, a economia, a sociedade, e portanto a vida cotidiana das pessoas não são elementos independentes entre si. Pelo contrário, são elos de uma corrente que permite que as nações se comuniquem no mundo globalizado, o qual confia nas leis de mercado para oportunizar a sua evolução.

Atualmente as decisões tomadas no mercado financeiro afetam direta e/ou indiretamente a sociedade porque na maioria das vezes grandes investidores são responsáveis por organizações que mantêm famílias empregadas, aumentam a produção nacional e colaboram para a ascensão econômica de um país. Sabendo-se que estes investidores atuam no mercado de capitais e que portanto seus laboratórios são as bolsas de valores, é conveniente pensar que os estudos e análises desenvolvidas para este setor são importantes tanto pelo ponto de vista da sociedade quanto (principalmente) dos próprios investidores.

Através de diversas áreas da ciência, os estudos nos mercados financeiros como sobre a captação e aplicação de recursos em bolsas de valores, índices, decisões políticas que são dependentes do capital privado etc; têm sido realizados possibilitando que investidores construam estratégias e consigam retornos financeiros cada vez mais próximos do esperado. Por consequência, esses estudos trazem às sociedades alguma forma de progresso através da otimização de estratégias mercadológicas, se se considerar que os mercados são eficientes e que as teorias liberais e neoliberais se concretizam na atual dinâmica do capitalismo. Afinal, de acordo com Smith (1996) em sua obra - *Inquérito sobre a natureza e as causas da riqueza das nações*- o mercado é a única forma de superar o egoísmo oriundo da natureza humana.

Por outro lado, pensar que o bem estar de uma população pode estar sujeito à tomada de decisão de poucas pessoas (os grandes investidores), faz com que os estudos sobre as leis de mercado, tornem-se cada vez mais necessários para o processo da compreensão da dinâmica político-econômica que ditam o ritmo do progresso social.

Os estudos que possuem tal perspectiva caracterizam-se como ciência social e portanto, o fato de que as dinâmicas do mercado financeiro causam impacto direto e/ou indireto na sociedade exige que tais estudos sejam interdisciplinares. Apesar da importância de trabalhos desta natureza, se comparada às demais áreas das ciências sociais, a literatura neste campo ainda é limitada em território nacional. Logo, o presente estudo busca, além de seus objetivos específicos, contribuir para com a literatura em finanças.

O presente estudo parte da ótica de investidores para analisar quais são os principais fatores que afetam a sua rentabilidade, baseando-se em modelos estatísticos e nas teorias das finanças. Mais especificamente, a rentabilidade aqui será estudada a partir de um tipo de retorno gerado pelas chamadas operações de oferta pública inicial (*Initial Public Offering* - IPO) de instituições financeiras.

Como objetivos específicos, o presente trabalho empenha-se em utilizar métodos distintos para realizar a análise do comportamento da rentabilidade a partir de dados dos cinco maiores bancos brasileiros. Estes métodos são as ferramentas estatísticas conhecidas como regressão linear múltipla (RLM) e redes neurais artificiais (RNA). Pretende-se utilizar tais ferramentas de forma complementar visando aproveitar as melhores informações que cada uma é capaz de fornecer.

2 Referencial teórico

2.1 Investimentos: risco e retorno

As oscilações nos mercados financeiros acontecem porque as decisões tomadas por seus agentes dependem de muitas combinações de diversos fatores econômicos, políticos, sociais, entre outros. Assim, tais oscilações produzem os principais fatores que impactam diretamente nas decisões de investidores: risco e retorno.

Em sua definição mais geral, risco pode ser entendido como a possibilidade de perigo ou como a ocorrência de um evento não desejável (BRUGNI, 1998). Por outro lado, dado que um investidor aplica seus recursos na data presente visando obter resultados futuros, o retorno é a variação na riqueza de um investidor, comumente representado na forma percentual (ibidem). Portanto, diante de todas as variações e possibilidades de investimento, o que move o mercado financeiro são os retornos esperados por seus agentes perante os riscos conhecidos ou não por eles.

Na definição de Júnior e Marcos (2001), o retorno é entendido como a estimação de capital ao final do horizonte de investimento. Como há oscilações constantes nos mercados financeiros, há também incertezas com relação a tal estimação de capital pelos investidores. Ao se medir essas incertezas obtém-se o risco (MINARDI, 2006). Especificamente nas finanças, Mayo (2008) define o risco como “a incerteza de que o retorno realizado não seja igual ao retorno esperado”.

Nos mercados financeiros, o conceito de risco cobre quatro grandes grupos: risco de mercado, risco operacional, risco de crédito e risco legal. Júnior e Marcos (2001) especificam tais grupos como se segue:

- Risco de mercado é função do preço do ativo diante das condições de mercado. Sendo assim, investigar o que impacta o comportamento do preço do ativo é uma forma de mensurar o risco de mercado.
- Risco operacional está relacionado a possíveis perdas de sistemas e/ou controles inadequados, falhas de gerenciamento e erros humanos. O risco operacional é dividido entre três outros subgrupos: risco organizacional (relacionado com a eficiência da administração

da instituição), risco de operações (relacionado com rigorosidade do processamento e verificação de informações, sistemas de tecnologia etc.) e risco de pessoal (relacionado com a provisão de crédito de liquidez duvidosa de um dos contratantes).

- O risco legal está relacionado com a juridicidade de contratos que por algum motivo não puderam ser amparados devido a documentação insuficiente, insolvência, ilegalidade, falta de representatividade e/ou autoridade por parte de um negociador etc.

O retorno financeiro e seu risco associado são os fatores elementares nas decisões de investimento. Por consequência, estudos sobre análise de desempenho de instituições antes e após negociarem suas ações em bolsas de valores são cada vez mais comuns, assim como também são os estudos sobre quais fatores macroeconômicos e microeconômicos têm maior influência nestas operações (AZIZ; BRUGNI; FLORES, 2015; BASTOS; FIGUEIREDO; KLOTZLE et al, 2016; KOS, BARROS e COLAUTO, 2017; DE JONG; ROSENTHAL; VAN, 2009; FORTES; SILVEIRA; BACIC, 2012; IYENGAR; PANDEY; JADHAV, 2016; MINARDI; FERRARI; ARAÚJO, 2013). Na grande maioria destes estudos utilizam-se técnicas estatísticas e econométricas que buscam explicar algum tipo de retorno financeiro. O principal deles é o retorno anormal acumulado (*cummulative abnormal return - CAR*), pois são emissões de ações que são vistas por investidores como uma possibilidade de se auferir lucros acima (ou abaixo) da média de mercado, que podem vir por meio da depreciação ou por reações do mercado que fogem do esperado (AZIZ; BRUGNI; FLORES, 2015). Além disso, o CAR vem sendo utilizado como principal norteador para análises de desempenho empresarial em processos de abertura de capital nas bolsas de valores, ou seja, as chamadas ofertas públicas iniciais.

2.2 Ofertas públicas iniciais

As ofertas públicas iniciais (*initial public offering - IPO*) surgiram nos Estados Unidos na década de 1990 e até os dias atuais este processo de publicização da participação financeira de instituições em bolsas de valores ocorre com frequência nos mercados nacionais e internacionais. O processo é caracterizado pela publicização primária de ações de uma empresa em alguma bolsa de valor do mercado financeiro, ou seja, a partir dele qualquer investidor pode se tornar sócio (ou dono) da instituição de forma proporcional à quantidade de ações adquiridas. Ao responder a pergunta “por que as empresas se tornam públicas?”, Ritter e Welch (2002) explicam que a razão primária é o desejo (estratégia) de aumentar o capital social da empresa além de criar um mercado público no qual os fundadores e outros acionistas possam converter parte de sua riqueza em dinheiro no futuro.

Por conseguinte, sob a ótica das empresas, as operações de IPO permitem que elas passem por um processo de alavancagem financeira por meio da captação de recursos aplicáveis em investimentos produtivos (PROCIANOY; ANTUNES, 2001). Sob a ótica do mercado, essas

operações são estratégias de participação do fluxo de caixa futuro da instituição investida (ibidem).

Com o surgimento das IPOs, as bolsas de valores receberam diferentes investidores que obtiveram diferentes resultados (retornos). O fato é que investir em empresas que abrem seu capital sob operações de IPO é uma estratégia de captação de recursos que tem obtido sucesso entre os agentes do mercado financeiro. Uma das formas para tal captação acontece no processo chamado na literatura de *exit modes* ou desinvestimento. Neste processo, investidores aplicam seus recursos em firmas que iniciam estas operações e no futuro negociam suas ações a um preço maior do que foi investido (IYENGAR; PANDEY; JADHAV, 2016).

De acordo com Alcino e Pessanha (2017), as operações de IPO proporcionaram a investidores grande captação financeira quando este tipo de operação chegou ao Brasil. Segundo dados da BM&FBovespa (2015), entre 2004 e 2007 (período conhecido como o *boom* das IPOs) houve 73 emissões e um total de R\$ 61,8 bilhões captados.

Em finanças, as operações de IPO são objeto de estudo de pesquisadores e investidores, porém, (obviamente) cada um deles possuem interesses distintos. Pesquisadores podem estudar os mercados e seus comportamentos para que se compreenda sua dinâmica e através dela possam desenvolver e aprimorar o estudo das ciências sociais, por exemplo. Por outro lado, os investidores talvez tenham um interesse mais direto nesses estudos, como resolver a dicotomia existente entre o risco e o retorno e assim realizar melhores investimentos financeiros.

2.3 Estudos empíricos

O aumento da complexidade dos derivativos negociados em bolsas de valores, a grande demanda por produtos sofisticados e os métodos de avaliação exata exigidos por bancos, seguradoras e investidores nos mercados financeiros criaram uma grande demanda por métodos matemáticos e modelos que antes não eram encontrados nesta área (KORN; KROISANDT, 2010, p. 175).

O retorno anormal acumulado tem sido utilizado por pesquisadores para analisar e desenvolver métodos que visam a ampliação da eficiência das operações de IPO nos mercados financeiros. A partir das evidências empíricas que serão apresentadas a seguir, buscar-se-á encontrar determinantes do CAR em diferentes naturezas (macroeconômicas, sociais, administrativas, de mercado etc). Tal investigação dará suporte para que a metodologia deste trabalho satisfaça as suas intenções.

Com o objetivo de investigar o desempenho dos IPO's brasileiros que tiveram presença de capital privado no longo e no curto prazo, Minardi, Ferrari e Araújo (2013) utilizaram o CAR como fator determinante para tal investigação. Nela, a sua amostra foi dividida nos

períodos 2004-2006 e 2007-2008 e assim, foi realizada uma análise de regressão que concluiu que a presença de capital privado tem impacto positivo no retorno anormal das instituições que realizaram IPO. Em seu modelo final, as variáveis mais significativas foram o tamanho da oferta, o nível de governança corporativa e o índice dívida/capital no trimestre antes do IPO.

Bastos, Figueiredo, Klotzle et al (2016), utilizaram o CAR na tentativa de investigar a relação entre a participação de fundos *Private Equity/Venture Capital* (PE/VC) antes da oferta pública inicial (IPO) e o desempenho das ações das companhias pós-IPO. Em sua análise, foi utilizado o modelo de regressão linear múltipla e as regressões apontaram que a participação dos fundos influencia o CAR apenas no curto prazo pós IPO. Neste estudo, os autores dividiram sua amostra por setor de atividade e como resultado, as variáveis mais significativas no modelo foram a presença ou não (variável *dummy*) de um fundo PE/VC, *Market Cap* (preço da ação multiplicado pela quantidade total de ações da empresa no dia do IPO), volume total captado no IPO e o número de investidores que participaram da oferta.

Souza (2015) utilizou a variável riqueza relativa para analisar o desempenho em IPOs fazendo uma comparação entre as instituições financeiras do Brasil e dos Estados Unidos no curto e no longo prazos. Em sua análise, o retorno anormal foi utilizado para a construção da variável dependente em seu modelo.

De Jong, Rosenthal e Van (2009) coletaram dados de uma amostra de doze empresas de dupla lista (*Dual List Company - DLC*) para avaliar o risco e o retorno das estratégias de arbitragem. Neste estudo, o autor também utilizou o retorno anormal como variável dependente em seu modelo de regressão. As variáveis explicativas foram somatórios de retornos de registro dos índices de mercado doméstico e os retornos do logaritmo no dia da primeira e segunda parte do DLC em suas moedas locais. Após as análises estatísticas, o autor concluiu que arbitragens em DLC's produzem retornos anormais de quase 10% ao ano, porém isso é compensável por um alto risco, já que se constatou que não existe uma data identificável em que os preços duplos convergem.

Iyengar, Pandey e Jadhav (2016) realizaram uma análise comparativa dos diferentes modos de desinvestimento para IPOs que tiveram presença de capital privado. Este foi um estudo empírico que consistiu em uma Análise de Variância (ANOVA) para a diferença nos retornos médios gerados usando diferentes formas de desinvestimento.

Kos, Barros e Colauto (2017) buscaram entender o impacto da divulgação de eventos subsequentes no retorno anormal das ações em empresas que participam do IBOVESPA. Para isso, os autores utilizaram modelos de regressão linear múltipla com dados em painel. As variáveis utilizadas em seu modelo foram: eventos subsequentes no CAR, tamanho da empresa, alavancagem, retorno sobre ativos (ROA) e retorno sobre patrimônio líquido (ROE). Os resultados mostraram que 16 eventos apresentaram pelo menos um retorno anormal significativo na janela temporal, enquanto os outros doze eventos da amostra não impactaram o mercado.

Já Fortes, Silveira e Bacic (2012), empregaram o CAR para avaliar o desempenho de empresas após IPO, tendo a presença de fundos de capital privado como fator determinante. Os autores utilizaram uma base de dados que consiste em todas as ofertas de ações realizadas no Brasil, entre janeiro de 2004 e dezembro de 2007, para realizarem um modelo de regressão linear múltipla. Este modelo recorreu às seguintes variáveis independentes para explicar o retorno anormal acumulado: o percentual da emissão que foi primária, o valor de mercado da empresa, o *free float* da companhia após o IPO, uma variável *dummy* para o nível de governança corporativa da empresa e outra variável *dummy* que indica a presença ou não de *private equity* no capital da empresa. Os resultados mostraram que a presença de fundos de capital privado como acionistas em uma empresa que realiza um IPO tem influência positiva sobre o retorno anormal acumulado.

No Quadro 1 se apresenta um resumo dos estudos empíricos:

Autor	Objetivo	Metodologia	Resultados
Kos, Barros e Colauto (2017)	analisar o impacto da divulgação de eventos subsequentes no Retorno Anormal das ações em empresas que participam do IBOVESPA.	modelo de regressão com dados em painel	os resultados mostraram que 16 eventos apresentaram pelo menos um Retorno Anormal significativo na janela temporal, enquanto os outros 12 da amostra não impactaram o mercado.
Bastos, Figueiredo, Klotzle et al (2016)	investigar a relação entre a presença de capital privado antes do IPO e o desempenho das instituições após IPO.	modelo de regressão linear múltipla.	a presença de PE tem impacto positivo no CAR apenas no curto prazo.
Iyengar, Pandey e Jadhav (2016)	comparar diferentes modos de desinvestimento.	Análise de Variância (ANOVA).	não houve significância entre os modos de desinvestimento analisados.
Souza (2015)	comparar performance de IPO's brasileiros e dos Estados Unidos em instituições financeiras.	Wealth Relative Buy-and-Hold (WRBH).	no longo prazo, houve diferenças de médias significativas nos CAR's entre os países a partir de 90 dias das datas dos IPO's e tal comportamento continua nos períodos subsequentes para os CAR's de 1,2 e 3 anos.
Minardi, Ferrari e Araújo (2013)	investigar a performance dos IPO's brasileiros que tiveram presença de capital privado no longo e curto prazo.	análise de regressão linear múltipla.	a presença de PE tem impacto positivo no CAR das instituições que realizaram IPO.
Fortes, Silveira e Bacic (2012)	avaliar desempenho de empresas após IPO tendo a presença de PE como fator determinante.	modelo de regressão linear múltipla (MQO).	a presença de PE tem impacto positivo no CAR das instituições que realizaram IPO.
De Jong, Rosenthal e Van (2009)	avaliar o risco e o retorno das estratégias de arbitragem.	modelo de regressão linear múltipla.	as empresas <i>dual list company</i> produzem retornos anormais de quase 10% ao ano.

Quadro 1: Resumo dos estudos empíricos apresentados.
Elaborado pelos autores.

Com a leitura dos estudos apresentados anteriormente, observa-se que direta ou indiretamente todas serviram-se do CAR para atingir os seus propósitos, mesmo que estes fossem distintos. Isto evidencia a importância de tal indicador para análises de desempenho. Na seção seguinte será apresentada a forma como este indicador é calculado e assim, respaldado pelos autores acima, este trabalho estabelecerá as pressuposições para realizar a análise proposta.

3 Metodologia

3.1 Dados

Para atender problema proposto neste trabalho e também por causa de sua disponibilidade, utilizou-se dados dos cinco maiores bancos brasileiros de capital aberto na bolsa de valores BMF&BOVESPA. Estes dados foram retirados do programa Economática e além disso, tanto a manipulação quanto a análise estatística foram trabalhadas computacionalmente, através das linguagens de programação Python (Anaconda, 2017) e R (R Core Team, 2017) com utilização específica do pacote neuralnet (STEFAN; FRAUKE, 2016). Ambas possuem licença gratuita.

Devido à disponibilidade dos dados, estes estão organizados em forma de painel desbalanceado e separados trimestralmente. Os dados retirados são referentes às variáveis expostas no Quadro 2, baseadas nos autores do referencial teórico deste estudo.

Variável	Descrição	Metodologia de Cálculo	Fonte
Valor de Mercado	valor de mercado da instituição	mensurado pelo produto do preço da ação da oferta pelo número total de ações que compõem o capital social da empresa após IPO.	Econômática
Nível de Governança	segmentos corporativos criados para diferenciar empresas que se comprometem a seguir regras específicas de governança corporativa. Variável <i>dummy</i>	valor 1 para empresas do Novo Mercado; 0 quando não listadas em seguimentos de governança corporativa estabelecidos pela BMF&BOVESPA.	Econômática
Presença de Capital Privado	assume valores 0 para instituições não <i>PEbacked</i> e 1 para <i>PEbacked</i> . variável <i>dummy</i> .	-	Econômática
Volume Total Capitado no IPO	volume total captado na emissão primária	-	Econômática
Crise 2008	crise financeira internacional, evidenciada a partir da crise no mercado imobiliário norte-americano. Variável <i>dummy</i>	assume valores 0 para IPO ocorridos antes de 2008 e 1 para os posteriores à 2008. Variável <i>dummy</i>	Bloomberg e Econômática
ROE	indicador contábil que analisa o resultado de seu próprio recurso.	$ROE = \text{Lucro Líquido} / \text{Patrimônio Líquido}$	Econômática
ROA	indicador contábil que mostra a capacidade da empresa em gerar resultados	$ROA = \text{Lucro Líquido} / \text{Total dos Ativos}$	Econômática
<i>Underpricing</i>	mostra o quanto o preço da oferta estava aderente às expectativas dos investidores	preço da ação no primeiro dia de negociação da bolsa subtraído pelo preço de mercado da carteira utilizada.	Econômática

Quadro 2: Resumo das variáveis utilizadas.
Elaboração dos autores.

Segundo o site do Banco Central do Brasil, os cinco maiores bancos brasileiros que possuem participação na bolsa de valores BMF&Bovespa são: Itau Unibanco, Banco do Brasil, Bradesco, Santander e Banrisul. O critério considerado para este *ranking* foi o total do ativo financeiro.

Cada um dos bancos analisados neste estudo possui uma trajetória particular no mercado financeiro. Sendo assim, os dados disponibilizados possuíam diferentes cortes temporais e isto justifica a organização deles sob a forma de painel desbalanceado para realizar a análise proposta. Na Tabela 1 se apresenta as instituições financeiras e as suas respectivas datas de informações disponíveis.

Tabela 1: Corte temporal de cada banco.

Banco	Data Início	Data Final	Total
Itaú Unibanco	1T1986	3T2017	127 trimestres
Brasil	1T1986	3T2017	127 trimestres
Bradesco	1T1986	3T2017	127 trimestres
Santander	4T2005	3T2017	48 trimestres
Banrisul	4T1986	3T2017	124 trimestres

Um fato importante ocorrido no Brasil que afetou diretamente toda a economia do país foi a implementação do Plano Real, iniciado em fevereiro do ano de 1994. Com esta política, o governo brasileiro buscou controlar a inflação existente através da Unidade Real de Valor (URV). Assim, como os dados deste estudo envolvem o corte temporal de 1986 à 2017, o plano real pode ser um fator que cause algum tipo de impacto nos resultados. Uma das alternativas para este problema seria trabalhar com os dados a partir do ano de 1995. Entretanto, isto reduziria a quantidade de dados disponíveis para as análises propostas e, conseqüentemente, a solidez estatística do estudo.

Além das variáveis expostas no Quadro 2, há duas outras que foram incluídas no modelo. Assim como feito por Pessanha (2016), estas variáveis adicionais têm o objetivo de captar efeitos específicos. A primeira, calculada pela Equação 1, busca capturar efeitos específicos de cada banco:

$$E_{EIF} = \frac{i}{N}, \quad (1)$$

em que E_{EIF} são os efeitos específicos das instituições financeiras; e i varia de 1 a N ; N é o tamanho do corte transversal (total de bancos).

Já na segunda, calculada pela Equação 2, busca-se captar os efeitos das especificidades dos períodos que compõem o horizonte temporal estudado:

$$E_{ET} = \frac{t}{T}, \quad (2)$$

em que E_{ET} representa os efeitos específicos do tempo; t varia de 1 a T ; T é o tamanho do corte

temporal de cada banco.

Logo, com os dados recolhidos e organizados, cabe à próxima seção tratar da construção do modelo conceitual-teórico que será aplicado à eles.

3.2 Modelo conceitual-teórico e hipóteses

Ter o Retorno Anormal Acumulado (CAR) como referência para avaliar quaisquer tipos de desempenho empresarial, não importando o setor de atividade, é uma técnica eficiente utilizada por pesquisadores na literatura (AZIZ; BRUGNI; FLORES, 2015; BASTOS; FIGUEIREDO; KLOTZLE et al, 2016; KOS, BARROS e COLAUTO, 2017; DE JONG; ROSENTHAL; VAN, 2009; FORTES; SILVEIRA; BACIC, 2012; IYENGAR; PANDEY; JADHAV, 2016; MINARDI; FERRARI; ARAÚJO, 2013). Tal eficiência é dada pela forma que tal indicador é calculado, que leva em consideração sempre o preço atual da ação em relação ao seu preço passado, além de indicar proporcionalidade.

Apesar de existirem diferentes formas de se calcular o CAR, esse índice é um somatório de diferenças da proporção entre o retorno individual de uma instituição e o retorno médio do mercado que, no presente trabalho será o Ibovespa. Tal somatório dá a ideia de cumulatividade, o que justifica o nome do indicador.

Minardi, Ferrari e Araújo (2013) propõem que o CAR seja calculado através das equações 3, 4 e 5:

$$R_{i,t} = \frac{P_{i,t}}{P_{i,t-1}} - 1, \quad (3)$$

em que $R_{i,t}$ é o retorno do estoque i no tempo t ; $P_{i,t}$ é o preço do estoque i no tempo t e $P_{i,t-1}$ é o preço do estoque i no tempo $t - 1$. Com $R_{i,t}$, calculam-se os retornos anormais do estoque i no tempo t ($AR_{i,t}$):

$$AR_{i,t} = R_{i,t} - R_{IBOVESPA,t}, \quad (4)$$

em que $R_{IBOVESPA,t}$ são preços de fechamento de estoque Ibovespa no tempo t . Por fim o CAR é um somatório dos retornos anormais do estoque i no tempo t , ou seja,

$$CAR_{i,t} = \sum_{t=0}^T AR_{i,t}. \quad (5)$$

É necessário expor quais são os determinantes do objeto deste estudo e de que forma eles o afetam. Baseado nos estudos dos autores do referencial teórico deste trabalho (AZIZ; BRUGNI; FLORES, 2015; BASTOS; FIGUEIREDO; KLOTZLE et al, 2016; KOS, BARROS e

COLAUTO, 2017; DE JONG; ROSENTHAL; VAN, 2009; FORTES; SILVEIRA; BACIC, 2012; IYENGAR; PANDEY; JADHAV, 2016; MINARDI; FERRARI; ARAÚJO, 2013), acredita-se que tais determinantes são compostos pelos indicadores apresentados no Quadro 2. Assim, partindo do pressuposto de que essas oito variáveis possam explicar o retorno anormal das instituições financeiras, a seguir apresenta-se o significado de cada uma delas e as suas respectivas hipóteses.

O valor de mercado da empresa é dado pelo produto do preço da ação da oferta pela quantidade de ações que compõem o capital social da empresa após IPO. Assim, acredita-se que esta variável tenha impacto positivo na determinação do CAR devido a sua atratividade financeira sob a ótica de investidores. Em seu estudo, Fortes, Silveira e Bacic (2012) obtiveram coeficiente positivo do valor de mercado em sua análise. Sendo assim tem-se a hipótese 1:

H₁: o indicador valor de mercado da empresa é diretamente relacionado ao CAR.

A governança corporativa é um conjunto de segmentos criados pela BM&FBOVESPA que possui, entre outros fins, assegurar direitos e garantias aos acionistas, bem como a divulgação de informações mais completas para controladores, gestores da empresa e participantes do mercado para que o risco seja reduzido. Assim como fizeram Fortes, Silveira e Bacic (2012), na análise deste estudo a governança corporativa é uma variável *dummy*, que assume valor 1 para empresas pertencentes ao Novo Mercado e valor igual 0 quando não listadas em segmentos de governança corporativa diferenciada ou presentes no Nível 1 ou 2. Logo, a segunda hipótese é de que:

H₂: O nível de governança corporativa é inversamente relacionado ao CAR.

Assim como concluíram Fortes, Silveira e Bacic (2012), entende-se que a presença de fundos de capital privado no capital social (variável *dummy*) da empresa influencie positivamente no CAR. Estes fundos, conhecidos na literatura como *private equity* são formas de alavancagem financeira, além de favorecer a atratividade de investimento. Logo, a terceira hipótese é de que:

H₃: A presença de capital privado é diretamente relacionada ao CAR.

De acordo com a forma com que o retorno anormal foi calculado neste trabalho, espera-se que quanto maior o volume total captado no IPO, maior o CAR. Além disso, tanto nos estudos de Bastos, Pinto, Klotzle et al (2016), quanto nos de Minardi et al (2013), tal variável obteve coeficiente positivo na determinação do CAR. Assim, a quarta hipótese é de que:

H₄: volume total captado no IPO é diretamente relacionado ao CAR.

Assim como fez Bastos, Figueiredo, Klotzle et al (2016), crise é uma variável *dummy* cujo valor atribuído é 1 para IPOs ocorridos após setembro de 2008 e 0 para aqueles anteriores à esta data. A quinta hipótese portanto, é de que:

H₅: crise de 2008 é diretamente relacionada ao CAR.

De acordo com as pressuposições do estudo de Kos, Barros e Colauto (2017), espera-se

que o indicador financeiro ROE tenha uma relação direta com o retorno anormal acumulado.

H₆: retornos sobre patrimônio líquido são diretamente relacionados ao CAR.

Ainda com base no trabalho de Kos, Barros e Colauto (2017), a sétima hipótese deste trabalho sugere que o indicador financeiro ROA tenha uma relação direta com o retorno anormal acumulado. Assim, a sétima hipótese é de que:

H₇: retornos sobre ativos são diretamente relacionados ao CAR.

O *underpricing* é verificado no primeiro dia de negociação de uma ação em bolsa de valores e mostra quanto o preço da oferta estava aderente às expectativas dos investidores. No trabalho de Bastos, Pinto e Silva (2016), em todos os períodos analisados esta variável obteve relação direta com o CAR. Por isso (analogamente), a oitava hipótese é de que:

H₈: O *underpricing* é inversamente relacionado ao CAR.

Na Tabela 2 apresentam-se as variáveis e seus sinais esperados:

Tabela 2: Variáveis do modelo e sinais esperados.

Sigla	Variável	Hipótese	Sinal Esperado
MC	Valor de Mercado	H ₁	+
GC	Nível de Governança Corporativa	H ₂	-
PE	Presença de Capital Privado	H ₃	+
VL	Volume Total Capitado no IPO	H ₄	+
CR	Crise 2008	H ₅	+
ROA	Retornos Sobre Ativos	H ₆	+
ROE	Retornos Sobre PL	H ₇	+
UP	Underpricing	H ₈	-

Sendo assim, na seção 3.3 serão definidos os métodos estatísticos a serem utilizados para abordar o problema.

3.3 Métodos aplicados

Para atender às finalidades deste trabalho foram utilizados o modelo de regressão linear múltipla (RLM) e as redes neurais artificiais (RNA). Basicamente, a escolha destes métodos se justifica pelo fato de que cada um deles gerará informações complementares e que serão fundamentais para alcançar os objetivos propostos.

A regressão será capaz desvendar as relações entre as variáveis de entrada com o CAR. Assim, as hipóteses construídas na seção 3.2 poderão ser confirmadas (ou contraditadas), tornando possível a comparação e discussão com os resultados obtidos pelos estudos do referencial teórico.

Em comparação com a RLM, as redes neurais artificiais são métodos estatísticos que normalmente têm melhores ajustes aos dados e conseqüentemente maior poder de previsão, além de não precisarem atender muitos pressupostos. Como exemplo, Mueller (1996), ao utilizar as redes neurais para analisar o mercado acionário obteve resultados que demonstraram que este método atingiu um poder de previsão significativamente maior do que os métodos convencionais, como as séries temporais. Entretanto, este método (devido a sua complexidade) traz consigo o ônus de não ser possível entender de forma precisa o que acontece durante o seu processo e assim entender como cada determinante influencia na variável resposta.

A ideia de utilizar diferentes métodos e utilizar seus resultados de forma complementar foi empregada por Pessanha (2016), que em uma de suas análises integrou resultados de uma regressão logística e resultados de uma RNA. Em sua tese, o autor apresenta algumas vantagens e desvantagens de se utilizar RNA, as quais podem ser observadas no Quadro 3.

Vantagens	Desvantagens
1- Modelos de redes neurais requerem menos treinamento estatístico	1- Redes neurais são "caixas-pretas" e têm habilidade limitada para identificar explicitamente relações causais
2- Modelos de redes neurais podem detectar complexas relações não lineares entre as variáveis	2- Modelos de redes neurais podem ser mais difíceis de serem aplicados em campo
3- Modelos de redes neurais têm a habilidade de detectar todas as possíveis interações entre as variáveis	3- A modelagem de redes neurais requer melhores recursos computacionais
4- Redes neurais podem ser desenvolvidas utilizando-se diferentes algoritmos de treinamento	4- Modelos de redes neurais são propensas ao sobreajuste
5- Habilidade de aprender a partir de dados observados de um processo que se pretende modelar/emular (CHERKASSKY; MULIER, 2007)	5- O desenvolvimento do modelo é empírico e problemas metodológicos ainda devem ser resolvidos
6- Capacidade de aproximação universal de mapeamentos estáticos não lineares e multidimensionais (HORNIK; STINCHOMBE; WHITE, 1989)	
7- Capacidade de aproximação de mapeamentos dinâmicos não lineares e multidimensionais (NARENDRA; PARTHASARATHY, 1990, 1991)	
8- Habilidade para implementação de memória associativa e para a solução de problemas combinatórios pela busca de pontos de equilíbrio em dinâmicas de relaxação (HOPFIELD, 1982)	
9- Capacidade de auto-organização e de treinamento não supervisionado (KOHONEN, 1989)	

Quadro 3: Vantagens e Desvantagens de se utilizar RNA.

Fonte: Pessanha (2016).

Por estes motivos, os métodos escolhidos são complementares, ou seja, enquanto um desvendará as relações entre as variáveis, o outro contribuirá com alto poder de previsão. Assim, acredita-se que os objetivos propostos possam ser alcançados.

3.3.1 Modelo de regressão linear múltipla

Ao propor um modelo de regressão linear (múltipla), busca-se saber se o comportamento de uma variável é determinado pelo comportamento de outra(s). Assim, é comum relacionar o conceito de regressão linear com o de correlação. Entretanto, é importante esclarecer suas diferenças. Em uma análise de correlação, deseja-se encontrar a força ou o grau de associação linear entre duas variáveis. Por outro lado, na análise de regressão, busca-se estimar o valor médio de uma variável com base nos valores fixos de outras variáveis (GURAJATI; PORTER, 2011).

Em um modelo de regressão linear, basicamente o que se faz é encontrar uma reta (o que justifica o nome dado ao método) que consiga estabelecer a relação e o grau de dependência entre as variáveis preditoras e a variável dependente. Assim, a média condicional da variável dependente é uma função linear de variáveis independentes (ibidem). Na equação 6 expressa-se a notação de um modelo simples.

$$Y = \alpha + \beta_1 X_1 + \epsilon, \quad (6)$$

em que Y é a variável dependente, α é uma constante (ou intercepto quando X_1 assume zero), X_1 é a variável independente e aleatória, ϵ é o resíduo do modelo e por fim, β_1 é o coeficiente da reta regressão (GURAJATI; PORTER, 2011).

A presença da variável ϵ e da aleatoriedade faz com que estes modelos sejam estocásticos, e portanto, a reta de regressão não consegue se ajustar perfeitamente aos dados. Ou seja, a distância entre os pares de observações e a reta estimada é considerada o erro do modelo (FILHO; NUNES; ROCHA et al. 2011). Em outras palavras, tudo aquilo que também explica a variável dependente mas não foi considerado no modelo será responsável pelo não ajustamento perfeito da reta de regressão e conseqüentemente será incluso no erro (Figura 1).

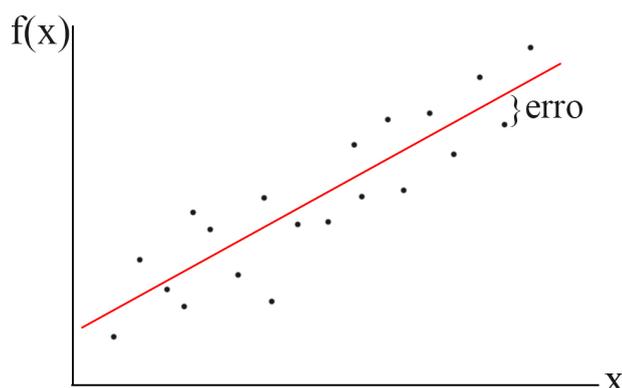


Figura 1: Erro no modelo RLM.
 Fonte: Elaboração dos autores.

Uma das vantagens de se utilizar este método é que com ele se torna possível inferir quanto e como cada determinante influencia a variável resposta (FILHO; NUNES; ROCHA et al, 2011). Na Figura 2 se apresenta um esquema deste método aplicado às pressuposições deste estudo.

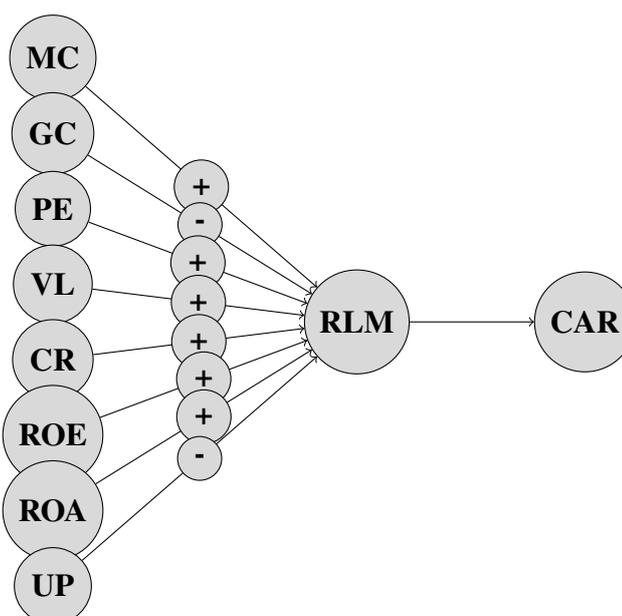


Figura 2: Modelo conceitual-teórico e hipóteses.
 Fonte: Elaboração dos autores.

Segundo Krueger e Lewis-Beck (2008), entre os diferentes métodos de regressão, os Mínimos Quadrados Ordinários (MQO) possuem uma frequência de utilização que se sobressai entre outros. Estes autores afirmam que 30,8% dos estudos publicados em importantes periódicos da ciência política entre 1990 e 2005 utilizaram este método. Ajustar um modelo de regressão utilizando MQO, é fazer com que uma reta minimize a soma dos quadrados dos resíduos (erros) e assim, esta reta será utilizada para explicar a relação linear entre a variável dependente e as independentes (ibidem).

A metodologia deste trabalho utilizará um modelo de regressão linear múltipla (pois

contém mais de uma variável preditora) para atingir o objetivo proposto. Com base em estudos apresentados no referencial teórico e nas hipóteses apresentadas anteriormente, construiu-se o modelo dado pela equação 7:

$$CAR_{i,t} = \beta_1 MC + \beta_2 GC + \beta_3 PE + \beta_4 VL + \beta_5 CR + \beta_6 ROA + \beta_7 ROE + \beta_8 UP + \beta_9 E_{EIF} + \beta_{10} E_{ET} + \epsilon_t, \quad (7)$$

em que $CAR_{i,t}$ é o retorno anormal acumulado i no tempo t , MC é o valor de mercado, GC é o nível de governança corporativa, PE é a presença ou não de capital privado na instituição antes do IPO, VL é o volume total captado no IPO, CR é a crise de 2008 (*dummy*), ROA é o retorno sobre os ativos, ROE é o retorno sobre os patrimônio líquido, UP é o *underpricing* e ϵ é o erro envolvido.

A decisão de trabalhar com regressão múltipla envolve obrigatoriamente uma série de suposições sobre as variáveis contidas no modelo, assim como outros métodos de regressão também envolvem. Estas suposições, ou pré-requisitos, devem ser respeitadas justamente para responder à seguinte questão: “Os erros na previsão são um resultado de uma ausência real de uma relação entre as variáveis, ou eles são causados por algumas características dos dados não acomodadas pelo modelo de regressão?” (HAIR, BLACK, BABIN et al. 2009).

Assim, as suposições que devem ser atendidas estão em quatro áreas: linearidade do fenômeno medido, variância constante dos termos de erro (homoscedasticidade), independência dos termos de erro e normalidade da distribuição dos termos de erro (*ibidem*).

A linearidade do fenômeno medido representa o grau de associação entre as variáveis independentes e a dependente. Como o conceito de correlação é baseado em uma relação linear, tal suposição pode ser facilmente identificada por meio de um gráfico de dispersão dos resíduos (*ibidem*).

A variância constante dos termos de erro (ou homoscedasticidade) é uma suposição que exige que os erros (resíduos) do modelo devem possuir variância constante. Caso isto não ocorra, diz-se que os resíduos da regressão possuem comportamento heteroscedástico (*ibidem*).

A independência dos termos de erro é um pressuposto que assume que cada valor previsto na regressão é independente e assim cada um destes valores não está relacionado com qualquer outra previsão (*ibidem*).

Por fim, uma das importantes suposições de uma regressão é que os resíduos têm distribuição normal. Segundo Hair et al. (2009), esta é uma das violações de suposição mais frequentes em análise de regressão, mas que pode ser facilmente identificada através de um histograma dos resíduos com uma verificação visual para uma distribuição que se aproxime da normal.

3.3.2 Redes neurais artificiais

As redes neurais artificiais oferecem uma abordagem atrativa que pode ser utilizada de forma eficiente na tomada de decisões frente ao comportamento dinâmico do mercado, pois com elas não há a necessidade de conhecer modelos matemáticos complexos que descrevem tal comportamento (FREITAS e SILVA, 1999).

A rede neural artificial é um método matemático que visa reproduzir o funcionamento do cérebro humano. Embora os atuais avanços tecnológicos e da neurocomputação, a ciência ainda não conseguiu realizar esta tarefa de forma próxima a realidade.

Segundo RAUBER (2005), as informações no cérebro humano são processadas e compartilhadas por bilhões de unidades com estrutura relativamente simples. Estas estruturas são os neurônios (células) que através de reações químicas e elétricas processam informações.

Na Figura 3 apresenta-se uma simplificação de um neurônio real. Em sua estrutura, cada um de seus componentes possui uma função específica, ou seja, recepção, processamento e distribuição da informação.

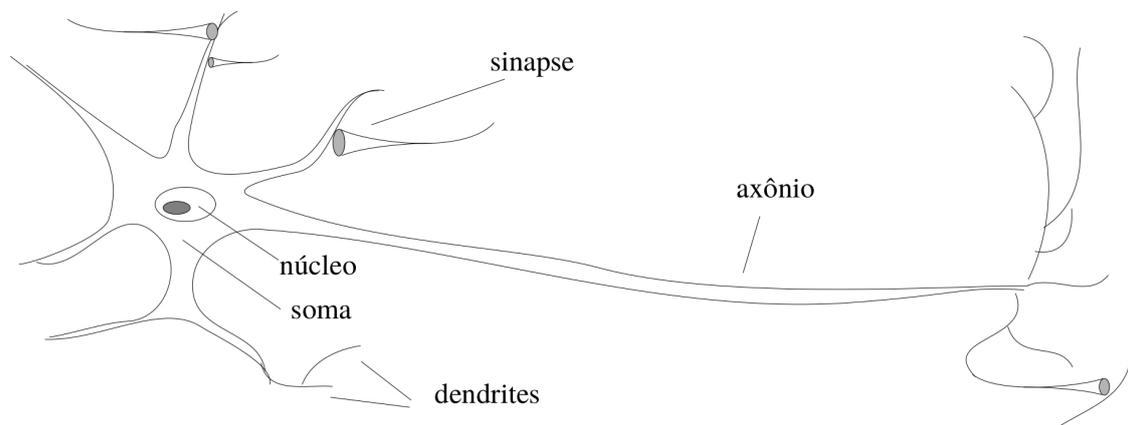


Figura 3: Neurônio biológico humano.
Fonte: Rauber (2005)

O processo de uma RNA envolve fundamentalmente três etapas: treinamento/aprendizado, associação e generalização (VELLASCO, 2007). A primeira acontece no ambiente gerador dos dados, onde a rede aprenderá a partir deles. Na segunda etapa acontece o reconhecimento dos padrões distintos e por último, a terceira etapa é a capacidade de a rede reconhecer com sucesso o ambiente que deu origem aos dados e com isso realizar previsões (ibidem).

Durante o seu processo, a rede neural busca “aprender” com os dados. Para isso, durante o processo de uma RNA são realizadas inúmeras iterações de forma que o processo é realimentado com as informações do conjunto de dados até que ela consiga alcançar o aprendizado deles e assim “explique” de maneira significativa a variável resposta.

É importante dizer que, diferentemente dos modelos de regressão lineares, as redes neurais

artificiais não traçam uma reta de regressão entre os pontos da variável explicativa e das variáveis independentes, elas atuam em cada observação do conjunto de dados. As retroalimentações se repetem até que o modelo se ajuste de forma significativa (aprendendo com os dados), tornando possível realizar previsões com melhores ajustes. Na Figura 4 apresenta-se o esquema simplificado.

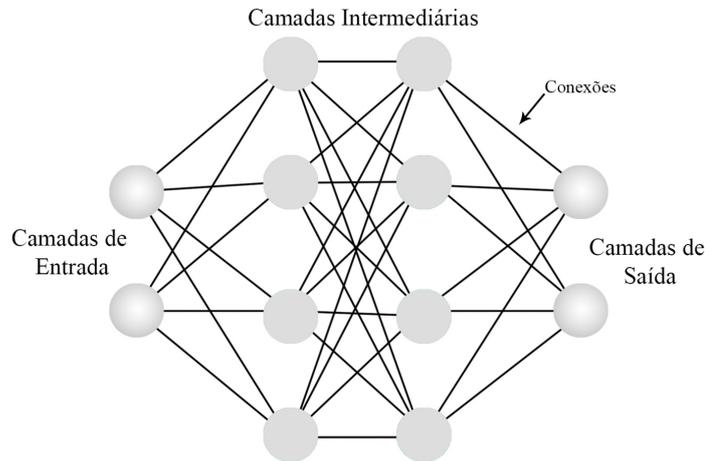


Figura 4: Esquema de rede neural.
Fonte: Elaboração dos autores.

Com relação à estrutura da rede, ainda não há consenso na literatura sobre qual a melhor forma de se construí-la. Essa tarefa deve levar em consideração a quantidade de observações disponíveis até a determinação dos componentes da camada oculta (BRESSAN, 2004). Assim, com relação às camadas ocultas, KOHZADI et al. (1995) afirma que número inicial de neurônios na camada de entrada pode ser estabelecido pela natureza do problema estudado e por seu referencial teórico. Esta deve ser uma etapa cuidadosa para que a rede não “decore” os dados, ao invés de “aprender” com eles.

No presente estudo, 60% dos dados foram destinados ao treinamento da rede e 40% destinados ao aprendizado.

4 Resultados

Apresenta-se na Tabela 3 o resumo estatístico das instituições financeiras da amostra com relação ao CAR.

Tabela 3: Resumo Estatístico da variável CAR em cada banco.

Banco	Média	Desvio Padrão	Mínimo	Máximo
Itau Unibanco	-2,78	1,11	-5,04	-0,38
Brasil	-6,73	2,28	-9,64	-0,22
Bradesco	-4,82	1,30	-6,95	-1,34
Santander	0,35	0,31	0,20	1,30
Banrisul	0,61	2,49	-3,91	2,46

A análise descritiva do CAR no conjunto de dados mostra que foram raros os momentos em que se observou retornos positivos. O que explica este fato é a cumulatividade do retorno aqui estudado, uma vez que em determinado período de tempo (que pode ser observado na Figura 6) houve queda contínua do CAR em todas as instituições.

Além destas estatísticas, é possível realizar uma análise gráfica da dispersão do retorno anormal de cada banco ao longo do tempo quando se observa a Figura 5, na qual são resumidos os dados apresentados na Tabela 3 por meio de *boxplots*.

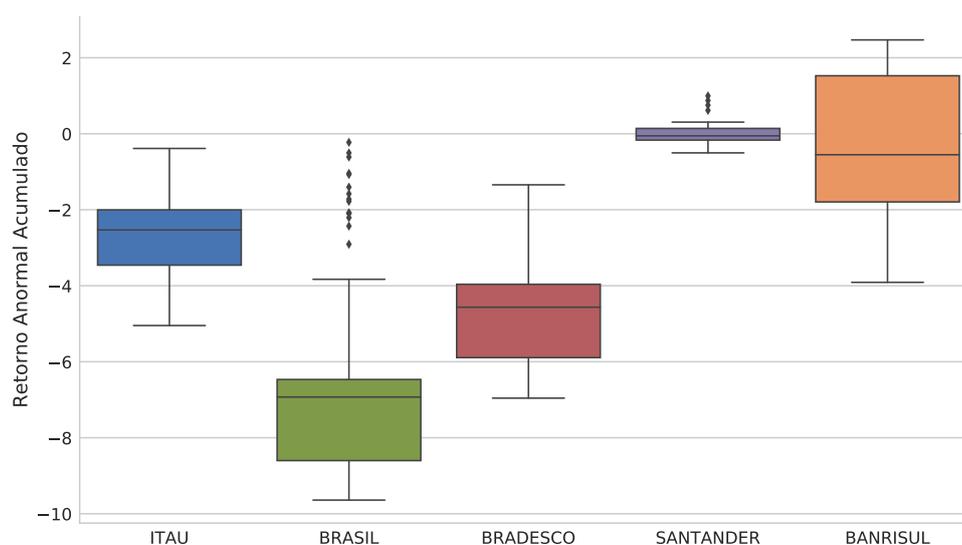


Figura 5: retorno anormal acumulado e sua dispersão.
Elaboração dos autores.

Um fato importante na Figura 5 é a baixa variabilidade do CAR do banco Santander, que pode ser explicada primeiramente porque a instituição não enfrentou as diferentes fases do mercado financeiro ao longo do tempo. Neste sentido, também pode ser observada a resiliência do banco Itaú Unibanco, que enfrentou todas as fases apresentadas na Figura 6 e mesmo assim possui a terceira maior média e a segunda menor variabilidade no retorno anormal acumulado.

Conhecer o grau de associação das variáveis incluídas também pode ser importante para a interpretação tais resultados. Na Tabela 4 é apresentada a matriz de correlação das variáveis.

Tabela 4: Matriz de correlação das variáveis.

	CAR	VM	VL	ROA	ROE	E _{EIF}	E _{ET}	CR	GC	PE	UP
CAR	1,00	-0,06	-0,33	0,12	-0,16	0,57	0,08	0,32	-0,32	0,01	-0,04
VM		1,00	0,26	-0,07	0,04	-0,39	0,03	0,58	-0,08	0,43	-0,06
VL			1,00	-0,21	0,06	-0,18	-0,02	0,39	0,11	-0,26	-0,04
ROA				1,00	0,80	-0,02	-0,08	-0,37	0,37	0,04	0,08
ROE					1,00	-0,10	-0,09	-0,23	0,39	-0,21	-0,01
E _{EIF}						1,00	0,04	0,07	-0,17	-0,45	0,03
E _{ET}							1,00	0,10	-0,24	0,07	-0,01
CR								1,00	-0,28	0,07	-0,10
GC									1,00	-0,28	0,03
PE										1,00	0,01
UP											1,00

Observando a Tabela 4, alguns valores chamam a atenção por sua magnitude. São as relações: (CAR – E_{EIF}), (ROE – ROA) e (CR – VM). Todas elas são valores de correlações positivos e relativamente altos. O grau de associação entre a variável Crise e Valor de Mercado representa como este evento ocasionado pelo mercado imobiliário norte-americano afetou empresas do mundo todo, principalmente as instituições financeiras. Na relação (ROE – ROA) era de se esperar um valor de alta magnitude devido a forma com que tais indicadores são calculados. Entretanto, o valor da correlação na relação (CAR – E_{EIF}) não era esperado e com isso, torna-se importante estudar o resultado específico desta variável após a execução do modelo. Analogamente, o tempo de atuação no mercado financeiro (E_{ET}) não se mostrou correlacionado ao CAR.

Observando a Figura 6, é possível realizar uma comparação entre as instituições financeiras.

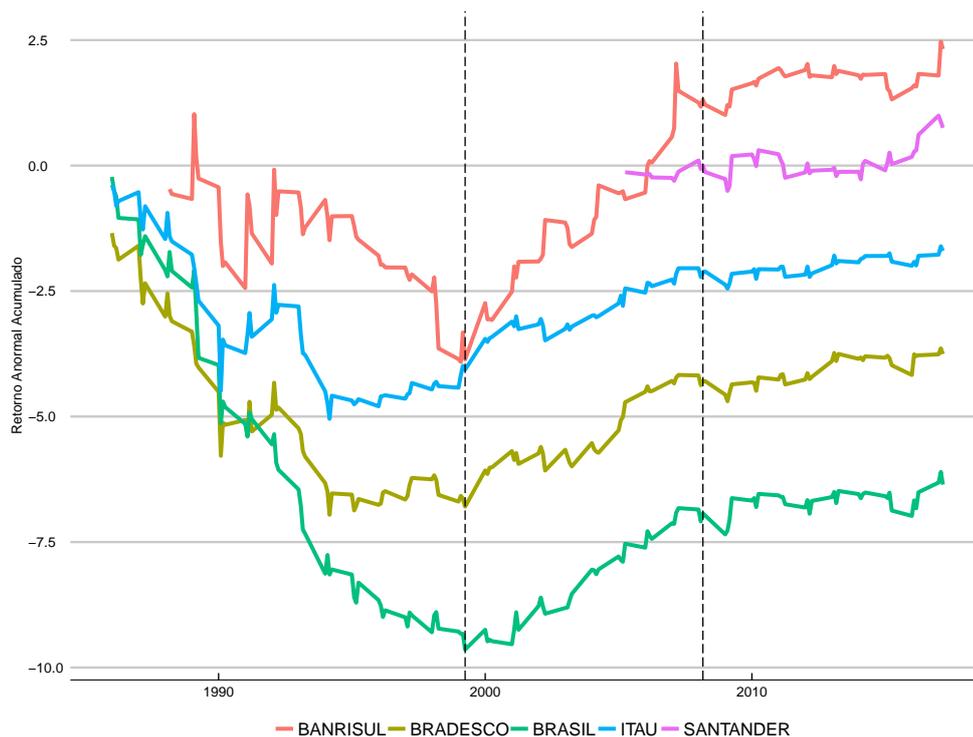


Figura 6: Retorno anormal acumulado ao longo do tempo. Elaboração dos autores.

A primeira conclusão é de que seus retornos anormais acumulados tiveram comportamento relativamente parecido. É possível dividir o período de 1986 a 2017 em três fases, as quais estão demarcadas pelas linhas pontilhadas na Figura 6. Na primeira delas, período que compreende janeiro de 1986 a outubro de 1999, todos os bancos obtiveram retornos anormais acumulados decrescentes, exceto o banco Santander devido a não participação na bolsa. Na segunda fase, período entre janeiro de 2000 e junho de 2008, percebe-se uma significativa ascensão (ou recuperação) destes retornos. A explicação para isto pode ser que neste período aconteceu no Brasil, de acordo com Souza (2015), o *boom* dos IPOs. A nova forma de investimento trouxe ao mercado mais investidores e como consequência bons resultados às instituições financeiras. No terceiro trimestre de 2008 estourou a crise econômica mundial ocorrida no mercado imobiliário norte-americano. Imediatamente após o evento, houve uma queda média de 3,5% em nos retornos anormais acumulados. A partir daí, a terceira e última fase pode ser caracterizada como um período de estagnação, já que apesar de ter havido um crescimento, este foi irrelevante se comparado com a segunda fase do período.

4.1 Resultados da regressão linear múltipla

Foram necessários três modelos de regressão. Primeiramente o MQO com todas as variáveis propostas na seção 3.2, como consequência, o MQO apenas com as variáveis significativas e por

fim, um modelo de Mínimos Quadrados Ponderados (MQP). O terceiro foi necessário devido a ocorrência de problemas nos modelos anteriores, referentes aos pressupostos exigidos pelo método.

Com relação à confirmação de que os resíduos têm distribuição normal, a Figura 7 apresenta graficamente esta confirmação para as regressões que utilizaram o método MQO, mesmo que ela possa ser checada através da estatística Jarque-Bera¹ na Tabela 5.

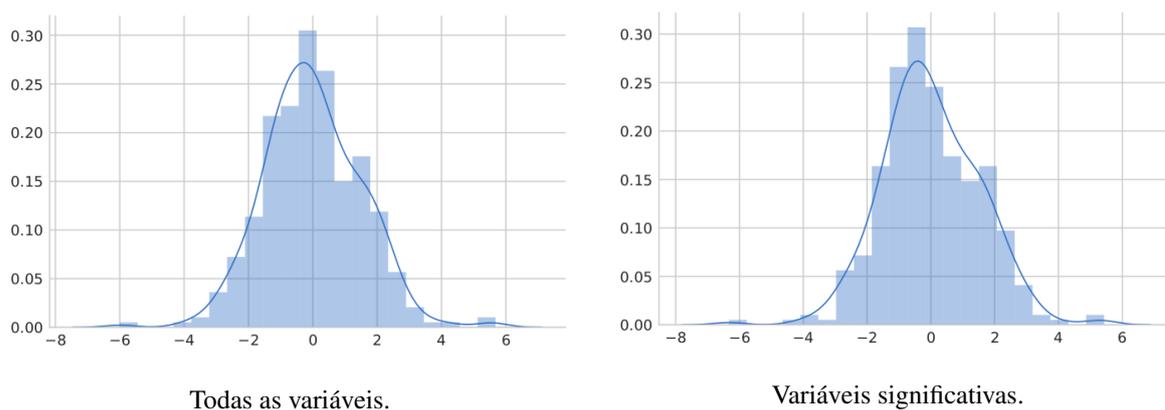


Figura 7: Teste de Normalidade dos Resíduos. Elaboração dos autores.

Apesar da confirmação de que os resíduos do modelo possuem distribuição normal, houve problema de heterocedasticidade². Segundo Wooldridge (2011), uma possível solução seria utilizar o método MQP. Objetivo deste método é fazer com que uma nova regressão seja realizada ponderada por uma matriz de pesos obtidos a partir dos resíduos dos mínimos quadrados ordinários.

A matriz de pesos utilizada na regressão MQP foi obtida a partir dos valores previstos resultantes de um modelo auxiliar. Os pesos então podem ser obtidos através da equação 8:

$$P_{i,t} = \frac{1}{e^v}, \quad (8)$$

em que $P_{i,t}$ são os pesos de cada observação e v são os valores previstos pela regressão feita utilizando mínimos quadrados ordinários.

Sendo assim, apresenta-se na Tabela 5 os resultados das regressões.

¹O teste de Jarque-Bera tem como hipótese nula a normalidade. Assim, se o valor-p for menor do que 0,05 (ou 0,10), então rejeita-se a normalidade dos resíduos. Caso contrário, aceita-se a normalidade dos resíduos.

²Pressuposto da regressão linear múltipla no qual a hipótese nula é de que os resíduos possuem variância constante. Se tal hipótese for rejeitada, os resíduos do modelo não apresentam homocedasticidade.

Tabela 5: Resultados das regressões.

Variável	Modelo MQO completo			Modelo MQO restrito			Modelo MQP					
	Coef.	Teste T	Valor-p	Significância	Coef.	Teste t	Valor-p	Significância	Coef.	Teste t	Valor-p	Significância
Intercepto	-5,92	-10,98	0,00	***	-5,98	-11,30	0,00	***	-4,86	-9,46	0,00	***
VM	2,9e-9	1,51	0,13	NS	-	-	0,00	***	3,4e-9	1,92	0,00	***
VL	-2,3e-7	-8,25	0,00	***	-2,2e-7	-8,15	0,00	***	-2,1e-7	-9,65	0,00	***
ROA	2,96	-14,75	0,00	***	2,87	14,45	0,00	***	2,81	13,69	0,00	***
ROE	-0,17	-11,22	0,00	***	-0,16	-11,03	0,00	***	-0,13	-7,12	0,00	***
E _{EIF}	3,4	7,45	0,00	***	3,33	7,66	0,00	***	2,589	5,742	0,00	***
E _{ET}	-0,0004	-0,28	0,78	NS	-	-	-	-	-	-	-	-
CR	3,10	12,11	0,00	***	3,29	16,24	0,00	***	2,68	11,12	0,00	***
GC	-2,24	-6,69	0,00	***	-2,11	-6,48	0,00	***	-3,14	-11,85	0,00	***
PE	-0,51	-1,77	0,08	*	-0,30	-1,15	-	-	-0,96	-3,20	0,00	***
UP	0,0005	0,00	0,99	NS	-	-	-	-	-	-	-	-
Estatística	Modelo MQO completo			Modelo MQO restrito			Modelo MQP					
R ²	0,769			0,764			0,848					
R ² ajust.	0,762			0,754			0,844					
Jarque-Bera	14,990			11,155			0,684					
Durbin-Watson	0,479			0,46			-					
Breush-Pagan	1,8E-13			5,9E-12			-					

Obs.: ***, **, * : 1%, 5%, 10% respectivamente; NS: não significativo.

O resultado da regressão MQP mostrou que as variáveis VM e PE, classificadas como não significativas nos resultados das regressões MQO, também são capazes de explicar o CAR de alguma forma. Além disso, com sua inclusão o modelo MQP obteve melhor ajuste (R^2 ajustado) do que o modelo MQO.

É necessário checar se as hipóteses criadas na sessão 3.2 também se confirmam após a sua execução. É válido lembrar que, por motivos de significância estatística, as variáveis *underpricing* e E_{ET} foram removidas da verificação. Portanto, apresenta-se na Tabela 6, o confronto entre os sinais esperados e observados.

Tabela 6: Sinais Esperados e Observados.

Sigla	Variável	Hipótese	Sinal Esperado	Sinal Observado
VM	Valor de Mercado	H_1	+	+
GC	Nível de Governança Corporativa	H_2	-	-
PE	Presença Capital Privado	H_3	+	-
VL	Volume Total Capitado no IPO	H_4	+	-
CR	Crise 2008	H_5	+	+
ROA	Retornos Sobre Ativos	H_6	+	+
ROE	Retornos Sobre PL	H_7	+	-

Os indicadores crise, ROA, valor de mercado e governança corporativa confirmaram as hipóteses. O resultado da regressão para estas variáveis faz sentido levando em consideração as suas naturezas. Entretanto, as variáveis ROE, volume captado e presença de capital privado contrariaram as hipóteses da seção 3.2, que por sua vez foram criadas com base nos trabalhos de KOS et al. (2017) e MINARDI et al. (2013). Estas relações inesperadas talvez possam ser explicadas por alguns fatores não captados e não inclusos no modelo, como decisões políticas e outros efeitos macroeconômicos. Já com relação à variável adicional E_{EIF} , com significância estatística de 1%, esta mostrou que há efeitos específicos de cada instituição no retorno anormal acumulado.

Cada variável considerada estatisticamente significativa na Tabela ?? obteve um valor de coeficiente próprio. As variáveis VL, ROE, GC e PE obtiveram coeficientes de $-2,114e^{-09}$, $-0,134$, $-3,140$ e $-0,9587$ respectivamente. Isto significa que um aumento (diminuição) delas ocasiona uma diminuição (aumento) proporcional a seus coeficientes no CAR. Já as variáveis VM, ROA, EEF e CR obtiveram coeficientes de $3.497e^{-07}$, 2.807 , 2.589 , 2.687 respectivamente. Isto significa que um aumento (diminuição) delas ocasiona um aumento (diminuição) proporcional a seus coeficientes no CAR.

4.2 Resultados da rede neural

Neste estudo a rede neural foi composta de cinco neurônios e apenas uma camada escondida, que realizaram 1044 reiterações para alcançar um resultado significativo. Na Figura 8 são

apresentadas todas as iterações feitas pelo algoritmo e seus respectivos resultados.

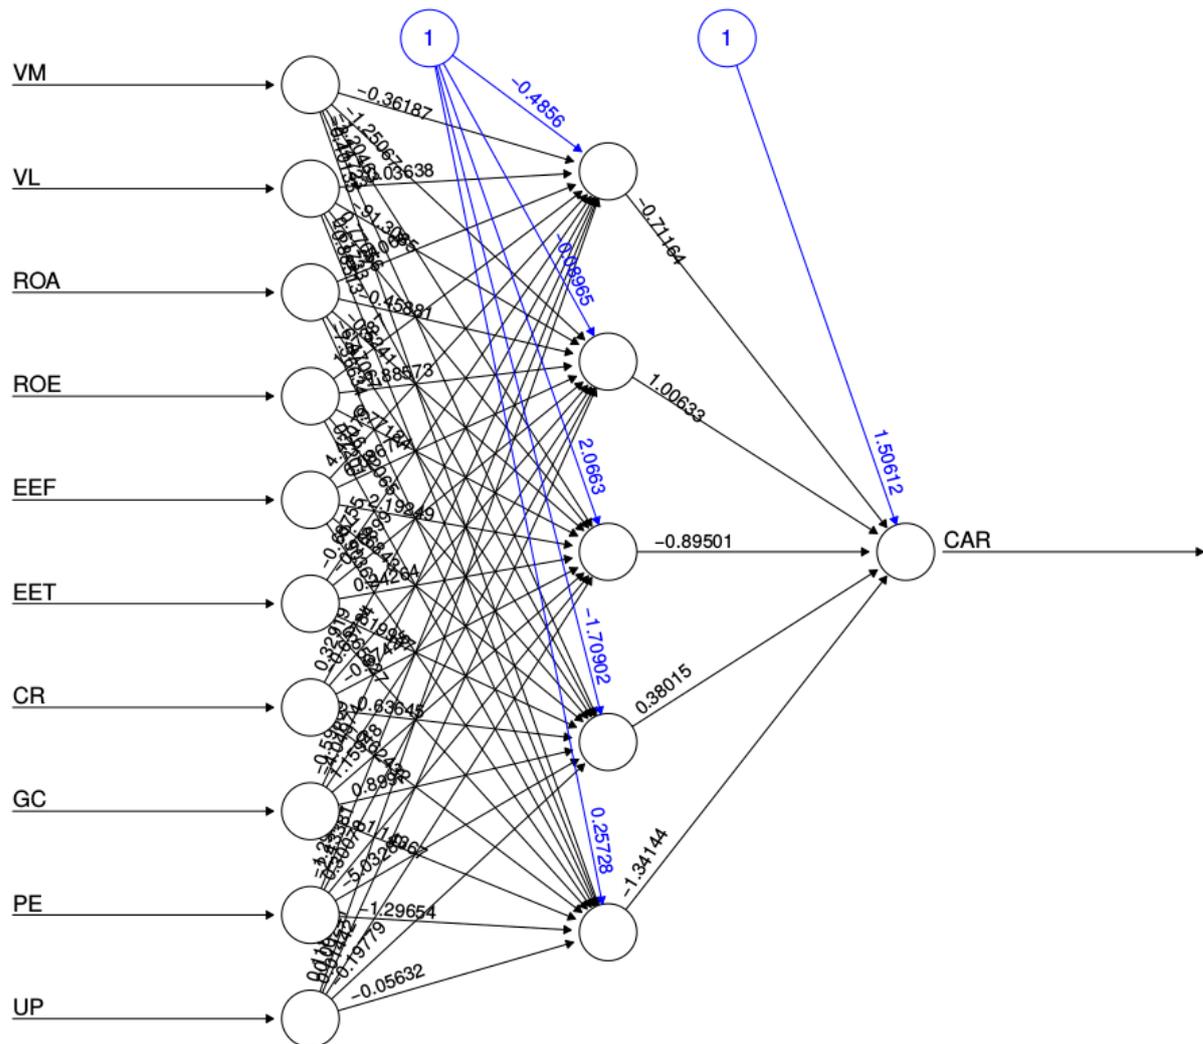


Figura 8: Resultados da rede neural.
Fonte: Pacote Neuralnet (R).

O critério para que a rede fosse estruturada com cinco neurônios foi o erro quadrado médio (EQM). Entre diversas combinações de número de neurônios e camadas utilizadas, esta obteve menor EQM. Em comparação com a regressão linear múltipla, as redes neurais obtiveram um poder de previsão significativamente maior, como pode ser observado na Tabela 7.

Tabela 7: Erro quadrado médio nos diferentes métodos.

Método	Erro Quadrado Médio
Regressão linear múltipla	2,2609
Redes neurais artificiais - teste	0,0087
Redes neurais artificiais - treinamento	0,0009

A magnitude do EQM obtido na rede neural justifica a frequência de utilização do método atualmente no mercado financeiro. Com a Figura 9, é possível uma percepção da precisão do método. Nela, tanto nos dados separados para treino quanto nos dados separados para teste, o

valores estimados e observados possuem correlação aproximadamente perfeita (0,9915 e 0,9862 respectivamente).

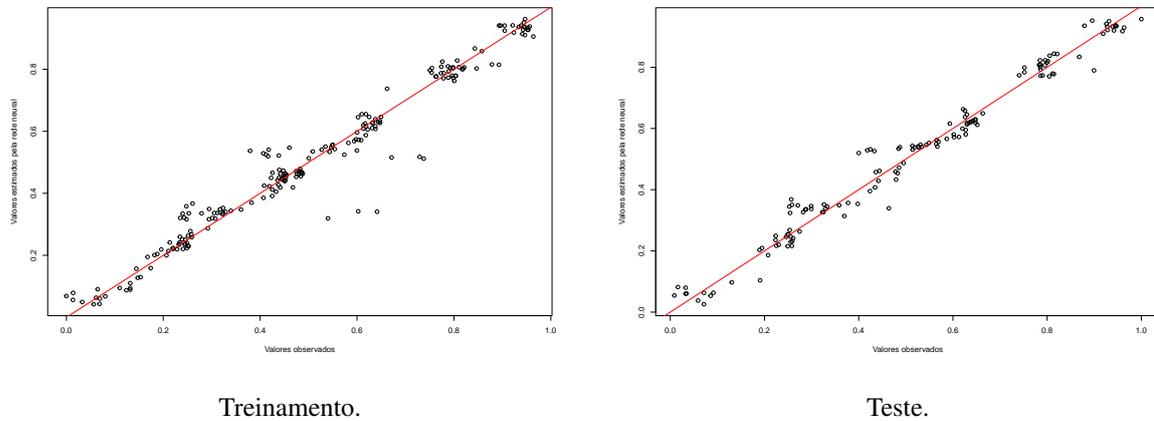


Figura 9: Valores estimados e observados. Elaboração dos autores.

Mesmo que na Figura 8 haja valores que foram considerados pela rede como os coeficientes de cada variável de entrada, não é possível entender de forma clara o que a levou a estes resultados. Tal fato é causado pelo número de retroalimentações necessárias que o método utilizou para concluir seu processo e, isto é um dos principais motivos pelos quais Pessanha (2016) o caracteriza como “caixa preta”.

Portanto, o uso de RLM e RNA de forma complementar pode ajudar a construir uma estratégia de investimento eficiente, visto que eles geram informações relevantes e particularidades de cada um.

5 Considerações finais

De acordo com os resultados obtidos na seção 4, a análise das relações observadas na Tabela 6 pode resultar em estratégias eficazes de investimento. Além disso, os resultados obtidos pela rede neural ajudam a reduzir a dicotomia existente entre risco e retorno explicitado na seção 2.1.

Assim se dá a complementariedade dos métodos proposta na seção 3.3. Com a regressão linear múltipla foi possível entender a relação de cada variável independente com o retorno anormal acumulado. Por outro lado, a rede neural conforme afirma Pessanha (2016) é uma “caixa preta” em que não é possível analisar as variáveis explicativas separadamente, entretanto seu poder de previsão (segundo o critério do erro quadrado médio) foi superior ao do método anterior.

O estudo apresentado neste trabalho buscou, através de ferramentas estatísticas, identificar fatores contábeis e macroeconômicos que pudessem explicar o comportamento do retorno

anormal acumulado nos cinco maiores bancos brasileiros. A principal motivação para realizá-lo foi que as decisões tomadas nos mercados financeiros podem afetar direta e indiretamente a sociedade. Felizmente, não são apenas as decisões no mercado financeiro que ditam o rumo da sociedade. O comportamento dela é resultado de infinitas reações às interações complexas de eventos que envolvem diversas ciências, tais como a economia, ciência política, sociologia, tecnologia, etc. Entretanto o poder econômico-político que instituições financeiras atualmente possuem, faz com que a vida cotidiana das pessoas dependa de suas estratégias mercadológicas.

Para trabalhos futuros, sugere-se investigar o retorno anormal acumulado de outros tipos de instituições utilizando outros indicadores financeiros, macroeconômicos e sociais. Além disso, sugere-se também investigar o impacto que a política econômica do Plano Real, implementada pelo governo brasileiro em 1994, tem sobre indicadores financeiros, em especial o retorno anormal acumulado.

Referências

ANACONDA SOFTWARE DISTRIBUTION. Computer software. Versão 5.0.1. Anaconda, Nov. 2017. Disponível em: <<https://anaconda.com>>. Acesso em dezembro de 2017.

ALCINO, M. S.; PESSANHA, G. R. G. Análise do Banco Santander S.A.: Os Impactos de Variáveis Macroeconômicas no Retorno Anormal das Ações. **62ª Reunião Anual da RBras e 17º SEAGRO**, 2017.

AZIZ, X. B.; BRUGNI, T. V.; FLORES, E.; DE LIMA, V. S. Ações Primárias Geram Retorno Acima da Média? Evidências de retornos anormais no mercado de capitais brasileiro. **Revista de Gestão, Finanças e Contabilidade**, v. 5, n. 2, p. 87, 2015.

BASTOS, R. M. P.; PINTO, A. C. F.; KLOTZLE, M. C.; GAMA, P. V. J. S. Fundos de investimento e desempenho pós-IPO no Brasil. **Revista Pensamento Contemporâneo em Administração**, v. 10, n. 3, 2016.

BRESSAN, A. A. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. **RAE-eletrônica**, v. 3, n. 1, 2004.

BRUNI, A. L. Risco, retorno e equilíbrio: uma análise do modelo de precificação de ativos financeiros na avaliação de ações negociadas na Bovespa (1988-1996). **Projeto de dissertação de mestrado apresentado à Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, São Paulo**, 1998.

DE JONG, A.; ROSENTHAL, L.; VAN, M. A. D. The risk and return of arbitrage in dual-listed companies. **Review of Finance**, v. 13, n. 3, p. 495-520, 2009.

- FILHO, D. F.; NUNES, F.; ROCHA, E. C.; SANTOS, M. L.; BATISTA, M.; JÚNIOR, J. A. S. O que Fazer e o que Não Fazer com a Regressão: pressupostos e aplicações do modelo linear de Mínimos Quadrados Ordinários (MQO). **Revista Política Hoje-ISSN: 0104-7094**, v. 20, n. 1, 2011.
- FREITAS, A A. C.; SILVA, I. N. Análise técnica de títulos financeiros através de redes neurais artificiais. In: **IV Congresso Brasileiro de Redes Neurais**. 1999. p. 888-999.
- FORTES, P. C. B.; SILVEIRA, R. L. F.; BACIC, M. J. Desempenho das empresas após IPO: análise da importância dos fundos de private equity. **Anais do SEMEAD**, v. 15, 2012.
- GUJARATI, D. N.; PORTER, D. C. **Econometria Básica-5**. AMGH Editora, 2011.
- HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. (2009). **Análise multivariada de dados**. Bookman Editora.
- IYENGAR, M.; PANDEY, D.; JADHAV, N. Different exit modes for PE/VC—A comparative analysis. **IJAR**, v. 2, n. 12, p. 82-85, 2016.
- JÚNIOR, D.; MARCOS, A. AM Risco: definições, tipos, medição e recomendações para seu gerenciamento. **Gestão de risco e Derivativos**. São Paulo: Atlas, 2001.
- KOHZADI, Nowrouz et al. Neural networks for forecasting: an introduction. **Canadian Journal of Agricultural Economics/Revue canadienne d'agroeconomie**, v. 43, n. 3, p. 463-474, 1995.
- KORN, R.; KORN, E.; KROISANDT, G. **Monte Carlo methods and models in finance and insurance**. CRC press, 2010.
- KOS, S. R.; BARROS, C. M. E.; COLAUTO, R. D. Impacto da divulgação de eventos subsequentes no retorno anormal: Estudo em companhias do ibovespa. **Revista Ambiente Contabil**, v. 9, n. 2, p. 60, 2017.
- KRUEGER, J. S.; LEWIS-BECK, M. S. Is ols dead?. **The Political Methodologist**, v. 15, n. 2, p. 2-4, 2008.
- MAYO, H. B. **Finanças básicas**. Cengage Learning, 2008.
- MINARDI, A. A gestão de risco financeiro. **Revista de Administração de Empresas**, v. 46, n. 4, p. 120-120, 2006.
- MINARDI, A.; FERRARI, G. L.; ARAÚJO, T. Performances of Brazilian IPOs backed by private equity. **Journal of Business Research**, v. 66, n. 3, p. 448-455, 2013.
- MUELLER, A. Uma aplicação de redes neurais artificiais na previsão do mercado acionário. Dissertação. Universidade Federal de Santa Catarina, Centro Tecnológico 1996.

- PESSANHA, G. R. G. Estudos empíricos de fusões e aquisições no setor bancário brasileiro. 2016. Lavras, 2016.
- PROCIANOY, J. L.; ANTUNES, M. A. Os efeitos das decisões de investimento das empresas sobre os preços de suas ações no mercado de capitais. **Campinas (Brasil): XXV ENANPAD**, p. 163-83, 2001.
- R Core Team (2017). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. Disponível em <<https://www.R-project.org/>>. Acesso em dezembro de 2017
- RAUBER, T. W. Redes neurais artificiais. **Universidade Federal do Espírito Santo**, 2005.
- RITTER, J. R.; WELCH, I. A review of IPO activity, pricing, and allocations. **The Journal of Finance**, v. 57, n. 4, p. 1795-1828, 2002.
- SOUZA, W. L. de. Avaliação de performance em IPOs: uma análise comparativa entre Brasil e Estados Unidos. 2016. Dissertação (Administração de Empresas) - Universidade Presbiteriana Mackenzie, São Paulo.
- SMITH, A. **A riqueza das nações**: investigação sobre sua natureza e suas causas. São Paulo: Nova Cultura, c1996.
- STEFAN F.; FRAUKE G. neuralnet: Training of Neural Networks. R package version 1.33. (2016) Disponível em: <<https://CRAN.R-project.org/package=neuralnet>>
- VELLASCO, M. M. B. R. Redes Neurais Artificiais. **Rio de Janeiro, Brasil, PUC, notas de Aula, Brasil**, 2007.
- WOOLDRIDGE, J. M. **Introdução à econometria**: uma abordagem moderna. São Paulo: Cengage Learning, 2011