



UNIVERSIDADE FEDERAL DO CEARÁ
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO, ATUÁRIAS, CONTABILIDADE
E SECRETARIADO EXECUTIVO
DEPARTAMENTO DE FINANÇAS
CURSO DE GRADUAÇÃO EM FINANÇAS

SANDY STEFANNY NASCIMENTO DE MELO

ANÁLISE SOBRE A RELAÇÃO DO RETORNO AÇIONÁRIO COM VARIÁVEIS
MACROECONÔMICAS UTILIZANDO O LASSO

FORTALEZA

2019

SANDY STEFANNY NASCIMENTO DE MELO

ANÁLISE SOBRE A RELAÇÃO DO RETORNO ACIONÁRIO COM VARIÁVEIS
MACROECONÔMICAS UTILIZANDO O LASSO

Monografia apresentada ao curso de Bacharelado em Finanças da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Bacharel em Finanças.

Orientador: Prof. Dr. Roberto Tatiwa Ferreira.

FORTALEZA

2019

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- M486a Melo, Sandy Stefanny Nascimento de.
ANÁLISE SOBRE A RELAÇÃO DO RETORNO ACIONÁRIO COM VARIÁVEIS
MACROECONÔMICAS UTILIZANDO O LASSO / Sandy Stefanny Nascimento de Melo. – 2019.
28 f.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Faculdade de Economia,
Administração, Atuária e Contabilidade, Curso de Finanças, Fortaleza, 2019.
Orientação: Prof. Dr. Roberto Tatiwa Ferreira.
1. Variáveis Macroeconômicas. 2. Retorno acionário. 3. LASSO. I. Título.

CDD 332

SANDY STEFANNY NASCIMENTO DE MELO

ANÁLISE SOBRE A RELAÇÃO DO RETORNO ACIONÁRIO COM VARIÁVEIS
MACROECONÔMICAS UTILIZANDO O LASSO

Monografia apresentada ao curso de Bacharelado em Finanças da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Bacharel em Finanças.

Aprovada em: ___/___/_____.

BANCA EXAMINADORA

Prof. Dr. Roberto Tatiwa Ferreira (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Luiz Ivan de Melo Castelar
Universidade Federal do Ceará (UFC)

Prof. Dr. Vitor Borges Monteiro
Universidade Federal do Ceará (UFC)

AGRADECIMENTOS

A Deus e à Virgem Maria, que guiaram meus passos até aqui.

Aos meus pais por todo o amor, dedicação e exemplo que formaram a pessoa que sou hoje.

Ao Prof. Dr. Roberto Tatiwa Ferreira, pela excelente orientação.

Aos professores participantes da banca examinadora Dr. Luiz Ivan de Melo Castelar e Dr. Vitor Borges Monteiro pelo tempo, pelas valiosas colaborações e sugestões.

Ao meu namorado Paulo Victor Mota Tavares, pelo amor a mim dedicado e por sempre apoiar meus estudos.

Aos meus amigos da turma de Finanças 2015.1, pela amizade e agradáveis momentos que tivemos nestes anos de graduação.

RESUMO

Diante das evidências na literatura que, de forma geral, as variáveis macroeconômicas podem influenciar o retorno acionário, surgem muitos trabalhos buscando evidenciar essa relação aplicando metodologias diversas. Neste sentido, o *Least Absolute Shrinkage and Selection Operator* (LASSO) se apresenta como uma metodologia diferenciada que seleciona variáveis relevantes em um conjunto de possíveis preditores, possibilitando que os preditores irrelevantes tenham seus coeficientes zerados (*shrink toward 0*), colaborando para modelos mais parcimoniosos e de simples interpretação. O objetivo deste trabalho é aplicar a metodologia LASSO de seleção de variáveis para relacionar o retorno de ações brasileiras com variáveis macroeconômicas do país. A base de dados utilizada conta com o retorno do índice Ibovespa e de mais seis ações do setor financeiro (ITUB4 e BBAS3), setor de consumo (ABEV3 e BRFS3) e setor de materiais básicos (PETR4 e VALE5). Para possíveis preditores, foram escolhidas 15 variáveis macroeconômicas indicadas na literatura anterior a este trabalho. A variável com maior probabilidade de inclusão foi Prêmio de Risco (contida em todas as regressões) e a ação PETR4 apresentou mais coeficientes relevantes. Com relação à previsão, foi calculado o Erro Quadrático Médio de Previsão para cada uma das ações e o resultado apontou uma qualidade de ajuste das regressões por apresentarem valor mais baixo que de outras metodologias que utilizaram a mesma base de dados, indicando uma superioridade do LASSO para previsão.

Palavras-chave: Retorno acionário. Variáveis macroeconômicas. LASSO.

ABSTRACT

In front of the evidences in the literature that, in general, macroeconomic variables can influence shareholder returns, many studies emerge trying to demonstrate this relationship by applying different methodologies. In this sense, the Least Absolute Shrinkage and Selection Operator (LASSO) presents itself as a differentiated methodology that selects relevant variables in a set of possible predictors, allowing the irrelevant predictors to have their coefficients zero (shrink toward 0), collaborating for more parsimonious and simple interpretation models. This work aims to apply the LASSO methodology of variables selection to relate the Brazilian stock returns with macroeconomic variables of the country. The database used includes the return of the Ibovespa index and a further six stock exchanges of the financial sector (ITUB4 and BBAS3), consumer sector (ABEV3 and BRFS3) and basic materials sector (PETR4 and VALE5). For possible predictors, 15 macroeconomic variables were chosen in the literature prior to this study. The variable with the highest probability of inclusion was "Prêmio de Risco", contained in all regressions. Regarding the prediction, the Average Quadratic Forecast Error was calculated for each of the equities and the result indicated a quality of adjustment of the regressions because they presented a lower value than other methodologies that used the same database, indicating a superiority of LASSO for forecasting.

Keywords: Shareholder Return. Macroeconomic variables. LASSO.

LISTA DE TABELAS

Tabela 1 – Estatísticas Descritivas Séries de Retorno Mensal (Mai/2003 – Jul/2017).....	16
Tabela 2 – Fatores Macroeconômicos.....	17
Tabela 3 – Estatísticas descritivas dos fatores econômicos (Mai/2003 a Jul/2017) – Valores em porcentagem.....	18
Tabela 4 – Coeficientes gerados pelo LASSO para cada uma das ações.....	22
Tabela 5 – Erro Quadrático Médio na Previsão <i>out-of-sample</i>	24
Tabela 6 – Erro Quadrático Médio de Previsão e λ ótimo.....	25

SUMÁRIO

1	INTRODUÇÃO.....	9
2	REVISÃO DE LITERATURA.....	11
2.1	Retorno acionário e variáveis macroeconômicas.....	11
2.2	Aplicações do LASSO na literatura.....	14
3	BASE DE DADOS.....	16
4	METODOLOGIA.....	19
5	RESULTADOS.....	22
6	CONCLUSÃO.....	26
	REFERÊNCIAS.....	27

1 INTRODUÇÃO

O sistema econômico financeiro tem agentes superavitários e deficitários, sendo os deficitários aqueles que buscam recursos com os superavitários em troca de um benefício pelo recurso disponibilizado (BERNARDELLI; BERNARDELLI, 2016). Da mesma forma podemos comparar as empresas em busca de recursos para expandir seus negócios, que emitem ações no mercado de capitais e os investidores compram desejando um retorno por este investimento.

Muitos trabalhos apontam que a saúde do mercado de capitais está ligada ao desempenho econômico do país, já que os investidores irão procurar um ambiente seguro para investir seu dinheiro, esperando obter retornos positivos aos seus investimentos. Portanto, os níveis de investimento possuem uma relação direta com o mercado financeiro (GRÔPPO, 2004).

No caso brasileiro, há um destaque para desequilíbrios macroeconômicos causados principalmente por conta da grave crise política instaurada no país, que contribuiu para o declínio do desempenho econômico do país (BERNARDELLI; BERNARDELLI, 2016). Dentre este e outros motivos, faz-se necessário o estudo do impacto destas variáveis sobre o mercado de ações brasileiro, principalmente eleger dentre as diversas variáveis macroeconômicas, aquelas que têm maior impacto sobre os retornos acionários.

Neste sentido, muitos trabalhos utilizam metodologias diversas para identificar o impacto das variáveis macroeconômicas sobre o retorno acionário, tanto do Brasil quanto de outros países do mundo. Dentre estas metodologias, podemos citar os métodos de *shrinkage*. Esses métodos têm como característica apresentarem menor variabilidade e estão na classe de estimadores de regressão com penalidade (VASCONCELOS, 2017).

Nos métodos de *shrinkage*, destacam-se seus dois extremos: a regressão *ridge* e *Least Absolute Shrinkage and Selection Operator* ou LASSO, como é mais conhecido. A regressão *ridge* utiliza uma penalização de norma 2 (L_2) aos coeficientes, que aplica uma penalização homogênea a todos eles. Já o LASSO utiliza a norma 1 (L_1) que possibilita um destaque aos preditores mais relevantes em explicar a variável que se esteja estudando. Por este motivo, o LASSO é utilizado como um seletor de variáveis.

Tibshirani (1996) desenvolveu o LASSO e argumenta que ele é superior à regressão *ridge* e os demais modelos de *shrinkage*, pois estes métodos se tornam de difícil interpretação por permanecerem com todos os preditores do modelo, mesmo quando seus

coeficientes são diminuídos quando tem menos importância na explicação da variável que se está estudando.

Neste sentido, o presente trabalho tem como objetivo aplicar a metodologia LASSO para relacionar o retorno de ações brasileiras com variáveis macroeconômicas do país. As ações foram escolhidas de diferentes setores da economia e as variáveis macroeconômicas foram selecionadas com base na literatura anterior a este estudo, seguindo base de dados de Peixoto (2017) e comparando os resultados de previsão encontrados. A metodologia é aplicada de modo a selecionar as variáveis mais importantes na explicação do retorno de cada uma das ações escolhidas.

Este estudo está dividido em 6 seções. Além desta introdução, a seção 2 faz um resumo dos principais trabalhos tratando a relação das variáveis macroeconômicas com retorno acionário e aplicações do LASSO para este mesmo contexto. Na seção 3 é apresentada a base de dados que será utilizada, com suas devidas estatísticas descritiva. Na seção 4 temos a explicação da metodologia LASSO em seus principais pontos. Na seção 5 serão apresentados os resultados obtidos com a aplicação da metodologia e por fim, na seção 6 temos o encerramento deste trabalho, trazendo as principais conclusões e a indicação de possíveis estudos futuros que podem complementar este trabalho.

2 REVISÃO DE LITERATURA

Nas seções a seguir serão expostos alguns dos trabalhos mais relevantes na literatura no que concerne à motivação para a escolha de variáveis macroeconômicas como preditores na previsão dos retornos acionários, como também algumas aplicações do LASSO para o mercado de ações e em outras áreas, de modo a mostrar os resultados já encontrados com o uso desta metodologia.

2.1 Retorno acionário e variáveis macroeconômicas

Há diversos trabalhos na literatura que estudam a relação entre variáveis macroeconômicas e retorno acionário. Em especial, estes trabalhos buscam entender quais e como estas variáveis macroeconômicas impactam o retorno acionário, se essa influência se dá positivamente ou negativamente; em magnitude para entender se esta influência é realmente relevante; e se, a partir dessa influência, pode-se prever o retorno acionário.

Perobelli, Perobelli e Arbex (2000) e Grôppo (2006) destacam a relação do retorno acionário com os instrumentos de política monetária como taxa de juros e taxa de câmbio para o caso brasileiro, de forma a compreender qual é a resposta do mercado a estas políticas, utilizando como *proxy* o retorno do índice Ibovespa. A escolha do Ibovespa como representante do mercado acionário se justifica pelo fato desse índice ser formado pelas ações das empresas com maior liquidez e maior volume financeiro negociado de todo o volume de negócios da Bolsa de Valores, além disso o Ibovespa manteve a integridade de sua série histórica e não sofreu modificações metodológicas desde sua implementação em 1968 (MARIANI, 2010). De fato, a maioria dos trabalhos nesta seção utiliza somente o Ibovespa para representar os retornos do mercado acionário como um todo, utilizando diversas metodologias para mapear a influência das variáveis macroeconômicas sobre esse índice.

Bernardelli, Bernardelli e Castro (2017) buscam analisar a influência de algumas variáveis macroeconômicas brasileiras (Produto Interno Bruto, taxa Selic Over e taxa de câmbio) e de um índice de expectativas (FECOMÉRCIO) sobre o índice Ibovespa para o período de 1995 a 2015. Os autores utilizam a metodologia de regressão linear múltipla pelos Mínimos Quadrados Ordinários. Os autores sustentam a hipótese de que as variáveis macroeconômicas são tão significantes quanto às demais utilizadas na literatura, e por isto, merecem uma atenção especial. Para conferir credibilidade ao estudo, o trabalho reúne uma

lista de trabalhos anteriores, de mesmo tema, destacando seus principais resultados, sendo alguns listados a seguir.

Grôppo (2004, 2005) faz o estudo no período entre 1995 e 2003, e encontra forte relação de retornos acionários com taxa de juros da economia brasileira, em especial a taxa de juros de curto prazo. Oliveira (2006) encontra relação positiva entre mercado acionário e taxa de câmbio no período de 1972 a 2003. Ainda para o caso brasileiro, Bernardelli e Bernardelli (2016) apontam uma expressiva correlação das variáveis acionárias com taxa de juros, inflação, taxa de câmbio e nível de atividade econômica.

Bernardelli, Bernardelli e Castro (2017) encontraram resultados condizentes com a literatura anterior ao seu estudo, destacando taxa de juros e PIB que tem relação negativa e positivamente relacionada, respectivamente, com o retorno do Ibovespa. A respeito da taxa de câmbio, o resultado divergiu dos encontrados na literatura anterior ao trabalho, apontando uma relação inversa ao retorno do Ibovespa.

Bernardelli e Bernardelli (2016) também utilizam a metodologia de Mínimos Quadrados Ordinários para analisar a influência das variáveis macroeconômicas sobre o mercado acionário, também escolhendo o índice Ibovespa como variável dependente. O trabalho seleciona como variáveis independentes as variáveis macroeconômicas taxa de câmbio média, taxa de juros SELICOVER, Índice de Preços ao Produtor Amplo (IPA) e o Produto Interno Bruto Nominal (PIB), todos em logaritmo e a base de dados é de 2004 a 2014. Os resultados rejeitam a hipótese de heterocedasticidade para todas variáveis macroeconômicas, mas para o caso de multicolinearidade, apenas a taxa SELICOVER e a taxa de câmbio média não apresentaram este problema. É calculado também o R^2 e o R^2 ajustado, onde foram encontrados valores altos para os mesmos (maior que 90%), indicando uma boa qualidade de ajustamento da regressão.

Como resultado, o trabalho encontrou relação positiva do Ibovespa com o PIB, o que está de acordo com a teoria econômica sobre o bom desenvolvimento do mercado acionário estar ligado com bons níveis de atividade econômica. Para taxa de juros e inflação, a relação encontrada com o Ibovespa é negativa. No caso da taxa de juros, no trabalho de Oliveira (2006) a relação encontrada com o Ibovespa é positiva, divergindo desse trabalho. Porém há divergências no arcabouço teórico acerca dessa relação em específico. Para taxa de câmbio, o resultado encontrado aponta que uma desvalorização cambial diminui o índice Ibovespa, significando que há uma relação positiva quando visualizada do ponto de vista da valorização do real (BERNARDELLI; BERNARDELLI, 2016).

Nunes, Costa Jr. e Meurer (2005) investigam se há relação entre um conjunto de variáveis macroeconômicas e o retorno dos ativos no mercado de ações brasileiro. O trabalho destaca em especial a relação entre o retorno dos ativos e a taxa de inflação a partir das hipóteses de *Proxy Effect*, Causalidade Reversa e Suposição Fisheriana Modificada, buscando provar ou desaprovar o pressuposto na curva de Philips. Os autores utilizam-se de uma estimativa VAR para estabelecer uma relação dinâmica entre as variáveis no período janeiro de 1995 a dezembro de 2004, selecionando como variáveis macroeconômicas relevantes o PIB (mensal e dessazonalizado fornecido pelo Banco Central do Brasil), a taxa de juros (utilizando como *proxy* a taxa SELIC), taxa de câmbio, taxa de inflação, entre outras, incluindo também variáveis *dummy* para destacar períodos de crises financeiras e quebras estruturais em países. Finalmente, os retornos do mercado de ações foram representados pelo Ibovespa.

Como resultado deste estudo, foi constatada uma relação negativa entre retornos do mercado brasileiro e a taxa de inflação, além de uma relação positiva entre o PIB e os retornos médios do Ibovespa. Também se verificou uma relação negativa pouco significativa entre taxa de juros e retornos de mercado, indicando que o Banco Central reage às oscilações das variações no mercado por intermédio de alterações nas taxas de juros, mas muito provavelmente, de forma indireta, como forma de conter pressões inflacionárias (NUNES; COSTA JR.; MEURER, 2005).

Outro trabalho que utiliza o VAR para esta temática é Silva Júnior, Menezes e Fernandez (2011). Nesse trabalho se utiliza o Ibovespa e taxas de câmbio, SELIC, PIB e IGP-M como macro-indicadores. Foi apontada uma relação significativa entre o Ibovespa e taxa de câmbio. Também foi feito o teste de causalidade de Granger, que indicaram causalidade unidirecional da taxa de câmbio para PIB e Ibovespa, como também a relação Ibovespa e SELIC tem causalidade bidirecional no sentido de Granger.

Alguns trabalhos utilizam o *Arbitrage Pricing Theory* (APT) para estudar a relação do retorno acionário com variáveis macroeconômicas. Esta metodologia é vista como uma expansão do modelo tradicional CAPM, onde os retornos dos títulos podem ser descritos por um fator sistemático. Podemos citar o trabalho de Schor, Bonomo e Pereira (1998) e Callado *et al.* (2010).

Peixoto (2017) também analisa a relação do retorno acionário com variáveis macroeconômicas utilizando a metodologia APT. Além disso, o trabalho utiliza a metodologia *Dynamic Model Avaraging* (DMA) que considera a incerteza própria dos modelos através de ponderação bayesiana e permite que os pesos e parâmetros mudem para cada período. O

diferencial deste trabalho é utilizar, além do Ibovespa, o retorno de 6 ações dos setores de materiais básicos, consumo e financeiro, de modo a analisar como se dá a influência das variáveis macroeconômicas sobre ações de setores diferentes. Os resultados deste trabalho indicaram taxa de juros e inflação como fatores fortes em influenciar os retornos das ações escolhidas.

2.2 Aplicações do LASSO na literatura

Existem diversos trabalhos na literatura onde o LASSO é utilizado em diferentes áreas da economia, devido sua característica de selecionar preditores importantes. Esta característica é especialmente importante para tratar modelos de alta dimensionalidade, onde o autor pode encontrar dificuldade em selecionar variáveis ou até mesmo de usar todas elas em uma única equação, tornando difícil a interpretação e com resultados pouco significativos. Nesta seção serão apresentados alguns destes trabalhos, com foco na justificativa para o uso do LASSO, apontando vantagens e desvantagens.

Barbosa e Guimarães (2015) utiliza o LASSO para selecionar variáveis instrumentais fracas que ajudem a prever o retorno da educação para diversas regiões do Brasil, em especial para o estado do Ceará. O uso do LASSO neste trabalho é justificado pela falta de variáveis instrumentais fortes no contexto brasileiro, sendo a metodologia LASSO, neste caso, uma alternativa factível e promissora para a estimação de equações mais apropriadas para os retornos da educação. Além disso, outra motivação para o uso do Lasso é a necessidade de haver critérios estatísticos para a escolha de variáveis, de modo que elas tenham realmente uma significância na explicação da variável endógena que se está estudando, evitando a escolha de instrumentos *ad-hoc*, ou seja, por meio somente da teoria econômica, que pode estar sujeita a enganos (BARBOSA; GUIMARÃES, 2015).

Vasconcelos (2017) estuda o comportamento de economias mundiais, em especial aplica metodologias para seleção de variáveis e escolha de modelos mais adequados para este contexto. O autor destaca a importância do modelo de Mínimos Quadrados Ordinários (MQO) como referência em relação a outros métodos de estimação, porém salienta que o método tem limitações para selecionar variáveis preditoras importantes no modelo, necessitando assim, de métodos alternativos para fazer esta seleção.

Como metodologia, o autor reúne métodos para identificação de variáveis relevantes dentro de um universo significativo de preditores, os mais utilizados na literatura entre métodos lineares e não lineares. Dentre os lineares, destacam-se os métodos de

Shrinkage, da classe de estimadores de regressões com penalidade: *elastic net*, *ridge* e LASSO. O autor faz uma comparação interessante entre o uso dos modelos *ridge* e lasso, argumentando que o LASSO tem vantagens sobre o *ridge* devido a possibilidade de alguns coeficientes do modelo que sejam pouco relevantes na explicação da variável dependente sejam próximos ou iguais a 0 (*shrink toward 0*), sendo importante ferramenta para diminuir o número de preditores em um modelo que tenha muitos, facilitando a interpretação. Além disso, o LASSO é mais eficiente em destacar os coeficientes das variáveis *signal* (variáveis realmente importantes para explicar a variável objetivo) e variáveis *noise* (variáveis não relacionados com o que se quer estudar) (VASCONCELOS, 2017).

Konzen (2014) ressalta problemas que podem ocorrer com a alta dimensionalidade de modelos, apesar de ganhos que a inclusão de muitas variáveis econômicas e financeiras podem dar. Dentre os problemas o autor cita a dificuldade de interpretação, acurácia estatística e complexidade computacional que podem ocorrer ao se utilizar de métodos tradicionais. O autor cita trabalhos que abordam o contexto multidimensional de variáveis macroeconômicas, com trabalhos que utilizam o VAR como Sims (1980) para analisar a coevolução destas variáveis. Porém, o VAR cresce quadraticamente com o número de variáveis, tornando-se inadequada sua utilização para o caso de muitas variáveis pelos motivos citados anteriormente e indicando o LASSO como uma alternativa adequada para este caso.

3 BASE DE DADOS

A base de dados utilizada neste trabalho é a mesma que foi utilizada no trabalho de Peixoto (2017) para fins de comparação. Peixoto (2017) seleciona como preditores retornos reais de 6 ações de diferentes setores da economia e o índice IBOVESPA.

As ações selecionadas foram Itaú Unibanco (ITUB4) e Banco do Brasil (BBAS3) representando o setor financeiro; AMBEV (ABEV3) e Brasil Foods (BRFS3) representando o setor de consumo; Petrobrás (PETR4) e Vale (VALE5) representando o setor de materiais básicos. Estas ações foram selecionadas com base nos critérios: apresentar alta liquidez no mercado acionário; pertencer a empresas e setores de atuação diferentes; estar sendo negociadas no BM&FBovespa desde abril de 2003 (PEIXOTO, 2017).

A base conta com dados no período entre maio de 2003 e junho de 2017 e estas informações foram retiradas do site Yahoo Finanças. Na Tabela 1 temos as estatísticas descritivas das ações escolhidas.

Tabela 1 – Estatísticas Descritivas Séries de Retorno Mensal (Mai/2003 – Jul/2017)

Sigla	Variável	Média	Desvio Padrão	Mínimo	Máximo	Mediana
IBOV	Índice Bovespa	0.47	6.54	-28.82	15.18	0.50
ABEV3	Ambev SA ON	2.08	7.48	-29.43	28.07	1.81
BBAS3	Banco do Brasil ON	0.87	11.58	-43.45	37.26	0.50
BRFS3	Brasil Foods ON	1.33	12.78	-47.95	43.65	0.24
ITUB4	Itaú PN	0.38	8.15	-31.72	20.08	0.85
PETR4	Petrobrás PN	0.11	11.71	-41.20	47.41	0.50
VALE5	Vale PN	0.58	10.84	-35.58	31.63	0.30

Fonte: Peixoto (2017).

Os retornos foram calculados como:

$$r_t = \ln(P_t/P_{t-1})$$

Onde r_t é o retorno do ativo no tempo t , P_t e P_{t-1} representam respectivamente o preço da ação no tempo t e $t - 1$. As séries de retorno foram descontadas usando a série de inflação mensal (IPCA), resultando, portanto, no retorno real (PEIXOTO, 2017).

Como preditores, Peixoto (2017) seleciona 15 fatores econômicos indicados no trabalho de Chen, Roll e Ross (1986). As variáveis selecionadas estão descritas na Tabela 2, sendo algumas delas séries derivadas, como por exemplo, Inflação Inesperada (calculada

como a diferença entre a inflação no tempo t e a inflação esperada mensurada pelo Relatório Focus para t , no tempo $t - 1$), o Prêmio de Risco (medido como a diferença entre o rendimento do Ibovespa e da TJLP), o termo estrutural (representa o retorno de longo prazo não antecipado e é calculado como a diferença entre TJLP no tempo t e SELIC no tempo $t - 1$).

Foram também utilizadas as variáveis: Índice de Commodities, o retorno do Índice Dow Jones (importante indicador de retorno acionário americano) e Risco País (medido pelo EMBI-BR) como forma de observar o efeito do setor externo (PEIXOTO, 2017). Todas estas variáveis macroeconômicas mencionadas anteriormente estão apresentadas na Tabela 2.

Tabela 2 – Fatores Macroeconômicos

Fator	Descrição	Cálculo
CAM	Variação percentual na Taxa de Cambio	$CAM_t = \ln(TC_t/TC_{t-1})$
COM	Variação percentual do Índice de Commodities	$COM_t = \ln(IC_t/IC_{t-1})$
CONS	Variação percentual Índice de Consumo	$CONS_t = \ln(C_t/C_{t-1})$
DJ	Retorno do Índice Dow Jones	$DJ_t = \ln(IDJ_t/IDJ_{t-1})$
EIPCA	Inflação Esperada	$EIPCA_t = E(IPCA_{t+1} t)$
EMBI	Variação percentual no Risco Brasil	$EMBI_t = \ln(RB_t/RB_{t-1})$
EST	Estrutura de prazo das taxas de juros	$EST_t = TJLP_t - SELIC_{t-1}$
IIPCA	Inflação Inesperada	$IIPCA_t = IPCA_t - EIPCA_{t-1}$
IND	Variação percentual no Índice de Produção Industrial	$IND_t = \ln(IPI_t - IPI_{t-1})$
DIPCA	Variação percentual no IPCA	$DIPCA_t = IPCA_t - IPCA_{t-1}$
DPIB	Variação percentual no PIB	$DPIB_t = PIB_t - PIB_{t-1}$
DPET	Variação percentual no Preço do Petróleo	$DPET_t = PET_t - PET_{t-1}$
PREMIO	Prêmio de Risco do Mercado	$PREMIO_t = IBOV_t - TJLP_t$
SELIC	Taxa de Juros para títulos públicos	$SELIC = Taxa Selic Over$
TJLP	Taxa de Juros de títulos públicos de longo prazo	$TJLP = Taxa de Juros de LP$

Fonte: Peixoto (2017).

Nota-se que estamos utilizando a variação das séries, eliminando possíveis problemas de raiz unitária (PEIXOTO, 2017). Na Tabela 3 podemos observar as estatísticas descritivas dos fatores econômicos anteriormente descritos na Tabela 2.

Tabela 3 – Estatísticas descritivas dos fatores econômicos (Mai/2003 a Jul/2017) – Valores em porcentagem

Série	Média	Desvio Padrão	Mínimo	Máximo	Mediana
CAM	0.02	3.63	-7.03	18.86	-0.54
COM	0.33	3.35	-6.98	9.65	-0.01
CONS	0.29	5.42	-27.76	24.05	0.76
DJ	0.55	3.72	-15.15	9.12	0.76
EIPCA	0.45	0.16	0.14	1.21	0.43
EMBI	-0.18	10.70	-18.21	68.55	-1.85
EST	-0.45	0.18	-1.14	-0.09	-0.44
IIPCA	0.03	0.22	-1.01	0.54	0.04
IND	0.06	1.86	-13.64	5.88	0.30
IPCA	0.47	0.27	-0.23	1.32	0.46
PIB	0.36	0.44	-1.10	1.32	0.39
PPET	0.47	8.84	-40.74	25.45	0.63
PREMIO	0.38	6.48	-28.87	15.00	0.26
SELIC	0.54	0.42	-0.50	2.12	0.52
TJLP	0.09	0.32	-0.87	1.10	0.09

Fonte: Peixoto (2017).

4 METODOLOGIA

Tibshirani (1996) propõe um novo método para estimação em modelos lineares chamado LASSO (*Least Absolute Shrinkage and Selection Operator*), sendo uma melhoria do tradicional método de Mínimos Quadrados Ordinários, a medida que acrescenta um fator de penalização do tipo L_1 . Com essa introdução, o LASSO permite que os preditores que não tenham grande importância em explicar a variável dependente tenham coeficientes nulos, sendo bastante útil para diminuir modelos de alta dimensionalidade, selecionando as variáveis realmente relevantes no estudo. Nasekin (2013) argumenta que um modelo que exclui variáveis irrelevantes possui menor erro de previsão e é mais parcimonioso.

Em um modelo linear, temos a seguinte equação, na forma vetorial:

$$y_i = \beta_0 + X_i^T \beta + \epsilon_i$$

Onde y_i é a variável resposta; β_0 é uma constante; $X_i^T = (x_{1i}, \dots, x_{ki})^T$ é o conjunto de preditores; $\beta = (\beta_1, \dots, \beta_k)^T$ é o conjunto dos parâmetros e ϵ_i representa o erro com média zero e variância σ^2 .

Dentre os métodos de estimação, o de Mínimos Quadrados Ordinários (MQO) é o mais comum para estimar parâmetros de modelos lineares. Sua forma baseia-se na minimização da soma dos quadrados dos resíduos (SQR), descrito na equação abaixo:

$$\hat{\beta} = \underset{\beta_0, \beta_1, \dots, \beta_k}{\operatorname{argmin}} \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^k \beta_j x_{ji} \right)^2 .$$

O MQO é um método eficiente e geralmente eficaz, apesar da sua simplicidade. Porém, um de seus problemas é não ser adequado quando o número de parâmetros é maior que o número de observações, além de que, com muitos preditores, o método tem grande variância apesar do baixo viés (KONZEN, 2014). Daí surge a motivação para o LASSO, que escolhe um número de coeficientes mais importantes na explicação da variável resposta, apesar de acrescentar um pouco de viés.

Segundo Breiman (1998), o LASSO enquadra-se entre as técnicas de regularização chamadas de regressões penalizadas, onde a regularização acontece pela minimização de uma função do erro, e não somente do erro isoladamente, conforme a equação seguinte:

$$Erro_{modelo} = Erro_{dados} + \lambda \times complexidade_{modelo}$$

O primeiro termo ($Erro_{modelo}$) representa a soma do quadrado dos resíduos que se iguala ao segundo termo, que é o termo de regularização, onde a complexidade do modelo é penalizada por um termo λ , que é o grau de intensidade da penalização. Sobre o termo λ , esse varia entre 0 e 1, e geralmente é otimizado via *cross-validation*. Nesta técnica, como explica Konzen (2014), a base de dados é dividida em K amostras aleatórias de mesmo tamanho. Retira-se uma das K amostras e o modelo é estimado com o restante das observações ($K - 1$ amostras). Este procedimento é feito para cada uma das K amostras, de modo a realizar previsões fora da amostra e comparar com os dados que foram retirados, ou seja, os dados originais, obtendo-se os erros de previsão para cada uma das tentativas. Faz-se a média desses erros para obter um erro quadrático médio de previsão (EQMP) único que mede a qualidade de ajuste do modelo. O λ ótimo será aquele que minimiza essa medida de erro (KONZEN, 2014).

Voltando à descrição do LASSO, sua equação principal é descrita a seguir:

$$\hat{\beta}^{LASSO} = \underset{\beta_0, \beta_1, \dots, \beta_k}{\operatorname{argmin}} \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^k \beta_j x_{ji} \right)^2 \quad \text{sujeito a} \quad \sum_{j=1}^k |\beta_j| \leq t$$

O parâmetro de ajuste é $t \geq 0$; esse controla a penalização, quanto maior for t , maior a penalização dos coeficientes na medida que aproxima os valores para 0 aos preditores menos relevantes. Importante salientar para todo t , a solução para β_0 é $\hat{\beta}_0 = \bar{y}$. Então podemos assumir, sem perda de generalidade, que $\bar{y} = 0$ e então omitir β_0 (KONZEN, 2014). Isto permite que a penalização não dependa da origem, ou seja, do seu intercepto.

Usando o Lagrangeano, podemos obter a expressão a seguir:

$$\hat{\beta}^{LASSO} = \underset{\beta_0, \beta_1, \dots, \beta_k}{\operatorname{argmin}} \left\{ \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^k \beta_j x_{ji} \right)^2 + \lambda \sum_{j=1}^k |\beta_j| \right\}$$

Nesta equação, o coeficiente λ é função de t . Logo, quanto maior λ , maior a penalização dos coeficientes. Quando $\lambda = 0$, as estimativas do LASSO se igualam às de MQO.

Se λ for muito grande, apenas modelos muito simples são obtidos e pode ser introduzido um grande viés (KONZEN, 2014).

É importante tratar a respeito da consistência do LASSO como seletor de variáveis, ou seja, se suas estimativas apontam para o modelo verdadeiro, com o número de variáveis explicativas tendendo ao infinito. O trabalho de Zhao e Yu (2006) estuda a consistência do LASSO baseado em duas premissas: se existe uma quantidade determinística de regularização que fornece a consistência na seleção e se para cada amostra existe uma quantidade correta de regularização que seleciona o modelo verdadeiro (KONZEN, 2014). Os resultados mostram que a consistência do LASSO está ligada ao montante λ que é utilizado na regularização; também neste trabalho se tem a constatação que o LASSO não é consistente em algumas circunstâncias específicas (MONTEIRO, 2017).

Neste sentido, há outros trabalhos que desenvolvem adaptações à metodologia LASSO, buscando melhorar seus pontos negativos, porém estes não serão abordados a fundo neste trabalho.

5 RESULTADOS

Os resultados encontrados com a aplicação a metodologia LASSO na base de dados escolhida estão dispostos na Tabela 4. O software utilizado para rodar o modelo foi o RStudio com o pacote “glmnet”, que permite fazer a *cross-validation* para otimizar λ e calcula os coeficientes do LASSO para a base de dados escolhida. Os resultados estão expostos na Tabela 4.

Tabela 4 – Coeficientes gerados pelo LASSO para cada uma das ações

<i>Variável/Ação</i>	<i>IBOV</i>	<i>ITUB4</i>	<i>BBAS3</i>	<i>ABEV3</i>	<i>BRFS3</i>	<i>PETR4</i>	<i>VALE5</i>
IPCA	-	-	-1.1699	-	-	-	-
SELIC	0.1845	-	-	-	-	-	-
TJLP	0.6779	-	-	-	-	0.9473	-
PIB	-	0.5115	-	-	-	-	-
IND	-	-	-	-	-	-	-
CONS	-	-	-	-	-	0.0206	-
EIPCA	-	-	-1.3465	-	-	-3.2758	-
IIPCA	-	-1.0122	-	-	-	-	-6.6611
PREMIO	0,9876	0.8279	1.3262	0.1124	0.2904	1.27	0.9245
EST	0,4244	-	-	-	-	-	-
CAM	-	-	-0.0655	-	-	-	-
EMBI	-	-	-	-0.0038	-	-	-
PPET	-	-	-	-	-	0.2544	0.0393
COM	-	-	-	-	-	-0.2414	-
DJ	-	0.1865	-	-	-	-0.2332	-
Intercepto	0.1357	-0.2312	1.5557	2.0084	1.2627	1.1294	0.3744

Fonte: Elaborada pela autora.

Analisando os coeficientes gerados pelo LASSO, observamos as variáveis que tem realmente uma significância para explicar o retorno acionário, enquanto as demais são zeradas. A variável macroeconômica PREMIO mostrou-se importante na explicação de todas as ações e o Ibovespa e teve seu coeficiente positivo para todos os casos, o que é bastante intuitivo e demonstra que uma variação positiva no prêmio de risco causa uma variação positiva no retorno acionário.

Para o retorno do Ibovespa, as variáveis que tem importância em explicá-lo aparecem todas com sinais positivos, indicando os retornos do índice aumentam com variações positivas das variáveis SELIC, TJLP, PREMIO e EST. Comparando com os trabalhos de Bernardelli e Bernardelli (2016) e Nunes, Costa Jr. e Meurer (2005), o resultado

diverge, pois foi encontrada uma relação positiva do retorno do Ibovespa com as variáveis de taxa de juros (SELIC e TJLP), enquanto nestes trabalhos a relação encontrada é negativa.

Para o retorno das ações do setor financeiro, ITUB4 e BBAS3, apenas a variável PREMIO foi comum à explicação dos seus retornos. A ação ITUB4 aponta relação positiva com o PIB e negativa com o IIPCA (Inflação Inesperada), além de uma relação positiva com a variável de Dow Jones, que é um importante indicador do retorno acionário americano, indicando que uma variação positiva no mercado americano impacta positivamente o retorno desta ação brasileira. Já a ação BBAS3 reage negativamente para três das quatro variáveis macroeconômicas importantes selecionadas pela metodologia, sendo elas variáveis de inflação e variação percentual da taxa de câmbio, indicando que uma variação positiva nestas variáveis, impacta negativamente o retorno da ação.

Para o retorno das ações do setor de consumo, ABEV3 e BRFS3, as variáveis macroeconômicas selecionadas neste trabalho apresentaram pouca importância na explicação das mesmas. Além da variável PREMIO e o intercepto, para a ação ABEV3 temos uma relação negativa com a variável de EST, que representa a diferença entre a TJLP e a taxa SELIC, porém de coeficiente muito baixo (-0,0038), quase insignificante.

Para o retorno das ações do setor de materiais básicos, PETR4 e VALE5, a metodologia LASSO destacou diversos coeficientes interessantes para interpretação e relativamente altos comparados aos demais gerados para as ações dos outros setores.

A ação que mais destacou coeficientes explicativos foi PETR4, totalizando sete variáveis macroeconômicas. Podemos explicar essa maior influência pelo fato da empresa Petrobrás ter como acionista majoritário a União Federativa do Brasil. Portanto, variações na política macroeconômica e em variáveis produtivas do país afetam em maior grau a ação PETR4 que as demais. Aqui damos destaque ao coeficiente das variáveis EIPCA (Inflação Esperada), com relação negativa, e PREMIO, com relação positiva com o retorno da ação, onde ambas tem valores maiores que 1.

A ação VALE5 teve menos variáveis macroeconômicas significantes que a PETR4, porém destaca-se a IIPCA (Inflação Inesperada) como muito relevante na explicação do retorno da VALE5, com relação negativa e coeficiente maior que 6.

Com os coeficientes estimados, foi feita a previsão dos retornos (a partir de 2007) de cada uma das ações e comparados com o retorno real observado. Foi utilizado o Erro Quadrático Médio de Previsão (EQMP) para observar a qualidade do ajuste da regressão. O EQMP é definido como:

$$EQMP = \frac{1}{N} \sum_{i=1}^N (Y_i - Y'_i)^2$$

Onde Y_i é o retorno real da ação; Y'_i é o retorno estimado e N é o número de observações. O EQMP faz a média do quadrado da diferença entre o retorno previsto e o real, de modo a calcular a capacidade preditiva do modelo, ou seja, se ele está prevendo um valor próximo do real. Com o $EQMP = 0$, o modelo está prevendo perfeitamente as observações reais, ou seja, quanto mais próximo de 0 o EQMP for, melhor ajustado está o modelo.

Para o trabalho de Peixoto (2017), foram calculados o EQMP dos 10 modelos escolhidos e os resultados estão na Tabela 5.

Tabela 5 – Erro Quadrático Médio na Previsão *out-of-sample*

	IBOV	ABEV3	BBAS3	BRFS4	ITUB4	PETR4	VALE5
AR (1)	0,00509	0,00564	0,01604	0,00670	0,00776	0,01746	0,01511
AR (1,3,6,12)	0,01211	0,00465	0,01625	0,00755	0,00749	0,01891	0,01422
DMA com λ = 0,99 e $\alpha =$ 1	0,00581	0,00435	0,01610	0,00746	0,00745	0,01708	0,01407
DMA com $\lambda = \alpha = 0,99$	0,00502	0,00455	0,01582	0,00579	0,00785	0,01761	0,01337
DMS com $\lambda = \alpha = 0,99$	0,00515	0,00512	0,01586	0,00582	0,00757	0,01771	0,01290
DMA com $\lambda = \alpha = 0,95$	0,00537	0,00481	0,01625	0,00638	0,00827	0,01862	0,01419
DMS com $\lambda = \alpha = 0,95$	0,00537	0,00554	0,01758	0,00719	0,00875	0,02001	0,01447
BMA: DMA com λ = $\alpha = 1$	0,00485	0,00459	0,01561	0,00587	0,00757	0,01748	0,01288
BMS: DMS com $\lambda = \alpha = 1$	0,00469	0,00497	0,01585	0,00623	0,00736	0,01759	0,01286
Regressão Simples	0,03117	0,00892	0,01978	0,08523	0,01166	0,04415	0,01691

Fonte: Adaptado de Peixoto (2017).

Na Tabela 6 temos o EQMP para as seis ações e o Ibovespa, juntamente com o λ ótimo que minimiza o EQMP e que foram usados para gerar os coeficientes da Tabela 4.

Tabela 6 – Erro Quadrático Médio de Previsão e λ ótimo

	ABEV3	BBAS3	BRFS3	IBOV	ITUB4	PETR4	VALE5
EQMP	0.00524222	0.00522742	0.00489606	0.00000515	0.00278829	0.00541075	0.00704897
λ	0.8200808	0.4689963	1.703614	0.09037686	0.4623555	0.3216397	0.7524041

Fonte: Elaborada pela autora.

Comparando o EQMP da previsão feita com o LASSO com o EQMP de 10 modelos estimados no trabalho de Peixoto (2017), o LASSO mostrou-se superior a todos eles, apresentando um EQMP menor para todas as ações, exceto para a ação ABEV3, que tem o valor de 0.00435 com o modelo DMA.

O índice IBOVESPA indicou o menor EQMP em comparação às outras ações e também ao EQMP dos modelos descritos em Peixoto (2017), onde o menor erro se deu para os modelos bayesianos, que tiveram um valor de 0,00469, enquanto o LASSO tem um EQMP de 0,00000515. Isto indica uma boa capacidade preditiva do LASSO e uma qualidade de ajustamento das regressões produzidas pelo mesmo, especialmente para o Ibovespa.

Quanto ao λ ótimo, podemos observar que o mesmo varia muito de ação para ação. O Ibovespa apresenta menor λ , indicando uma menor penalização para seus coeficientes, a medida que seus resultados estão próximos dos resultados de MQO tradicional. As ações ABEV3 e VALE5 apresentaram λ ótimo mais próximo de 1, indicando alta penalização que pode ser observada por suas equações serem formadas por poucas variáveis relevantes. Para a ação BRFS3, o λ ótimo que minimizou o EQMP apresentou valor maior que 1, o que pode ser explicado pela pouca relação entre as variáveis macroeconômicas e o retorno desta ação em específico.

6 CONCLUSÃO

Este trabalho teve como objetivo aplicar a metodologia LASSO para estudar a relação do retorno acionário com variáveis macroeconômicas brasileiras, destacando as mais importantes pela própria natureza da metodologia, pois o LASSO é utilizado como um seletor de variáveis, zerando os coeficientes dos preditores poucos significantes na explicação do retorno acionário e auxiliando na criação de regressões mais simples de serem interpretadas.

Um diferencial neste trabalho é o de relacionar ações de diferentes setores com as variáveis macroeconômicas utilizando a metodologia LASSO, pois a grande maioria dos trabalhos na área só se utilizam do retorno do índice Ibovespa. Como resultado, foram obtidas equações com preditores significantes e que tiveram um EQMP mais baixo que outros modelos que mantêm todos os preditores utilizando a mesma base de dados, indicando um poder preditivo superior do LASSO, dando destaque à variável PREMIO, que esteve presente em todas as equações e para a ação PETR4 que obteve o maior número de variáveis macroeconômicas relevantes.

Porém, há formas de melhorar os resultados deste trabalho, com a inclusão de variáveis de expectativa, pois os agentes tendem a preparar-se para o futuro e se antecipam a este (PEIXOTO, 2017). Bernardelli, Bernardelli e Castro (2017) mostra que a variável representante das expectativas tem relação significativa com o retorno acionário e reforça a ideia do uso desse tipo de variável no contexto brasileiro, devido às péssimas expectativas instauradas no país, principalmente pelo cenário político instável. Importante citar também a presença de volatilidade nas séries de retorno para alguns períodos, abrindo possibilidade para a introdução de um componente que capte períodos de saltos nas séries de modo a melhorar sua previsão.

Surgiram recentemente modelos que trazem adaptações à metodologia LASSO, pois essa pode gerar estimativas viesadas, devido ao *trade-off* entre variância e viés (HASTIE *et al.*, 2012). Como exemplo temos o Post-LASSO utilizado no trabalho de Barbosa e Guimarães (2015), o *Adaptive LASSO* (adaLASSO) e *Weighted Lag adaptive LASSO* (WLadaLASSO) utilizados no trabalho de Konzen (2014). Estas metodologias apresentaram erros de previsão menores que a metodologia LASSO tradicional e podem ser aplicadas para melhorar os resultados encontrados no presente trabalho.

REFERÊNCIAS

- BARBOSA, R. B.; GUIMARÃES, D. B. Estimando retornos da educação no Ceará: uma aplicação do método do Lasso para seleção de variáveis instrumentais fracas. In: ENCONTRO ECONOMIA DO CEARÁ EM DEBATE, 11., 2015, Fortaleza. **Anais...** Fortaleza: IPECE. p. 1-17. Disponível em: <<http://www2.ipece.ce.gov.br/encontro/2015/trabalhos/ESTIMANDO%20RETORNOS%20DA%20EDUCA%C3%87%C3%82O.pdf>>. Acesso em: 20 nov. 2018.
- BERNARDELLI, L. V.; BERNARDELLI, A. G. Análise sobre a Relação do Mercado Acionário com as Variáveis Macroeconômicas no Período de 2004 a 2014. **Revista Evidenciação Contábil & Finanças**, v. 4, n. 1, p. 4-17, jan./abr. 2016. Disponível em: <<http://www.periodicos.ufpb.br/ojs2/index.php/recfin/article/view/27671/15254>>. Acesso em: 20 nov. 2018.
- BERNARDELLI, L. V.; BERNARDELLI, A. G.; CASTRO, G. H. L de. A Influência das Variáveis Macroeconômicas e do Índice de Expectativas no Mercado Acionário Brasileiro: Uma Análise Empírica para os Anos de 1995 a 2015. **Revista de Gestão, Finanças e Contabilidade**, Salvador, v. 7, n. 1, p. 78-96, jan./abr. 2017. Disponível em: <file:///C:/Users/Windows/Downloads/A_Influencia_das_Variaveis_Macroeconomicas_e_do_In.pdf>. Acesso em: 20 nov. 2018.
- BREIMAN, L. Bias-variance, regularization, instability and stabilization. **NATO ASI series. Series F: COMPUTER AND SYSTEM SCIENCES**, v. 168, n. 1, p. 27-56, 1998. Disponível em: <<https://www.ingentaconnect.com/content/ssam/02581248/1998/00000168/00000001/art00002#Data>>. Acesso em: 20 nov. 2018.
- CALLADO, A. A. C. *et al.* Relações entre os retornos das ações e variáveis macroeconômicas: um estudo entre empresas do setor de alimentos e bebidas através de modelos APT. **Sociedade, Contabilidade e Gestão**, Rio de Janeiro, v. 5, n. 1, jan./jun. 2010. Disponível em: <<http://www.atena.org.br/revista/ojs-2.2.3-06/index.php/ufrrj/article/view/806/809>>. Acesso em: 20 nov. 2018.
- CHEN, N.; ROLL, R.; ROSS, S. A. Economic Forces and the Stock Market. **The Journal of Business**, v. 59, n. 3, p. 383-403, jul. 1986. Disponível em: <https://www.jstor.org/stable/2352710?seq=1#page_scan_tab_contents>. Acesso em: 20 nov. 2018.
- GRÔPPO, G. S. **Causalidade das variáveis macroeconômicas sobre o Ibovespa**. 2004. 120 f. Dissertação (Mestrado em Ciências) – Universidade de São Paulo, Piracicaba, 2004. Disponível em: <<file:///C:/Users/Windows/Downloads/gustavo.pdf>>. Acesso em: 20 nov. 2018.
- _____. Relação dinâmica entre IBOVESPA e variáveis de política monetária. ©**RAE**, v. 46, p. 72-85, 2006. Disponível em: <<http://www.scielo.br/pdf/rae/v46nspe/v46nspea06.pdf>>. Acesso em: 20 nov. 2018.

_____. Relações dinâmicas entre um conjunto selecionado de variáveis macroeconômicas e o Ibovespa. **Revista de Economia e Administração**, v. 4, n. 4, p. 445-464, 2005. Disponível em: <file:///C:/Users/Windows/Downloads/Gr%C3%B4ppo_2005_Relacoes-dinamicas-entre-um-co_25836.pdf>. Acesso em: 20 nov. 2018.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: data mining, inference and prediction**. 2. ed. Springer, 2012.

KONZEN, E. **Penalizações tipo LASSO na seleção de covariáveis em séries temporais**. 2014. 48 f. Dissertação (Mestrado em Economia) – Faculdade de Ciências Econômicas da UFRGS, Porto Alegre, 2014. Disponível em: <<https://lume.ufrgs.br/handle/10183/103896>>. Acesso em: 20 nov. 2018.

MARIANI, Luigi Filho, **Retorno Acionário e Variáveis Macroeconômicas: uma análise setorial para o Brasil**. São Paulo, 2010. 31 f. Dissertação (Mestrado) – Insper Instituto de Ensino e Pesquisa, São Paulo, 2010.

MONTEIRO, L. da S. **Uma nova aplicação para o método lasso: index tracking no mercado brasileiro**. 2017. 78 f. Dissertação (Mestrado em Administração) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2017. Disponível em: <<https://lume.ufrgs.br/handle/10183/171244>>. Acesso em: 20 nov. 2018.

NASEKIN, S. **High-Dimensional Lasso Quantile Regression Applied to Hedge Funds' Portfolio**. 2013. 76 f. Dissertação (Master of Science in Economics and Management Science) – Center of Applied Statistics and Economics Humboldt-Universität zu Berlin, Berlin, 2013. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download;jsessionid=25DD15138BABE751BEC824CBFB452B8A?doi=10.1.1.424.8623&rep=rep1&type=pdf>>. Acesso em: 20 nov. 2018.

NUNES, M. S.; COSTA JR., N. C. A. da; MEURER, R. A relação entre o mercado de ações e as variáveis macroeconômicas: uma análise econométrica para o Brasil. **RBE**, Rio de Janeiro, v. 59, n. 4, p. 585-607, out./dez. 2005. Disponível em: <<http://www.scielo.br/pdf/rbe/v59n4/a04v59n4.pdf>>. Acesso em: 20 nov. 2018.

OLIVEIRA, L. O. G. **Análise empírica da relação entre o mercado acionário e variáveis macroeconômicas: de 1972 a 2003**. Dissertação (Mestrado em Economia) - Universidade Federal de Santa Catarina, Florianópolis, 2006. Disponível em: <<https://repositorio.ufsc.br/bitstream/handle/123456789/103158/224510.pdf?sequence=1&isAllowed=y>>. Acesso em: 12 fev. 2019.

PEIXOTO, B. K. da S. **Previsão de retorno acionário: uma aplicação do Dynamic Model Avaraging**. 2017. 43 f. Trabalho de Conclusão de Curso (Graduação em Finanças) – Universidade Federal do Ceará, Faculdade de Economia, Administração, Atuária e Contabilidade, Fortaleza, 2017. Disponível em: <<http://www.repositoriobib.ufc.br/000040/00004032.pdf>>. Acesso em: 20 nov. 2018.

PEROBELLI, F. F. C.; PEROBELLI, F. S.; ARBEX, M. A. Expectativas racionais e eficiência informacional: análise do mercado acionário brasileiro no período 1997-1999. **RAC**, v. 4, n. 2, maio/ago. 2000. Disponível em: <<http://www.scielo.br/pdf/rac/v4n2/v4n2a02.pdf>>. Acesso em: 20 nov. 2018.

SCHOR, A.; BONOMO, M. A.; PEREIRA, P. L. V. **Arbitrage Pricing Theory (APT) e variáveis macroeconômicas**: um estudo empírico sobre o mercado acionário brasileiro. Texto para discussão, PUC-Rio, n. 391, 1998. Disponível em: <<https://bibliotecadigital.fgv.br/dspace/bitstream/handle/10438/603/000087858.pdf?sequence=1&isAllowed=y>>. Acesso em: 20 nov. 2018.

SILVA JUNIOR, J. C. A. da; MENEZES, G.; FERNANDEZ, R. N. Uma análise VAR das relações entre o mercado de ações e as variáveis macroeconômicas para o Brasil. **Revista Economia e Desenvolvimento**, n. 23, 2011. Disponível em: <<https://periodicos.ufsm.br/eed/article/view/4931/2962>>. Acesso em: 20 nov. 2018.

SIMS, C. A. Macroeconomics and Reality. **Econometrica**, v. 48, n. 1, p. 1-48, jan. 1980. Disponível em: <https://www.jstor.org/stable/1912017?seq=1#page_scan_tab_contents>. Acesso em: 20 nov. 2018.

TIBSHIRANI, R. Regression shrinkage and selection via lasso. **Journal of Royal Statistics Society B**, v. 58, n. 1, p. 267-288, 1996. Disponível em: <https://www.jstor.org/stable/2346178?seq=1#page_scan_tab_contents>. Acesso em: 20 nov. 2018.

VASCONCELOS, B. F. B. de. **Poder preditivo de métodos de Machine Learning com processos de seleção de variáveis**: uma aplicação às projeções de produto de países. 2017. 90 f. Tese (Doutorado em Economia) – Faculdade de Economia, Administração e Contabilidade, Universidade de Brasília, Brasília, 2017. Disponível em: <http://repositorio.unb.br/bitstream/10482/23995/1/2017_BrunoFreitasBoynarddeVasconcelos.pdf>. Acesso em: 12 fev. 2019.

ZHAO, P.; YU, B. On model selection consistency of lasso. **The Journal of Machine Learning Research**, Cambridge, v. 7, p. 2541-2563, 2006. Disponível em: <<http://www.jmlr.org/papers/volume7/zhao06a/zhao06a.pdf>>. Acesso em: 20 nov. 2018.