

Seleção de portfólios: uma análise comparativa dos cinco fatores de FAMA e FRENCH e redes neurais artificiais

Doi: 10.4025/enfoque.v37i2.38329

Kleverson Dáliton Silva Moreira

Mestrando em Administração
Universidade Federal de Uberlândia – UFU,
Faculdade de Gestão e Negócios – FAGEN,
Programa de Pós-Graduação em Administração (PPGA) da
Universidade Federal de Uberlândia - UFU,
Faculdade de Gestão e Negócios – FAGEN.
E-mail: kleversondaliton@hotmail.com
ORCID: <https://orcid.org/0000-0002-4393-284X>

Antonio Sérgio Torres Penedo

Doutor em Engenharia de Produção
Universidade Federal de Uberlândia – UFU,
Faculdade de Gestão e Negócios – FAGEN,
Programa de Pós-Graduação em Administração (PPGA)
da Universidade Federal de Uberlândia - UFU,
Faculdade de Gestão e Negócios – FAGEN.
E-mail: drpenedo@gmail.com
ORCID: <https://orcid.org/0000-0001-7763-8457>

Recebido em: 21.07.2017

Aceito em: 18.09.2017

2ª versão aceita em: 22.09.2017

RESUMO

O presente artigo buscou avaliar o desempenho de uma rede neural artificial desenvolvida com o objetivo de identificar padrões e classificar títulos em carteiras de ações de empresas do mercado de capitais brasileiro, levando em consideração os pressupostos evidenciados pela Teoria das Carteiras de Markowitz (1952) de que a formação de portfólios reduz a variabilidade e possibilita a obtenção de maiores retornos ajustados ao risco. Para isto, utilizou-se variáveis em nível da firma, componentes dos cinco fatores de Fama e French (2015), os quais, inclusive, serviram para a montagem de portfólios por meio da utilização de regressão linear múltipla com dados em painel. Os resultados comparativos dos métodos de regressão com dados em painel e redes neurais artificiais apontaram que ambas as metodologias permitiram a obtenção de retornos acima da média de mercado, no entanto, que a rede neural artificial apresenta maior capacidade de evitar títulos que sejam prejudiciais ao portfólio e permite a suavização das perdas em momentos de instabilidade.

Palavras-chave: Seleção de Portfólios; Teoria das Carteiras; Redes Neurais Artificiais.

Selection of portfolios: a comparative analysis of the five factors of FAMA and FRENCH and artificial neural networks

ABSTRACT

This paper aimed to evaluate the performance of an artificial neural network developed with the objective of identifying standards and classifying securities in Brazilian stock market in portfolios, taking into account the assumptions evidenced in Portfolio Theory by Markowitz (1952) that the formation of portfolios reduces the variability and makes it possible to obtain higher risk-adjusted returns. For this, we used firm-level variables, components of the five factors of Fama and French (2015), which were also used for the assembly of portfolios through the use of multiple linear regression with panel data. The comparative results of the regression methods with panel data and artificial neural networks indicated that both methodologies allowed to obtain returns above the market average, however, that the artificial neural network presents greater capacity to avoid securities that are detrimental to the portfolio and allows smoothing losses in times of instability.

Keywords: Portfolios Selection; Portfolio Theory; Artificial Neural Networks.

1 INTRODUÇÃO

O objetivo principal de qualquer investidor no mercado de capitais é maximizar a sua riqueza e, para isto, é necessário que escolha

um conjunto de títulos que lhe propicie o maior retorno possível. Por este motivo, segundo Oliveira, Nobre e Zárte (2013), analistas de mercado e os próprios investidores observam a movimentação do mercado visando a

Enf.: Ref. Cont.	UEM - Paraná	v. 37	n. 2	p. 141-155	maio / agosto 2018
------------------	--------------	-------	------	------------	--------------------

encontrar situações favoráveis para compra e venda de seus ativos financeiros.

Segundo Kolm, Tütüncü e Fabozzi (2014), uma das maiores quebras paradigmáticas no sentido de entender o mercado de capitais e subsidiar o processo de tomada de decisões foi a publicação da Moderna Teoria de Portfólios, em 1952, por Harry Markowitz. Segundo Nazemi e Tahmasbi (2014) o modelo construído por Markowitz é recentemente o núcleo central das decisões tomadas por analistas e sistemas de planejamento para construir carteiras de investimentos otimizadas considerando todos os riscos e retornos envolvidos.

Conforme Brealey, Myers e Allen (2011), a construção de portfólios é importante para reduzir o risco do investimento, uma vez que possibilita a diversificação. A diversificação permite uma menor variabilidade nos retornos, isto acontece pelo fato de que os títulos componentes do mercado não são perfeitamente correlacionados, e por este motivo, quando se adquire uma carteira de ações, e não somente o título de uma organização, há uma suavização das perdas. Segundo os mesmos autores, há evidências de que as ações estão se tornando mais arriscadas individualmente, no entanto, menos correlacionadas, o que aumenta os benefícios proporcionados pela diversificação.

Fama e French (1992, 1993) compreenderam que existiria a possibilidade de utilizar indicadores e dados históricos para selecionar títulos que pudessem ter maior rentabilidade no futuro. Assim, os autores analisaram diversas variáveis entre as quais se destacaram o tamanho da empresa e os índices *Market-to-book* (M/B), preço/lucro (P/L) e risco, este último ganhando destaque pelo fato de que ficou evidenciado que ao contrário do que foi proposto por Markowitz (1952), não existiria a relação negativa entre risco (baseado em dados históricos) e retorno nos períodos subsequentes.

No âmbito nacional, Santos e Montezano (2011) e Serra e Martelanc (2014) pesquisaram, pela aplicação de métodos estatísticos, quais os determinantes, de forma hierárquica, influenciam o retorno de ações, com o objetivo de possibilitar a formação de carteiras de títulos com maiores retornos usando, além das variáveis individuais das empresas já propostas por Fama e French (1992), combinações destas e até mesmo indicadores em nível da indústria. Como resultados, o primeiro estudou verificou que o

índice P/L produziu carteiras com melhores resultados, já o segundo, indicou existir uma relação significativa entre o retorno das ações e os indicadores tamanho, liquidez e *Market-book-to*, portanto, ainda apresentando resultados controversos.

Desta maneira, apesar da ampla utilização do modelo de Markowitz (1952) e dos esforços realizados por Fama e French (1992, 1993) e demais estudos que seguiram a mesma temática, Nazemi e Tahmasbi (2014) expuseram que o uso de redes neurais para otimização de portfólios trouxe a possibilidade de solução de problemas com programação não-linear, complementando assim os modelos estatísticos e lineares tradicionalmente utilizados.

Ashwood (2013) comprovou a eficiência do uso de redes neurais para a construção de portfólios, uma vez que em sua pesquisa, evidenciou que 88% dos modelos testados utilizando ações negociadas na Bolsa de Valores da Austrália produziram retornos ajustados ao risco anormais, revelando assim que os preços dos títulos analisados são ineficientes, e que esta ineficiência pode ser superada pela utilização de redes neurais para a construção de portfólios.

Assim, Mansini, Ogryczak e Speranza (2014) complementam afirmando que, atualmente, os modelos de programação linear são mais competitivos e apresentam resultados mais satisfatórios do que a utilização de modelos estatísticos tradicionais, dada a possibilidade de inclusão de maior quantidade de variáveis e a capacidade de solução de problemas mais complexos com a utilização de menos recursos.

Mais recentemente, Fama e French (2015) elaboraram um modelo de cinco fatores considerando as variáveis já utilizadas para representar o tamanho, índice M/B (*market-to-book*), P/L (preço/lucro) e acrescentando a rentabilidade e a quantidade de investimentos realizados pela empresa com o objetivo de explicar o comportamento anormal das ações em uma análise *cross-section*. Nesta pesquisa, evidenciou-se que este modelo é adequado quando se deseja mensurar e formar portfólios.

Neste contexto, considerando a incapacidade dos modelos estatísticos tradicionais, como regressões lineares (*cross-section* ou com dados em painel), em realizar análises não-lineares e as divergências verificadas na teoria acerca da possibilidade de previsão de retorno

Enf.: Ref. Cont.	UEM - Paraná	v. 37	n. 2	p. 141-155	maio / agosto 2018
------------------	--------------	-------	------	------------	--------------------

de ações que surge a contribuição desta pesquisa, que se propõe a utilizar um modelo de rede neural artificial, assim como realizado por Ashwood (2013), para captar o relacionamento das variáveis propostas nos estudos de Fama e French (1993, 2013 e 2015) e no mercado nacional principalmente por Santos e Montezano (2011) e Serra e Martelanc (2014) para verificar o potencial e a precisão da referida ferramenta nas atividades de previsão e classificação no mercado de capitais brasileiro.

Assim, este estudo apresenta o objetivo principal de elaborar um modelo de rede neural artificial para construir carteiras de investimento que possibilite os maiores rendimentos possíveis, tomando como base dados históricos, e comparar os resultados obtidos com portfólios formados pelo modelo de cinco fatores de Fama e French apoiado pelo uso de modelos estatísticos lineares (regressão com dados em painel).

Para atingir o objetivo principal, será necessário cumprir com os seguintes objetivos específicos: definir, dentre os fatores propostos por Fama e French (2015), os determinantes do retorno das ações das empresas listadas na BM&FBOVESPA; elaborar um modelo de rede neural artificial para prever e classificar os retornos de ações; montar carteiras de investimento atualizadas anualmente; comparar os resultados encontrados para o uso de métodos lineares e não-lineares para a definição de investimentos.

Portanto, este estudo se justifica com o intuito de introduzir uma nova ferramenta que apresenta grande potencial na solução de problemas complexos e que envolve relacionamentos obscuros entre variáveis buscando superar a ineficiência do mercado na precificação de ativos, além do fato de que busca propiciar uma alternativa estratégica de investimentos de maneira efetiva.

A presente pesquisa está estruturada em cinco partes, sendo que a primeira apresenta a contextualização e objetivos a serem atingidos, a segunda sessão contém a revisão de literatura acerca da construção de portfólios, Eficiência de Mercado e Redes Neurais Artificiais. A terceira destaca os aspectos metodológicos a serem utilizados, a quarta aponta e discute os resultados obtidos e a quinta apresenta as conclusões obtidas.

2 REFERENCIAL TEÓRICO

2.1 MODERNA TEORIA DE PORTFÓLIOS E EFICIÊNCIA DE MERCADO

Para Markowitz (1952), existiria uma relação positiva entre o risco inerente a cada título e seu retorno esperado, ou seja, esperava-se maior retorno ao aplicar recursos em um investimento mais arriscado, de forma a remunerar de maneira justa o aplicador. Pelo método elaborado pelo autor era possível selecionar ações para comporem uma carteira de investimentos baseado no risco inerente, medido pela variância de seus retornos e com a utilização de análise de correlação em busca de títulos negativamente correlacionados que permitissem formar portfólios com mínima possibilidade de perdas e maior probabilidade de obtenção de retornos. Desta maneira, sua pesquisa impulsionou o meio acadêmico a criar diversas ferramentas e estratégias que fossem capazes de prever o comportamento destes títulos e orientar o investidor a quais títulos deveria adquirir para compor o seu portfólio diversificado, dentre elas destacando-se o surgimento da eficiência de mercado.

Segundo Brealey, Myers e Allen (2011), a eficiência de mercado foi originalmente descoberta na pesquisa do estatístico Maurice Kendall, em 1953, em uma tentativa de encontrar padrões no comportamento dos preços de ações e commodities, no entanto, não foi verificado nenhum ciclo, e por este motivo, surgiu a expressão de que os preços seguem uma ordem aleatória (*random walk*).

Apesar disto, o termo de Eficiência de Mercado se popularizou no estudo de Fama (1970), onde o autor criou uma nova metodologia unindo estudos de eventos e o modelo de precificação de ativos (CAPM), ferramenta criada por Treynor, Sharpe, Lintner e Mossin na década de 1960, possibilitando que fosse verificado o momento exato no qual as notícias relacionadas à empresa fossem refletidas no preço das ações. De acordo a eficiência de mercado, não seria possível a obtenção de retornos anormais, uma vez que toda a informação disponível refletiria nos preços das ações imediatamente, inviabilizando a compra do título para especulações.

Após revisão da teoria e diversas descobertas sobre o tema, Fama e French (1992) publicaram novo artigo demonstrando que existiriam fatores que influenciavam os retornos médios dos ativos, sendo eles, o tamanho, índice B/M e L/P. Modelo este que

Enf.: Ref. Cont.	UEM - Paraná	v. 37	n. 2	p. 141-155	maio / agosto 2018
------------------	--------------	-------	------	------------	--------------------

foi denominado como Modelo dos Três Fatores. Ainda neste artigo, evidenciou-se que o risco, mensurado pelo beta de Markowitz (1952), não explicava os retornos dos preços das ações.

Ainda neste sentido, Haugen (1995) publicou um livro criticando a eficiência de mercado, tal qual apresentada por Fama (1970), no qual demonstrava uma compilação de estudos que comprovaram a possibilidade de obtenção de retornos anormais, desde que se formassem portfólios utilizando os pressupostos de Markowitz (1952), exceto o beta, e definindo grupos de empresas separadas entre empresas de crescimento e de valor, sendo estas últimas as que possibilitavam maiores retornos, uma vez que existiria a tendência à reversão de médias dos retornos estudados.

Carhart (1997) elaborou um modelo de quatro fatores, e Fama e French (2015) publicaram artigo com novo modelo, de cinco fatores, mediante a inclusão das variáveis lucratividade e investimentos ao modelo de três fatores originais, indicando assim a possibilidade de montagem de novas carteiras de investimento pela aplicação destes novos determinantes.

No Brasil, Rostagno, Soares e Soares (2006) elaboraram portfólios, seguindo a metodologia proposta em Haugen (1995) entre empresas de valor e de crescimento, e evidenciaram, com significância estatística, a existência de maior retorno nas estratégias de valor em relação às de crescimento em cinco dos seis indicadores analisados no período compreendido entre 1994 a 2003.

Já Santos e Montezano (2011), em sua pesquisa envolvendo empresas brasileiras listadas na bolsa de valores de São Paulo, no período de 1989 a 2009, verificaram que as ações de valor, em média apresentam menor risco, medido pelo beta, e apresentam maiores retornos do que as ações de crescimento, evidenciando assim a inexistência da relação proposta por Markowitz (1952).

Em novo estudo, realizado por Cordeiro e Machado (2013) com empresas brasileiras, no período de 1995 a 2008 com o intuito de verificar quais os determinantes dos preços das ações pela utilização de estratégias de valor e crescimento evidenciaram que empresas de crescimento apresentaram maiores retornos acumulados para o período analisado, contrariando demais estudos.

Mais recentemente, Noda, Martelanc e Kayo (2016) em análise do período de 1995 a 2013

evidenciaram que a variável L/P quando escolhida para a composição dos portfólios apresenta melhores resultados em comparação com os demais indicadores e estratégias utilizadas.

Estes estudos demonstraram não haver um consenso sobre qual a melhor estratégia utilizar, nem quais os determinantes devem ser utilizados para a formação de portfólios de investimento, além de que todos se utilizaram de modelos estatísticos lineares, insuficientes para captar toda a complexidade do mercado de capitais e por isto, sendo insuficientes para a determinação de um modelo geral, que possa ser utilizado tanto em momentos de crise, quanto em momentos de estabilidade econômica.


2.2 REDES NEURAIS ARTIFICIAIS

Haykin (2001) define uma rede neural artificial como sendo uma estrutura construída com o objetivo principal de mimetizar a forma pela qual o cérebro biológico (dentre eles o homem) processa informações recebidas do ambiente externo e as transforma em conhecimento, mediante a utilização de experiências vividas previamente.

Segundo Ashwood (2013), o modelo mais utilizado de redes neurais artificiais é composto por uma camada de input, onde os dados são inseridos na mesma, de uma camada de neurônios de entrada, uma segunda camada de neurônios ocultos, uma camada de neurônios de saída, um bias e um algoritmo de retropropagação responsável por ajustar os pesos sinápticos de forma a atingir o resultado alvo durante as etapas de treinamento. Um modelo simplificado de rede neural pode ser observado na figura 1.

Enf.: Ref. Cont.	UEM - Paraná	v. 37	n. 2	p. 141-155	maio / agosto 2018
------------------	--------------	-------	------	------------	--------------------

Figura 1 – Modelo simplificado de Rede Neural Artificial.



Fonte: adaptado de Ashwood (2013).

Segundo dados levantados em estudo bibliométrico realizado por Paliwal e Kumar (2009), as principais funções exercidas por uma rede neural artificial, assim como o cérebro humano, são as de prever e classificar dados, e apresentam como principais vantagens em comparação aos métodos estatísticos a possibilidade de aproximar qualquer função matemática não-linear de forma automática, permite a identificação de padrões mesmo quando não há semelhanças explícitas entre os dados analisados, permite trabalhar com modelos não-lineares e não-paramétricos e consegue resolver problemas de inter-relação entre as variáveis. Os autores recomendam ainda que para a maximização de sua aplicação, adotar abordagens que permitam a integração entre redes neurais e métodos estatísticos tradicionais como complementares e não concorrentes excludentes.

Para Laboissiere, Fernandes e Lage (2015) uma das principais características das redes neurais artificiais é a sua capacidade de aprender não somente pelos exemplos que lhe são fornecidos, mas também pela generalização, identificando e formando padrões que são armazenados por meio do ajuste dos pesos sinápticos, permitindo assim que sejam possíveis prever e classificar resultados com base no conhecimento

adquirido e pelas experiências acumuladas pela rede.

Segundo Nazemi e Tahmasbi (2014), uma rede neural com boa performance deve ser capaz de satisfazer algumas exigências. A primeira é de ser capaz de convergir os resultados a um estado inicial, deve conter parâmetros que não sejam variáveis e manter pontos de equilíbrio que permitam respostas exatas ou aproximadas para determinado problema.

Segundo Ashwood (2013), a utilização de redes neurais artificiais se justifica, inicialmente, pela quantidade de estudos comparativos entre modelos de regressão múltiplas os quais apontaram haver superioridade dos modelos computacionais e não-lineares para a solução de problemas relativamente complexos. O segundo motivo é de que para a redução do erro de uma regressão, é necessário a padronização de dados e satisfazer os pressupostos de que existe uma relação linear entre as variáveis, o que pode levar a uma análise incorreta no caso de existência de uma relação não-linear não identificada previamente. Por fim, os modelos de regressão são propensos à ocorrência de erros do Tipo I e Tipo II pela existência de problemas de homocedasticidade e heterocedasticidade. Desta maneira, justifica-se a utilização do

modelo de redes neurais artificiais pelas limitações impostas aos modelos de regressão comumente utilizados para a criação de portfólios de investimento no mercado de capitais.

3 METODOLOGIA

Para atingir ao objetivo de elaborar um modelo de rede neural artificial para construir carteiras de investimento que possibilite os maiores rendimentos possíveis, tomando como base dados históricos, e comparar os resultados obtidos com portfólios formados pelo modelo de cinco fatores de Fama e French apoiado pelo uso de modelos estatísticos lineares (regressão com dados em painel) serão utilizados os procedimentos metodológicos conforme apresentado nesta sessão.

3.1 AMOSTRA

Serão coletados dados anuais de todas as empresas listadas na BM&FBOVESPA no período de 2006 a 2015. Para auxiliar nesta coleta, será utilizado o banco de dados Economatica®. Os dados foram coletados com periodicidade anual com o intuito de melhorar a qualidade das informações utilizadas, uma vez que os dados contábeis utilizados são auditados apenas ao final de cada exercício, além disto, de acordo com de Oliveira, Nobre e Zárate (2013), quanto menor a frequência da amostra, mais difícil se torna a capacidade de previsão. O período de dez anos se justifica para a obtenção de uma amostra com tamanho suficiente para garantir a viabilidade de aplicação dos métodos propostos. Além disto, o período de 2006 a 2015 se justifica ainda para aplicação dos dados mais recentes disponíveis e englobar diferentes momentos econômicos, tais como momentos de estabilidade, crises financeiras, recessão etc.

Para garantir maior homogeneidade da amostra e evitar possíveis distorções, foram excluídas da amostra as empresas dos setores de finanças, seguros e fundos, conforme a classificação do Economatica, resultando assim em um total de 662 organizações com dados coletados.

3.2 VARIÁVEIS DE ESTUDO

Para a construção tanto do modelo de

regressão com dados em painel, quanto do modelo de rede neural artificial foi utilizado um conjunto de variáveis, as quais foram subdivididas em três categorias: variável dependente, variáveis de interesse e variáveis de controle.

A variável dependente deste estudo é o retorno das ações (RET), que foi calculada pela a variação percentual do preço de fechamento das ações no último dia de negociação de cada ano, conforme a pesquisa de Santos e Montezano (2011). Esta variável permite verificar o ganho que o investidor pode conseguir e não simplesmente prever o preço da ação de determinado período. Ressalta-se ainda que foi calculado apenas o retorno da classe de ações da empresa que apresentou maior volume de negociações (liquidez) no ano em análise.

Foram consideradas variáveis independentes de interesse aquelas propostas por Fama e French (2015), no denominado Modelo de Cinco Fatores, são elas: *market-to-book* (MB), tamanho (TAM), preço sobre lucro (PL), nível de investimento (INV) e Rentabilidade da empresa (RENT). Estas variáveis se justificam como de interesse, uma vez que inicialmente pretende-se analisar quais destas apresentam relação estatisticamente significativa com o retorno das ações e posteriormente, aquelas que apresentarem referida significância serão utilizadas como indicadores para a composição dos portfólios. Espera-se a obtenção de relações negativas entre as variáveis MB e TAM conforme verificado nos estudos em Haugen (1995) e Moreira et al. (2016) e PL conforme apresentado em Santos e Montezano (2011). Já as variáveis INV e RENT componentes do modelo de cinco fatores de Fama e French (2015) ainda não foram testadas no Brasil, no entanto, segundo os autores, espera-se uma relação positiva destas variáveis com o retorno das ações.

Para controlar os efeitos das variáveis de interesse com o retorno das ações, foram escolhidas variáveis de controle, as quais já apresentaram relação estatisticamente significativa entre outros estudos, desta maneira, foram utilizadas as seguintes variáveis de controle: risco (BETA), desempenho (ROA), oportunidades de crescimento (CRESC), liquidez (LIQ) e *payout* (PAY - dividendos somados a juros sobre capital próprio), bem como as variáveis independentes de teste: CRISEI (crise internacional), CRISEII (crise doméstica), PL, MB (*market-to-book*) e TAM.

Enf.: Ref. Cont.	UEM - Paraná	v. 37	n. 2	p. 141-155	maio / agosto 2018
------------------	--------------	-------	------	------------	--------------------

O beta é uma das medidas mais usadas para representar o risco de uma empresa e é calculado pela razão da covariância do retorno de mercado pelo retorno da ação e a variância do retorno de mercado dos últimos 60 meses. No entanto, espera-se que não haja comprovação da relação entre beta e retorno das ações, uma vez que Santos e Montezano (2011), Serra e Martelanc (2014) e Noda, Martelanc e Kayo (2016) evidenciaram que o beta não é uma medida de risco satisfatória no mercado acionário brasileiro, assim, existe a expectativa de que as variáveis de interesse possuam maior poder de explicação.

Como uma maneira de controlar a relação existente entre o desempenho da organização e seu retorno no mercado financeiro foi utilizada a variável ROA, a qual foi calculada pela razão entre o lucro líquido obtido no período pelo Ativo Total que a empresa mantenha, indicando o retorno sobre os investimentos realizados. Segundo Soares e Galdi (2011) existe uma relação positiva do ROA com o retorno das ações, indicando que o mercado valoriza empresas que apresentam os melhores desempenhos.

Segundo Serra e Martelanc (2014), empresas que apresentam maiores oportunidades de crescimento apresentam maior tendência à reversão de médias com menores retornos no

futuro. Assim, espera-se uma relação negativa entre as oportunidades de crescimento e o retorno futuro de uma ação.

Outra variável que pode ser utilizada como controle do retorno das ações é a liquidez, uma vez que os investidores desejam que seus títulos sejam negociáveis a qualquer momento, tendo assim seu capital disponível em momentos de dificuldade financeira, conforme apresentando Lee, Strong e Zhu (2014).

Por fim, a última variável de controle utilizada faz referência ao pagamento de dividendos, e foi denominada PAY. Esta variável foi calculada pela multiplicação entre o *dividend yield* pelo preço de fechamento da ação ao final do período. Segundo Goldstein et al. (2015), empresas que pagam maiores dividendos apresentam melhores retornos nas ações, já que isto representa mais uma maneira de remuneração ao capital investido, tornando-se mais atraente aos acionistas, desta maneira, existe a expectativa de que haja uma relação positiva para esta variável de controle.

O Quadro 1 traz o resumo das variáveis de estudo, bem como sua fórmula de cálculo e autores que evidenciaram a relação entre estas e o retorno das ações.

Variável	Tipo de Variável ^a	Sigla	Forma de Mensuração	Autores ^b
Retorno por ação	VD	RET	Retorno percentual da ação no período de um ano	(1) e (5)
Indicador Preço/Lucro	VI	PL	$\frac{\text{Cotação}}{\text{Lucro por ação}}$	(1) e (5)
Indicador Market-to-book	VI	MB	$\frac{\text{Valor de Mercado}}{\text{Valor Patrimonial}}$	(1) e (5)
Tamanho da Empresa	VI	TAM	Logaritmo natural do Valor de Mercado	(1) e (5)
Nível de Investimento	VI	INV	$\frac{\text{Ativo Total} - \text{Ativo Total}_{t-1}}{\text{Ativo Total}_{t-1}}$	(7)
Rentabilidade da empresa	VI	RENT	$\frac{\text{Lucro Líquido}_{\text{Final do período}}}{\text{Patrimônio Líquido}_{\text{Início do período}}}$	(7)
Beta (risco)	VC	BETA	$\frac{\text{Covariância (Retorno da ação, Retorno do Mercado)}}{\text{Variância (Retorno de Mercado)}}$	(1), (4) e (5)

Desempenho	VC	ROA	$\frac{\text{Lucro Líquido}}{\text{Ativo Total}}$	(3)
Oportunidades de crescimento	VC	CRESC	Variação percentual da receita bruta	(5)
Liquidez	VC	LIQ	$100 * \frac{P}{P} * \sqrt{\frac{n}{N} * \frac{p}{V}}$	(6)
Payout por ação	VC	PAY	$\text{Dividend yield} * \text{preço da ação}$	(8)

Quadro 1 – Definição das variáveis.

(a): VD = Variável Dependente; VI = Variável Independente; VC = Variável de Controle. (b): 1 – Fama e French (1992), 2 – Santos e Montezano (2011), 3 – Soares e Galdi (2011), 4 – Chen e Hill (2013), 5 – Serra e Martelanc (2014), 6 – Lee, Strong e Zhu (2014), 7 – Fama e French (2015), 8 – Goldstein et al (2015), 9 – Noda, Martelanc e Kayo (2016).

FONTE: Elaborado pelos autores com base na pesquisa.

3.3 COMPOSIÇÃO DOS PORTFOLIOS PELO MODELO DE CINCO FATORES

Inicialmente, utilizando as variáveis de estudo expostas no título anterior, será aplicado o modelo de regressão, com dados em painel, mediante utilização do *software* Stata, para a determinação de quais destes fatores apresentam relação com o retorno dos títulos em análise. Para isto, será utilizado o modelo econométrico apresentado na Equação 1.

$$RET_{it} = \alpha + \beta_1 PL_{it} + \beta_2 MB_{it} + \beta_3 TAM_{it} + \beta_4 INV_{it} + \beta_5 RENT_{it} + \beta_6 BETA_{it} + \beta_7 ROA_{it} + \beta_8 CRESC_{it} + \beta_9 LIQ_{it} + \beta_{10} PAY_{it} + \varepsilon_i \quad (1)$$

Após a análise de quais os determinantes do retorno das ações que negociam seus títulos no mercado de capitais brasileiros, por meio da aplicação do Modelo de Cinco Fatores de Fama e French (2015) com a utilização de regressão com dados em painel, serão elaborados portfólios baseados nas variáveis de interesse (MB, TAM, PL, INV, RENT) descritas no tópico anterior que apresentarem relação estatisticamente significativa.

Para a composição dos portfólios, serão utilizados os indicadores ao final do ano do ano T e será considerado o seu retorno ao final do ano T+1, possibilitando desta maneira avaliar o potencial de obtenção de retorno de

cada portfólio conforme utilizado na pesquisa de Santos e Montezano (2011), ou seja, serão utilizados os dados das variáveis de interesse para o ano de 2006 e o retorno do portfólio será considerado aquele verificado ao final do ano de 2007.

Os títulos serão divididos em duas categorias na quantidade identificada pela rede neural artificial e ordenados pela variável independente escolhida de acordo com os resultados dos modelos de regressão, sendo que a primeira categoria será aquela de títulos que devem compor o portfólio e a segunda contendo os títulos a serem rejeitados no período determinado. Como o intuito deste trabalho é conseguir formar o portfólio com o maior retorno possível, serão consideradas para análises apenas os resultados da primeira categoria para cada indicador.

Os retornos obtidos pelos portfólios formados pelo uso das variáveis de interesse com a aplicação de estatística tradicional serão posteriormente comparados entre si, com o retorno máximo possível de se atingir, com o retorno do Índice Bovespa (IBOVESPA) e com os portfólios formados pela utilização do modelo de rede neural artificial. Esta comparação terá os objetivos de verificar se é possível obter retornos maiores que a média de mercado, qual método produzirá melhores resultados e o quão perto do melhor resultado possível os portfólios conseguem chegar.

3.4 COMPOSIÇÕES DOS PORTFOLIOS COM UTILIZAÇÃO DE REDES NEURAIIS ARTIFICIAIS

Depois de construídos os portfólios de comparação, pelos determinantes obtidos do modelo de regressão, indicador de mercado e os melhores resultados possíveis, será

Enf.: Ref. Cont.	UEM - Paraná	v. 37	n. 2	p. 141-155	maio / agosto 2018
------------------	--------------	-------	------	------------	--------------------

construída uma rede neural artificial de múltiplas camadas e com algoritmo de retropropagação, com o auxílio do software de análises numéricas MATLAB.

Para isto, será utilizado o módulo de Redes Neurais artificiais do *software* citado, mais especificamente a Ferramenta de Reconhecimento de Padrões e Classificação (*Pattern Recognition and classification*), a qual, segundo a documentação do MATLAB, é recomendada para classificar elementos em categorias alvo.

Desta maneira, serão consideradas como *inputs* (dados de entrada) todas as variáveis independentes de estudo e de controle, já expostas nesta sessão. Para a etapa de treinamento da rede, será definido como *target* (valor alvo) uma nova variável, denominada TARGETRN, dividida em duas colunas, na qual o valor 1 estando na primeira indica a aceitação do título na carteira de investimento e o valor 1 na segunda coluna indica a rejeição daquele título. Esta variável será construída por meio do ordenamento anual e crescente da variável RET e aceitando-se os títulos com valores positivos. Esta categorização permite ainda que se formem portfólios com um número aproximado de títulos componentes tanto pelo modelo de regressão como pela rede neural mediante ordenação pela variável identificada pelos modelos de regressão ou pelos retornos positivos, no caso da rede neural artificial.

A variável TARGETRN será importante, pois permitirá que a rede compreenda os padrões existentes na relação entre as variáveis de estudo propostas e a classificação que se deseja para os títulos (aceitos ou rejeitados no portfólio), ajustando os pesos sinápticos para que possam realizar a tarefa de previsão de quais papéis obterão retorno positivo em determinado período futuro. O ajuste dos pesos sinápticos acontece pela comparação dos *inputs* informados com os *targets* fornecidos, definindo o peso que cada neurônio (vinculado a determinada variável) apresenta para a obtenção do resultado desejado, mediante o uso do algoritmo de retropropagação.

Além dos *inputs* e *targets*, a rede neural será constituída ainda de uma camada de neurônios ocultos, que utilizarão uma função de ativação não-linear sigmoide (em forma de S), que segundo Haikyn (2001, p. 184, 274-275) permite que cada neurônio das camadas ocultas produzam um hiperplano no espaço de decisão, assim, a combinação dos hiperplanos

do conjunto de todos os neurônios desta camada são ajustados simultaneamente, separando os padrões de classes e/ou categorias com o menor número de erros, em média. A existência desta função de ativação sigmoide permite a presença da não-linearidade na rede neural, sendo um diferencial em relação aos modelos estatísticos tradicionais. A camada de saída usará uma função *softmax* e a função de retropropagação será por gradiente escalonado conjugado.

Portanto, a rede neural artificial construída terá o objetivo de identificar os padrões presentes por todas as variáveis informadas para classificar os títulos em um portfólio que terá como meta atingir o retorno máximo possível de se obter no mercado de capitais, considerando a alteração dos referidos portfólios anualmente. Para verificar a acurácia deste método, além da comparação com os modelos estatísticos tradicionais será avaliado o erro da rede, ou seja, a capacidade desta de formar o portfólio mais eficiente possível pela análise da Matriz de Confusão gerada pelos *outputs*.

4 ANÁLISE DOS RESULTADOS

Nesta seção serão apresentados os resultados obtidos pela aplicação do modelo de regressão linear múltipla com dados em painel utilizando-se dos cinco fatores de Fama e French (2015), para serem comparados com a carteira de títulos formada pelo uso de uma rede neural artificial elaborada com o intuito de classificação de ativos, permitindo a identificação da potencialidade deste método para a tarefa de classificação de ativos financeiros rentáveis.

4.1 OS CINCO FATORES DE FAMA E FRENCH

Para início das análises, foi construída uma base de dados utilizando as variáveis especificadas na metodologia, com uma amostra abrangendo todas as empresas que negociam seus títulos na BM&FBOVESPA compreendendo os anos de 2006 a 2015. Devido à característica diversa em relação às demais companhias, foram excluídas aquelas classificadas nos setores de Finanças, Seguros e os Fundos de Investimento.

Para a correta aplicação do método, os dados obtidos foram submetidos à winsorização

Enf.: Ref. Cont.	UEM - Paraná	v. 37	n. 2	p. 141-155	maio / agosto 2018
------------------	--------------	-------	------	------------	--------------------

visando a minimizar os possíveis efeitos ocasionados pela presença de *outliers*. Em seguida, verificou-se pela análise da matriz de correlação de Pearson e do teste dos fatores de invariância (VIF) a inexistência de problemas de multicolinearidade, sendo que os valores individuais e a média das variáveis utilizadas foram todos inferiores a dez.

Por fim, para verificação de qual modelo mais se adequa aos dados analisados, procedeu-se à realização dos testes de Breusch-Pagan,

Chow e de Hausman, os quais identificaram que o modelo de efeitos fixos é o mais adequado para a situação e dados propostos.

Desta maneira, procedeu-se à realização da regressão com dados em painel, com a utilização de estimadores robustos, para eliminar possíveis problemas de autocorrelação, para evitar a contaminação dos dados e para garantir a normalidade dos erros. Os resultados obtidos estão descritos na Tabela 1.

Tabela 1 – Resultados da Regressão.

RET	Coefficiente	Erro Padrão	t	P>t	Intervalo de Confiança 95%	
PL	-0.0011	0.0010	-1.0700	0.2840	-0.0030	0.0009
MB	-0.0707	0.0214	-3.3000	0.0010***	-0.1128	-0.0285
TAM	-0.2772	0.0430	-6.4500	0.0000***	-0.3618	-0.1925
INV	-0.0226	0.0900	-0.2500	0.8020	-0.2000	0.1547
RENT	-0.0005	0.0023	-0.2300	0.8200	-0.0051	0.0040
BETA	-0.0335	0.0585	-0.5700	0.5670	-0.1488	0.0818
ROA	0.0187	0.0060	3.1400	0.0020***	0.0069	0.0304
CRESC	0.0059	0.0058	1.0300	0.3050	-0.0054	0.0173
LIQ	-3.1425	4.6721	-0.6700	0.5020	-12.3476	6.0626
PAY	0.0003	0.0003	1.0500	0.2940	-0.0003	0.0009
ANO						
2007	-0.6580	0.0489	-13.4600	0.0000***	-0.7543	-0.5617
2008	0.1356	0.0611	2.2200	0.0270	0.0152	0.2561
2009	-0.2789	0.0576	-4.8400	0.0000***	-0.3925	-0.1654
2010	-0.4937	0.0616	-8.0100	0.0000***	-0.6151	-0.3722
2011	-0.3342	0.0689	-4.8500	0.0000***	-0.4699	-0.1985
2012	-0.4427	0.0649	-6.8200	0.0000***	-0.5706	-0.3148
2013	-0.6391	0.0679	-9.4100	0.0000***	-0.7729	-0.5053
2014	-0.7981	0.0725	-11.0000	0.0000***	-0.9410	-0.6552
Constante	6.5412	0.8709	7.5100	0.0000***	4.8252	8.2571

Fonte: Elaborado pelos autores.

Pelos resultados expostos na Tabela 1, verifica-se que, dentre os cinco fatores propostos por Fama e French (2015), apenas MB e TAM apresentaram relação estatisticamente significativa e negativa em relação ao retorno obtido pelos títulos no mercado de capitais. A variável P/L seguiu o comportamento sugerido por Fama e French (1992), quando evidenciaram que a combinação das variáveis MB e TAM dissipam

o papel deste indicador sobre o retorno das ações. As variáveis INV e RENT para os dados analisados não apresentaram relação com o retorno das ações e por terem sido incluídos recentemente ao modelo, necessitam de análises mais aprofundadas para o esclarecimento desta relação. Além destes, a variável de controle ROA também apresentou relação estatisticamente significativa e positiva com o retorno das ações, assim como já evidenciado em Soares

Enf.: Ref. Cont.	UEM - Paraná	v. 37	n. 2	p. 141-155	maio / agosto 2018
------------------	--------------	-------	------	------------	--------------------

e Galdi (2011), indicando que a lucratividade da empresa está positivamente relacionada com o retorno do título no mercado de capitais, uma vez que grande parte dos investidores tomam este indicador como base de suas decisões.

As variáveis MB e TAM apresentaram resultados condizentes com Fama e French (1992) e Serra e Martelanc (2014), indicando assim que aquelas empresas que apresentam seus valores de mercado abaixo do valor contábil apresentam potencial para uma reversão de médias de forma a manter o equilíbrio destes indicadores, bem como que aquelas empresas de menor tamanho possuem maiores capacidade de crescimento a curto prazo, propiciando assim retornos anormais por períodos determinados de tempo.

4.2 REDE NEURAL ARTIFICIAL

Com o auxílio do *software* Matlab, versão 2015a, foi elaborada uma rede artificial para reconhecimento de padrões, a qual é capaz de realizar classificações, com o intuito de montar os portfólios de ações negociadas na BM&FBOVESPA. Para isto, foi utilizada a base de dados mencionada na metodologia e para possibilitar a correta aprendizagem da rede, foram excluídas as amostras com dados incompletos, permanecendo assim, 1169

observações referentes aos anos de 2006 a 2015, com retornos auferidos a partir de 2007.

Devido à complexidade no reconhecimento de padrões do retorno das ações utilizando somente os dados em nível das firmas, exigiu-se que a mesma somente fosse capaz de identificar os títulos que trouxeram retornos positivos nos anos subsequentes aos dados fornecidos, desta maneira, os títulos alvo foram determinados sendo aqueles que apresentaram retorno das ações maior que zero no período de 12 meses após sua aquisição.

Construiu-se uma rede neural com duas camadas, sendo uma oculta, e com algoritmo de retropropagação, utilizando-se de uma função sigmoide para a separação em categorias e função *softmax* na camada de saída para que seja apresentada a probabilidade de que cada título esteja em determinada classe, no caso, se deve ou não compor o portfólio a ser formado. Desta maneira, a rede conta com dez variáveis em sua camada de entrada e conseqüente dez neurônios na camada oculta e dois neurônios na camada de saída, permitindo a classificação em duas categorias, a de aceitação ou não de determinado título no portfólio. Assim, a figura 2 traz a representação gráfica da rede neural construída.




Figura 2 – Representação gráfica da Rede Neural Artificial utilizada.

Fonte: Elaborado pelos autores.

Para as etapas de treinamento, validação e testes, a amostra foi dividida em três partes, cada uma contendo 70, 15 e 15% dos dados respectivamente. A etapa de treinamento é aquela na qual os dados são apresentados à rede, contendo as variáveis bem como os respectivos resultados esperados e é pela análise dos erros desta etapa que a rede ajusta os pesos sinápticos de seus

neurônios para a generalização das funções a serem aplicadas. A etapa de validação é utilizada para mensurar a capacidade de generalização da rede e quando a mesma deixa de aprimorar sua capacidade com a entrada de novos dados. Por fim, a etapa de teste não exerce influência nos ajustes da rede e é utilizada para avaliar a performance obtida durante e após o final da etapa de treinamento.

Enf.: Ref. Cont.	UEM - Paraná	v. 37	n. 2	p. 141-155	maio / agosto 2018
------------------	--------------	-------	------	------------	--------------------

Após a etapa de testes, verificou-se que a rede apresentou um desempenho de aproximadamente 72,3% na classificação das 1169 observações submetidas, classificando corretamente 845 títulos. Quanto à performance referente à cada

categoria, observou-se que a rede se saiu melhor na classificação dos títulos que não devem compor o portfólio, determinando corretamente 73,6% destes e 69,9% dos títulos que devem ser escolhidos, conforme observa-se na Figura 3.



Figura 3 – Matriz de Confusão dos resultados da Rede Neural Artificial.

Fonte: Elaborado pelos autores.

Quanto aos aspectos práticos dos resultados obtidos foram comparados os retornos acumulados do período compreendido entre 2007 e 2015 dos portfólios formados utilizando as duas variáveis indicadas pelo método de regressão linear múltipla com dados em painel (MB e TAM), o retorno máximo possível com os títulos presentes na base de dados, o retorno médio de todos os títulos e o retorno dos portfólios formados pela rede neural artificial. O tamanho do portfólio foi determinado pelos resultados da rede neural, sendo que seu tamanho variou de zero a 154 títulos no período de doze meses.

A Tabela 2 evidencia que ambos os métodos (rede neural artificial e regressão múltipla com dados em painel) formaram portfólios com valores muito inferiores ao máximo possível, considerando-se a formação de uma carteira de investimento com os melhores títulos possíveis. No entanto, deixa claro ainda que o modelo de rede neural artificial possibilitou a obtenção de retornos superiores comparando-se com a variável MB indicada pelo modelo de regressão, no entanto, resultados inferiores ao comparado com a variável TAM.

Tabela 2 – Resultados Comparativos dos modelos em %.

Ano	MB	TAM	MAX	Média	RN	Títulos escolhidos	Títulos não escolhidos	Total de Títulos
2007	0,5535	0,5478	0,5611	0,5502	0,5579	89	1	90
2008	0,0000	0,0000	0,0000	-0,3611	0,0000	0	88	88
2009	0,7635	0,7635	0,7635	0,7635	0,7635	94	0	94
2010	0,0195	0,0366	0,4173	0,0890	0,0743	43	69	112
2011	-0,0665	-0,2174	0,3315	-0,1214	0,0839	21	100	121
2012	0,0833	0,0826	0,0999	0,0840	0,0814	154	3	157
2013	0,1114	1,2226	2,0610	-0,0457	-0,3164	2	170	172
2014	0,0000	0,0000	0,0000	-0,2052	0,0000	0	168	168
2015	-0,8908	-0,7904	0,8784	-0,2670	-0,1657	2	165	167
TOTAL ACUMULADO	0,5738	1,6453	5,1127	0,4861	1,0790	405	764	1169

Fonte: Elaborado pelos autores.

Cabe ressaltar ainda que a rede neural apresentou boa capacidade para não escolher títulos com retorno negativo, o que fica evidenciado nos anos de 2008 e 2014, nos quais os retornos médios foram de -0,3611 e -0,2052 respectivamente e nos anos de 2013 e 2015 escolheu-se somente dois títulos, anos nos quais também se verificou retornos médios negativos. Por outro lado, nos anos nos quais o retorno médio foi alto, a rede encontrou dificuldade em limitar somente os títulos mais rentáveis, escolhendo assim a maior parte das ações

disponíveis para estes períodos.

A Figura 4 representa graficamente o retorno acumulado por cada método utilizado ao longo dos anos. Fica evidente que todos os portfólios formados superaram a média do mercado, e que aquele elaborado pelo uso dos resultados da rede neural artificial foi o que se manteve mais constante no período, de forma que suavizou suas perdas em períodos de instabilidade e de quedas bruscas do mercado, o que já não ocorre pelas carteiras formadas pelos resultados da regressão com dados em painel.




Figura 4 – Evolução do retorno por portfólio.

Fonte: Elaborado pelos autores.

Enf.: Ref. Cont.	UEM - Paraná	v. 37	n. 2	p. 141-155	maio / agosto 2018
------------------	--------------	-------	------	------------	--------------------

Portanto, o modelo de rede neural artificial se apresentou como satisfatório na tarefa de realizar montagem de portfólios de ações do mercado de capitais brasileiros utilizando somente variáveis em nível da firma, no entanto, esta capacidade também deve ser avaliada ao se considerar o ambiente econômico na qual está inserida, possibilitando que haja, desta maneira, um desempenho superior ao evidenciado neste trabalho.

5 CONSIDERAÇÕES FINAIS

Este estudo se baseia nos pressupostos da Moderna Teoria de Portfólios de Markowitz (1952), de que é necessário criar carteiras de investimento otimizadas para obter os melhores retornos ajustados ao risco possíveis e que a diversificação dos títulos é a base para a menor variabilidade dos retornos, evitando assim que o investidor se depare com prejuízos não previstos anteriormente.

Para a composição destas carteiras, este artigo se propôs a utilizar o método de regressão múltipla com dados em painel utilizando os cinco fatores de Fama e French (2015) e comparar seus resultados com a aplicação de uma rede neural artificial programada para classificar se os títulos disponíveis devem ou não fazer parte da carteira do possível investidor.

Os resultados apontaram que as variáveis MB e TAM apresentam relação estatisticamente significativa e negativa com o retorno dos títulos, de acordo com Fama e French (1992) e Serra e Martelanc (2014), assim, empresas com preços de mercado inferiores ao contábil e também aquelas de menor porte apresentam maior probabilidade de obterem retornos anormais, confirmando assim que as ações consideradas como de valor apresentam melhor desempenho no mercado de capitais do que aquelas consideradas de crescimento, como exposto por Haugen (1995).

Tratando-se do uso do método de rede neural artificial, evidenciou-se que esta foi capaz de classificar corretamente 72,3% dos títulos apresentados, indicando quais deveriam ou não compor uma carteira de investimentos que possibilitasse retorno positivo nos doze meses subsequentes à sua aquisição. Estes resultados estão condizentes com aqueles obtidos por Ashwood (2013), o qual identificou que a rede neural artificial para classificação

pode apresentar dificuldade para prever reversões ou mudanças na volatilidade no mercado de capitais.

Comparando-se os resultados aplicados para composição de carteiras de investimento com indicadores selecionados pelo método de regressão múltipla com dados em painel com a rede neural artificial, verificou-se que o portfólio formado pela rede neural apresentou resultados de 1,0970%, superior ao portfólio formado pela variável MB (0,5738%) e também à média do mercado (0,4861%), no entanto, inferior ao formado pela variável TAM. Ainda ficou evidenciado que a rede neural, para classificação de títulos, permite uma suavização de perdas, uma vez que consegue identificar períodos em que o investidor não deve adquirir títulos, bem como apresenta maior capacidade de identificar aqueles que não devem ser selecionados.

Portanto, verificou-se que uma rede neural artificial de reconhecimento de padrões é capaz de montar carteiras de investimento, que possibilitem retorno no futuro utilizando somente variáveis em nível da firma e que apresenta potencial para superar os modelos de regressão com dados em painel, assim como já verificado em trabalhos como os de Oliveira, Nobre e Zarate (2013) e Ashwood (2013).

Contudo, apesar dos resultados obtidos neste estudo serem satisfatórios, acredita-se que os mesmos podem ser aprimorados com o acréscimo de variáveis que considerem o ambiente externo à empresa, já que o tem grande impacto nos resultados obtidos pelas organizações, além disto, a amostra utilizada necessitou ser reduzida pela grande quantidade de dados faltantes, inclusive daqueles títulos que apresentaram os maiores retornos, o que pode ter dificultado para o reconhecimento de padrões por parte da rede neural, assim, sugere-se para estudos futuros, uma análise de maiores períodos de tempo ou mesmo a formação de uma base de dados com maior quantidade de informações, com o intuito de maximizar o poder de classificação do modelo de rede neural artificial.

REFERÊNCIAS

ASHWOOD, A. J. **Portfolio Selection Using Artificial Intelligence**. 2013. f 170. Tese de Doutorado (*Business Administration*) – *Business School – Queensland University of Technology*, Queensland, Australia.

Enf.: Ref. Cont.	UEM - Paraná	v. 37	n. 2	p. 141-155	maio / agosto 2018
------------------	--------------	-------	------	------------	--------------------

BREALEY, R. A.; MYERS, S. C.; ALLEN, F. **Principles of Corporate Finance**. The McGraw-Hill/Irwin, 10^a ed. 2011.

CARHART, Mark M. On persistence in mutual fund performance. **The Journal of Finance**, v. 52, n. 1, p. 57-82, 1997.

CHAN, L. KC; LAKONISHOK, J.. *Are the reports of beta's death premature?*. **The Journal of Portfolio Management**, v. 19, n. 4, p. 51-62, 1993.

CORDEIRO, R. A.; MACHADO, M. A. V. *Value or Growth Strategy? Empirical Evidence in Brazil*. **Review of Business Management**, v. 15, n. 46, jan./mar. de 2013.

FAMA, E. *Efficient Capital Markets: A Review of Theory and Empirical Work*. **Journal of Finance**, vol. 25, nº 2, 1970.

FAMA, E. *The cross-section of expected stock returns*. **Journal of Finance**, v. 47, nº 2, 1992.

FAMA E., FRENCH, K. *A five-factor asset pricing model*. **Journal of Financial Economics**, v. 116, p. 1-22, 2015.

HAUGEN, R. A. **The New Finance: the case against efficient markets**. Prentice Hall: New Jersey, 1995.

HAYKIN, S. **Redes Neurais, Princípios e Prática**. 2ed. Porto Alegre: Bookman, 2001. Capítulos 1 e 2.

LABOISSIERE, L. A.; FERNANDES, R. AS; LAGE, G. G. *Maximum and minimum stock price forecasting of Brazilian power distribution companies based on artificial neural networks*. **Applied Soft Computing**, v. 35, p. 66-74, 2015.

MANSINI, R.; OGRYCZAK, W.; SPERANZA, M. G. *Twenty years of linear programming based portfolio optimization*. **European Journal of Operational Research**, v. 234, n. 2, p. 518-535, 2014.

MARKOWITZ, Harry. *Portfolio selection*. **The Journal of Finance**, v. 7, n. 1, p. 77-91, 1952.

NAZEMI, A.; TAHMASBI, N. *A computational intelligence method for solving a class of portfolio optimization problems*. **Soft Computing**, v. 18, n. 11, p. 2101-2117, 2014.

NODA, R. F.; MARTELANC, R.; KAYO, K. O. Fator de Risco Lucro/Preço em Modelos de Precificação de Ativos Financeiros. **Revista Contabilidade & Finanças**, v. 27, n. 70, jan/abr de 2016.

OLIVEIRA, F. A.; NOBRE, C. N.; ZARATE, L. E. Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index—Case study of PETR4, Petrobrás, Brazil. **Expert Systems with Applications**, v. 40, n. 18, p. 7596-7606, 2013.

PALIWAL, M.; KUMAR, U. A. *Neural networks and statistical techniques: A review of applications*. **Expert Systems with Applications**, v. 36, n. 1, p. 2-17, 2009.

ROSTAGNO, L.; SOARES, R. O.; SOARES, K. T. C. Estratégias de Valor e de Crescimento em Ações na Bovespa: uma análise de sete indicadores relacionados ao risco. **Revista Contabilidade & Finanças**, n. 42, set/dez de 2006.

SANTOS, L. R.; MONTEZANO, R. M. S. Ações de Valor e de Crescimento no Brasil: riscos e retornos de carteiras uni e bidimensionais em diferentes estados da economia. **Revista Contabilidade & Finanças**, v. 22, n. 56, mai/ago de 2011.

SERRA, R. G.; MARTELANC, R.. *Hierarchical Determinants of Brazilian Stock Returns During the 2008 Financial Crisis*. **Emerging Markets Finance & Trade**, v. 50, p. 51-67, 2014.

Endereço dos Autores:

Av. João Naves de Ávila, 2121.
Santa Mônica - Uberlândia, MG – Brasil.
CEP: 38.400 - 902

Enf.: Ref. Cont.	UEM - Paraná	v. 37	n. 2	p. 141-155	maio / agosto 2018
------------------	--------------	-------	------	------------	--------------------