

**FUNDAÇÃO INSTITUTO CAPIXABA DE PESQUISAS EM
CONTABILIDADE, ECONOMIA E FINANÇAS – FUCAPE**

SERGIO GREGORIO HERMESMEYER JUNIOR

**MAXIMIZANDO O RETORNO DE ESTRATÉGIAS DE
INVESTIMENTO BASEADAS NA ANÁLISE DE DEMONSTRAÇÕES
FINANCEIRAS IDENTIFICANDO NÍVEIS DE RELEVÂNCIA DA
INFORMAÇÃO CONTÁBIL: um teste no Brasil**

**VITÓRIA
2011**

SERGIO GREGORIO HERMESMEYER JUNIOR

**MAXIMIZANDO O RETORNO DE ESTRATÉGIAS DE
INVESTIMENTO BASEADAS NA ANÁLISE DE DEMONSTRAÇÕES
FINANCEIRAS IDENTIFICANDO NÍVEIS DE RELEVÂNCIA DA
INFORMAÇÃO CONTÁBIL: um teste no Brasil**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Contábeis, linha de pesquisa Finanças, da Fundação Instituto Capixaba de Pesquisas em Contabilidade, Economia e Finanças (FUCAPE), como requisito parcial para obtenção do título de Mestre em Ciências Contábeis, na área de concentração Finanças.

Orientador: Prof. Dr. Fernando Caio Galdi

**VITÓRIA
2011**

SERGIO GREGORIO HERMESMEYER JUNIOR

**MAXIMIZANDO O RETORNO DE ESTRATÉGIAS DE
INVESTIMENTO BASEADAS NA ANÁLISE DE DEMONSTRAÇÕES
FINANCEIRAS IDENTIFICANDO NÍVEIS DE RELEVÂNCIA DA
INFORMAÇÃO CONTÁBIL: um teste no Brasil**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Contábeis, linha de pesquisa Finanças, da Fundação Instituto Capixaba de Pesquisas em Contabilidade, Economia e Finanças (FUCAPE), como requisito parcial para obtenção do título de Mestre em Ciências Contábeis, na área de concentração Finanças.

Aprovada em 5 de setembro de 2011.

COMISSÃO EXAMINADORA

**Prof. Dr. Fernando Caio Galdi
FUCAPE**

**Prof. Dr. Bruno Funchal
FUCAPE**

**Prof. Dr. Alfredo Sarlo
UFES**

A Diovana e Davi

AGRADECIMENTOS

Ao Prof. Fernando Caio Galdi pelo incentivo à realização do curso de mestrado, pelas valiosas discussões e por sua orientação objetiva e desafiadora.

Aos que com suas críticas e sugestões contribuíram para o enriquecimento deste trabalho, em especial ao Prof. Bruno Funchal, Prof. Graziela Fortunato, Prof. Alfredo Sarlo, Spencer Greenberg e os participantes do fórum de pesquisa do EAA 2010.

À minha esposa Diovana pelo carinho, compreensão e incentivo, sem os quais este trabalho não teria sido possível.

RESUMO

A literatura de finanças apresenta diversas evidências de que investir em ações de empresas com alto índice valor patrimonial-preço (VPA/P) gera retornos acima do mercado. Adicionalmente, Piotroski (2000) mostra que uma estratégia de investimentos baseada na análise de demonstrações financeiras e que objetiva selecionar empresas com alto VPA/P e fortes financeiramente, identificadas com base em uma nota composta de nove sinais indicadores de performance, todos com o mesmo peso, melhora ainda mais os retornos dos investidores. O presente trabalho questiona se os indicadores de performance têm a mesma importância e utiliza a técnica de algoritmos genéticos para buscar um conjunto de pesos para os indicadores de performance que resultem em retornos significativamente maiores do que os obtidos por pesos uniformes. Simultaneamente, contorna o problema da baixa liquidez dos portfólios de trabalhos anteriores (Lopes e Galdi, 2007; Galdi, 2008), viabilizando sua implementação. Os resultados apontam para um retorno de 1 ano ajustado ao mercado de 19%, maior do que o método original (2%) e a média das empresas com alto índice VPA/P (11%), embora apenas a diferença para o método original seja estatisticamente significativa.

Palavras-chave: análise de demonstrações financeiras; algoritmos genéticos; investimento em ações.

ABSTRACT

The finance literature shows that investing in high book-to-market (HBM) firms yields returns higher than the market average. Additionally, Piotroski (2000) shows that an accounting-based fundamental analysis strategy to select financially strong HBM firms based on a score composed by nine performance indicators, all of them with the same weight, can shift the distribution of returns earned by investors. This paper questions whether the performance indicators really have the same importance and, using the Genetic Algorithms technique, searches a set of weights for the indicators that would result returns higher than those achieved by uniform weights. Simultaneously, a workaround to the portfolio low-liquidity problem of previous papers (Lopes and Galdi, 2007; Galdi, 2008) is proposed to allow its implementation. The results obtained show 1 year buy-and-hold adjusted return of 19%, higher than the original method (2%) and the average return of all HBM firms (11%), although only the difference to the original method is statistically significant.

Keywords: financial statement analysis; genetic algorithms; stock investment

LISTA DE TABELAS

Tabela 1 – Índices de corte VPA/P	24
Tabela 2 – Estatística Descritiva.....	25
Tabela 3 – Retornos da estratégia baseada no BrF_SCORE – Conjunto de Treino	30
Tabela 4 – Retornos da estratégia baseada no BrF_SCORE – Conjunto de Teste	31
Tabela 5 – Retornos da estratégia utilizando pesos otimizados – Conjunto de Teste	35

LISTA DE FIGURAS

Figura 1 – Representação dos mecanismos dos Algoritmos Genéticos.....	18
Figura 2 - Distribuição de liquidez das ações com alto índice VPA/P entre 1997 e 2009	24
Figura 3 – Pesos dos Indicadores	32
Figura 4 – Retornos médios ajustados de 1 e 2 anos para a estratégia <i>buy-and-hold</i> utilizando informações financeiras no período de teste	33
Figura 5 – Retornos anuais da estratégia buy-and-hold de 1 ano.....	36
Figura 6 – Retornos anuais da estratégia buy-and-hold de 2 anos	37

SUMÁRIO

1	INTRODUÇÃO	10
2	REFERENCIAL TEÓRICO	14
2.1	DA ANÁLISE FUNDAMENTALISTA AO BRF_SCORE	14
2.2	ALGORITMOS GENÉTICOS.....	17
3	DESCRIÇÃO DA METODOLOGIA	22
4	RESULTADOS.....	32
5	CONCLUSÃO	40
	REFERÊNCIAS.....	43

Capítulo 1

1 INTRODUÇÃO

O investimento em *value stocks* é tema recorrente na literatura (Graham e Dodd, 1934; Fama e French, 1995). Há ampla evidência, particularmente em mercados desenvolvidos, de que carteiras compostas por ações com alto índice valor patrimonial-preço (VPA/P) gera retornos acima dos obtidos por carteiras compostas por ações com baixo índice VPA/P. Rosenberg, Reid e Lanstein (1984), Fama e French (1992, 1995) e Lakonishok *et al.* (1994), concordam com a evidência de que o índice VPA/P está fortemente e positivamente correlacionado com o desempenho futuro das ações.

Abarbanell e Bushee (1997) relatam que uma estratégia de investimento baseada em sinais financeiros ajuda investidores a obter retornos anormais significativos. Com relação a sinais financeiros específicos, Sloan (1996) encontra evidências de que empresas com maiores quantidades de *accruals* (diferença entre lucro e fluxo de caixa operacionais) têm desempenho inferior no futuro. Piotroski (2000) agrega o efeito do alto índice VPA/P à análise de demonstrações financeiras e mostra que o retorno médio obtido por um investidor pode ser aumentado em pelo menos 7,5% ao ano pela seleção de empresas com alto índice VPA/P fortes financeiramente. Piotroski (2000) propõe uma estratégia baseada na análise de demonstrações financeiras para selecionar ações com potencial para exceder o retorno médio de mercado. A estratégia consiste em selecionar empresas com alto índice VPA/P e classificá-las de acordo com um sistema de

pontos baseado em sinais financeiros. Quando o sinal é dito positivo (ou bom), o indicador é igual a 1; quando é negativo (ou ruim), o indicador é igual a zero. A soma de todos os indicadores resulta o escore obtido pela empresa. Nove sinais financeiros e seus respectivos indicadores compõem a estratégia e foram escolhidos para refletir a rentabilidade, estrutura de capital e eficiência operacional: retorno sobre os ativos, variação do retorno sobre os ativos, *accruals*, fluxo de caixa, variação da liquidez, variação da alavancagem, variação da margem bruta, giro do ativo e oferta pública de ações. Lopes e Galdi (2007) e Galdi (2008) adaptaram esta estratégia ao mercado brasileiro, também obtendo retornos acima da média significativos.

A estratégia acima assume que todos os indicadores possuem igual importância na formação do escore e assim, possuem igual relevância para o mercado. A literatura tem, contudo, mostrado diferente relevância para os indicadores financeiros: Sloan (1996) aponta que os investidores tendem a se fixar no lucro, menosprezando o conteúdo informacional contido no fluxo de caixa e nos *accruals*. Ou e Penman (1989) constroem um indicador para prever lucros futuros baseado em 68 indicadores contábeis ponderados diferentemente, enquanto Abarbanell e Bushee (1998) identificam variações de estoque e nível de investimentos como fortes preditores de lucro futuro. Bartov *et al.* (2001) mostram que a relevância de lucro e fluxo de caixa varia entre países, sendo que em geral, o lucro provê mais informação para a avaliação de empresas em países anglo-saxões, enquanto em países não-anglo-saxões o lucro não possui conteúdo informacional maior do que o fluxo de caixa.

O objetivo deste trabalho é contribuir para a identificação de diferentes níveis de importância para os indicadores financeiros no mercado brasileiro no

contexto das empresas com alto índice VPA/P. A abordagem empregada é diferente da tradicionalmente utilizada, por meio de regressões: se houver um conjunto de pesos λ_i para os indicadores F_i que otimize a seleção de ações, o retorno da estratégia seria ainda maior do que aqueles encontrados nos estudos anteriores. Além disso, este conjunto de pesos contribuiria para a discussão de quais indicadores financeiros são considerados mais relevantes para o mercado. Adicionalmente, este trabalho estabelece para a amostra um limite mínimo de liquidez das ações, endereçando assim a maior dificuldade para a implementação da estratégia proposta por Lopes e Galdi (2007) e Galdi (2008).

Atribuir pesos a indicadores financeiros para formar um valor escalar não é uma idéia nova. Por exemplo, Ou e Penman (1989) propõem este método para prever o retorno de ações e utilizam um modelo logit para estimar pesos para indicadores financeiros. Neste trabalho, porém, uma técnica computacional comumente utilizada para otimização, conhecida como Algoritmos Genéticos (AGs), foi utilizada para encontrar o conjunto de pesos λ_i que maximizam o retorno de uma carteira.

Este trabalho contribui para a literatura propondo maior discussão sobre a métrica utilizada na maioria dos estudos citados. A seleção de sinais para realizar a análise de demonstrações financeiras é por si só uma tarefa discricionária, assim como o uso de uma ponderação uniforme para estes sinais. Este trabalho verifica se uma técnica de Inteligência Artificial pode, consistentemente, aumentar o retorno de estratégias baseadas na análise de demonstrações financeiras. Se a atribuição de pesos uniformes para todos os sinais financeiros é arbitrária, por que não tentar otimizar o resultado de uma estratégia de investimento permitindo que os pesos variem? Estes pesos poderiam revelar alguma peculiaridade que poderia

ser utilizada na análise de demonstrações financeiras, considerando as características do mercado no qual as empresas estão inseridas?

Na mesma linha de Lopes e Galdi (2007) foi utilizado o mercado de capitais brasileiro, uma proeminente economia emergente, para testar a estratégia de investimento considerando que os pesos obtidos pelo algoritmo de otimização podem ser significativamente diferentes daqueles obtidos quando implantando a estratégia em um mercado desenvolvido.

Os resultados mostram que o método baseado nos pesos uniformes perde eficácia quando estabelecido o limite mínimo de liquidez, obtendo retorno de 1 ano ajustado ao mercado de 2% (estratégia *buy-and-hold*), bastante abaixo da média de todas as empresas com alto índice VPA/P (11%). De forma contrária, os pesos obtidos no processo de otimização levam a um retorno de 1 ano ajustado ao mercado de 19%. A análise mostra que os sinais mais relevantes são os *accruals* e o ROA, embora com sinal contrário ao esperado. Estes resultados podem levantar a discussão acerca da sobre-reação do mercado a determinados indicadores financeiros e em que momento ocorrem.

O restante do trabalho está organizado conforme segue. O capítulo 2 a estratégia adaptada por Lopes e Galdi (2007) ao mercado brasileiro é apresentada. O capítulo 3 apresenta as principais características dos algoritmos genéticos. O capítulo 4 apresenta a descrição do experimento realizado e mostra como a estratégia foi implementada. Os resultados são apresentados no capítulo 5. O capítulo 6 conclui o trabalho.

Capítulo 2

2 REFERENCIAL TEÓRICO

2.1 DA ANÁLISE FUNDAMENTALISTA AO BRF_SCORE

A premissa de que as características financeiras de uma empresa podem estar relacionadas com o seu valor real é o tema central da análise fundamentalista (Damodoran 2002). Há vasta literatura mostrando várias maneiras de como a interpretação destas características pode levar à composição de carteiras que podem ter o desempenho acima da média de mercado. Particularmente, a seleção de empresas com alto índice VPA/P comprovou ter sucesso, sendo a causa dos retornos superiores assunto entre pesquisadores: uma corrente defende que os investidores seriam pessimistas demais em relação às *value stocks*, levando um erro de precificação (Lakonishok, Schleifer, Vishny 1994; Skinner e Sloan 2002), enquanto outros afirmam que o retorno superior é apenas a justa recompensa pelo maior risco destas ações (Fama e French 1992).

Contudo, Piotroski (2000) aponta que este retorno superior se deve ao forte desempenho de poucas empresas, tolerando a fraca performance da maior parte das demais. O autor propõe uma estratégia baseada em valores contábeis com o objetivo de, por meio da identificação de sinais positivos, selecionar entre empresas com alto índice VPA/P somente aquelas que teriam retorno acima do mercado. Ele propõe a observação de nove índices financeiros para avaliar as empresas em termos de rentabilidade, estrutura de capital e eficiência operacional:

retorno sobre os ativos, variação do retorno sobre os ativos, *accruals*, fluxo de caixa, variação da liquidez, variação da alavancagem, variação da margem bruta, giro do ativo e oferta pública. Segundo o autor, retorno sobre os ativos, sua variação com relação ao ano anterior e fluxo de caixa, quando positivos, são tidos como “bons”, pois mostram capacidade de gerar recursos internamente. Já *accruals* positivos, segundo Sloan (1996), estão negativamente relacionados com resultados futuros e são portanto “ruins”. Ainda segundo Piotroski (2000), redução da liquidez e aumento da alavancagem são considerados “ruins”, tendo em vista que grande parte das empresas com alto índice VPA/P estaria financeiramente estressada. A realização de oferta pública de ações também seria um mau sinal para empresas financeiramente estressadas, indicando que elas não estariam gerando recursos suficientes internamente para cumprir com suas obrigações. Finalmente, aumento da margem e do giro são tidos como “bons” por refletirem melhoria da eficiência operacional.

A estratégia é simples: cada variável está associada a um indicador, igual a um quando o valor da variável é tido como “bom” para o desempenho da empresa e igual a zero quando for tido como “ruim”. A soma de todos os nove indicadores resulta em um escore (F_SCORE). A cada ano, após todas as empresas terem publicado os seus resultados, calcula-se o F_SCORE e o índice VPA/P das empresas, ordenando-as relação a este índice. Aquelas pertencentes ao maior quinto do índice VPA/P são identificadas e, dentre elas, aquelas com o maior F_SCORE são selecionadas para serem mantidas em carteira por 1 e 2 anos (*buy-and-hold*). A aplicação desta técnica no mercado norte-americano levou a retornos ajustados ao mercado (acima da média de mercado) de 13,4% e 28,7% para o período de 1 e 2 anos, respectivamente.

Lopes e Galdi (2007), adaptando a proposta de Piotroski (2000) às características do mercado brasileiro, alteraram o F_SCORE criando o BrF_SCORE:

$$BrF_SCORE = F_ROA + F_ΔROA + F_ACCRUAL + F_CF + F_ΔLIQUID + F_ΔLEVER + F_ΔMARGIN + F_ΔTURN + OF_PUB \quad (1)$$

Fonte: Lopes e Galdi (2007)

onde:

$F_ROA = 1$ se $ROA > 0$, zero caso contrário. ROA é definido como o lucro líquido dividido pelo ativo total no início do período;

$F_ΔROA = 1$ se $ΔROA > 0$, zero caso contrário. $ΔROA$ é definido como o ROA no período atual menos o ROA do período anterior;

$F_ACCRUAL = 1$ se $ACCRUAL < 0$, zero caso contrário. $ACCRUAL$ é definido como as variações do ativo circulante (exceto caixa e equivalentes) menos as variações do passivo circulante (exceto dívida de curto prazo). Este valor é dividido pelo ativo total do início do período. (Este cálculo foi aplicado porque as normas contábeis brasileiras não exigiam a demonstração de fluxo de caixa até 2008);

$F_CF = 1$ se $CF > 0$, zero caso contrário. CF é definido como a variação de caixa e equivalentes com relação ao período anterior, dividido pelo ativo total no início do período;

$F_ΔLIQUID = 1$ se $ΔLIQUID > 0$, zero caso contrário. $ΔLIQUID$ mede as variações do índice de liquidez corrente com relação ao período anterior. O índice de liquidez corrente é definido como ativo circulante dividido pelo passivo circulante no final do período;

$F_ΔLEVER = 1$ se $ΔLEVER < 0$, zero caso contrário. $ΔLEVER$ é a variação da dívida total dividido por ativo total com relação ao período anterior;

$F_ΔMARGIN = 1$ se $ΔMARGIN > 0$, zero caso contrário. $ΔMARGIN$ é a variação do lucro bruto dividido pelas vendas totais com relação ao período anterior (margem bruta);

$F_ΔTURN = 1$ se $ΔTURN > 0$, zero caso contrário. $ΔTURN$ é a variação das vendas divididas pelo ativo total no início do período com relação ao período anterior (giro do ativo);

$OF_PUB = 1$ se a empresa não emitiu novas ações no período anterior à formação da carteira, zero caso contrário.

De forma semelhante às pesquisas anteriores, esta também mostrou que a aplicação desta técnica ao mercado brasileiro resultou em maiores retornos

ajustados nos períodos de 1 e 2 anos. Para calcular o retorno ajustado ao mercado foi utilizado o índice IBrX-100 da Bovespa como *benchmark*.

2.2 ALGORITMOS GENÉTICOS

Algoritmos Genéticos (AGs) são técnicas da Computação Evolutiva (CE), um dos ramos da Inteligência Artificial que, segundo Bittencourt (1998), propõem um novo paradigma, alternativo ao processamento de dados convencional, no qual não é requerido conhecimento prévio sobre o problema a ser resolvido. Ainda segundo o autor, seu mecanismo é baseado na teoria da seleção natural de Charles Darwin, na qual os indivíduos melhor adaptados ao ambiente possuem maior chance de se reproduzir, levando à evolução da população.

Quando utilizando AGs, o problema a ser otimizado é o ambiente e a população é um conjunto de indivíduos, cada um deles uma possível solução para o problema. Os indivíduos são compostos por genes, os parâmetros da solução, e a sua capacidade de resolver o problema é avaliada por uma função objetivo (De Jong, 1988). Como exemplo, dada uma situação na qual se queira otimizar o consumo de combustível no transporte de cargas entre dois pontos conhecidos, onde é possível definir o peso da carga e a velocidade média do veículo, cada indivíduo seria composto por um par de genes (peso, velocidade) e seria avaliado pelo consumo de combustível que esta combinação produziria. AG são geralmente aplicados na solução de problemas de procura e otimização, especialmente quando eles não são diferenciáveis, possuem múltiplos ótimos locais ou o seu modelamento matemático é muito complexo ou mesmo inexistente.

A Figura 1 representa o mecanismo dos AGs utilizando como exemplo indivíduos com oito genes. Uma população inicial (a) é avaliada pela função objetivo (b). Esta atribui os valores 24, 23, 20 e 11 para os quatro indivíduos: quanto melhor o indivíduo, maior o valor atribuído e maiores as chances de se reproduzir. Neste exemplo particular, a probabilidade que um indivíduo tem de se reproduzir é diretamente proporcional ao resultado da função objetivo. Em (c) os casais são aleatoriamente selecionados para reprodução segundo as probabilidades de (b). Neste exemplo, um dos indivíduos foi selecionado duas vezes, enquanto um outro não foi selecionado nenhuma vez. Ainda em (c), os pontos de crossover são também aleatoriamente selecionados, criando em (d) a geração seguinte de indivíduos. Este mecanismo consiste na combinação da primeira parte (antes do ponto de crossover) de um genitor com a última parte de outro genitor: o primeiro descendente do primeiro casal herdou os seus primeiros três genes do indivíduo cinza e os últimos cinco do indivíduo branco, enquanto o segundo descendente herdou os seus três primeiros genes do indivíduo branco e os últimos cinco do indivíduo cinza. Finalmente, em (e) cada indivíduo pode sofrer uma mutação aleatória em um dos seus genes, produzindo genes que podem não estar presentes na população inicial (Russel e Norvig, 2003).




Figura 1 – Representação dos mecanismos dos Algoritmos Genéticos.

Fonte: Russell e Norvig (2003)

Nota: População inicial (a) é avaliada e classificada (b), selecionando casais para reprodução (c). Os descendentes gerados (d) podem ter seus genes afetados pela mutação (e)

Em uma boa implementação de AG a população deve “convergir”, ou sucessivamente evoluir e se tornar mais homogênea, enquanto a avaliação do melhor indivíduo converge para o ótimo global. Entretanto, dadas as características do método, não é garantido que um ótimo global seja encontrado. Ainda assim, pontos ótimos “aceitavelmente bons” podem ser geralmente encontrados em tempo aceitável (Beasley, Bull, Martin 1993).

Há extensa literatura quanto à aplicação dos AGs nas mais diversas áreas, desde o projeto de turbinas de aviões até softwares para identificação criminal, passando pelo projeto de redes de comunicação e o gerenciamento de gasodutos (Drake e Marks, 2002). Em Finanças, a aplicação de AGs não é recente: Kingdom e Feldman (1995) documentam seu uso para avaliação de risco de seguros, otimização de portfólio, análise de séries temporais, predição de falência e detecção de fraude. Mais recentemente, Brabazon e O'Neill (2008) relatam aplicações em projeções financeiras, avaliação de risco de crédito, predição de volatilidade, precificação de instrumentos financeiros complexos e na negociação de ativos como suporte às análises técnica ou fundamentalista. Os autores mencionam que de forma geral, as aplicações podem ser classificadas como problemas de: (i) otimização: quando o modelo financeiro é conhecido mas complexo e com muitas dimensões, técnicas de computação evolutiva como AGs podem ser utilizados para encontrar a melhor solução no espaço de estados; (ii) indução de modelo: quando o modelo é desconhecido, AGs podem ser utilizados para, a partir de conjuntos de dados de entrada e saída, “descobrir” ou estimar o modelo subjacente.

Grande parte dos estudos nesta área se ocupam da otimização de portfólios, utilizando como dados de entrada apenas as cotações de ativos (Yang, 2006;

Hochreiter, 2007; Lin e Liu, 2008; Dallagnol *et al.* 2009; Chen, 2011). Aqueles que utilizam dados contábeis como dados de entrada para algoritmos genéticos são principalmente os que investigam métodos para detecção de inadimplência como Chen *et al.* (2011), que empregam AGs para avaliar 31 indicadores de empresas francesas e Min *et al.* (2006), que utilizam AGs para otimizar os parâmetros de um SVM (*Support Vector Machine*), técnica computacional para reconhecimento de padrões, aplicado à identificação de inadimplência de clientes bancários na Coréia do Sul.

Já a formação de portfólios utilizando AGs e indicadores financeiros não possui, no melhor conhecimento do autor, literatura tão extensa. Yan e Clack (2007) testam variações de AGs para a seleção de ativos de um *hedge-fund* no mercado malaio. Yu *et al.* (2009) aplicam AGs para selecionar empresas que comporão uma carteira utilizando indicadores financeiros como parâmetros (ROCE, índice P/L, lucro por ação e índice de liquidez). Na linha das aplicações de indução de modelo, este busca identificar os níveis de cada um dos indicadores que levam à melhor predição do retorno no período seguinte, mas não diferencia a importância dos indicadores (i.e., todos têm o mesmo peso). Em seguida, aplica novamente AGs para determinar a participação ideal de cada um dos ativos na carteira segundo o modelo de Markowitz.

Grande parte desta literatura é produzida pela academia das áreas de Pesquisa Operacional, Matemática Aplicada, Ciências da Computação e Engenharia e tem como foco testar a eficácia de diferentes métodos computacionais em diversas aplicações, dentre elas Finanças. Assim, de forma geral, Finanças são apenas o pano de fundo para o teste de ferramentas computacionais e os estudos fazem tão somente referências superficiais às teorias

e à literatura de Finanças e Contabilidade. Este trabalho, ao contrário, parte de um questionamento pertinente à Contabilidade acerca de uma eventual diferenciação na relevância de indicadores contábeis em uma situação bastante particular: empresas com alto índice VPA/P com um nível mínimo de liquidez. O método computacional AGs é a ferramenta utilizada para a indução de um modelo (conforme classificação de Brabazon e O'Neill, 2008) que ajude a identificar se há e qual seria a importância relativa dos indicadores financeiros analisados.

Capítulo 3

3 DESCRIÇÃO DA METODOLOGIA

Inicialmente foi aplicada uma versão adaptada da estratégia proposta por Piotroski (2000), que construiu um escore composto de sinais extraídos das demonstrações financeiras. Estas variáveis se destinam a prever o desempenho futuro das empresas, especialmente aquelas em dificuldades financeiras (alto índice VPA/P). Oito sinais identificados por Piotroski (2000) são utilizados com algumas adaptações em função das características contábeis e do mercado de capitais brasileiros. O valor de cada sinal é classificado como “bom” ou “ruim” dependendo do impacto teórico nos preços e desempenho futuros. Se o valor do sinal é “bom”, o indicador é igual a um (1); se é “ruim”, o indicador é igual a zero (0). O principal motivo para a adaptação do escore de Piotroski é a ausência da demonstração de fluxo de caixa no Brasil no período analisado.

A amostra consiste de empresas não financeiras (exclusão de bancos e seguradoras) listadas na Bovespa entre 1997 e 2011. Os dados foram extraídos da base de dados Economática e se referem ao período de 1997 a 2009 para as demonstrações financeiras e de 1998 a 2011 para as cotações usadas nos cálculos dos retornos de 1 e 2 anos ajustados ao mercado. Para cada empresa-ano, os retornos ajustados de 1 e 2 anos são calculados utilizando a primeira cotação disponível após o dia primeiro de maio. Este procedimento é coerente com a legislação brasileira, que requer a publicação das demonstrações financeiras até 30 de abril de cada ano. As demonstrações contábeis de 2010, embora já

disponíveis à época deste trabalho, não foram utilizadas pois as cotações para cálculo dos retornos de 1 ano ainda não estavam disponíveis. Pelo mesmo motivo, para as demonstrações contábeis de 2009 não foram calculados os retornos de 2 anos (i.e.: demonstrações contábeis do ano n são divulgadas no início do ano $n+1$, quando ocorre a formação da carteira. Os retornos de 1 e 2 anos são calculados com a cotação após primeiro de maio dos anos $n+2$ e $n+3$, respectivamente).

No Brasil, ambas as ações preferenciais e ordinárias são consideradas patrimônio e em alguns casos há ainda mais de um tipo de ações preferenciais. As ações mais líquidas para cada empresa-ano foram selecionadas, excluindo aquelas com dados insuficientes para calcular os índices VPA/P, indicadores ou retornos. A liquidez é medida pela fórmula:

$$L_a = 100 \frac{p}{P} \sqrt{\frac{n}{N} \cdot \frac{v}{V}} \quad (2)$$

onde p é o número de dias nos quais a ação foi negociada no período escolhido, P é o número de dias no período escolhido, n é o número de vezes que a ação foi negociada no período escolhido, N é o número total de negócios de todas as ações no período escolhido, v é o volume negociado da ação (em Reais) no período escolhido e V é o volume total negociado de todas as ações no período escolhido.

Galdi (2008) menciona a dificuldade de implementação da estratégia baseada em BrF_SCORE para empresas com alto índice VPA/P em função da

baixa liquidez destas ações, que pode ser verificada na Figura 2. Afim de mitigar esta dificuldade, foi estabelecido um limite mínimo de liquidez de 0,02¹.




Figura 2 - Distribuição de liquidez das ações com alto índice VPA/P entre 1997 e 2009
Fonte: Elaborado pelo autor

Em seguida, é composta a carteira de alto índice VPA/P com as empresas pertencentes ao maior quinto do índice VPA/P, resultando 489 observações. Os índices VPA/P de corte são apresentados na Tabela 1 e a estatística descritiva na Tabela 2. Finalmente, os 1% maiores e menores retornos foram excluídos, resultando 484 observações de empresas-ano.

Tabela 1 – Índices de corte VPA/P

Ano	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009
VPA/P	2,29	3,16	1,94	1,96	2,04	1,85	1,26	1,00	0,88	0,60	0,58	1,11	0,73

Fonte: Elaborado pelo autor

¹ Utilizando a fórmula $L_a = 100 \frac{p}{P} \sqrt{\frac{n}{N} \cdot \frac{v}{V}}$ conforme descrito acima e estabelecendo-se os seguintes

valores: $p / P = 1$ (ação negociada em todos os pregões); $n = 100$ negócios diários; $N = 431$ mil negócios diários (média no mercado a vista da Bovespa em 2010); $v = R\$1$ milhão diários; $V = R\$6,5$ bilhões diários (média no mercado a vista da Bovespa em 2010). (Bovespa, 2010)

Pode-se observar na Tabela 1 a redução do índice de corte VPA/P desde 2003 causado pelo crescimento de valor de mercado das empresas listadas na Bovespa e, possivelmente, indicando a formação de uma “bolha” que estourou em 2008.

Tabela 2 – Estatística Descritiva

*Estatística descritiva dos indicadores financeiros de empresas com alto índice VPA/P
(Observações de empresas-ano de 1997 a 2009)*

	Média	Desvio Padrão	Min	Q1	Mediana	Q3	Max	n
PL/P	2.3851	2.0373	0.5834	1.1003	1.9373	2.9150	15.3876	224
Mkt Cap (R\$ mil)	3,269,116	6,154,210	9,206	303,568	877,424	3,294,312	40,100,342	224
Ativo (R\$ mil)	12,581,653	26,345,172	51,572	1,106,391	3,524,474	11,934,623	138,053,932	224
Liquidez Ação	0.5005	0.8138	0.0203	0.0535	0.1615	0.5836	4.6909	224
ROA	0.0370	0.0851	-0.2276	0.0030	0.0336	0.0669	0.5528	224
FLC	0.0205	0.1022	-0.2395	-0.0136	0.0068	0.0304	0.7463	224
Δ ROA	-0.0016	0.0884	-0.4808	-0.0325	-0.0032	0.0198	0.5125	224
Accrual	-0.0143	0.0947	-0.2986	-0.0639	-0.0244	0.0149	0.6810	224
Δ Liquid	-0.1824	2.6931	-32.5931	-0.2187	0.0258	0.2730	4.7179	224
Δ Lever	0.0119	0.0768	-0.2891	-0.0267	0.0063	0.0442	0.4370	224
Δ Turn	0.0176	0.3726	-1.4597	-0.0496	0.0068	0.0628	3.8544	224
Δ Margin	-0.0121	0.1398	-1.0611	-0.0373	0.0000	0.0281	0.7039	224

Fonte: Elaborado pelo autor

Nota:

VPA/P – índice valor patrimonial-preço, ou o patrimônio no fim do período dividido pelo Valor de Mercado no fim do período.

Valor de Mercado (mil R\$) - preço das ações no final do ano multiplicado pelo número de ações em circulação.

Ativo (mil R\$) – ativo total da empresa no final do período.

Liquidez das Ações – índice que representa a liquidez das ações negociadas na Bovespa. Quanto maior o valor, mais líquida a ação. Definida como: $L_a = 100 \frac{p}{P} \sqrt{\frac{n}{N} \cdot \frac{v}{V}}$, onde p é o número de dias nos

quais a ação foi negociada no período escolhido, P é o número de dias no período escolhido, n é o número de vezes que a ação foi negociada no período escolhido, N é o número total de negócios de todas as ações no período escolhido, v é o volume negociado da ação (em Reais) no período escolhido e V é o volume total negociado de todas as ações no período escolhido.

ROA – retorno sobre os ativos, ou lucro líquido dividido pelo ativo no início do período.

FCF – fluxo de caixa livre, definido como a variação de caixa e equivalentes dividido pelo ativo no início do período.

Δ ROA – variação do retorno sobre os ativos, ou o ROA da empresa-ano menos o ROA da empresa-ano.

Accrual – variações de ativo circulante (exceto caixa e equivalentes) menos as variações de passivo circulante (exceto dívida de curto prazo) menos depreciação no período. Este valor é dividido pelo ativo total no início do período (este cálculo foi realizado porque a legislação brasileira não requeria a demonstração de fluxo de caixa até 2008).

Δ Liquid – variação do índice de liquidez da empresa com relação ao período anterior. O índice de liquidez é calculado dividindo-se o ativo circulante pelo passivo circulante do fim do período.

Δ Lever – variação da alavancagem em relação ao período anterior. Alavancagem é calculada como a dívida total dividida pelo ativo no início do período.

$\Delta Turn$ – variação do giro do ativo. Giro do ativo é calculado como a receita líquida dividida pelo ativo no início do período.

$\Delta Margin$ – variação da margem bruta dividida pelo ativo no início do período. Margem bruta é calculada dividindo-se o lucro bruto pela receita líquida.

Por uma questão de simplificação, o método original foi modificado: o indicador OF_PUB (emissão de ações) foi excluído do modelo uma vez que, no período analisado, poucas empresas listadas na Bovespa levantaram capital por meio de emissão de ações. Ao invés disso, as empresas se financiam preferencialmente através da emissão de títulos de dívida, a forma mais usual de levantar recursos no mercado brasileiro (Studard, 2000). Além disso, Galdi (2008) mostra que este indicador tem correlação com os retornos significativamente menor do que os demais indicadores.

Em seguida a amostra foi dividida em dois conjuntos: o primeiro (conjunto de treino) é composto pelas empresas-ano de 1997 a 2004; o segundo (conjunto de teste) é composto pelas empresas-ano de 2005 a 2009. O conjunto de treino foi utilizado para rodar o algoritmo de otimização e encontrar os pesos otimizados, que foram aplicados no conjunto de teste. A Tabela 3 e a Tabela 4 mostram os retornos da estratégia baseada no BrF_SCORE para as empresas-ano dos conjuntos de treino e de teste, respectivamente.

Comparando os resultados com os obtidos por Galdi (2008), que analisa o mesmo período do conjunto de treino porém sem aplicar o limite mínimo de liquidez, observa-se que os resultados para retornos de 1 e 2 anos foram menores do que os obtidos pelo estudo citado (39% e 186%, respectivamente), sendo que nem a diferença entre as empresas com alto score e as de baixo score, nem a diferença entre as empresas com alto score e a média de todas as empresas foram econômica- ou estatisticamente significativas. Isso comprova a dificuldade da

implementação da estratégia na prática, conforme havia sido alertado no estudo. Como de se esperar, o mesmo ocorre no conjunto de teste, porém com resultados ainda inferiores aos do conjunto de treino.

Para obtenção dos pesos é realizado experimento no conjunto de dados do período de treino. Neste experimento, um indivíduo é composto por oito genes, cada um sendo o peso associado a um indicador. Ele é avaliado pela função objetivo definida como o retorno ajustado médio. Dessa forma, os indivíduos cujos genes (ou pesos) proporcionam melhor avaliação (ou maior retorno) terão maiores chances de se reproduzir, disseminando seus genes e gerando descendentes melhor adaptados e capazes de selecionar ações que terão melhores retornos.

Foi definida uma população inicial de 100 indivíduos (ou 100 conjuntos de 8 pesos) que se reproduzem por até 300 gerações. O algoritmo também é interrompido se nenhum novo melhor indivíduo (com maior retorno) surgir em 100 gerações. A população inicial foi aleatoriamente definida com seus pesos variando de +0.5 a -0.5 e evolui a partir daí de acordo com os mecanismos de reprodução e mutação. Nenhuma restrição é imposta aos valores que os pesos podem assumir (por exemplo, valores negativos). Admitiu-se que os pesos poderiam ser diferentes para os retornos ajustados de 1 e 2 anos, por isso foram executados experimentos separados para cada um dos períodos de retorno.

Um novo escore (O_BrF_SCORE) foi criado para incorporar os pesos na estratégia:

$$O_BrF_SCORE = \sum_i \lambda_i F_i \quad (3)$$

A estratégia baseada no BrF_SCORE atribui a cada empresa-ano um escore que varia de 0 a 9 e seleciona aquelas com alto escore (7 a 9). Todavia, os valores que O_BrF_SCORE pode assumir não estão em uma faixa fixa, uma vez que os pesos podem assumir qualquer valor durante a otimização. Assim, “alto escore” foi definido como a metade mais alta do O_BrF_SCORE para um dado conjunto de pesos (ou dado indivíduo). As empresas-ano com alto escore são então selecionadas para compor a carteira daquele ano.

Apesar de terem sido excluídos da amostra os maiores retornos (1% das observações), há ainda observações cujo retorno ajustado é muito maior do que a média. Isto pode causar um problema de *overfitting* para o algoritmo de otimização, ou seja, uma especialização no conjunto de treino, perdendo a generalidade e a capacidade de escolher boas empresas no conjunto de teste. Isso poderia ocorrer com o algoritmo tendendo a “escolher” pesos para que estas empresas (de retorno muito acima da média) permanecessem no portfolio, mesmo que estes pesos acabassem selecionando também empresas com baixo retorno. Esta situação foi contornada impondo como limite aos retornos de 1 e 2 anos o sexto maior retorno para cada período (limite aos 2% mais altos retornos). Esta limitação foi imposta apenas no conjunto de dados utilizado na otimização (conjunto de treino).

O mecanismo de mutação, descrito na seção anterior, existe para ajudar o algoritmo a evitar ótimos locais, mas não garante que ótimos globais sejam encontrados. Assim, na tentativa de aumentar as chances de encontrar um resultado melhor, o processo de otimização foi repetido 20 vezes, resultando 20 conjuntos de pesos. Destes, o melhor conjunto foi escolhido.

Finalmente, os pesos foram normalizados (i.e., divididos pelo maior peso em módulo) para facilitar a comparação entre os diferentes conjuntos de pesos.

Tabela 3 – Retornos da estratégia baseada no BrF_SCORE – Conjunto de Treino

Esta tabela apresenta nos painéis A e B os retornos (para 1 e 2 anos) buy-and-hold da estratégia de investimento baseada nos sinais financeiros extraídos das demonstrações contábeis para empresas com alto índice PL/P. Empresas classificadas com Baixo Escore são aquelas que obtiveram BrF_SCORE de 0 a 2. Empresas classificadas como Alto Escore são aquelas que obtiveram BrF_SCORE de 6 a 8).

Painel A - Retorno de 1 ano ajustado pelo mercado (empresas-ano de 1997 a 2004)

		Média	Percentil 10%	Percentil 25%	Mediana	Percentil 75%	Percentil 90%	n
Todas Empresas-Ano		0.0594	-0.4391	-0.2820	-0.0655	0.2410	0.7691	125
BrF_SCORE	0	-0.0931	-	-	-0.0931	-	-	1
	1	0.1150	-	-0.3796	-0.0316	0.7691	-	8
	2	-0.1014	-	-0.3750	-0.3363	0.3479	-	8
	3	0.0521	-0.4752	-0.3572	-0.0430	0.2374	1.0560	23
	4	0.0677	-0.4376	-0.3190	-0.1549	0.3138	0.6257	25
	5	0.0960	-0.5546	-0.1643	0.0268	0.2338	0.7694	19
	6	-0.0171	-0.6158	-0.4391	-0.0218	0.1243	0.2837	21
	7	0.0671	-0.4600	-0.1708	-0.0798	0.1779	0.5274	17
	8	0.6376	-	-	0.3613	-	-	3
	Baixo Escore (0-2)	0.0009	-0.6608	-0.3750	-0.3222	0.3479	0.7691	17
	Alto Escore (6-8)	0.0657	-0.5276	-0.1763	-0.0218	0.1779	0.5274	41
Alto - Baixo		0.0648	0.1332	0.1987	0.3004	-0.1700	-0.2417	
estat-t		0.4485						
p-Value		0.3278						
Alto - Todos		0.0063	-0.0885	0.1057	0.0437	-0.0631	-0.2417	
estat-t		0.0712	0.8673					
p-Value		0.4716						

Painel B - Retorno de 2 anos ajustado pelo mercado (empresas-ano de 1997 a 2004)

		Média	Percentil 10%	Percentil 25%	Mediana	Percentil 75%	Percentil 90%	n
Todas Empresas-Ano		0.2339	-0.5391	-0.3864	0.0088	0.5381	1.4082	125
BrF_SCORE	0	-0.4565	-	-	-0.4565	-	-	1
	1	0.5663	-	-0.6334	-0.0108	1.4630	-	8
	2	-0.0772	-	-0.5817	-0.2135	0.4786	-	8
	3	0.1507	-0.5838	-0.3466	-0.1286	0.3763	1.1373	23
	4	0.3408	-0.6140	-0.4223	0.1089	0.7422	1.8373	25
	5	0.2365	-0.4835	-0.4353	-0.0560	0.7213	1.4250	19
	6	0.2407	-0.5511	-0.3865	0.0318	0.7518	1.1366	21
	7	0.0236	-0.4380	-0.2876	-0.0018	0.1078	0.6768	17
	8	1.2843	-	-	1.4082	-	-	3
	Baixo Escore (0-2)	0.2034	-0.8234	-0.5817	-0.0812	0.4786	1.4630	17
	Alto Escore (6-8)	0.2270	-0.4415	-0.2879	0.0281	0.5008	1.1366	41
Alto - Baixo		0.0237	0.3819	0.2938	0.1093	0.0223	-0.3264	
estat-t		0.0932						
p-Value		0.4630						
Alto - Todos		-0.0069	0.0976	0.0986	0.0193	-0.0373	-0.2715	
estat-t		-0.0469						
p-Value		0.5187						

Fonte: Elaborado pelo autor

Tabela 4 – Retornos da estratégia baseada no BrF_SCORE – Conjunto de Teste

Esta tabela apresenta nos painéis A e B os retornos (para 1 e 2 anos) buy-and-hold da estratégia de investimento baseada nos sinais financeiros extraídos das demonstrações contábeis para empresas com alto índice PL/P. Empresas classificadas com Baixo Escore são aquelas que obtiveram BrF_SCORE de 0 a 2. Empresas classificadas como Alto Escore são aquelas que obtiveram BrF_SCORE de 6 a 8).

Painel A - Retorno de 1 ano ajustado pelo mercado (empresas-ano de 2005 a 2009)

	Média	Percentil 10%	Percentil 25%	Mediana	Percentil 75%	Percentil 90%	n
Todas Empresas-Ano	0.1070	-0.3630	-0.1649	0.0616	0.3510	0.5636	99
BrF_SCORE	0	-	-	-	-	-	0
	1	0.1220	-	0.1220	-	-	2
	2	0.2251	-0.4140	0.2809	0.5148	0.9368	13
	3	0.1268	-0.3656	0.0739	0.2184	0.5636	13
	4	0.1664	-0.5553	0.2054	0.5050	0.5942	24
	5	0.0603	-0.4842	-0.0014	0.3798	0.5187	19
	6	-0.0570	-0.5409	-0.0935	0.1878	0.3510	12
	7	0.1217	-0.3371	0.1163	0.2557	0.5598	10
	8	0.0179	-	-0.0484	0.1922	-	6
	Baixo Escore (0-2)	0.2113	-0.4140	0.1979	0.5148	0.9368	15
	Alto Escore (6-8)	0.0229	-0.3933	-0.2169	0.2114	0.5077	28
Alto – Baixo	-0.1884	0.0207	0.0298	-0.1755	-0.3034	-0.4291	
estat-t	-1.5671						
p-Value	0.9376						
Alto – Todos	-0.0842	-0.0303	-0.0521	-0.0391	-0.1396	-0.0560	
estat-t	-1.1188	0.8673					
p-Value	0.8673						

Painel B - Retorno de 2 anos ajustado pelo mercado (empresas-ano de 2005 a 2008)

	Média	Percentil 10%	Percentil 25%	Mediana	Percentil 75%	Percentil 90%	N
Todas Empresas-Ano	0.1445	-0.5041	-0.2700	0.0400	0.4316	0.7660	75
BrF_SCORE	0	-	-	-	-	-	0
	1	-0.0160	-	-0.0160	-	-	1
	2	0.2970	-0.6257	0.1607	0.8978	1.5727	12
	3	0.0228	-	0.0755	0.2788	-	9
	4	0.2947	-0.7592	0.3255	0.5761	1.1367	14
	5	0.1810	-0.4675	0.2398	0.5068	0.9538	15
	6	-0.1868	-	-0.1438	-0.0744	-	9
	7	0.1190	-	0.1127	0.4316	-	9
	8	0.1419	-	0.0087	0.1319	-	6
	Baixo Escore (0-2)	0.2729	-0.6257	0.1073	0.7660	1.5727	13
	Alto Escore (6-8)	0.0101	-0.3865	-0.2286	0.3026	0.4414	24
Alto - Baixo	-0.2628	0.2392	0.3211	-0.1453	-0.4634	-1.1313	
estat-t	-1.3018						
p-Value	0.8993						
Alto - Todos	-0.1344	0.1176	0.0414	-0.0780	-0.1290	-0.3246	
estat-t	-1.1109						
p-Value	0.8653						

Fonte: Elaborado pelo autor

Capítulo 4

4 RESULTADOS

A Figura 3 e a Figura 4 apresentam os resultados dos experimentos de otimização para os períodos de 1 e 2 anos, comparando-os com a estratégia original de pesos uniformes. Os resultados são significativamente mais altos ($\alpha=5\%$) do que a estratégia original apenas para os retornos de 1 ano.

Dois pontos chamam a atenção já à primeira vista: a diferença entre os pesos para retornos de 1 e 2 anos e a presença de pesos negativos.




Figura 3 – Pesos dos Indicadores

Fonte: Elaborado pelo autor




Figura 4 – Retornos médios ajustados de 1 e 2 anos para a estratégia *buy-and-hold* utilizando informações financeiras no período de teste

Fonte: Elaborado pelo autor

Nota: Período de teste compreende 2005 a 2009 para retorno de 1 ano e 2005 a 2008 para retorno de 2 anos.

Da primeira observação percebe-se que as empresas que tiveram melhor desempenho em 1 ano no período de treino (1997 a 2004) não necessariamente estão entre aquelas que tiveram o melhor desempenho em 2 anos, caso contrário os pesos seriam semelhantes. Além disso, mostra que estas empresas possuem perfis diferentes. Contudo, quando aplicados ao período de teste (Figura 4), apenas os pesos para retorno de 1 ano tiveram desempenho superior aos pesos uniformes, embora nenhum deles tenha apresentado desempenho significativamente maiores que a média de mercado.

A Tabela 5 apresenta a distribuição de retornos por faixas de *O_BrF_SCORE*. O Painel A mostra que empresas com alto escore obtiveram retorno ajustado de 1 ano 12 p.p. acima daquelas com baixo escore e 8 p.p. acima de todas as empresas com alto índice VPA/P entre 2005 e 2009, embora com nível de significância maior do que 5%. Já o painel B mostra retornos ajustados de 2

anos significativamente menores para empresas com alto escore, tanto em comparação com todas as empresas quanto na comparação com empresas com baixo escore, evidenciando a ineficácia dos pesos otimizados para identificação de empresas com alto potencial de retorno em 2 anos.

Este resultado já poderia ser esperado: se a liquidez das ações, trazendo reação mais rápida às informações disponíveis, impactou negativamente os retornos de 1 ano quando comparadas à amostra sem limite mínimo de liquidez de Galdi (2008), pode-se inferir que este efeito seria ainda mais pronunciado para o retorno de 2 anos, que sofre efeito de informações mais recentes. Resultado semelhante foi encontrado por Abarbanell e Bushee (1998) que, em uma amostra não restrita a empresas com alto índice VPA/P (e portanto com maior liquidez), não encontram evidências de que os indicadores financeiros contenham informação sobre o resultado de um período maior que 1 ano.

Tabela 5 – Retornos da estratégia utilizando pesos otimizados – Conjunto de Teste

Esta tabela apresenta nos painéis A e B os retornos (para 1 e 2 anos) buy-and-hold da estratégia utilizando pesos otimizados no período de 1997 a 2006 através da técnica de Algoritmos Genéticos. Empresas classificadas como Alto Escore (Baixo Escore) são aquelas que obtiveram O_BrF_SCORE entre -1,05 e 0,98 (-3,07 e -1,05) para retorno de 1 ano e entre 0,03 e 1,55 (-1,49 e 0,03) para retorno de 2 anos.

Painel A - Retorno de 1 ano ajustado pelo mercado (empresas-ano de 2005 a 2009)

		Média	Percentil 10%	Percentil 25%	Mediana	Percentil 75%	Percentil 90%	n
Todas Empresas- Ano		0.1070	-0.3612	-0.1579	0.0616	0.3510	0.5636	99
O_BrF_SCORE	-3.07 a -2.4	0.2568	-0.1165	0.1955	0.2247	0.4208	0.5598	5
	-2.4 a -1.72	0.1070	-0.2372	-0.1579	0.0289	0.2557	0.6105	33
	-1.72 a -1.05	0.0076	-0.3630	-0.2169	-0.0676	0.2114	0.5077	32
	-1.05 a -0.37	0.1893	-0.3656	0.0336	0.2322	0.4996	0.5556	24
	-0.37 a 0.3	0.1990	-0.4631	-0.2467	0.0461	0.3832	1.2754	5
	0.3 a 0.98	-	-	-	-	-	-	0
	Baixo Escore	0.0723	-0.3371	-0.1579	0.0080	0.2557	0.5598	70
	Alto Escore	0.1910	-0.4631	0.0336	0.2184	0.4996	0.5636	29
Alto-Baixo		0.1187						
estat-t		1.7569						
p-Value		0.0857						
Alto-Todos		0.0840	-0.1019	0.1915	0.1568	0.1486	0.0000	
estat-t		1.4306						
p-Value		0.1600						

Painel B - Retorno de 2 anos ajustado pelo mercado (empresas-ano de 2005 a 2008)

		Média	Percentil 10%	Percentil 25%	Mediana	Percentil 75%	Percentil 90%	n
Todas Empresas- Ano		0.1445	-0.4696	-0.2592	0.0400	0.4316	0.7660	75
O_BrF_SCORE	-1.49 a -0.98	0.0610	-0.4675	-0.3353	0.0165	0.3294	0.5481	12
	-0.98 a -0.47	0.2272	-0.5041	-0.2051	0.2398	0.4414	0.7660	21
	-0.47 a 0.03	0.2109	-0.2700	-0.0927	0.0755	0.4806	0.6947	25
	0.03 a 0.54	-0.1864	-0.6497	-0.4696	-0.2043	-0.0226	0.1319	14
	0.54 a 1.05	1.1310	1.1310	1.1310	1.1310	1.1310	1.1310	1
	1.05 a 1.55	0.7699	-0.3320	-0.3320	0.7699	1.8718	1.8718	2
	Baixo Escore	0.1858	-0.4148	-0.1566	0.1100	0.4414	0.7660	58
	Alto Escore	0.0036	-0.6497	-0.3477	-0.1493	0.0400	1.1310	17
Alto-Baixo		-0.1822						
estat-t		1.4642						
p-Value		0.8420						
Alto-Todos		-0.1409	-0.1801	-0.0885	-0.1893	-0.3916	0.3650	
estat-t		1.2752						
p-Value		0.7838						

Fonte: Elaborado pelo autor

Os valores na Figura 5 mostram o desempenho dos pesos otimizados ano a ano comparando-os com os pesos uniformes. Os períodos marcados com * pertencem ao conjunto de dados de teste e não foram utilizados no processo de otimização para encontrar os pesos; os demais pertencem ao conjunto de treino e foram utilizados no processo de otimização. De forma semelhante aos resultados apresentados acima, o retorno dos pesos otimizados para 1 ano no conjunto de teste foi superior ao retorno dos pesos uniformes (média de 26% contra 1%), enquanto para o retorno de 2 anos ambos os conjuntos de pesos se mostraram ineficientes, levando a retornos negativos (-4% para os pesos uniformes e -15% para os pesos otimizados).




Figura 5 – Retornos anuais da estratégia buy-and-hold de 1 ano

Fonte: Elaborado pelo autor

Nota: Períodos marcados com “*” pertencem ao conjunto de dados de teste.




Figura 6 – Retornos anuais da estratégia buy-and-hold de 2 anos

Fonte: Elaborado pelo autor

Nota: Períodos marcados com “*” pertencem ao conjunto de dados de teste.

A existência de pesos negativos é ainda mais interessante dado que, por definição, todos os indicadores deveriam apontar para condições “boas”. Uma hipótese para este resultado aparentemente contraditório seria que o algoritmo tenha selecionado ações que teriam sido excessivamente penalizadas no período entre a divulgação dos resultados e a data de formação do portfolio (1 de maio).

Para avaliar esta hipótese, calculou-se o retorno das ações alterando a data de compra da primeira cotação a partir de primeiro de maio para a primeira cotação a partir da divulgação do resultado da empresa, com a venda ocorrendo um ano após a compra (realizado teste apenas para retorno de 1 ano). O retorno das empresas com alto score passa de 19,1% para 17,1%, enquanto que o retorno médio de todas as empresas passa de 10,7% para 11,3%. Percebe-se que, como não há variação significativa nos retornos montando a carteira a partir da data de

publicação dos resultados ou a partir de primeiro de maio, a hipótese de reação excessiva do mercado entre estes dois eventos não parece plausível.

Outra hipótese seria que esta penalização já venha ocorrendo antes mesmo da divulgação dos resultados do ano completo, uma vez que a divulgação dos resultados dos três primeiros trimestres teriam antecipado boa parte do desempenho anual. Os pesos negativos com maior módulo apontariam então para aqueles indicadores mais observados pelo mercado num primeiro momento (ROA e *accruals*), enquanto os positivos (em especial Δ MARGEM) indicariam aqueles aos quais o mercado demoraria mais a reagir e responsáveis pelo melhor desempenho num prazo maior. Novamente, resultado semelhante foi encontrado por Abarbanell e Bushee (1998), que obtiveram retornos significativamente mais altos em sua estratégia de composição de carteira baseada em indicadores financeiros, quando aplicando-a à amostra de empresas que tiveram “más notícias” sobre seus lucros (definidas como redução do lucro no ano anterior). Adicionalmente, também identificaram nesta amostra correlação positiva entre a variação de margem bruta e retornos anormais futuros.

Ao contrário do método original de Piotroski (2000), que busca empresas com bons indicadores financeiros, os pesos otimizados aparentemente buscam empresas com indicadores financeiros ruins cujas ações tenham sido excessivamente penalizadas e, por isso, com potencial de recuperação. Obviamente, as hipóteses acima são meramente especulativas e requerem uma investigação mais aprofundada.

Conforme mencionado anteriormente, o processo de otimização foi repetido 20 vezes para cada experimento e somente o melhor conjunto de pesos foi

explorado neste trabalho. Assim, há outros conjuntos de pesos que, mesmo não levando a resultados tão altos quanto aos aqui apresentados, também levam a retornos muito acima dos obtidos por pesos uniformes. Estes outros conjuntos de pesos também revelam diferentes perfis de empresas que obtiveram retorno superior. Uma análise mais aprofundada poderia ser assunto para pesquisas posteriores, assim como a variação da importância relativa dos pesos, indicando uma possível mudança nos critérios de avaliação do mercado.

Esta última hipótese de mudança nos critérios de avaliação do mercado é particularmente importante e tange uma outra limitação deste trabalho referente ao processo de convergência às normas contábeis internacionais que vem ocorrendo desde 2008 com a aprovação da lei 11.638/97 e os pronunciamentos contábeis posteriores emitidos pelo CPC. O conjunto de treino é homogêneo e contém apenas informações financeiras anteriores às mudanças contábeis. Os pesos obtidos com base nestas informações foram utilizados no conjunto de teste, mais heterogêneo por conter dados de antes e depois do início das mudanças. É possível que neste período a interpretação e a importância atribuída aos indicadores financeiros tenha mudado, o que levaria a conjuntos de pesos diferentes dos encontrados. Este assunto não foi endereçado no trabalho e permanece como oportunidade para investigações futuras.

Capítulo 5

5 CONCLUSÃO

Este trabalho investiga quais indicadores financeiros são mais relevantes na identificação de empresas cujas ações teriam retornos futuros maiores que a média de mercado e especula sobre que tipo de empresa seria selecionada. É baseado na estratégia desenvolvida por Piotroski (2000) e adaptada ao mercado brasileiro por Lopes e Galdi (2007), a qual observa nove indicadores financeiros e seleciona empresas com os escores mais altos (BrF_SCORE) dentre aquelas com alto índice VPA/P. Estes estudos mostraram que a utilização desta técnica aumenta significativamente os retornos anormais de 1 e 2 anos, mas encontra dificuldade de aplicação por causa da baixa liquidez de muitas das ações com alto índice VPA/P (Galdi, 2008). Para contorná-la, este trabalho estabelece para a amostra um limite mínimo de liquidez e mostra que o método baseado em BrF_SCORE perde eficiência com o aumento de liquidez das ações. Este resultado já seria esperado, uma vez que as empresas com maior liquidez sofrem maior escrutinação do mercado (Galdi, 2008), reduzindo a oportunidade de arbitragem.

A abordagem empírica aqui apresentada associa pesos aos indicadores financeiros e, por meio da técnica computacional Algoritmos Genéticos, otimiza a seleção de empresas (e o retorno da carteira) escolhendo estes pesos e criando um novo escore: O_BrF_SCORE. O processo de otimização foi realizado utilizando as informações financeiras das empresas listadas na Bovespa entre 1997 e 2004 e os pesos encontrados foram aplicados no período entre 2005 e 2009 para as

ações com liquidez acima do limite mínimo. Os resultados foram comparados com o método original do BrF_SCORE, sendo significativamente maiores apenas para o retorno de 1 ano (+17pp; p-value 0,04). Também foram superiores ao retorno médio de 1 ano de todas as empresas com alto índice VPA/P (+8pp) e ao retorno médio de 1 ano das empresas com baixo O_BrF_SCORE (+12pp), embora o resultado não tenha sido estatisticamente significativo (p-value 0,16 e 0,086 respectivamente). Para os retornos de 2 anos os resultados encontrados não foram superiores nem à média de todas as empresas, nem ao método baseado no BrF_SCORE.

Diferentemente do BrF_SCORE, que busca selecionar empresas com bons indicadores financeiros dentre as empresas com alto índice VPA/P, os pesos otimizados revelam que o algoritmo selecionou empresas com indicadores financeiros em sua maioria ruins (em especial ROA, *accruals* e variação do giro do ativo). O motivo desta seleção aparentemente contraditória não é claro, mas poderia estar relacionado com a perspectiva excessivamente negativa para estas empresas, que o mercado vem construindo a partir das divulgações trimestrais de resultado. Não considerar o efeito dos resultados trimestrais como antecipação de parte do resultado anual é uma limitação deste estudo e uma abordagem mais aprofundada deste fenômeno poderia ser objeto de estudos posteriores.

Para manter a comparabilidade, este trabalho utilizou a mesma definição dos indicadores financeiros aplicada em estudos anteriores, que não diferenciam o desempenho das empresas em função do seu setor. Não considera também que os pesos (i.e. percepção relativa de importância entre os indicadores financeiros) possam mudar ao longo do tempo, em particular por causa das mudanças nas normas contábeis brasileiras que ocorrem desde 2008 no processo de

convergência às normas contábeis internacionais. Estas considerações impõem limitações aos resultados obtidos neste trabalho.

REFERÊNCIAS

ABARBANEL, J.S.; BUSHEE, B.J. Financial Statement Analysis, Future Earnings and Stock Prices. **Journal of Accounting Research** 35, 1-24, 1997.

_____. Abnormal Returns to a Fundamental Analysis Strategy. **The Accounting Review** 73, 19-45, 1998.

BARTOV, E., GOLDBERG, S.R., KIM, M.S. The Valuation-relevance of Earnings and Cash Flows: an International Perspective. **Journal of International Financial Management and Accounting** 12, 42-67, 2001.

BEASLEY, D., BULL, D.R., MARTIN, R.R. **An overview of genetic algorithms: Part 1, fundamentals**. Tech. rep., Inter-University Committee on Computing, 1993.

BITTENCOURT, G. **Inteligência Artificial: Ferramentas e Teorias**. Florianópolis: Editora da UFSC, 1998.

BOVESPA. **Estatísticas Anuais 2010**. Disponível em:
<<http://www.bmfbovespa.com.br>>. Acesso em: 3 jun. 2011.

BRABAZON, A.; O'NEILL, M. An Introduction to Evolutionary Computation in Finance. **IEEE Computation Intelligence Magazine**. Vol 3, Issue 4, 2008.

CHEN, N.; RIBEIRO, B.; VIEIRA, A.S.; DUARTE, J.; NEVES, J.C. A genetic algorithm-based approach to cost-sensitive bankruptcy prediction. **Expert Systems with Applications** 38, 12939-12945, 2011.

CHEN, Y.; MABU, S.; HIRASAWA, K. Genetic relation algorithm with guided mutation for the large-scale portfolio optimization. **Expert Systems with Applications** 38, 3353-3363, 2011.

- DALLAGNOL, V.A.F.; VAN DEN BERG, J.; MOUS, L. Portfolio Management Using Value at Risk: A Comparison between Genetic Algorithms and Particle Swarm Optimization. **International Journal of Intelligent Systems** 24, 766-792, 2011.
- DAMODARAN, A. **Investment Valuation: Tools and Techniques for Determining the Value of Any Asset**. 2nd ed. New York: Wiley, 2002.
- DE JONG, K. Learning with Genetic Algorithms: An Overview. **Machine Learning** 3, 121-138, 1988.
- DRAKE, A. E.; MARKS, R. E. Genetic Algorithms in Economics and Finance: Forecasting Stock Market Prices and Foreign Exchange - A Review. In: CHEN, S. **Genetic Algorithms and Genetic Programming in Computational Finance**. Massachussets: Kluwer Academic Publishers, 2002.
- FAMA, E.F; FRENCH, K.R. The cross section of expected stock returns. **Journal of Finance** 47, 427-465, 1992.
- _____. Size and Book-to-Market factors in Earnings and Returns. **Journal of Finance** 50,131-135, 1995.
- GALDI, F.C. **Estratégias de investimento em ações baseadas na análise de demonstrações contábeis: é possível prever o sucesso?** PhD Thesis – Universidade de São Paulo, São Paulo, 2008.
- GRAHAM, B., AND DODD, D.L. **Security Analysis**. McGraw-Hill, New York, 1934.
- HOCHREITER, R. An evolutionary computation approach to scenario-based risk-return portfolio optimization for general risk measures. In: GIACOBINI, M. **Applications of Evolutionary Computing**. Heidelberg: Springer, 2007, 199-207, 2007.

KINGMAN, J.; FELDMAN, K. Genetic algorithms and applications to finance.

Applied Mathematical Finance 2, 89-116, 1995.

LA PORTA, R.; LAKONISHOK, J.; SCHLEIFER, A.; VISHNY, R. Good News for Value Stocks: Further Evidence on Market Efficiency. **Journal of Finance** 52, 859-874, 1997.

LAKONISHOK, J.; SCHLEIFER, A.; VISHNY, R. Contrarian investments, extrapolation and risk. **Journal of Finance** 49, 1541-1578, 1994.

LIN, C.C.; LIU, Y-T. Genetic algorithms for portfolio selection problems with minimum transaction lots. **European Journal of Operational Research** 185, 393-404, 2008.

LOPES, A.B.; GALDI, F.C. Does Financial Statement Analysis Generate Abnormal Returns Under Extremely Adverse Conditions? In: **American Accounting Association (AAA) Meeting**, Chigago-EUA, 2007.

MIN. S.H.; LEE, J.; HAN, I. Hybrid genetic algorithms and support vector machines for bankruptcy prediction. **Expert Systems with Applications** 31, 652-660, 2006.

OU, J.A.; PENMAN, S.H. Accounting Management, Price-Earnings Ratio and the information Content of Security Prices. **Journal of Accounting Research** 27, 111-144, 1989.

PIOTROSKI, J.D. Value Investing: The Use of Historical Financial Statement Information to Separate Winners from Losers. **Journal of Accounting Research** 38, 1-41, 2000.

ROSENBERG, B., REID, K., AND LANSTEIN, R. Persuasive evidence of market inefficiency. **Journal of Portfolio Management** 11, 9-17, 1984.

RUSSEL, S.; NORVIG, P. **Artificial Intelligence A Modern Approach**. 2nd edition. Upper Saddle River, New Jersey: Prentice Hall, 2003.

SKINNER, D.J.; SLOAN, R.G. Earnings Surprises, Growth Expectations, and Stock Returns or Don't Let an Earnings Torpedo Sink Your Portfolio. **Review of Accounting Studies** 7, 289-312, 2002.

SLOAN, R.G. Do Stock Prices Fully Reflect Information in *Accruals* and Cash Flows About Future Earnings? **The Accounting Review** 71, 289-315, 1996.

STUDART, ROGERIO. Financial Opening and Deregulation in Brazil in the 1990's: Moving Towards a New Pattern of Development Financing. **Quarterly Review of Economics and Finance**, Vol. 40, 25-44, 2000.

TAPIA, M.G.C.; COELLO, C.A.C. Applications of multi-objective evolutionary algorithms in economics and finance: A survey. **In: IEEE Congress on Evolutionary Computation**, 2007.

YAN, W.; CLACK, C.D. Evolving robust GP solutions for hedge fund stock selection in emerging markets. **In: Proceedings of the 9th annual conference on Genetic and evolutionary computation**, 2007.

YANG, X. Improving Portfolio Efficiency: A Genetic Algorithm Approach. **Computational Economics** 28, 1-14, 2006.

YU, L.; WANG, S.; LAI, K.K. Multi-Attribute Portfolio Selection with Genetic Optimization Algorithms. **INFOR: Information Systems and Operational Research** 47, 23-30, 2009.