

Modelos para otimização de portfólio de ações utilizando abordagem evolucionária - uma revisão sistemática

Deisy Cristina Corrêa Igarashi (UEM) deisyigarashi@gmail.com

Wagner Igarashi (UEM) wigarash@gmail.com

Lucas Perassoli Melquiades (UEM) pera.melquiades@gmail.com

Resumo:

Algumas pesquisas na área econômico-financeira têm originado o desenvolvimento de modelos de otimização de portfólio. Tais modelos auxiliam na determinação da carteira de ativos financeiros que tenha a melhor relação retorno/risco financeiro na percepção de um investidor. A diversificação ou balanceamento da carteira é uma das motivações para o desenvolvimento desses modelos, que podem se utilizar de uma abordagem evolucionária. Neste contexto, o presente estudo tem como objetivo identificar como abordagens evolucionárias tem sido utilizadas para resolver o problema de otimização de portfólios. Para tal, foi realizada uma revisão sistemática que resultou na análise de 18 estudos contemporâneos extraídos de quatro bases acadêmicas (Elsevier, Springer, ACM, IEEE) e que utilizaram abordagem evolucionário no processo de otimização de portfólios.

Palavras chave: Otimização de portfólio, algoritmos evolucionários, revisão sistemática.

Models for stock portfolio optimization using evolutionary approach - a systematic review

Abstract

Some researches in the economic-financial area have led to the development of portfolio optimization models. Such models help in determining the portfolio of financial assets that has the best financial risk / return ratio in the perception of an investor. The diversification or balance of the portfolio is one of the motivations for the development of these models, which can be used in an evolutionary approach. In this context, the present study aims to identify how evolutionary approaches have been used to solve the problem of optimization of portfolios. For this, a systematic review was carried out that resulted in the analysis of 18 contemporary studies extracted from four academic bases (Elsevier, Springer, ACM, IEEE) and using an evolutionary approach in the process of portfolio optimization.

Key-words: Portfolio Optimization, Evolutionary Algorithms, Systematic Review.

1. Introdução

Pesquisas na área econômico-financeira têm originado o desenvolvimento de modelos de otimização de portfólio. Tais modelos auxiliam na determinação da carteira de ativos financeiros tenha a melhor relação retorno/risco financeiro na percepção de um investidor. A diversificação ou balanceamento da carteira é uma das motivações para o desenvolvimento desses modelos. Por exemplo, as ações de uma determinada empresa podem se valorizar enquanto que as de uma outra se desvalorizam e vice-versa. Com isto, a exposição ao risco de um investidor que tenha investido nas ações das duas empresas será menor do que a exposição ao risco de um investidor que tenha investido exclusivamente nas ações de apenas uma das empresas.

Um conjunto de ativos organizados em um investimento é comumente chamado de carteira ou portfólio (GITMAN; ZUTTER, 2012). Assuma um cenário fictício, no qual um investimento é feito em uma carteira X composta por ações de três companhias A, B e C relacionadas ao comércio de carne bovina. Se os jornais passarem a noticiar diversas irregularidades em relação ao transporte, armazenamento e higiene da carne comercializada, as notícias, verdadeiras ou não, poderão influenciar no comportamento do consumidor e em um menor consumo do alimento. As ações das companhias A, B e C irão cair e a carteira irá gerar um prejuízo por ser composta de companhias de um mesmo setor.

No cenário apresentado o primeiro tópico de interesse desta proposta: a diversificação de portfólios (ou carteiras) de ações. Uma carteira Y composta de ações das companhias A, E e F, relacionadas respectivamente aos setores do comércio de carne bovina, eletrônicos e farmacêutico, não sofreria as mesmas perdas que a carteira X composta por ações de um único setor em crise. Na década de 1950, Markowitz (1959) apresentou o que se entende hoje por Teoria Moderna de Portfólio e destacava a maximização do lucro (retorno) e minimização do risco (variabilidade), ou seja, um problema de otimização com duas funções objetivo, que nos leva para o segundo tópico de interesse, a otimização de portfólios.

Alguns estudos contemporâneos como os de Suksonghong, Boonlong e Goh (2014), Lwin, Qu e MacCarthy (2017), Mishra, Panda e Majhi (2014), Saborido et al. (2016), Michalak (2015), Gaur e Deb (2016) utilizam modelagens com algoritmos evolutivos multiobjetivo (mais de uma função objetivo para evoluir seu conjunto solução) para tratar diversificação e otimização de portfólios de ações. Nestes estudos a carteira é representada por um vetor que guarda em cada posição a contribuição de uma ação para o portfólio. Em outros dois trabalhos (ZHAN; REA; REA, 2015; CHEOLJUN; PARK, 2017), a coleção de ações é representada por uma rede de correlações entre as ações, um grafo denso onde cada vértice contém uma ação e cada aresta o relacionamento entre duas ações.

No contexto apresentado, foi então estabelecida a seguinte pergunta de pesquisa: como a abordagem evolucionária tem sido utilizada para resolver o problema de otimização de portfólio de ações? Para responder tal pergunta, foi estabelecido como objetivo de pesquisa: a análise de abordagens evolucionárias para resolver o problema de otimização de portfólios.

2. Revisão sistemática

Esta seção apresenta uma revisão sistemática baseada no modelo descrito no Cochrane Handbook for Systematic Reviews of Interventions (IGARASHI; IGARASHI; BORGES, 2015; HIGGINS; GREEN, 2011) constituída de oito etapas: (1) Definir Pergunta da Revisão, (2) Buscar e Registrar Estudos, (3) Analisar e Selecionar Estudos, (4) Avaliar Riscos de Vieses, (5) Analisar Dados dos Estudos, (6) Tratar Vieses e Ampliar Fontes de busca, (7) Apresentar Resultados e (8) Analisar Resultados e Concluir.

Na etapa 1 (definir pergunta de, a pergunta objetivo da revisão foi definida como “Quais são os modelos mais adequados para otimizar portfólio de ações em uma abordagem evolucionária?”. Na etapa 2, as principais fontes de busca de Estudos foram Elsevier, Springer, ACM e IEEE, e as palavras chaves utilizadas foram: portfolio, selection, optimization, mean, variance, algorithm, multi-objective e evolutionary.

Na etapa 3, foram selecionados estudos a partir do ano de 2000 a 2017, com base na leitura do título, resumo, palavras-chave e introdução. Resultando em 18 estudos que podem ser observados no Quadro 1.

#	Algoritmos	Indicadores	Revista	Ano	Referência	Base
1	SPEA2	--	--	2001	Zitzler, Laumanns e Thiele	
2	NSGA2	--	IEEE Transactions on Evolutionary Computation, Vol. 6.	2002	Deb	IEEE
3	COGA2, SPEA2, NSGA2	Média, Variância, Assimetria, Amplitude	Electrical Power and Energy Systems	2014	Suksonghong, Boonlong e Goh	Elsevier
4	PESA2, SPEA2, NSGA2, 2 LB-MOPSO, NS-MOPSO	Média, Variância	Swarm and Evolutionary Computation	2014	Mishra; Panda e Majhi	Elsevier
5	ABC	Semivariância	Fifth International Conference on Intelligent Control and Information Processing	2014	Ge	IEEE
6	GA, ABC, DE, SA, PSO, MABC	Média, Desvio Probabilístico (Fuzzy) Semi Absoluto	Physic A	2015	Chen	Elsevier
7	EA, NSGA2	Semivariância, Média, Variância, Índice de Sharpe	Genetic and Evolutionary Computation Conference Companion	2015	Michalaf	ACM
8	NSGA2, MOEAD, GWASF-GA	Média, Desvio Probabilístico (fuzzy) Semi Absoluto, Assimetria	Applied Soft Computing	2016	Saborido, et al.	Elsevier
9	EMO1 (NSGA2 modificado), NSGA2	--	Genetic and Evolutionary Computation Conference Companion	2016	Gaur e Deb	ACM
10	GA	PDI, ICOMP,	Economic Research South Africa	2016	Oyenubi	Springer
11	SCA	Risk Parity	Acoustics, Speech and Signal Processing (ICASSP), 2016 IEEE International Conference on	2016	Feng e Palomar	IEEE
12	Matlab-GA, LassoGP, fmincon, CyCoDe	--	Decisions in Economics and Finance	2017	Giuzio	Springer
13	MODEGL, NSGA2, SPEA2, NSGA2GL, SPEA2GL	Média, Value at Risk	European Journal of Operational Research	2017	Lwin, Qu e MacCarth	Elsevier
14	NSGA2, SPEA2, TA (MACD, CBB, BB, RSI)	Média, Semivariância	Expert Systems With Applications	2017	Macedo, Godinho e Alves	Elsevier
15	ABC1 e ABC2	Média, Variância	Expert Systems With Applications	2017	Kalayci, et al.	Elsevier
16	--	Média, Variância	International Review of Financial Analysis	2017	Eom e Park	Elsevier
17	GA	Desvio Probabilístico (Fuzzy) Semi Absoluto	Applied Soft Computing	2017	Qin	Elsevier

18	MC-ABC	Covariância	Swarm and Evolutionary Computation	2017	Kumar e Mishra	Elsevier
----	--------	-------------	------------------------------------	------	----------------	----------

Quadro 1 - Artigos apurados na revisão sistemática com as palavras de busca (portfolio, selection, optimization, mean, variance, algorithm, multi-objective, evolutionary).

O Quadro 1 contém duas colunas (Algoritmos e Indicadores) que destacam as informações de maior relevância dos estudos. A coluna (Algoritmos) apresenta algoritmos utilizados para otimização de portfólio de ações, com abordagens evolucionárias em sua maioria, e a coluna (Indicadores) apresenta os indicadores econômicos utilizados na construção das funções objetivo. Em relação à etapa 4, verificou-se a necessidade de se verificar algum tipo de critério de relevância para diferenciar os artigos, de modo a não tratá-los com o mesmo peso. Dando continuidade, foi realizada a etapa 5, Analisar Dados dos Estudos, e, como resultado da etapa 7, apresentar resultados, foi dividida a seguir em 2 subseções, Algoritmos Genéticos e Algoritmos de Enxame.

2.1 Algoritmos Genéticos

O fluxo de dados em um algoritmo genético comum, como pode ser observado nos estudos de Suksonghong, Boonlong e Goh (2014), Saborido et al. (2016), Qin (2017), Deb (2002), Zitzler, Laumanns e Thiele (2001) é constituído das etapas de (1) criação da população inicial, que ocorre uma única vez, e as demais etapas que se repetem sob um critério de parada, (2) ordenação das amostras contidas na população pelo seu valor de desempenho, (3) seleção dos casais de amostras destinados a geração da próxima população, (4) cruzamento dos casais e (5) mutação. A seguir apresenta-se o funcionamento de cada uma dessas etapas para os estudos apurados na revisão sistemática que estão relacionados a algoritmos genéticos.

2.1.1 Criação da população inicial

Suksonghong, Boonlong e Goh (2014) geram a população inicial de maneira randômica. A estrutura de dados que representa um indivíduo dessa população (cromossomo) é um vetor com soma de seus valores totalizando 1. Cada valor nesse vetor representa o peso de uma ação no cálculo do retorno médio de um portfólio. A abordagem randômica é descrita por Saborido et al. (2016), Qin (2017), Deb (2002) e Zitzler, Laumanns e Thiele (2001).

2.1.2 Ordenação das amostras contidas na população pelo seu valor de desempenho

Suksonghong, Boonlong e Goh (2014) calculam o valor de desempenho do cromossomo pelas quatro funções objetivo (maximização do retorno, minimização da variância, maximização da assimetria e minimização da amplitude) em duas técnicas diferentes (1) Distância média di entre um indivíduo i e a fusão j dos melhores indivíduos produzidos para cada objetivo k ,

$$di = \left(\sum_{k=1}^m \left(\frac{f_{ik} - f_{jk}}{MAX(f_k) - MIN(f_k)} \right)^2 \right)^{\frac{1}{2}}$$

e (2) Hipervolume que é a multiplicação do resultado das quatro funções objetivo.

Saborido et al. (2016) apresentam três funções objetivo (maximização do retorno, minimização do downside risk e maximização da assimetria) para o cálculo do desempenho dos cromossomos. Qin (2017) apresentam duas funções objetivo (maximizar o retorno e minimizar desvio absoluto médio) utilizadas na construção de um *rank* que atribui maior grau de utilidade para os indivíduos do topo de maneira que o grau de utilidade se acumula a cada geração.

Deb (2002) ordena a população de soluções pelo resultado das funções objetivo aplicadas a métrica de crowding distance que qualifica como melhor, o cromossomo com maior distância relativa a seus vizinhos próximos. O uso da métrica ajuda na preservação da diversidade de soluções da população. O cálculo utiliza a distância euclidiana média do cromossomo em relação a todos os outros cromossomos como medida de comparação no processo de ordenação e cada função objetivo representa uma dimensão do espaço de soluções.

2.1.3 Seleção dos indivíduos destinados à geração da próxima população

Suksonghong, Boonlong e Goh (2014) selecionam o grupo dos cromossomos que irão gerar a próxima população em um método chamado de seleção binária. Esse método também é apresentado por Deb (2002), Zitzler, Laumanns e Thiele (2001). De dois em dois, cromossomos selecionados aleatoriamente são comparados e o melhor é separado para o cruzamento. Quando um número pré estabelecido de casais é atingido, a seleção encerra. Qin (2017) seleciona os casais de maneira randômica seguindo o grau de utilidade disponível em um *rank*. O indivíduo com maior grau de utilidade possui maior chance de ser selecionado para formar um casal.

2.1.4 Cruzamento dos casais

Suksonghong, Boonlong e Goh (2014) cruzam os casais pelas regras do simulated binary crossover (SBX) de maneira similar a Deb (2002). A nova geração é adicionada junto ao conjunto da velha geração. São gerados dois cromossomos filhos ($c1$ e $c2$) a partir de dois cromossomos pais ($p1$ e $p2$) com um valor randômica r entre 0 e 1, um valor n para o tamanho dos cromossomos e sob as regras a seguir.

$$c1 = \frac{p1 \cdot (1+\beta) + p2 \cdot (1-\beta)}{2} \quad c2 = \frac{p1 \cdot (1-\beta) + p2 \cdot (1+\beta)}{2}$$

$$\beta = \left\{ (2r)^{\frac{1}{n+1}}, r \leq 0.5; \left(\frac{1}{2(1-r)} \right)^{\frac{1}{n+1}}, r > 0.5 \right\}$$

Saborido et al. (2016) apresentam 4 casos de cruzamento devido a sua escolha de projeto que permite cromossomos de uma mesma população possuírem conjunto de pesos positivos para ações diferentes. Os 4 casos são, (1) a intersecção entre os dois cromossomos é vazia, ou seja, não existe pelo menos 1 peso positivo em cada cromossomo que seja atribuído para uma mesma ação, (2) a intersecção não é total e existe pelo menos 1 peso positivo em cada cromossomo que seja atribuído para uma mesma ação, (3.1) a intersecção é total com pesos diferentes, e (3.2) intersecção total com pesos idênticos. Por exemplo, em um conjunto de 10 ações que permita a criação de portfólios de investimento de apenas 4 ações (peso positivo) é possível criar 2 portfólios que invistam em ações totalmente diferentes.

O cruzamento ocorre em todos os 4 casos com a divisão de cada um dos dois cromossomos pais x_1 e x_2 em dois conjuntos randômicos (x_{11}, x_{12}) e (x_{21}, x_{22}) pesos positivos que são organizados para produzir dois filhos yx_1 e y_2 . Ao fim do cruzamento os cromossomos são todos normalizados.

O caso (1) produz dois filhos:

$$y_1 \equiv x_{11} \cup x_{22} \quad y_2 \equiv x_{12} \cup x_{21}$$

tal que:

$$x_1 \cap x_2 \equiv \emptyset \quad x_1 \equiv x_{11} \cup x_{12}$$

$$x_2 \equiv x_{21} \cup x_{22} \quad \#(x_1) = \#(x_2)$$

$$\#(x_{11}) + 2 - \#(x_1) \text{MOD} 2 = \#(x_{12})$$

$$\#(x_{21}) + 2 - \#(x_2) \text{MOD} 2 = \#(x_{22})$$

O caso (2) produz dois filhos:

$$y_1 \equiv x_{12} \cup x_{21}$$

$$y_2 \equiv x_{22} \cup x_{11}$$

tal que:

$$x_1 \equiv x_{11} \cup x_{12}$$

$$x_2 \equiv x_{21} \cup x_{22}$$

$$x_{11} \equiv x_{21}$$

$$x_{11} \cap x_{12} \equiv \emptyset$$

$$x_{21} \cap x_{22} \equiv \emptyset$$

$$\#(x_1) = \#(x_2)$$

O caso (3.1) produz dois filhos:

$$y_1 \equiv x_{11} \cup x_{22}$$

$$y_2 \equiv x_{21} \cup x_{12}$$

tal que:

$$x_1 \equiv x_2$$

$$x_1 \neq x_2$$

$$x_1 \equiv x_{11} \cup x_{12}$$

$$x_2 \equiv x_{21} \cup x_{22}$$

$$\#(x_1) = \#(x_2)$$

$$\#(x_{11}) + 2 - \#(x_1) \text{MOD} 2 = \#(x_{12})$$

$$\#(x_{21}) + 2 - \#(x_2) \text{MOD} 2 = \#(x_{22})$$

O caso (3.2) produz dois filhos:

$$y_2 \equiv x_{12} + x_{22}$$

$$y_2 \equiv x_1 - x_{21}$$

tal que:

$$x_1 \equiv x_2$$

$$x_1 = x_2$$

$$x_2 \equiv x_{21} \cup x_{22}$$

$$\#(x_1) = \#(x_2)$$

Qin (2017) inicia o cruzamento com uma verificação, se o valor randômico r é menor que o parâmetro P_c os dois cromossomos pais C_1 e C_2 geram os cromossomos filhos C'_1 e C'_2 que devem ser ambos verificados como adequados à população, caso contrário um novo r é gerado.

$$C'_1 = rC_1 + (1 - r)C_2$$

$$C'_2 = rC_2 + (1 - r)C_1$$

2.1.5 Mutação

Suksonghong, Boonlong e Goh (2014) realizam a mutação pelo método *Variable-Wise Polynomial Mutation*. A mutação ocorre em uma variável (peso) X_p pertencente a uma solução (cromossomo) de tamanho n , X_p é selecionada em um método que percorre cada peso no cromossomo e seleciona para mutação o primeiro peso que atende à condição (se um valor randômico entre 0 e 1 for maior ou igual $1/n$). O novo peso que substitui X_p no cromossomo é o valor X_c . Os outros valores, X_u e X_l são respectivamente o maior e o menor peso contido no cromossomo, r é um outro valor randômico entre 0 e 1, e n_m a posição de X_p no cromossomo. Todas as equações estão a seguir.

$$X_c = X_p + \delta_q(X_u - X_l)$$

$$\delta_q = [2r + (1 - 2r) (1 - \delta_1)^{n_m+1}]^{\frac{1}{n_m+1}} - 1, \text{ se } r \leq 0,5$$

$$\delta_q = 1 - [2(1 - r) + 2(r - 0,5) (1 - \delta_2)^{n_m+1}]^{\frac{1}{n_m+1}}, \text{ se } r > 0,5$$

$$\delta_1 = \frac{X_p - X_l}{X_u - X_l} \quad e \quad \delta_2 = \frac{X_u - X_p}{X_u - X_l}$$

Saborido et al. (2016) apresentam a mutação ligada a uma verificação que se repete para cada peso W_i maior que zero contido no cromossomo. A cada repetição é gerado um valor randômico r entre 0 e 1, que se for menor que $1/(quantidade\ k\ de\ pesos\ positivos\ contidos\ no\ cromossomo)$, a mutação ocorre. A mutação seleciona um peso W_j sem investimento para trocar de valor com W_i .

Qin (2017) apresenta a mutação com uma verificação, caso o valor randômico r for menor que o parâmetro P_m a mutação ocorre com cada posição c_i do cromossomo C sendo somada a um valor randômico d_i entre -1 e 1.

2.2 Algoritmos de Enxame

O fluxo de dados em um algoritmo genérico de enxame, como pode ser observado nos estudos de Ge (2014), Kumar, Mishra (2017), Kalayci et al. (2017) e Chen (2015), reúne as etapas de (1) produção das fontes de alimento (conjunto solução inicial), que ocorre somente uma vez, e as outras etapas que iteram sob uma condição de parada, (2) busca por fontes de alimento próximas e mais abundantes que as atuais, (3) seleção de fontes de alimento extras ponderada pelo valor das funções objetivo, e (4) substituição das fontes de alimento saturadas. Os parágrafos a seguir apresentam o funcionamento de cada uma dessas etapas para os estudos apurados na revisão sistemática que estão relacionados a algoritmos de enxame.

2.2.1 Produção das fontes de alimento

Ge (2014), Kumar e Mishra (2017), e Kalayci, et al. (2017) modelam a produção das fontes de alimento de maneira randômica pela equação a seguir, na qual i indica a fonte de alimento, j indica uma das coordenadas da fonte e max e min indicam o maior e menor valor que pode ser atribuído a uma coordenada j .

$$x_{ij} = x_j^{min} + rand(0,1)(x_j^{max} - x_j^{min})$$

2.2.2 Busca por fontes de alimento próximas e mais abundantes que as atuais

Ge (2014) destaca que a busca de fontes próximas pelas *employed bees* pode gerar atrasos na convergência para soluções melhores devido aos máximos locais e propõe a fórmula a seguir, na qual i e k indicam uma fonte de alimento, j indica uma das coordenadas da fonte, x_j é o peso da coordenada j para melhor fonte de alimento global, ϕ_{ij} é um valor randômico entre 0 e 1, φ_{ij} é um valor randômico discreto entre 0 e uma constante não negativa c , α é uma constante e z_{ij} é uma variável de decisão 0-1.

$$i \neq k$$

$$x_{ij} = \{x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) + \varphi_{ij}(x_j - x_{ij}), z_{ij} = 1; x_{ij}, z_{ij} = 0\}$$

$$z_{ij} = round\left(\frac{1}{1 + e^{-[z_{ij} + \phi_{ij}(z_{ij} - z_{kj}) + \varphi_{ij}(z_j - z_{ij})]}} - \alpha\right)$$

Kumar e Mishra (2017) utilizam o mesmo rank do algoritmo NSGA 2 (DEB, 2002) para ordenar as fontes de alimento inicial antes de distribuí-las entre as *employed bees*. A equação utilizada está a seguir e é semelhante a do estudo anterior (GE, 2014) e do algoritmo apresentado em Chen (2015). A escolha entre trocar de fonte de alimento ou não, é feita pela *pareto optimal selection* utilizada no SPEA 2 (ZITZLER; LAUMANN; THIELE, 2001).

$$i \neq k$$

$$x_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) + \varphi_{ij}(x_j - x_{ij})$$

2.2.3 Seleção de fontes de alimento extras ponderada pelo valor das funções objetivo

Ge (2014) modela esta etapa com uma busca feita pelas *onlooker bees* nas soluções já encontradas pelas *employed bees*. A fonte de alimento (solução) é escolhida pelo valor de seu desempenho (fit), i é o indicador da fonte e f é a função objetivo (minimização da semivariância). Kumar e Mishra (2017) e Chen (2015), ambas com funções objetivo de (maximização do retorno e minimização da variância), utilizam este mesmo modelo.

$$p_i = \frac{fit_i}{\sum_{j=1}^{SN} fit_i}$$

$$fit_i = \left\{ \frac{1}{1 + f(x_i)}, f(x_i) \geq 0; 1 + |f(x_i)|, f(x_i) < 0 \right\}$$

2.2.4 Substituição das fontes de alimento saturadas

Ge (2014) utiliza um contador que é incrementado em 1 toda vez que uma *employed bee* se mantém na mesma fonte de alimento depois de uma comparação com outras fontes próximas. Quando o contador atinge um valor limite pré estabelecido, a *employed bee* busca por uma nova fonte, guiada pela equação a seguir, na qual i indica a fonte de alimento, j indica uma das coordenadas da fonte e max e min indicam o maior e menor valor que pode ser atribuído a uma coordenada j .

$$x_{ij} = x_j^{min} + rand(0,1)(x_j^{max} - x_j^{min})$$

Kumar e Mishra (2017) substituem as fontes pela equação a seguir.

$$i \neq k$$

$$x_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) + \varphi_{ij}(x_j - x_{ij})$$

2.3 Tratar vieses

Em relação à etapa 6, não foi realizada ampliação das bases de dados. Contudo, como critério de relevância para diferenciar os artigos; foram utilizados os indicadores Google Scholar Citation, JCR e os do Qualis da capes, relativas às seguintes áreas: computação (periódicos e eventos), engenharias (periódicos) e administração (periódicos).

#	Ano	Referência	Base	google scholar citation	JCR	Qualis (computação, engenharias e administração)
1	2001	Zitzler, Laumanns e Thiele		6628		
2	2002	Deb	IEEE	25551	5,908	
3	2014	Suksonghong, Boonlong e Goh	Elsevier	35		A1
4	2014	Mishra; Panda e Majhi	Elsevier	27		A1
5	2014	Ge	IEEE	2		
6	2015	Chen	Elsevier	41	2,243	
7	2015	Michalaf	ACM	3		A1

8	2016	Saborido et al	Elsevier	41		A2
9	2016	Gaur e Deb	ACM	4		A1
10	2016	Oyenubi	Springer	2		
11	2016	Feng e Palomar	IEEE	0		A1
12	2017	Giuzio	Springer	0		B2
13	2017	Lwin, Qu e MacCarthy	Elsevier	11	2,679	
14	2017	Macedo, Godinho e Alves	Elsevier	10	2,981	A1
15	2017	Kalayci, et al.	Elsevier	8	2,981	A1
16	2017	Eom e Park	Elsevier	3	0,896	A1
17	2017	Qin	Elsevier	18		A2
18	2017	Kumar e Mishra	Elsevier	13		A1

Quadro 2 - Tratamento de vies - classificação segundo indicadores peso científico

Ao se analisar o quadro 2, verifica-se que alguns estudos são relevantes por terem elevado nível de citação por outros artigos, segundo o Google Scholar Citation, outros por serem oriundos de revistas com determinado peso JCR e outros por terem sido publicados em periódicos pontuados pelo Qualis Capes. No entanto cabe destacar que 2 artigos não apresentaram pontuação JCR e nem Qualis Capes, os artigos 5 e 10 apresentaram apenas Google Scholar Citation igual a 2, ou seja, foram pouco citados, indicando, segundo os critérios de classificação utilizados, um menor peso. Por fim, a etapa 8, Analisar Resultados e Concluir, da revisão sistemática é descrita na seção a seguir.

2.3 Conclusão da Revisão Sistemática

A pergunta objetivo da revisão foi definida como “Quais são os modelos mais adequados para otimizar portfólio de ações em uma abordagem evolucionária?”, dessa forma, os próximos parágrafos destacam os aspectos de maior recorrência nos estudos apurados, como medidas, algoritmos, conjunto de dados, resultados e conclusões de alguns estudos.

As abordagens evolucionárias verificadas nos diversos estudos foram de Algoritmos Genéticos e Algoritmos de Enxame. Em ambas a inicialização do primeiro conjunto de soluções ocorre de maneira randômica em vários estudos (SUKSONGHONG; BOONLONG; GOH, 2014; SABORIDO et al., 2016; QIN, 2017; DEB, 2002; GE, 2014; KUMAR; MISHRA, 2017; KALAYCI et al., 2017). A seleção ponderada de soluções pelo peso das funções objetivo é presente em vários estudos (SUKSONGHONG; BOONLONG; GOH, 2014; QIN, 2017; DEB, 2002; ZITZLER; LAUMANN; THIELE, 2001; GE, 2014; KUMAR; MISHRA, 2017; CHEN, 2015) seja para onlooker bee phase, cruzamento ou mutação de soluções. Outra equação recorrente, utilizada na geração de novas soluções para os estudos de enxames (GE, 2014; KUMAR; MISHRA, 2017; CHEN, 2015), é descrita a seguir e possui a característica de atribuir ao segundo termo uma garantia de evolução em torno de soluções locais e ao terceiro uma garantia de evolução ao redor da melhor solução x_j .

$$x_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) + \varphi_{ij}(x_j - x_{ij})$$

Os principais indicadores econômicos encontrados foram média, variância, semivariância e assimetria. Com destaque para os estudos de Suksonghong, Boonlong e Goh (2014), e Ge (2014) que abordam os indicadores de assimetria e semivariância, respectivamente, de maneira mais aprofundada. O Quadro 3 apresenta as equações para a principais medidas apuradas.

Medida	Equação
Retorno Esperado	$\bar{X} = \frac{\sum_{i=0}^P w_i (\sum_{j=0}^N x_{ij})}{N - 1}$
Variância	$\sigma^2 = \frac{\sum_{j=0}^N (\sum_{i=0}^P w_i x_{ij} - \bar{X})^2}{N - 1}$
Semivariância	$\sigma_-^2 = \frac{\sum_{j=0}^N \left(\min(0, \sum_{i=0}^P w_i x_{ij} - \bar{X}) \right)^2}{N - 1}$
Assimetria	$S = \frac{\sum_{j=0}^N \left(\frac{\sum_{i=0}^P w_i x_{ij} - \bar{X}}{\sigma} \right)^3}{N - 1}$

Quadro 3 - Equações para cálculo de medidas de um portfólio. N é quantidade de retornos na flutuação da ação i, P é a quantidade a ações no portfólio, x_{ij} é o retorno da ação i no momento j da sua flutuação e w_i o peso.

Alguns estudos (MISHRA; PANDA; MAJHI, 2014; KUMAR; MISHRA, 2017; KALAYCI et al., 2017; CHEOLJUN; PARK, 2017) optam apenas pelos indicadores estabelecidos por Markowitz (1959), média e variância, enquanto abordam questões algorítmicas com maior profundidade, apresentando uma variedade satisfatória de experimentos, hipóteses de desempenho e convergência de resultados.

Em relação a estrutura de dados e o tipo de dado utilizado, a maioria dos trabalhos optam por dados de flutuações históricos (LWIN; QU; MACCARTHY, 2017; MISHRA; PANDA; MAJHI, 2014; SABORIDO et al., 2016; OYENUBI, 2016; GE, 2014; KUMAR; MISHRA, 2017; KUMAR; MISHRA, 2017; KALAYCI et al., 2017; CHEN, 2015; MACEDO; GODINHO; ALVES, 2017; MICHALAK, 2015). A principal estrutura de dados utilizada na representação de uma carteira de ações é um vetor com a porcentagem de contribuição de cada ação. Em dois trabalhos (ZHAN; REA; REA, 2015; CHEOLJUN; PARK, 2017), essa estrutura é um grafo que contém em cada aresta um par de ações de companhias diferentes e seu valor de correlação. Outra tendência observada é a modelagem das flutuações das ações com dados fuzzy (SABORIDO et al., 2016; QIN, 2017; CHEN, 2015).

Michalaf (2015) descreve o desempenho dos portfólios produzidos em seus experimentos em dois principais padrões, (1) “aqueles portfólios que funcionam bem no passado e também funcionam bem no futuro” e (2) “em algumas situações os portfólios que oferecem os maiores retornos futuros são aqueles que alcançaram o menor risco nos dados históricos”. Chen (2015) comenta o oposto, “as variações esperadas de retornos de ações não podem ser bem refletidas pelos dados históricos por causa da alta volatilidade do ambiente do mercado”. Essa diferença pode ser explicada principalmente pela modelagem dos dados, Chen (2015) opta por uma modelagem fuzzy com restrições baseadas em investimentos reais, como as taxas geralmente cobradas pelas bolsas de investimentos por operações de compra e venda de ativos, enquanto Michalaf (2015) descreve os portfólios com pesos com valores contínuos.

Kumar e Mishra (2017) apresentam cinco aspectos interessantes das soluções obtidas em seus experimentos com um modelo de otimização por algoritmo de enxame de abelhas e covariância: (1) foi produzida uma variedade ampla de portfólios de investimentos; (2) com

mais opções para perfis de investimento interessados em relações de baixo retorno/risco; (3) portfólios de alto valor de retorno/risco são formados por ações de alto valor de retorno/risco e portfólios de baixo valor de retorno/risco são formados por ações de baixo valor de retorno/risco; (4) maior ocorrência de soluções com ações de menor risco cumulativo e ações de alto valor de retorno/risco; e (5) redução do risco de portfólios pelo investimento em um maior número de ações.

Oyenubi (2016) descreve que a adição de uma nova ação em um portfólio afeta a diversificação e a complexidade das relações do portfólio. Também, conclui de seus experimentos que o número ideal de ações em um portfólio é variável de mercado para mercado dependendo da rede de correlações entre as ações consideradas, da razão entre diversificação e complexidade e do grau de desenvolvimento do mercado avaliado. Em outro estudo, Mishra, Panda e Majhi (2014) observam em seus resultados que um investidor não precisa investir dinheiro em todas as ações disponíveis e do contrário, investir em poucas ações, aproximadamente 10% das ações disponíveis no mercado, e ainda explorar um espaço amplo de relações de retorno e risco.

Macedo, Godinho e Alves (2017) compara em seus experimentos o desempenho de dois algoritmos evolucionários consagrados de multiobjetivos NSGA2 (Non-dominated Sorting Genetic Algorithm) e SPEA2 (Strength Pareto Evolutionary Algorithm). Em ambos os algoritmos o conjunto das melhores soluções é dito fronteira. Enquanto, NSGA2 produz fronteiras mais amplas e com formatos semelhantes, SPEA2 produz fronteiras com formatos diferentes, mais concentradas e pouco diversas. NSGA2 supera SPEA2 com fronteiras mais amplas e melhores relações de retorno e risco. Em outro estudo, Zitzler, Laumanns e Thiele (2001) observam que em casos de otimização com maior número de dimensões, SPEA2 produz resultados melhores que NSGA2.

Essa revisão apresentou os objetos de estudo identificados em 18 estudos contemporâneos extraídos de quatro bases (Elsevier, Springer, ACM, IEEE) com as palavras de busca (portfolio, selection, optimization, mean, variance, algorithm, multi-objective, evolutionary). Dessa forma, a resposta para a questão “Quais são os modelos mais adequados para otimizar portfólio de ações em uma abordagem evolucionária?” está contida nos diversos aspectos e resultados relacionados nesta revisão.

Referências

- CHEN, W.** *Artificial bee colony algorithm for constrained possibilistic portfolio optimization problem*. Physica A 429, 125-139. 2015.
- CHEOLJUN, E.; PARK, J. W.** *Effects on common factors on stock correlation networks and portfolio diversification*. International Review of Financial Analysis 49, 1-11. 2017.
- DEB, K.** *A Fast and Elitist Multiobjective Genetic Algorithm: NSGA2*. IEEE Transactions on Evolutionary Computation, Vol. 6. 2002.
- GAUR, A.; DEB, K.** *Adaptative Use of Innovization Principles for a Faster Convergence of Evolutionary Multi-Objective Optimization Algorithms*. GECCO. 2016.
- GE, M.** *Artificial Bee Colony Algorithm for Portfolio Optimization*. Fifth International Conference on Intelligent Control and Information Processing. 2014.
- GITMAN, L. J.; ZUTTER, C. J.** *Principles of Managerial Finance*. 13 ed. Prentice Hall- Pearson. 2012.
- GIUZIO, M.** *Genetic algorithm versus classical methods in sparse index tracking*. Decisions in Economics and Finance. AMASES. 2017.

HIGGINS, J. P. T.; GREEN, S. *Cochrane Handbook for Systematic Reviews and Interventions Version 5.1.0* [updated March 2011]. The Cochrane Collaboration, 2011. Disponível em: <www.handbook-5-1.cochrane.org>. Acesso em: 05 jul. 2017.

IGARASHI, W.; IGARASHI, D. C. C.; BORGES, B. J. *Revisão Sistemática e sua potencial contribuição para “Negócios, Gerenciamento e Contabilidade”*. Gestão e Regionalidade - Vol. 31 - N91. 2015.

KALAYCI, C. B.; ERTENLICEA, O.; AKYERA, H.; AYGORENB, H. *An artificial bee colony algorithm with feasibility enforcement infeasibility toleration procedures for cardinality constrained portfolio selection optimization*. Expert Systems With Applications 85, 61-75. 2017.

KUMAR, D.; MISHRA, K. K. *Portfolio optimization using novel co-variance guided Artificial Bee Colony algorithm*. Swarm and Evolutionary Computation 33, 119-130. 2017.

LWIN, K. T.; QU, R.; MACCARTHY, B. L. *Mean-VaR portfolio optimization: A nonparametric approach*. European Journal of Operational Research 260, 751-766. 2017.

MACEDO, L.; GODINHO, P.; ALVES, M. *Mean-semivariance portfólio optimization with multiobjective evolutionary algorithms and technical analysis rules*. Expert Systems With Applications, 33-43. 2017.

MARKOWITZ, H. *Portfolio Selection - Efficient Diversification of Investments*. 1959. Cowles Foundation. Yale University.

MICHALAK, K. *Selecting Best Opportunities from Stocks Portfolios Optimized by a Multiobjective Evolutionary Algorithm*. Department of Information Technologies. Institute of Business Informatics. Wroclaw University of Economics. Poland. 2015.

MISHRA S. K.; PANDA, G.; MAJHI, R. *A comparative performance assessment of a set of multiobjective algorithms for constrained portfolio assets selection*. Swarm and Evolutionary Computation 16, 38-51. 2014.

OYENUBI, A. *Diversification Measure and optimal number of Stocks in a portfolio: An information theoretic explanation*. Economic Research South Africa working paper 666. 2016.

QIN, Z. *Random fuzzy mean-absolute deviation models for portfolio optimization problem with hybrid uncertainty*. Applied Soft Computing 56, 597-603. 2017.

SABORIDO, R.; RUIZ, A. B.; BERMÚDEZ, J. D.; VERCHER, E.; LUQUE, M. *Evolutionary multi-objective optimization algorithms for fuzzy portfolio selection*. Applied Soft Computing 39, 48-63. 2016.

SUKSONGHONG, K.; BOONLONG, K.; GOH, K.-L. *Multi-objective genetic algorithms for solving portfolio optimization problems in the electricity market*. International Journal of Electrical Power and Energy Systems 58, 150-159. Elsevier. 2014.

ZHAN, H. C. J.; REA, W.; REA, A. *A Comparison of Three Network Portfolio Selection Methods, Evidence from the Dow Jones*. University of Canterbury. New Zealand. 2015.

ZITZLER, E.; LAUMANN, M.; THIELE, L. *SPEA2: Improving the Strength Pareto Evolutionary Algorithm*. Department of Electrical Engineering and Networks Laboratory. Swiss Federal Institute of Technology, Zurich. 2001.