

# Portfólios baseados em Clusterização Espectral e *Factor Investing*

Lucas Siviero Sibemberg<sup>1</sup>

UFRGS, Porto Alegre, RS

Luiz Emilio Allem<sup>2</sup>

UFRGS, Porto Alegre, RS

Carlos Hoppen<sup>3</sup>

UFRGS, Porto Alegre, RS

O número de investidores em bolsas de valores nunca foi tão grande. Em contrapartida, novos entrantes acabam tendo menos conhecimento sobre o mercado para montar um portfólio que apresente um bom desempenho. Dessa forma estratégias que tomem pouco tempo do investidor, como por exemplo, delegar para algum fundo de investimentos a seleção de ativos, começam a ficar mais populares. Nesse trabalho propomos uma abordagem combinando clusterização espectral e *factor investing* para criação de um portfólio que pode ser feita uma vez no início de cada ano. A seguir apresentamos o procedimento de escolha de ativos que compõem o portfólio. Observamos que todos os dados utilizados ao longo desse trabalho foram retirados do *Yahoo Finance* e podem ser acessados em [https://github.com/Lucassib/Gestao\\_de\\_Portfolio.git](https://github.com/Lucassib/Gestao_de_Portfolio.git).

Assim, seja  $\mathcal{X} = \{x_1, \dots, x_n\}$  o conjunto de ativos que são as opções para a seleção do portfólio,  $k \in \mathbb{N}$  fixo e  $P$  denota o portfólio escolhido.

1. Divide os ativos em  $k$  classes, isto é,  $\{A_i \neq \emptyset\}_{i=1}^k$ ,  $A_i \cap A_j = \emptyset$ , se  $i \neq j$  e  $\cup_{i=1}^k A_i = \mathcal{X}$ .
2. Define  $P = \{x : y(x) = \min_j(y(x_j)), x_j \in A_i, \text{ para } i \in 1, \dots, k\}$ , onde  $y$  é uma métrica.

Para a divisão dos ativos em  $k$  classes utilizamos uma heurística espectral muito famosa, introduzida por [2]. Nessa abordagem associamos um conjunto de dados  $\mathcal{X} = \{x_1, \dots, x_n\}$  com uma matriz  $A = (a_{ij})$  de similaridade, onde  $a_{ij}$  indica a similaridade entre os dados  $x_i$  e  $x_j$ . Na heurística dividimos o conjunto de dados em  $k$  classes a partir de autovetores associados a uma matriz obtida com base em  $A$ . Vale ressaltar que o objetivo é que dados que pertençam a uma mesma classe sejam mais similares.

Para a montagem do portfólio, definimos  $A = A^m = (a_{ij}^m)$ , em que  $a_{ij}^m = \frac{1+w_{ij}^m}{2}$ , onde  $w_{ij}^m$  é a correlação entre os ativos  $i$  e  $j$  relacionada ao desempenho diário no ano  $m$ . Note que quanto maior é  $a_{ij}^m$  maior foi a correlação dos ativos  $i$  e  $j$  e, portanto, maior a chance de eles estarem em uma mesma classe e, por fim, dificilmente estarão no mesmo portfólio construído pela nossa estratégia.

A partir da saída do algoritmo de clusterização espectral há  $k$  classes distintas com ativos de  $\mathcal{X}$ , onde  $\mathcal{X}$  é o conjunto de ações negociadas na Bovespa. A próxima etapa foi escolher um ativo de cada classe para compor o portfólio. Existem critérios bem estabelecidos entre economistas para fazer essa seleção, conhecidos como critérios de *factor investing* [1].

O investimento em fatores (*factor investing*) é muito discutido no mundo dos investimentos. Um fator é uma característica relacionada a alguma métrica que é importante para explicar riscos e retornos dos ativo [1] e já há estratégias famosas baseadas em fatores. Nesse trabalho utilizamos

<sup>1</sup>lucas.siviero@ufrgs.br

<sup>2</sup>emilio.allem@ufrgs.br

<sup>3</sup>choppen@ufrgs.br

a métrica  $y_1 = \frac{P}{L}$  se  $L > 0$  e  $y_1 = 0$  caso contrário, onde  $P$  é o preço da ação no último dia considerado e  $L$  é o lucro acumulado por ação da empresa nos últimos doze meses. Também utilizamos a métrica  $y_2 = \frac{PL}{L_t}$  se  $L > 0$  e 0 caso contrário, onde  $PL$  é o patrimônio líquido da empresa e  $L_t$  seu lucro acumulado nos últimos doze meses. Note que podemos entender  $y_1 > 0$  como a quantidade de anos necessários para a empresa retornar ao acionista o valor investido em lucro líquido, assim, quanto menor é  $y_1$ , mais rápido é o retorno ao acionista. Já  $y_2$  é o patrimônio líquido por cada real lucrado, portanto é razoável que quanto menor, mais eficiente é a empresa.

Nós utilizamos  $m \in \{2017, 2018, 2019\}$  e escolhemos  $k = 10$ . Esse é um valor comumente utilizado em estratégias de *factor investing*. Seja  $r_i(m)$  a rentabilidade de  $x_i$  no ano  $m$ . Para cada  $m$ , denotamos por  $P_1^m = \{x_{j_k}\}_{k=1}^{10}$  é o portfólio gerado pelo algoritmo utilizando  $y = y_1$  e  $P_2^m = \{x_{j_i}\}_{i=1}^{10}$  é o portfólio gerado pelo algoritmo utilizando  $y = y_2$ . Definimos  $C_1^m = \frac{1}{10} \sum_{k=1}^{10} r_{j_k}(m+1)$  e  $C_2^m = \frac{1}{10} \sum_{i=1}^{10} r_{j_i}(m+1)$ , como as rentabilidades de  $P_1^m$  e  $P_2^m$ , respectivamente. Para comparar o desempenho dos portfólios montamos outras quatro carteiras de referência. Baseado no conjunto de ativos dentro do BOVESPA definimos  $C_3^m$  (o famoso Índice Bovespa), onde  $C_3^m = \sum_{i=1}^n p_i(m)r_i(m+1)$ , onde  $\sum_{i=1}^n p_i(m) = 1$ , e cada  $p_i(m)$  já está pré-definido, e  $C_4^m = \frac{1}{n} \sum_{i=1}^n r_i(m+1)$ . Os últimos dois portfólios  $P_5^m$  e  $P_6^m$  de *factor investing*, são montados escolhendo os 10 ativos que possuem menor  $y_1$  e  $y_2$  do BOVESPA, respectivamente, onde novamente sua rentabilidade é calculada pela médias das rentabilidades dos ativos de  $P_5^m, P_6^m$ , respectivamente. Por fim, observamos que quando olhamos para um período maior, de  $a$  anos, a cada ano o portfólio é revisto de acordo com o algoritmo e sua rentabilidade deve ser medida a partir de  $C_j = C_j^m \cdot C_j^{m+1} \dots C_j^{m+a}$ , para  $j \in \{1, 2, 3, 4, 5, 6\}$ .

Para  $m = 2017$ , o resultado obtido foi,  $P_1^{2017} = \{\text{SBSP3, BBAS3, BRAP4, EGIE3, MRVE3, SMLS3, CMIG4, IRBR3, BRKM5, VIVT3}\}$  e  $C_1^{2018} = 35,82\%$ .  $P_2^{2017} = \{\text{CVCB3, ITUB4, BRAP4, ECOR3, NTCO3, SMLS3, CMIG4, IRBR3, BRKM5, FLRY3}\}$  e  $C_2^{2018} = 26,98\%$ . Enquanto isso,  $C_3^{2018} = 17,05\%$ ,  $C_4^{2018} = 18,61\%$ ,  $C_5^{2018} = 26,89\%$ ,  $C_6^{2018} = 13,32\%$ . Nos anos que analisamos, o nosso procedimento gerou portfólios com desempenhos melhores que os demais. Na Tabela 1 realizamos uma comparação das rentabilidades dos portfólios.  $CF$  é o capital final utilizando a respectiva estratégia após os três anos, considerando um capital inicial de R\$ 10.000.

Tabela 1: Comparação das Estratégias.

	$m = 2018$	$m = 2019$	$m = 2020$	$CF$
$C_1^m$	35,82%	53,53%	1%	R\$21.064,37
$C_2^m$	26,98%	32,83%	4,06%	R\$17.554,15
$C_3^m$	17,04%	29,96%	-0,14%	R\$15.191,74
$C_4^m$	18,61%	50,12%	0%	R\$17.822,99
$C_5^m$	26,89%	45,18%	-0,33%	R\$17.827,25
$C_6^m$	13,32%	36,93%	-17,96%	R\$12.732,06

Nos anos analisados, com as métricas utilizadas, nossa estratégia se mostrou com bom desempenho frente a outras estratégias. Para próximos passos, planejamos estender nossa estratégia para outros anos e outras métricas possíveis. Pelos resultados parciais que tivemos, acreditamos que a estratégia é muito promissora e que é uma boa alternativa para o investidor.

## Referências

- [1] Bender, J., Briand, R., Melas D., Subramanian R. A. *Foundations of Factor Investing*. 2013.
- [2] Shi, J.; Malik, J. Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(8):888-905, 2000. DOI: 10.1109/34.868688.