

UNIVERSIDADE FEDERAL DE SANTA CATARINA

Nicollas Matteus Gomes

**MACHINE LEARNING EM UM AMBIENTE DE INTERAÇÃO SOCIAL  
PARA GERIR UM FUNDO DE INVESTIMENTOS PREVIDENCIÁRIO**

Florianópolis

2019

Nicollas Matteus Gomes

**MACHINE LEARNING EM UM AMBIENTE DE INTERAÇÃO SOCIAL  
PARA GERIR UM FUNDO DE INVESTIMENTOS PREVIDENCIÁRIO**

Trabalho de Conclusão do Curso de Graduação em Ciências Econômicas do Centro Socioeconômico da Universidade Federal de Santa Catarina como requisito para a obtenção do Título de Bacharel/Licenciado em Ciências Econômicas.  
Orientador: Prof. Dr. Helberte João França Almeida.

Florianópolis

2019

**Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática da Biblioteca Universitária da UFSC.**

GOMES, NICOLLAS MATTEUS  
MACHINE LEARNING EM UM AMBIENTE DE INTERAÇÃO SOCIAL  
PARA GERIR UM FUNDO DE INVESTIMENTOS PREVIDENCIÁRIO /  
NICOLLAS MATTEUS GOMES ; orientador, Helberte João França  
Almeida, 2019.  
34 p.

Trabalho de Conclusão de Curso (graduação) -  
Universidade Federal de Santa Catarina, Centro Sócio  
Econômico, Graduação em Ciências Econômicas, Florianópolis,  
2019.

Inclui referências.

1. Ciências Econômicas. 2. Aprendizado de Máquina. 3.  
Previdência. 4. Gestão de portfólio . 5. Sharpe. I. França  
Almeida, Helberte João . II. Universidade Federal de Santa  
Catarina. Graduação em Ciências Econômicas. III. Título.

Nicollas Matteus Gomes

**MACHINE LEARNING EM UM AMBIENTE DE INTERAÇÃO SOCIAL  
PARA GERIR UM FUNDO DE INVESTIMENTOS PREVIDENCIÁRIO**

A banca examinadora resolveu atribuir a nota 9.0 ao aluno Nicollas Matteus Gomes na disciplina CNM 7107 – Monografia, pela apresentação deste trabalho.

Florianópolis, 09 de julho de 2019.

---

Prof. Daniel De Santana Vasconcelos, Dr.  
Coordenador do Curso

**Banca Examinadora:**

---

Prof. Helberte João França Almeida, Dr.  
Orientador  
Universidade Federal de Santa Catarina

---

Prof.<sup>a</sup> Jaylson Jair de Silveira, Dr  
Universidade Federal de Santa Catarina

---

Prof. Dr. Mauricio Simiano Nunes  
Universidade Federal de Santa Catarina

“A economia é uma virtude distributiva e consiste não em poupar, mas em escolher”.

Edmund Burke

## AGRADECIMENTOS

Gostaria de agradecer acima de tudo a minha família que sempre me apoiou e acreditou em mim, ela é meu alicerce, não há palavra capa/z de descrever meu agradecimento, em especial a minha mãe, Marli Lorenssetti.

Vale ressaltar também todas as pessoas incríveis no qual a vida me deu a oportunidade de conviver até o presente momento, minha namorada, Luiza Schweitzer Strazzer que esteve ao meu lado em absolutamente todos os momentos independente se eram bons ou não, você é tão responsável pelas minhas conquistas quanto eu. Agradeço também aos meus amigos de toda vida Arthur Ventura, Gabriel Veber, Igor Melo e Thiago Ventura, saibam que todos vocês são parte fundamental em todas as minhas conquistas.

Agradeço a todos os amigos que me auxiliaram a superar as adversidades na universidade, André Scheidt, Giorgio Hanna, Raphael Inoue, Tiago Macedo e Vitor Junckes, espero ter ajudado vocês tanto quanto vocês me ajudaram.

Por fim, agradeço todo o corpo docente da Universidade Federal de Santa Catarina por me conceder seu conhecimento ao longo destes anos, em especial ao Prof. Helberte João França Almeida, Dr, que me concedeu subsídios para organizar este estudo.

Muito obrigado a todos vocês, é somente o início da caminhada, contem comigo.

## RESUMO

Os fundos previdenciários estão se avolumando em território nacional, tanto por razões de ordem social, quanto pelo crescente interesse dos indivíduos por um planejamento financeiro mais robusto, assim, tornando estes fundos maiores, mais diversificados e conseqüentemente mais relevantes para o mercado financeiro. Vislumbrando esta nova dinâmica, este estudo busca criar um modelo que utiliza machine learning (aprendizagem de máquina), interação social e simulação de sensibilidade para gerir um portfólio. Mais precisamente, o modelo determina a porcentagem do patrimônio que cada ativo do portfólio receberá a cada período de rebalanceamento algorítmico. Ao final de cada rebalanceamento, o modelo analisa individualmente a rentabilidade e índice de Sharpe de cada ativo, além do índice de Sharpe do portfólio, premiando ou punindo, com mais ou menos recursos, os ativos com melhor ou pior desempenho no período. As punições e as premiações abrandadas ou maximizadas pela sensibilidade do algoritmo podem variar entre arrojado, moderado e conservador. Por fim, o algoritmo foi exposto a uma série de testes para evidenciar sua eficiência. Os resultados demonstraram que os portfólios simulados obtiveram desempenhos satisfatórios em sua maioria.

**Palavras-chave:** Aprendizado de máquina. Previdência. Gestão de portfólio. Sharpe.

## **ABSTRACT**

The pension funds are piling up in the country, both for social reasons, as the growing interest of individuals for a more robust financial planning, thus making these major funds, more diverse and therefore more relevant to the financial market. Looking at this new dynamics, this study seeks to create a model that uses machine learning, social interaction and sensitivity simulation to manage a portfolio. More precisely, the model determines the percentage of equity that each asset in the portfolio will receive each period of algorithmic rebalancing. At the end of each rebalancing, the model individually analyzes the profitability and Sharpe ratio of each asset, beyond the Sharpe ratio of the portfolio, rewarding or punishing, with more or less resources, assets with better or worse performance in the period. Punishments and awards that are slowed down or maximized by algorithm sensitivity can range from bold, moderate, and conservative. Finally, the algorithm was exposed to a series of tests to show its efficiency. The results showed that the simulated portfolios obtained satisfactory performances in the majority.

**Keywords:** Machine learning. Social security. Portfolio management. Sharpe.



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>9</b>
1.1	TEMA E PROBLEMÁTICA DE PESQUISA.....	9
1.2	OBJETIVOS.....	9
<b>1.2.1</b>	<b>Objetivo Geral</b> .....	<b>10</b>
<b>1.2.2</b>	<b>Objetivos Específicos</b> .....	<b>10</b>
1.3	JUSTIFICATIVA.....	10
<b>2</b>	<b>REFERENCIAL TEÓRICO</b> .....	<b>11</b>
2.1	FUNDOS DE INVESTIMENTOS.....	11
<b>2.1.1</b>	<b>Fundos de investimentos em cotas de Fundo de investimentos</b> .....	<b>11</b>
<b>2.1.2</b>	<b>Fundos de investimentos de renda fixa e crédito privado</b> .....	<b>12</b>
2.2	APRENDIZADO DE MÁQUINA POR REFORÇO.....	12
2.3	INTERAÇÃO SOCIAL .....	14
<b>3</b>	<b>METODOLOGIA</b> .....	<b>16</b>
3.1	ESTRUTURA DE INVESTIMENTOS .....	16
3.2	ÍNDICE DE SHARPE.....	17
3.3	FEEDBACKS ALGORITMICOS .....	18
<b>3.3.1</b>	<b>Critérios para feedbacks</b> .....	<b>18</b>
<b>3.3.2</b>	<b>Sensibilidade algorítmica</b> .....	<b>19</b>
<b>3.3.3</b>	<b>Interação entre feedbacks e sensibilidade</b> .....	<b>21</b>
3.4	IMPLEMENTAÇÃO COMPUTACIONAL.....	22
<b>4</b>	<b>RESULTADOS</b> .....	<b>24</b>
<b>5</b>	<b>CONCLUSÃO</b> .....	<b>31</b>
	<b>REFERÊNCIAS</b> .....	<b>32</b>

## 1 INTRODUÇÃO

### 1.1 TEMA E PROBLEMÁTICA DE PESQUISA

Segundo Ferreira (2019), quem aplicou seus recursos em pelo menos um dos dez maiores fundos previdenciários brasileiros, geridos por grandes instituições bancárias, está acumulando um patrimônio financeiro menor do que poderia obter em outras aplicações de baixo risco. O levantamento feito pela plataforma Magnetis demonstra que estes fundos previdenciários apresentaram rendimento abaixo do índice CDI, nos períodos de 1, 5 e 10 anos. Portanto, a boa gestão dos fundos é de vital importância para esses acumularem bons lucros.

O fundo de investimento analisado neste estudo apresenta em sua política de investimentos a condição de somente poder investir seus recursos entre quatro fundos exclusivos da mesma entidade. Dois desses são fundos de investimentos de característica de renda fixa, sendo os outros dois, fundos de investimentos de crédito privado. Desta maneira, tanto os fundos de renda fixa, quanto os de crédito privado podem apresentar baixa liquidez, devido aos seus ativos terem como atributo recorrente serem pouco negociados, se tornando um dificultador para o processo de rebalanceamento do portfólio.

O estudo busca modelar um algoritmo que consiga realocar os recursos de forma realista, levando em consideração a impossibilidade de grandes e ágeis movimentações do patrimônio do portfólio entre os fundos, buscando por meio de machine learning elevar o índice de Sharpe e a rentabilidade da carteira. Com isso, fornece ferramentas para corrigir a baixa rentabilidade de uma parcela dos fundos de previdência no território nacional e busca elaborar uma metodologia que contribua com a elevação do bem-estar social.

### 1.2 OBJETIVOS

O presente estudo contribui para a literatura de otimização de fundos de investimento, ao elaborar um modelo que considera atributos privados (rentabilidade e índice de Sharpe) e atributos sociais (desempenho dos maiores fundos de mesmo segmento).

Portanto, ao realizar o estudo, pretende-se considerar os seguintes aspectos: aprendizagem por reforço e interação social, a fim de verificar se contribuem para que fundos de investimentos obtenham um melhor retorno.

### **1.2.1 Objetivo Geral**

Utilizar métodos de aprendizado de máquina por reforço em um ambiente de interação social para gerenciar um portfólio de investimentos de uma entidade previdenciária no ano de 2018.

### **1.2.2 Objetivos Específicos**

- i. Apresentar a literatura de fundos de investimentos, aprendizado de máquina e interação social.
- ii. Demonstrar as características dos fundos de investimentos otimizados no estudo.
- iii. Desenvolver um algoritmo que busque otimizar o índice de Sharpe e rentabilidade de um fundo previdenciário por meio de aprendizado de máquina por reforço e interação social, e demonstrar seus resultados.
- iv. Comparar os resultados do estudo com a real desempenho do fundo no ano de 2018.

### **1.3 JUSTIFICATIVA**

A elaboração de uma metodologia robusta para a tomada de decisão na gestão de recursos é essencial. Elas devem ser baseadas em métodos coerentes, minimizando o espaço para tomadas de decisões de cunho arbitrário ou inabilidade por parte do gestor, que podem levar a perda de capital. Desta forma, a criação deste modelo busca a não frustração dos cotistas do fundo ao entrarem no período de aposentadoria, ou até mesmo o total desalento com a inexistência de recursos que efetivamente irão lhes auxiliarem. Esta justificativa não está no âmbito teórico, é uma realidade atual, casos de gestões não satisfatórias de fundos previdenciários por grandes instituições.

## 2 REFERENCIAL TEÓRICO

Neste capítulo será abordado os seguintes temas: fundos de investimentos, aprendizado de máquina por reforço e interação social.

### 2.1 FUNDOS DE INVESTIMENTOS

Fundos de investimentos podem parecer algo distante da realidade da população em geral, porém estão diretamente vinculadas as suas vidas.

De acordo com EID JUNIOR (2017), os fundos de investimento exercem o papel de intermediários, atingindo uma gama imensa de investidores e de empresas, já que em suas carteiras há um conjunto de títulos voltados para o seu financiamento.

Por sua vez, Oliveira (2017) salienta que os fundos previdenciários atualmente ocupam lugar de destaque no capitalismo contemporâneo. Estes fundos passaram a constituir relevantes fontes de renda complementar para trabalhadores e tornaram-se agentes centrais nos mercados financeiros globais, se caracterizando como grandes investidores institucionais.

Coerente com os argumentos supracitados, os fundos previdenciários ocupam um espaço importante na dinâmica do mercado financeiro mundial, vinculados com a poupança de um país, estimulando e financiando suas atividades produtivas. Porém estes fundos não são homogêneos, eles podem ser constituídos de várias formas e características, adotando critérios legais que regem suas diretrizes de investimentos.

Além de possuírem características e diretrizes de investimentos diferentes entre si, dependendo de sua classe, os mesmos também diferem na forma como são geridos. Por exemplo, por um gestor humano, por um algoritmo ou até mesmo pela mescla de ambos. Os fundos que se utilizam de algoritmos para sua gestão são conhecidos como fundos quantitativos.

Segundo, Cutait (2019) nestes fundos as estratégias de investimentos são executadas por meio de algoritmos, ou seja, os gestores se utilizam da tecnologia para automatizar sua gestão, buscando explorar padrões de comportamento do mercado e suas ineficiências.

#### 2.1.1 Fundos de investimentos em cotas de Fundo de investimentos

O fundo de investimento em cotas de fundos de investimentos presente nesta monografia (o alvo da otimização do algoritmo) caracteriza-se como fundo de investimento em

multimercado, pois assume característica que o possibilita alocar seus recursos em outros de características diversas. Porém, além de ser um multimercado ele ostenta como principal característica ser um fundo de investimentos em cotas de fundos de investimentos.

De acordo com o conselho de valores monetários (2014), um fundo de investimento em cotas de fundos de investimento deve possuir, no mínimo, 95% de seu patrimônio alocado em cotas de fundos de investimento de uma mesma classe, a não ser os fundos de investimento em cotas de fundos de investimentos classificados como "Multimercado", estes podem investir em cotas de fundos de classes diferentes.

### **2.1.2 Fundos de investimentos de renda fixa e crédito privado**

O fundo de investimentos em cotas de fundos de investimentos otimizado pelo algoritmo do modelo a ser proposto, aloca seus recursos em dois tipos diferentes de fundos, renda fixa e crédito privado. De acordo com o conselho de valores monetários (2014), os classificados como "Renda Fixa", devem ostentar como principal fator de risco de seu portfólio a variação da taxa de juros e/ou de índice de preços. Além disso, esses devem observar o limite de 80%, no mínimo, de seu patrimônio líquido representado, isolado ou cumulativamente, por: títulos públicos federais ou ativos financeiros de renda fixa considerados de baixo risco de crédito.

De forma sucinta, um fundo de investimentos em crédito privado, de acordo com o conselho de valores monetários (2014), se trata de um fundo de investimento que pertence a alguma das categorias de que tratam as subseções I, III e IV da instrução nº555 do conselho de valores monetários, que excedam o percentual de 50% de seu patrimônio líquido em aplicações de quaisquer ativos ou modalidades operacionais de direito privado.

## **2.2 APRENDIZADO DE MÁQUINA POR REFORÇO**

Embora não restrito a contemporaneidade, somente ao final da década de 80, estudos relevantes na área voltaram a ser publicados. Segundo Honda et al. (2017), aprendizado de máquina é um programa que busca melhorar o desempenho de um agente, através da realização de tarefas, adquirindo experiência.

No que tange o assunto investimentos, Choi (2009), o autor discorre sobre investidores individuais, afirmando que eles se baseiam em seus resultados pessoais em períodos anteriores. Os investidores que obtiveram retornos mais elevados em seus investimentos, tendem a

umentar sua taxa de investimento em uma magnitude maior em comparação aos investidores que obtiveram experiências piores. Esta conduta é análoga ao comportamento de aprendizagem por reforço, que premia os acertos. Desta forma, o autor afirma a possibilidade de utilizar aprendizagem por reforço para criar algoritmos de investimentos.

Entre os diversos metodos de machine learning que atualmente existem, este estudo se concentra no aprendizado por reforço, que consiste em utilizar tentativa e erro para executar uma determina função. Ao final da execução, os resultados são avaliados e medidas são tomadas. Conforme salientado por Dias Júnior (2012), aprendizado por reforço [...] é um método de programação de agentes através do oferecimento de recompensas e punições, sem a necessidade de especificar como uma tarefa deve ser realizada.

Com bases nas citações supracitadas, é entendido que o algoritmo está introduzido ao meio ambiente. Ele interage com seu ecossistema por meio de ferramentas estatísticas e métodos de programação, onde busca adaptar-se com o objetivo tomar decisões acertivas em diferentes estados do ambiente.

O funcinamento do algoritmo pode ser simplificado. No momento inicial, o agente se encontra inativo, pois nenhuma ação foi tomada. No segundo momento, ele inicia seu estado de interação com o meio ambiente. Neste segundo estado, ele gera um valor e com base em sua ação, o algoritmo interpreta este valor segundo um critério pré-definido, determinando se ação foi desejável ou não, lhe atribuindo um feedback (reforço). Com base na resposta do algoritmo à sua ação, o agente se tornará mais ou menos propenso a executar esta ação no futuro. Ao final deste ciclo o agente volta ao seu estado inicial, esperando que o ciclo se repita, como visto na Figura 1.

**Figura 1** – Funcionamento do aprendizado por reforço



Fonte:Elaborado por Dias Júnior (2012).

Por fim, Mullainathan e Spiess (2017) destacam a possibilidade de utilizar o aprendizado por reforço destinado a estudos de reconhecimento de padrões em bancos de dados.

Na atualidade, com a acessão do big data, o aprendizado por reforço pode ocupar uma posição de destaque na ciência moderna e conseqüentemente em veículos de investimentos.

### 2.3 INTERAÇÃO SOCIAL

Visando uma maior proximidade entre teoria e dados empíricos, diferentes estudos recentes em economia tem considerado o papel da interação social no comportamento dos agentes econômicos. Neste contexto, Flieth e Foster (2002, p. 39) assim se manifestam sobre expectativas interativas:

“An interactive process of expectation formation involves discussion between agents, friends, business partners and competitors are asked for their opinions that, in turn, affect and agent’s own expectations. To observe such a process, it is necessary to analyse the expectations of a group of interacting individuals”.

Diferentes argumentos são encontrados para justificar a presença de interação social entre os agentes econômicos. Assim, Gale e Kariv (2003) e Tichy (1992) destacam a importância de introduzir a interação social entre os indivíduos, devido à possibilidade de que os agentes conectados observem quais são as decisões passadas tomadas por vizinhos, melhorando em sua própria decisão atual. Portanto, os autores discorrem que os agentes econômicos são limitados na sua racionalidade e, na presença de incerteza, observam o processo de formação e tomada de decisão dos agentes com os quais se comunicam, uma vez que as decisões dos vizinhos podem ter informações que sejam relevantes.

Outros dois argumentos bastante utilizados na literatura econômica para fundamentar a utilização da interação social nos modelos macroeconômicos são encontrados em Kaufman (1999) e Hommes (2006). O primeiro salienta que, nas decisões econômicas fatores emocionais podem estar envolvidos no processo de decisão dos agentes e que esses podem prevalecer sobre as atitudes racionais. Mais precisamente, Kaufman (1999) afirma que atributos emocionais podem gerar vieses e irracionalidade nas decisões econômicas. Por sua vez, Hommes (2006) salienta que interação social possibilita o surgimento de diferentes padrões de ações entre distintos grupos e este comportamento apresenta uma boa validação diante dos dados empíricos.

Como bem destaca Hommes (2006), quando um agente se encontra inserido em um ambiente de interação social, a utilidade ou payoff que o agente recebe por determinada ação, depende diretamente das escolhas dos outros agentes no grupo de referência deste indivíduo. Desta maneira, as escolhas dos agentes são afetadas pelo comportamento (decisão) dos outros

agentes, não apenas diretamente através do mercado, mas também através da imitação, aprendizagem, pressão social, compartilhamento de informação ou outro tipo de externalidades.

Portanto, quando um agente toma determinada decisão, além das motivações explícitas e observáveis relacionadas aos atributos particulares de uma ação perante alternativas, esse pode influenciar e ser influenciado pelas escolhas (decisões) dos seus vizinhos. Além disso, esses incentivos coletivos estão ligados a necessidade dos agentes em ajustar, em alguma medida, o seu comportamento de escolha ao comportamento do grupo que lhe servem de referência (Freitas 2003, p. 19).

Exemplificando, um investidor ao decidir se mantém ou não um determinado título na carteira, o incentivo social que pode influenciar a sua ação é encontrado na forma de como os demais investidores irão se comportar e o impacto deste comportamento sobre o preço de mercado do título. Outro exemplo da influência das motivações sociais é encontrado em firmas que reajustam os seus preços quando uma determinada empresa decidiu por elevar o preço do bem que produz. O reajuste não pode ser muito superior ao praticado por outras firmas que produzem bens substitutos próximos, pois há risco de perder clientes.

Por fim, cabe destacar que as interações entre os agentes são locais, isto é, realizada entre vizinhos sociais (Topa, 2001). Esta vizinhança é composta por agentes que partilham determinada proximidade socioeconômica, a qual não remete necessariamente a proximidade geográfica. Assim, dois agentes que residam em localidades geográficas distantes também podem ser considerados vizinhos sociais se frequentam o mesmo ambiente social, como, por exemplo, serviço, escola ou até mesmo se tenham a mesma fonte de informações que influenciam os seus comportamentos (Freitas 2003, p. 26).



### 3 METODOLOGIA

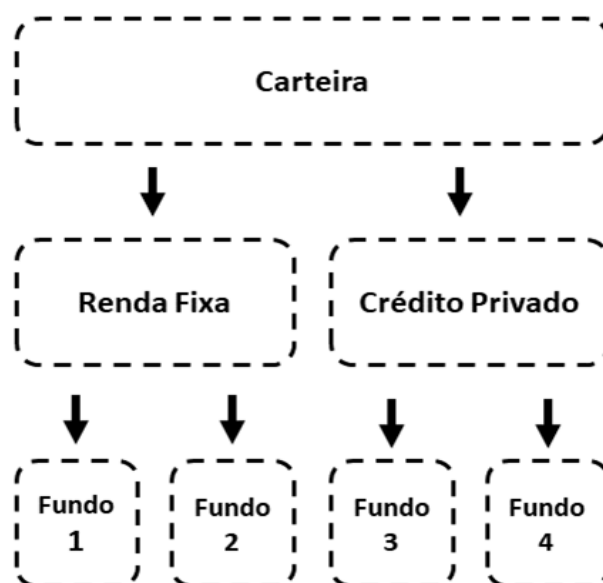
O objeto da pesquisa é um fundo de investimento em cotas (FIC), que chamar-se-á de carteira, as variáveis são os fundos de investimentos (FI) onde a carteira aloca seus recursos, estes “FIs” chama-se de fundos. O foco desta análise é visualizar o desempenho da carteira com a finalidade de observar se carteira simulada superou a carteira real no quesito de rentabilidade ao final do último período.

#### 3.1 ESTRUTURA DE INVESTIMENTOS

Os critérios de elegibilidade dos fundos estão descritos na política de investimentos da carteira (exógeno a essa análise). Isso significa que este estudo não apresenta em seu escopo uma metodologia de seleção de ativos. Além disso, a política de investimentos determina a impossibilidade de aplicação dos recursos da carteira em qualquer outro ativo que não nos fundos de investimentos pré-selecionados.

Ademais, os fundos estão divididos em duas categorias: renda fixa e crédito privado. Cada uma das categorias há dois fundos representantes e cada fundo é gerido individualmente por um gestor terceirizado. Esta estrutura está ilustrada na figura a 2.

**Figura 2** – Estrutura de investimentos



Fonte: Elaboração própria.

O patrimônio investido pela carteira não poderá ser alavancado, ou seja, o algoritmo deverá investir exatamente os recursos que possui, não excedendo, nem mesmo deixando recursos em caixa. Portanto, a cada período, o algoritmo realoca os recursos de forma que a soma das participações dos fundos na carteira seja sempre igual a 100%.

Para haver uma carteira de investimentos é necessário a existência de uma estrutura de custódia e administração. Esta demanda uma série de serviços terceirizados que apresentam custos. Estes custos impactam diretamente nas rentabilidades, pois são cobrados diariamente no valor das cotas da carteira e dos fundos. Porém, as cotas desse último já estão com os custos descontados. Para se obter uma simulação da cota líquida (descontado os custos) da carteira foi levado em consideração a taxa de auditoria, CETIP, gestão e outros, não havendo neste estudo custo de transação.

Portanto, todos os resultados obtidos pelo modelo proposto já estão com os custos considerados, com exceção do custo de transação.

### 3.2 ÍNDICE DE SHARPE

Neste estudo, o índice de Sharpe segue os padrões utilizados no dia-a-dia do mercado financeiro. Desta maneira este é dado por:

$$I = \frac{(Média de retorno) - (Média de retorno de CDI)}{(DP retorno)},$$

no qual  $I$  é o índice de Sharpe;  $(Média de retorno)$  é o retorno esperado do ativo em um determinado período de tempo;  $(Média de retorno de CDI)$  é o retorno médio do ativo livre de risco em um determinado período de tempo;  $(DP retorno)$  é o desvio padrão dos retornos do ativo em um determinado período de tempo.

Para se realizar o índice de Sharpe foi utilizado como o ativo livre de risco o certificado de depósito interbancário (CDI). As informações dessa taxa são divulgadas pela instituição CETIP. Já os históricos de cotas dos fundos (ativos) utilizados neste estudo foram obtidos juntamente com a entidade previdenciária.

### 3.3 FEEDBACKS ALGORITMICOS

O algoritmo interage com os fundos por meio de feedbacks positivos ou negativos. Um feedback positivo significa que uma parcela maior do patrimônio da carteira será destinada para o fundo. Isso quer dizer que quando um fundo recebe um feedback positivo, são transferidos mais recursos da carteira para este fundo comparativamente ao período de alocação anterior. Um feedback negativo representa a lógica inversa, uma parcela menor do patrimônio da carteira será destinada para o fundo. Isso indica que quando um fundo recebe um feedback negativo são transferidos menos recursos da carteira para este fundo comparativamente ao período de alocação anterior.

A magnitude de um feedback positivo sempre será três vezes maior do que um negativo, forçando assim que, ao final de cada período, a soma das participações dos fundos no patrimônio da carteira sempre será 100%, impossibilitando a alavancagem citada no tópico anterior.

Vale ressaltar que existe controles para alocações consideradas irregulares, como por exemplo, nenhum fundo poderá ter alocação maior que 97% do patrimônio da carteira aplicado em si, nem menor que 1%. Esta regra garante que todos os fundos tenham participação em todos os períodos da atuação do algoritmo.

#### 3.3.1 Critérios para feedbacks

A lógica algorítmica interpreta duas variáveis observáveis para atribuir feedbacks, a saber: Rentabilidade e Índice de Sharpe.

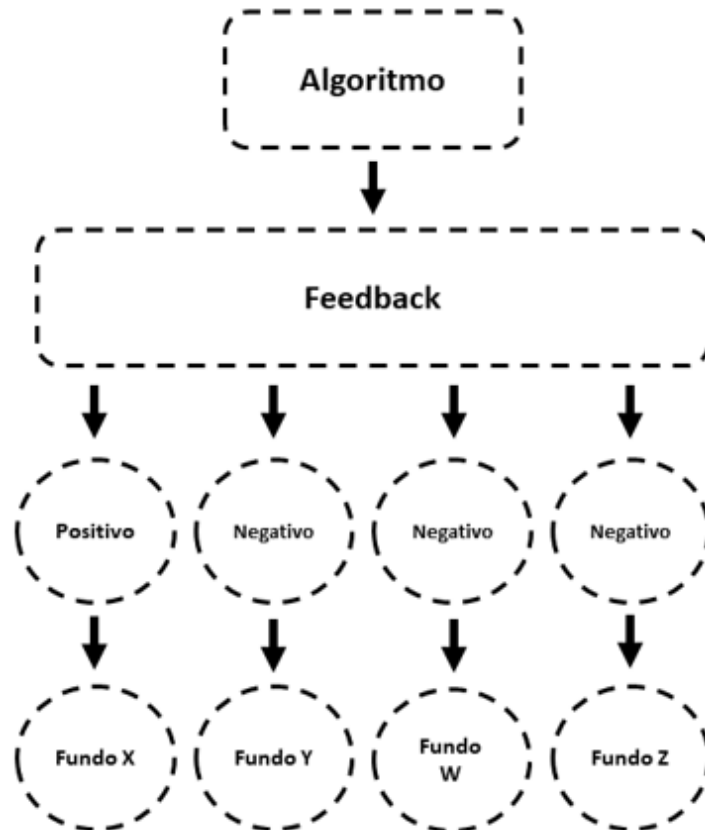
No que tange o critério rentabilidade, a cada período de avaliação o algoritmo irá comparar qual dos quatro fundos apresentou o maior retorno. Por fim, ele irá atribuir um feedback positivo para este fundo, e um feedback negativo para cada um dos outros três fundos. Esta dinâmica visa estimular a carteira a aplicar seus recursos em fundos que apresentam melhores rentabilidades ao longo do período da análise. Assim, buscando elevar os retornos da carteira.

No quesito Índice de Sharpe, a cada período de avaliação o algoritmo irá comparar se o Índice da carteira decresceu ou elevou. Assim, caso tenha decrescido comparativamente ao período de avaliação anterior, o algoritmo realiza um feedback positivo para o fundo com maior o Índice de Sharpe e um feedback negativo para cada um dos outros três fundos. Esta dinâmica

visa estimular a carteira a aplicar seus recursos em fundos que apresentam melhores índices de Sharpe.

Para ilustrar a dinâmica de feedbacks, segue a demonstração de como atua o algoritmo na prática em cada uma de suas intervenções.

**Figura 3 – Feedbacks algorítmicos**



Fonte: Elaboração própria.

### 3.3.2 Sensibilidade algorítmica

Cabe ao algoritmo a definição de quanto alocar em cada um dos quatro fundos segundo os critérios citados anteriormente. Contudo, além disso, é de sua responsabilidade definir a intensidade desta alocação. Esta intensidade busca simular uma proxy de humor do agente ou sensibilidade, que pode variar entre conservador, moderado e arrojado.

Um investidor conservador busca aplicações com baixa volatilidade em detrimento de rentabilidade, não que ele não a almeje, porém prioriza a preservação de capital investido. Já um investidor com perfil arrojado apresenta uma mentalidade inversa ao investidor conservador. Ele busca a rentabilidade como uma prioridade, mesmo que tenha que estar mais

exposto a riscos. Por fim, o Investidor moderado é um meio termo entre o conservador e o arrojado, sendo uma média de ambos.

A sensibilidade do algoritmo interfere nos dois critérios para feedbacks: Rentabilidade e Índice de Sharpe, os maximizando ou não. Além disso, para tornar a estrutura mais abrangente e complexa, existe uma sensibilidade para a rentabilidade e outra para o índice de Sharpe.

No primeiro período, tanto a sensibilidade da rentabilidade quanto a sensibilidade do índice de Sharpe são conservadoras. Portanto, correspondem ao valor de 1 (um) para sensibilidade da rentabilidade e de 3 (três) para a sensibilidade de índice de Sharpe. Porém, a cada período de avaliação algorítmica a sensibilidade é alterada conforme a experiência do agente, sempre respeitando o valor máximo de 3 (três) e o mínimo de 1 (um).

Desta forma, cada categoria de sensibilidade corresponde a um valor numérico. Para a sensibilidade de rentabilidade: conservador corresponde ao número 1 (um), moderado corresponde a 2 (dois) e arrojado a 3 (três). Já para a sensibilidade de índice de Sharpe a lógica é inversa: conservador 3 (três), moderado 2 (dois) e arrojado 1 (um).

Há três variáveis que interferem na sensibilidade do agente, cita-se: a primeira é a rentabilidade, onde a mudança de estado de sensibilidade segue a seguinte lógica, caso a rentabilidade da carteira atual for maior ou igual a rentabilidade da carteira no tempo anterior, adicione 1 (um) a variável sensibilidade de rentabilidade, caso falso, subtraia 1 (um) a variável sensibilidade rentabilidade.

Esta lógica reforça que caso o agente obtenha sucesso no quesito rentabilidade de uma alocação para outra, ele se torna mais confiante, assim um nível mais arrojado. Porém, a lógica inversa também é verdadeira. Caso ele não obtenha êxito na elevação da rentabilidade da carteira, ele se tornará mais conservador no quesito rentabilidade.

A segunda variável que interfere na sensibilidade do agente é o índice de Sharpe, onde a mudança de sensibilidade segue a seguinte lógica: caso o Índice de Sharpe da carteira atual seja maior ou igual ao índice de Sharpe da carteira no tempo anterior, subtraia 1 (um) a variável sensibilidade de índice de Sharpe, caso falso, adicione 1(um) a variável sensibilidade índice de Sharpe.

Esta lógica reforça que, caso o agente obtenha sucesso no quesito índice de Sharpe da carteira de uma alocação para outra, ele se tornará mais confiante. Assim, um nível mais arrojado, se tornando menos sensível a relação risco e retorno. A lógica inversa também é verdadeira. Caso ele não obtenha êxito na elevação do Índice de Sharpe da carteira ele se tornará mais conservador no quesito risco e retorno.

A terceira variável que interfere na sensibilidade do agente é a interação social. Essa é de suma importância para o desempenho do modelo, pois, sem ela o algoritmo não conseguiria se avaliar comparativamente com o meio no qual está introduzido. No máximo ele constataria internamente que seus indicadores estão melhorando. Porém sabemos que gestores de fundos de investimentos não vivem em bolhas, muito menos em torres de marfins. Seus resultados são comparados diariamente com seus pares. Além disso, é lógico afirmar que algumas ou se não todas suas atitudes sofrem interferências extremas de outros fundos de investimentos.

Buscando simular esta dinâmica, criou-se uma comparação de rentabilidades, no qual, a rentabilidade da carteira no período é comparada com a média da rentabilidade do mercado. Neste estudo, o mercado corresponde aos vinte maiores fundos de renda fixa e crédito privado do Brasil. Metade dos fundos são de característica renda fixa e a outra de característica crédito privado. A dinâmica de mudança de sensibilidade segue a seguinte lógica: caso a rentabilidade da carteira atual seja maior ou igual a rentabilidade média de mercado atual, a variável sensibilidade de rentabilidade permanece inalterada, caso falso, adicione 1 (um) a variável sensibilidade rentabilidade.

Esta lógica reforça que caso o agente fracasse no quesito interação social, ele necessita se tornar mais arrojado, pois sua atual estratégia está lhe atribuindo retornos abaixo da média de mercado.

### **3.3.3 Interação entre feedbacks e sensibilidade**

Este tópico é regido a luz dos conceitos de feedback e sensibilidade descritos na metodologia supracitada, sendo assim busca ser de cunho prático.

Após o algoritmo ter avaliado todos os parâmetros descritos em sua lógica metodológica, ele irá realizar, de fato, a alteração nas alocações. Portanto, as participações dos fundos no patrimônio da carteira irão se alterar por intermédio de feedbacks, sejam eles positivos ou negativos, onde serão impactados pelo sentimento algoritmo. Com isso a relação entre as duas variáveis se dá no momento da execução da nova alocação.

Para expressar esta interação entre feedback e sensibilidade seguem as fórmulas:

**Figura 4** – Fórmulas de novas alocações

**POSITIVO:**

*Nova alocação no fundo X = feedback positivo \* Sensibilidade de Rentabilidade*

*Nova alocação no fundo X = feedback positivo \* Sensibilidade de índice de Sharpe*

**NEGATIVO:**

*Nova alocação no fundo Y = feedback negativo \* Sensibilidade de Rentabilidade*

*Nova alocação no fundo Y = feedback negativo \* Sensibilidade de índice de Sharpe*

Fonte: Elaboração própria.

### 3.4 IMPLEMENTAÇÃO COMPUTACIONAL

Para implementação computacional do algoritmo foi utilizado a linguagem Python. A rotina computacional age a cada período. Assim, a cada período o algoritmo irá se deparar com os mesmos fundos e deverá realizar uma nova alocação, sempre utilizando todo o seu patrimônio.

A condição inicial para o período  $t=0$ , assume-se que a carteira simulada está com a mesma alocação que a real na data de 29/12/2017, sendo a única interferência algorítmica um feedback de rentabilidade em  $t=0$ . A partir de  $t=1$ , o algoritmo executa a cada novo tempo ( $t$ ) a mesma série de 5 (cinco) passos: definições de sensibilidades, feedbacks, correções alocativas, execuções das alocações e verificação temporal.

Com o objetivo de consolidar a metodologia citada anteriormente, a representação gráfica organiza a cronologia temporal dos acontecimentos algorítmicos, desde seu início até o final do período analisado. Por fim, segue a representação do fluxograma:

Figura 5 – Rotina algorítmica



Fonte: Elaboração própria.



## 4 RESULTADOS

Na presente sessão apresentar-se-á o resultado da carteira em diferentes tempos de rebalanceamento: 1 (um) dia útil, 10 (dez) dias úteis e 25 (vinte e cinco) dias úteis e magnitudes de feedback. Desta forma, a lógica algorítmica em todos os testes é igual, o que diverge é justamente a periodicidade dos rebalanceamentos e a intensidade dos feedbacks.


Ademais, para a presente análise a data inicial é de 29/12/2017 e a data final é 31/12/2018. Nas Figuras (6-11), comparasse o valor da cota da carteira simulada (em dourado) em relação ao valor da cota da carteira real (em verde).

No primeiro teste, a periodicidade dos feedbacks é de um dia útil, isso quer dizer que a cada dia útil a composição da carteira irá se alterar, havendo uma rebalanceamento entre os fundos. Além disso, o feedback positivo teve o valor de 0,06%, já os negativos de -0,02%. Esta lógica de proporção três para um, garante a não alavancagem ao longo da atuação algorítmica.

A explicação desta dinâmica será a busca por um algoritmo menos passivo, que busca uma maior adaptação ao meio ambiente. Para isso realiza alocações a cada dia útil, pois esse estudo presume-se que quanto mais atuação da lógica algorítmica, mais adaptado será o modelo ao meio ambiente. Além de todas as características citadas anteriormente, o primeiro teste executa pequenas alocações, o que facilita sua aplicação em meio a um mercado ilíquido, pois quanto mais ilíquido o mercado for, mais dificultoso é a venda ou compra de ativos, o que é um empecilho ao rebalanceamento da carteira.

Na Figura 6 apresenta o resultado da carteira para a lógica aplicada no primeiro teste.

**Figura 6** – Períodos diários, Feedbacks 0,06%, -0,02%




Fonte: Elaboração própria.

A Figura 6 representa o resultado da carteira simulada em comparação a real. Desta forma, o algoritmo apresentou uma rentabilidade de 8,55% no ano, já a real apresentou uma rentabilidade 7,83%, o que retrata uma superação de 9,20% do algoritmo em relação a real. Isto sinaliza que o algoritmo obteve êxito no seu objetivo de superar a carteira real.

No segundo teste, a periodicidade dos feedbacks na carteira continua em 1 (um) dia útil. Porém, o feedback positivo teve o valor de 1,2%, já os negativos de -0,4%. A lógica para esta dinâmica é mesma que a anterior, mas apresenta grandes ações alocativas, o que dificultaria sua aplicação em meio a um mercado ilíquido. Toda via, mesmo sendo improvável sua aplicação na prática seus resultados são os mais expressivos, devido seus feedbacks gerarem grandes ajustes na carteira e os rebalanceamentos serem diários, gerando uma grande adaptação ao meio ambiente, como demonstra o resultado na Figura 7.

**Figura 7**– Períodos diários, Feedbacks 1,2%, -0,4%




Fonte: Elaboração própria.

A Figura 7 representa o resultado da carteira simulada em comparação a real. Desta forma, a carteira simulada apresentou uma rentabilidade de 8,72% no ano, já a real uma rentabilidade 7,83%, o que retrata uma superação de 11,37% do algoritmo. Isto sinaliza que o algoritmo obteve êxito no seu objetivo de superar a carteira real.

No terceiro teste, a periodicidade dos feedbacks é de 10 (dez) dias úteis. Esta dinâmica busca observar como o algoritmo irá se comportar com menos rebalanceamentos, se tornando mais passivo, observando por mais tempo as variáveis para tomar uma decisão de aplicação de um feedback. Além disso, o feedback positivo teve o valor de 0,06%, já os negativos de -0,02%.

Seus feedbacks são de pequenas alocações, somado a uma frequência alocativa menor do que os teste anteriores, facilitando sua aplicação.

**Figura 8** – Períodos de 10 dias, Feedbacks 0,06%, -0,02%

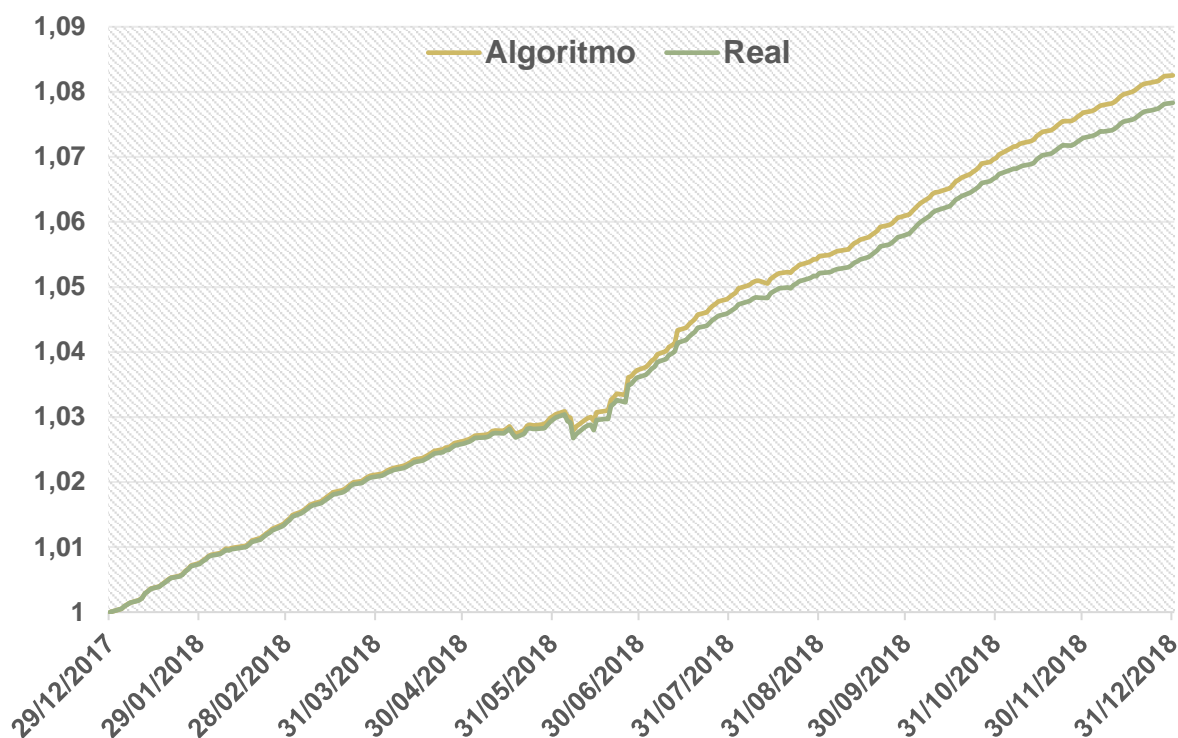


Fonte: Elaboração própria.

A Figura 8 representa o resultado da carteira simulada em comparação a real. Desta forma, a carteira simulada apresentou uma rentabilidade de 8,18% no ano, já a real uma rentabilidade 7,83%, o que retrata uma superação de 4,47% do algoritmo em relação ao gestor. Isto sinaliza que o algoritmo obteve êxito no seu objetivo de superar a carteira real.

No quarto teste, a periodicidade dos feedbacks continua em dez dias úteis, seguindo a mesma lógica de passividade do teste anterior. Porém, o feedback positivo teve o valor de 1,2%, já os negativos de -0,4%, efetuando grandes rebalanceamentos, o que na prática dificulta a execução do algoritmo. Porém, a combinação de uma frequência alocativa menor, de 10 (dez) dias úteis, facilita sua aplicação em meio a um mercado ilíquido, como é o mercado de renda fixa na prática.

**Figura 9**– Períodos de 10 dias, Feedbacks 1,2%, -0,4%




Fonte: Elaboração própria.

A Figura 9 representa o resultado da carteira simulada em comparação a real. Desta forma, a carteira simulada apresentou uma rentabilidade de 8,25% no ano, já a real uma rentabilidade 7,83%, o que retrata uma superação de 5,36% do algoritmo. Evidencia-se que a periodicidade de alocações e rebalanceamento mais agressivas neste teste, obteve resultados melhores do que uma alocação menos agressiva, como no caso do terceiro teste.

No quinto teste, a periodicidade dos feedbacks é de 25 (vinte e cinco) dias úteis. A lógica para esta dinâmica seria a busca por um algoritmo muito passivo, que procura uma adaptação lenta ao ambiente, observando por um longo período as variáveis para tomada de decisão.

O feedback positivo tem o valor de 0,06%, já os negativos de -0,02%. Esses, de pequenas alocações, somado a uma frequência alocativa espaçada temporalmente, facilita sua aplicação na prática. Vale a ressalva que, este teste seria o que mais se aproximaria de um algoritmo de gestão de renda fixa que poderia ser aplicado na prática, justamente por sua passividade e pequenos feedbacks.

**Figura 10** – Períodos de 25 dias úteis, Feedbacks 0,06%, -0,02%




Fonte: Elaboração própria.

A Figura 10 representa o resultado da carteira simulada em comparação a real. Desta forma, a carteira simulada apresentou uma rentabilidade de 8,17% no ano, já a real uma rentabilidade 7,83%, o que retrata uma superação de 4,34% do algoritmo.

Sendo este quinto teste o mais fidedigno de aplicação a realidade, apresentando êxito na superação da rentabilidade da carteira real, torna esse estudo exitoso em seu propósito.

O sexto teste, apresenta a mesma periodicidade de relançamentos do teste anterior, 25 (vinte e cinco) dias úteis. Porém, apresenta feedbacks agressivos. O positivo teve o valor de 1,2%, já os negativos de -0,4%. Porém, a magnitude de seus feedbacks não se torna um grande empecilho devido a frequência alocativa espaçada temporalmente.

**Figura 11** – Períodos de 25 dias úteis, Feedbacks 1,2%, -0,4%



Fonte: Elaboração própria.

A Figura 11 representa o resultado da carteira simulada contra a real, a carteira simulada apresentou uma rentabilidade de 7,45% no ano, já a real uma rentabilidade 7,83%, o que retrata uma derrota de -4,85% do algoritmo.

Ponto de reflexão, esse foi o único teste no qual o algoritmo não superou a carteira real. Esta aplicação respeitou as mesmas regras que todas as demais, porém a combinação de extrema passividade, com agressividade alocativa, não apresentou resultados favoráveis.

## 5 CONCLUSÃO

O presente estudo elaborou um modelo computacional que considera atributos observáveis (rentabilidade e índice de Sharpe) e atributos sociais (performance dos fundos com características semelhantes). Com base nesta metodologia foram realizados seis testes, como é esboçado no tópico resultados, no qual ficou evidente a superação da carteira simulada em comparação a carteira real na grande maioria dos testes.

Ademais, observa-se que a partir de maio de 2018, justamente em um momento de grande estresse do mercado financeiro, as carteiras simuladas apresentaram ganhos superiores as carteiras reais de forma mais expressiva. A provável causa para esse descolamento de rentabilidade talvez seja que as alocações algorítmicas ajam sempre de forma não arbitrária, o que para um humano é algo dificultoso em momentos de grande estresse e incerteza, podendo gerar perdas de capital.

Pode se concluir que, este estudo obteve sucesso no que se propôs, a grande maioria de seus testes provaram que o algoritmo é de fato eficiente. Porém, o mesmo comportamento não se apresentou em todos os testes, no sexto e último teste, o algoritmo não superou a carteira real. A provável explicação é que o algoritmo pode ter perdido o timing de mercado, não aproveitando o movimento ocorrido em maio de 2018.

Vale ressaltar que toda a aplicação feita neste trabalho contribuiu para a expansão dos seus resultados: o aprendizado de máquina, a sensibilidade algorítmica e a interação social. Todos estes fatores são essenciais para o sucesso deste estudo, pois se retirado qualquer um destes itens, causará uma perda de desempenho do algoritmo.

Por fim, não se pode descartar que com uma maior lapidação, utilização de metodologias mais robustas e maior tempo disponível para sua execução, é plausível afirmar que os resultados apresentados por este estudo podem ser ainda mais satisfatórios.



## REFERÊNCIAS

ALMEIDA, Helberte João França. Formação de expectativas de inflação em um ambiente de racionalidade limitada e implicações macroeconômicas: Uma abordagem de escolha discreta. *In*: TESE DE DOUTORADO, 2016, Universidade Federal de Santa Catarina. Acesso em: 30 abr. 2019.

ASNESS, Clifford S.; MOSKOWITZ, Tobias J.; PEDERSEN, Lasse Heje. Value and Momentum Everywhere. Acesso em: 16 fev. 2019.

ATHEY, Susan. The Impact of Machine Learning on Economics. NBER Working Papers, jan 2018.

As teorias de carteira de Markowitz e de Sharpe. Uma Aplicação No Mercado Brasileiro de Ações Entre Julho/95 e Junho/2000: Revista de Administração Mackenzie, 2005. Disponível em: <<http://editorarevistas.mackenzie.br/index.php/RAM/article/view/72>>. Acesso em: 07 nov. 2018.

BRASIL. INSTRUÇÃO CVM n. 555, de 17 de dez. de 2014. INSTRUÇÃO CVM Nº 555, DE 17 DE DEZEMBRO DE 2014. INSTRUÇÃO CVM Nº 555. COMISSÃO DE VALORES MOBILIÁRIOS. Acesso em: 12 nov. 2018.

BOYD, Stephen; BUSSETI, Enzo; DIAMOND, Steven; KAHN, R.N. Multi-Period Trading via Convex Optimization. Foundations and Trends in Optimization, v. 3, n. 1, p. 1-76, 2017.

CASTELLANO, Murilo. A Teoria do Risco Financeiro – Parte II. Disponível em: <<http://www.blogdocastellano.com.br/?p=1643>>. Acesso em: 01 jun 2018. CASTRO, U.C.

CHOI, J.J.; LAIBSON, David; MADRIAN, B.C.; METRICK, Andrew. Reinforcement Learning and Savings Behavior. The Journal of Finance, v. 64, n. 6, p. 2515-2534, dez 2009.

CUTAIT, Beatriz. Fundos Quantitativos: conheça os gestores que ganham com a volatilidade do mercado. [www.infomoney.com.br](http://www.infomoney.com.br), 2019. Disponível em: <https://www.infomoney.com.br/onde-investir/fundos-de-investimento/noticia/8305765/os-gestores-que-ganham-com-a-volatilidade-do-mercado>. Acesso em: 20 maio 2019.

Derivação de modelos de trading de alta frequência em juros utilizando aprendizado por reforço, 2017. Dissertação (Mestrado em Economia e Finanças) – Mestrado Profissional em Finanças e Economia, Fundação Getúlio Vargas, São Paulo.

DIAS JÚNIOR, E.P.F. Aprendizado por reforço sobre o problema de revisitação de páginas web, 2012. Dissertação (Mestrado em Informática) – PPG em Informática, Pontifícia Universidade Católica, Rio de Janeiro.

PRADO, Marcos López. The 7 Reasons Most Machine Learning Funds Fail. Acesso em: 4 mar. 2019.

DU, X.; ZHAI, J.; LV, K. Algorithm trading using q-learning and recurrent reinforcement learning. Citeseer, v. 1, p. 1, 2016.

FERREIRA, Gustavo. Maiores fundos de previdência rendem menos que o CDI. [www.valor.com.br](http://www.valor.com.br), 2019. Disponível em: <https://www.valor.com.br/financas/6244401/maiores-fundos-de-previdencia-rendem-menos-que-o-cdi>. Acesso em: 8 maio 2019.

Flieth, B. & Foster, J. (2002), 'Interactive expectations.', *Journal of Evolutionary Economics*, 12, 4, 375–395.

Freitas, G. G. (2003), *Economia e sistemas complexos: Interações sociais, dinâmicas emergentes e uma análise da difusão da internet na cidade de são paulo*, Master's thesis, Universidade de São Paulo.

Gale, D. & Kariv, S. (2003), 'Bayesian learning in social networks', *Games and Economic Behavior* 45(2), 329–346.

Hommes, C. H. (2006), 'Heterogeneous agent models in economics and finance', *Handbook of computational economics* 2, 1109–1186.

JORION, PHILIPPE. A nova fonte de referência o para controle do risco de mercado: Value at risk. 5. ed. São Paulo - SP: Bolsa de Mercadorias & Futuros, 2003. 300 p. v. 5.

Kaufman, B. (1999), 'Emotional arousal as a source of bounded rationality', *Journal of Economic Behaviour Organization* 38, 135–144.

MARKOWITZ, H. M. *Portfolio selection: efficient diversification of investments*. New York: John Wiley & Sons, 1959.

MULLAINAHAN, Sendhil; SPIESS, Jann. Machine Learning: An Applied Econometric Approach. *Journal of Economic Perspectives*, v. 31 n. 2, p. 87-106, mar-jun 2017

PEREIRA, L.B.T.; HENRIQUE, D.C. Otimização de investimentos pelo modelo de Markowitz via desenvolvimento de uma ferramenta em Excel. *Iberoamerican Journal of Industrial Engineering*, v. 8, n. 16, 2016.

REVISTA Eletrônica de Administração – FACEF – Vol. 12 – Edição 13 – Julho-Dezembro 2008: Comparação entre Diferentes Modelos de Precificação de Ativos com Risco: CAPM e Variantes. Franca - SP: Revista Eletrônica de Administração, [07/12/2008]. Disponível em: <<http://periodicos.unifacef.com.br/index.php/rea/article/view/214/66>>. Acesso em: 05 nov. 2018.

SHARPE, William F. The Sharpe Ratio. [web.stanford.edu](http://web.stanford.edu), 1994. Acesso em: 24 nov. 2018.

Tichy, G. (1992), 'Erwartungsbildung und konjunkturforschung: Axiomatik versus erhebungen.', *IFO- Studien* 38 (1), 43–82.

Topa, G. (2001), 'Social interactions, local spillovers and unemployment', *Review of economic studies* pp. 261–295.