

**UNIVERSIDADE FEDERAL DE MINAS GERAIS**  
**Escola de Engenharia**  
**Programa de Pós-Graduação em Engenharia Elétrica**

Breno Costa Dolabela Dias

**Agregação de Índices de Análise de Sentimentos com Conjuntos Nebulosos  
Hesitantes para Previsão de Séries Temporais no Mercado Financeiro**

Belo Horizonte

2021

Breno Costa Dolabela Dias

**Agregação de Índices de Análise de Sentimentos com Conjuntos Nebulosos  
Hesitantes para Previsão de Séries Temporais no Mercado Financeiro**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Mestre(a) em Engenharia Elétrica.

Orientador: Frederico Gadelha Guimarães  
Co-orientador: Petrônio Cândido de Lima e Silva

Belo Horizonte  
2021

D541a

Dias, Breno Costa Dolabela.

Agregação de índices de análise de sentimentos com conjuntos nebulosos hesitantes para previsão de séries temporais no mercado financeiro [recurso eletrônico] / Breno Costa Dolabela Dias. - 2021.

1 recurso online (53 f : il., color.) : pdf.

Orientador: Frederico Gadelha Guimarães.

Coorientador: Petrônio Cândido de Lima e Silva.

Dissertação (mestrado) - Universidade Federal de Minas Gerais, Escola de Engenharia.

Bibliografia: f. 49-53.

Exigências do sistema: Adobe Acrobat Reader.

1. Engenharia elétrica - Teses. 2. Análise de séries temporais - Teses. 3. Conjuntos difusos - Teses. 4. Mercado financeiro - Teses. I. Guimarães, Frederico Gadelha. II. Silva, Petrônio Cândido de Lima e. III. Universidade Federal de Minas Gerais. Escola de Engenharia. IV. Título.

CDU: 621.3(043)

**"Agregação de Índices de Análise de Sentimentos Com  
Conjuntos Nebulosos Hesitantes Para Previsão de Séries  
Temporais No Mercado Financeiro"**

**Breno Costa Dolabela Dias**

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 26 de julho de 2021.

Por:



---

**Prof. Dr. Frederico Gadelha Guimarães  
DEE (UFMG) - Orientador**



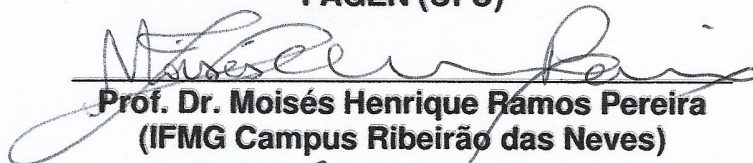
---

**Prof. Dr. Petrônio Cândido de Lima e Silva  
(IFNMG)**



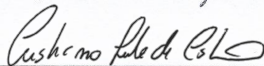
---

**Profa. Dra. Carla Bonato Marcolin  
FAGEN (UFU)**



---

**Prof. Dr. Moisés Henrique Ramos Pereira  
(IFMG Campus Ribeirão das Neves)**



---

**Prof. Dr. Cristiano Leite de Castro  
(UFMG)**

*A todas as pessoas que me fizeram ser quem eu sou hoje...*

## AGRADECIMENTOS

Gostaria de agradecer a todas as pessoas que de alguma forma fizeram parte deste trabalho e da minha vida.

Ao meu orientador, Fred, por toda paciência, disposição e por suas palavras que sempre tranquilizaram e incentivaram nos momentos em que tive dificuldade.

Ao meu co-orientador, Petrônio, pela grande ajuda e apoio, e por compartilhar tantos conhecimento sobre as séries temporais nebulosas.

À minha mãe, Heloísa, por todo o seu carinho incondicional. Ao meu pai, Alexandre, por todo apoio e suporte. Ao meu irmão, Igor, por ser uma referência para mim.

À minha avô, Mathilde (*in memoriam*), pelo exemplo de sabedoria e luta. Ao meu avô Jésus (*in memoriam*), que me mostrou que pode-se levar a vida sempre com bom humor. Às famílias Araújo Costa e Dolabela Dias, por todo o apoio.

À minha namorada, Marcela, por todo companheirismo, incentivo e amor.

A todas minhas amizades, pelas risadas, *memes* e momentos de descontração.

Aos professores, colegas e amigos do PPGEE e PPGCC, em especial ao laboratório MINDS, por todo o conhecimento compartilhado, cuidado e apoio.

Aos amigos e colegas da Tembici, Itaú Unibanco, Tyde e Sympla por todos os ensinamentos.

Aos meus gatos Jiji, Sula e Félix pela companhia.

E por último à CAPES, pelo apoio financeiro.

“Nothing in life is as important as you think it is, while you are thinking about it”  
(KAHNEMAN, 2011)

## RESUMO

A análise de sentimentos é uma técnica para automaticamente extrair informações subjetivas de textos, como opiniões e sentimentos. Para ser utilizada em uma previsão do mercado financeiro, as classificações de sentimento de notícias e postagens de mídias sociais devem ser agregadas em um único valor para produzir uma série temporal com a mesma periodicidade dos preços do mercado de ações, por exemplo, diariamente ou por hora. Nesta pesquisa, adotamos valores linguísticos (e seus conjuntos hesitantes correspondentes) para representar preços e sentimentos. Dado o índice de sentimento fuzzificado para cada tweet, fizemos uma agregação baseada em Conjuntos Nebulosos Hesitantes, que visa modelar a incerteza causada pela hesitação que pode surgir na atribuição de graus de pertinência dos elementos a um conjunto nebuloso. Depois de fuzzificar o índice de sentimento e agregá-lo no mesmo período de tempo, produzimos uma série de tempo fuzzificada de dados de sentimento, que pode ser usada como informação adicional para modelos de previsão. Neste trabalho, empregamos como modelo de aprendizado de máquina, a Weighted Multivariate Fuzzy Time Series (WMVFTS). Para os experimentos, coletamos tweets postados pela Bloomberg e os preços de fechamento do Standard & Poor's 500 Index e Nasdaq Composite Index. A principal característica entregue pelo método proposto é a capacidade de melhorar um método FTS usando informações hesitantes, como as notícias postadas no Twitter.

Palavras-chave: Análise de Sentimentos; Séries Temporais Nebulosas; Conjuntos Nebulosos Hesitantes; Séries Temporais Financeiras.



## ABSTRACT

Sentiment analysis is an automatic technique to extract subjective information from texts, such as opinions and sentiments. For providing a time series forecasting using sentiment analysis, sentiment classifications of news and social media posts have to be aggregated into a single value to produce a time series with the same periodicity of the stock market prices, for example daily or hourly. In this work, we adopt fuzzy linguistic values (and corresponding fuzzy sets) to represent prices and sentiments. Given the fuzzified sentiment index of each tweet, we proceed to an aggregation based on hesitant fuzzy sets, which aim to model the uncertainty caused by the hesitation that may arise in the attribution of degrees of membership of the elements to a fuzzy set. Having fuzzified the sentiment index and aggregated them within the same time period, we produce a fuzzified time series of sentiment data, which can be used as additional information for forecasting models. In this research, we employ a multivariate fuzzy time series (FTS) method, namely Weighted Multivariate Fuzzy Time Series (WMVFTS), as the machine learning model. For the experiments we collected tweets posted by Bloomberg and the closing prices of Standard & Poor's 500 Index and Nasdaq Composite Index. The main feature delivered by the proposed method is the capability of improving an FTS method by using hesitant information, such as the news posted on Twitter.

Keywords: Sentiment Analysis; Fuzzy Time Series; Hesitant Fuzzy Set; Financial Time Series.

## LISTA DE FIGURAS

Figura 1 – Procedimentos do treinamento do FTS . . . . .	21
Figura 2 – Procedimentos do MVFTS . . . . .	23
Figura 3 – Léxico de sentimentos (BENEVENUTO; RIBEIRO; ARAÚJO, 2015) .	27
Figura 4 – Fluxograma de treinamento do modelo <i>Skip-gram with negative sampling</i> (MIKOLOV et al., 2013) . . . . .	28
Figura 5 – <i>Pre-training</i> do BERT (DEVLIN et al., 2018) . . . . .	29
Figura 6 – <i>Fine-tuning</i> do BERT (DEVLIN et al., 2018) . . . . .	30
Figura 7 – Fluxograma da metodologia proposta . . . . .	32
Figura 8 – Histograma com a frequência dos sentimentos dos <i>tweets</i> da Bloomberg’s	37
Figura 9 – Preços de fechamento e preços de fechamento diferenciados do índice Nasdaq . . . . .	38
Figura 10 – Preços de fechamento e preços de fechamento diferenciados do índice S&P 500 . . . . .	39
Figura 11 – Correlação cruzada entre a série diferenciada do S&P 500 e a série de sentimento hesitante . . . . .	39
Figura 12 – Correlação cruzada entre a série diferenciada da Nasdaq e a série de sentimento hesitante. . . . .	40
Figura 13 – Amostra de conjuntos hesitantes para as séries de preços utilizando 5 partições . . . . .	41
Figura 14 – Amostra de conjuntos hesitantes para as séries de preços utilizando 10 partições . . . . .	42
Figura 15 – Amostra de conjuntos hesitantes para as séries de preços utilizando 15 partições . . . . .	42
Figura 16 – Amostra de conjuntos hesitantes para a série de sentimento hesitante utilizando 3 partições . . . . .	42
Figura 17 – Amostra de conjuntos hesitantes para a série de sentimento hesitante utilizando 5 partições . . . . .	43

## LISTA DE TABELAS

Tabela 1 – Amostra de tweets removidos . . . . .	33
Tabela 2 – Amostra de tweets e suas pontuações correspondentes . . . . .	34
Tabela 3 – Amostra de tweets com suas datas ajustadas para o mercado . . . . .	35
Tabela 4 – Amostra de tweets com o sentimento agregado . . . . .	35
Tabela 5 – Amostra de <i>features</i> e variável <i>alvo</i> usados no treinamento do modelo .	36
Tabela 6 – Tweets postados anualmente . . . . .	37
Tabela 7 – Métricas para a predição do Nasdaq usando 570 dias de treinamento e 30 para prever 30 dias <i>out-of-sample</i> . . . . .	43
Tabela 8 – Métricas para a predição do S&P 500 usando 570 dias de treinamento e 30 para prever 30 dias <i>out-of-sample</i> . . . . .	44
Tabela 9 – Resultados do teste de Friedman . . . . .	44
Tabela 10 – Testes de Finner comparando o modelo proposto com diferentes parâmetros com os testes de <i>benchmark</i> . . . . .	45
Tabela 11 – Testes de Finner comparando as diferentes parametrizações com as melhores performances . . . . .	46

## LISTA DE ABREVIATURAS E SIGLAS

AMH	Adaptative Market Hypothesis
BERT	Bidirectional Encoder Representations from Transformers
BSE	Bombay Stock Exchange
DJIA	Dow Jones Industrial Average
EMH	Efficient Market Hypothesis
FTS	Fuzzy Time Series
FST	Fuzzy Sets Theory
GPOMS	Google-Profile of Mood States
HFTS	Hesitant Fuzzy Time Series
MCDM	Multiple criteria decision making
MLM	Masked Language Model
MINDS	Machine Intelligence and Data Science
MISO	Multiple Input-Single Output
MVFTS	Conventional Multivariate Fuzzy Time Series
Nasdaq	National Association of Securities Dealers Automated Quotations
NLI	Natural Language Inference
NSP	Next Sentence Prediction
POMS-bi	Profile of Mood States
QA	Question Answering
S&P 500	Standard and Poor's 500
SVM	Support Vector Machine
TAIFEX	Taiwan Futures Exchange
WMVFTS	Weighted Multivariate Fuzzy Time Series
UFMG	Universidade Federal de Minas Gerais

## LISTA DE SÍMBOLOS

$Y$	Conjunto de dados nítidos
$k$	Conjuntos fuzzy
$\tilde{A}$	Variável Linguística
$U$	Universo de discurso
$\Omega$	Quantidade de defasagens
$\mathcal{M}$	Modelo de conhecimento
$f(t)$	uma instância de $F$ no tempo $t$ ,
$\hat{y}(t + 1)$	um ponto de previsão para o tempo $t + 1$
$w_i$	Cada peso $w$
$\tilde{\mathcal{V}}_i \in \mathcal{V}$	Cada variável de $\mathcal{V}$
$*\mathcal{V} \in \mathcal{V}$	A variável <i>target</i> de $\mathcal{V}$

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>15</b>
1.1	Motivação	15
1.2	Objetivo Geral	17
1.3	Divisão do trabalho	17
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>18</b>
2.1	Previsibilidade do Mercado	18
2.1.1	Hipótese do Mercado Eficiente	18
2.1.2	Finanças Comportamentais	19
2.1.3	Hipótese do Mercado Adaptativo	19
2.2	Fuzzy Time Series	20
2.3	Conventional Multivariate Fuzzy Time Series	22
2.4	Weighted Multivariate Fuzzy Time Series	24
2.5	Hesitant Fuzzy Sets	25
2.6	Análise de sentimentos	26
2.6.1	Abordagens léxicas	27
2.6.2	word2vec	27
2.6.3	BERT	28
2.7	Análises de sentimentos na previsão do mercado financeiro	30
2.8	Conclusão	31
<b>3</b>	<b>METODOLOGIA</b>	<b>32</b>
3.1	Coleta e processamento de dados	33
3.2	Obtenção de sentimentos	33
3.3	Agregação	34
3.4	Previsão	35
3.5	Conclusão	36
<b>4</b>	<b>EXPERIMENTOS</b>	<b>37</b>
4.1	Dados	37
4.2	Métricas de avaliação	39
4.3	Métodos	40
4.4	Reprodutibilidade	41
4.5	Hiperparâmetros e configurações dos testes	41
4.6	Resultados	43
4.7	Conclusão	46
<b>5</b>	<b>CONCLUSÃO</b>	<b>47</b>
5.1	Limitações da metodologia proposta	47

5.2	Propostas de trabalhos futuros . . . . .	48
5.3	Contribuições do trabalho . . . . .	48
<b>REFERÊNCIAS</b>	. . . . .	<b>49</b>

# 1 INTRODUÇÃO

## 1.1 Motivação

Segundo [Neto \(2003\)](#), o mercado de ações é um multiplicador da riqueza nacional. É uma importante fonte de financiamento para as empresas, o que permite a viabilização de seus projetos de investimento. Está dividido em dois: o mercado primário e o mercado secundário. O mercado primário é onde as ações das empresas são pela primeira vez emitidas e negociadas diretamente com os investidores de mercado. Esse dinheiro arrecadado com a venda é utilizado para financiar os investimentos, sendo assim uma importante alternativa de captação de recursos. O mercado secundário não propicia a oferta de novas ações, mas é onde os investidores podem fazer as negociações de compra e venda de ações já emitidas. É onde ocorre somente uma transferência da propriedade das ações, não ocorrendo a entrada de novos recursos para as empresas. Por muitos anos, investidores e pesquisadores estiveram interessados em desenvolver e testar modelos para previsão de preços de ações ([FAMA, 1995](#)). No entanto, devido ao ruído e à não estacionariedade, as séries temporais financeiras estão entre os sinais mais difíceis de prever ([ABU-MOSTAFA; ATIYA, 1996](#)).

Várias teorias foram criadas ao longo dos anos para tentar explicar a natureza do mercado de ações. A Efficient Market Hypothesis (EMH) afirma que os preços do mercado de ações em qualquer momento “refletem totalmente” as informações disponíveis ([FAMA, 1965](#)), assumindo que todos os agentes estão totalmente informados sobre o mercado. Conseqüentemente, um investidor que escuta uma notícia sobre uma empresa não consegue lucrar com ela. No entanto, o campo da economia comportamental critica o EMH, argumentando que os investidores muitas vezes são irracionais, devido aos vieses que os humanos possuem. Essas irracionalidades podem fazer com que um investidor por exemplo não reaja da forma mais apropriada ao escutar uma notícia sobre alguma empresa. A Adaptive Market Hypothesis (AMH) é um framework proposto por [Lo \(2004\)](#), [Lo \(2005\)](#) que concilia o EMH e a economia comportamental, assumindo a existência de preços ineficientes em alguns momentos. Várias técnicas tentam tirar proveito dessas ineficiências, como a análise de sentimentos de notícias e de redes sociais.

A análise de sentimentos tem como objetivo desenvolver técnicas automáticas de extração de informações subjetivas de textos, como opiniões e sentimentos, ajudando na tomada de decisão ([BENEVENUTO; RIBEIRO; ARAÚJO, 2015](#)). Tem aplicações em negócios, política, ações públicas e mercado financeiro ([ALESSIA et al., 2015](#)). Nos mercados financeiros, vários estudos previram os preços das ações usando diferentes fontes de dados, como redes sociais ([OLIVEIRA; CORTEZ; AREAL, 2017](#); [NISAR; YEUNG, 2018](#)) e notícias ([OLIVEIRA; CORTEZ; AREAL, 2017](#); [STAMBAUGH; YU; YUAN, 2012](#)).



De acordo com (SHAH; ISAH; ZULKERNINE, 2019), a análise de sentimentos com base em várias fontes de dados pode fornecer *insights* sobre como os mercados de ações reagem a diferentes tipos de notícias. Com isto, surgiu uma nova linha de pesquisa que mede o sentimento de notícias, redes sociais e outras fontes de dados para identificar seu impacto nos mercados financeiros.

Para fornecer uma previsão de série temporal usando análise de sentimento, algumas questões precisam ser levadas em consideração. As postagens de notícias e redes sociais têm periodicidade variável, podendo ser publicadas a qualquer momento. Para os preços do mercado de ações, no entanto, a periodicidade é fixa, podendo ser diária ou de hora em hora, por exemplo. Para uma previsão de série temporal, é necessária uma forma de lidar com essa divergência de frequência dos dados. Uma solução é agregar o sentimento dos tweets de um mesmo dia ou hora para um único valor. No entanto, uma vez que o sentimento dos tweets extraídos pela análise de sentimentos é uma informação subjetiva, é necessário aplicar uma agregação que leva em conta essa característica.

Essa dissertação lidou com a subjetividade dos sentimentos dos tweets adotando valores linguísticos nebulosos (e conjuntos nebulosos correspondentes), e então utilizando uma agregação com base em Conjuntos Fuzzy Hesitantes (HFS). Os Conjuntos Fuzzy Hesitantes foram propostos por Torra e Narukawa (2009), Torra (2010) e são uma extensão dos Conjuntos Fuzzy que visam modelar a incerteza causada pela hesitação que pode surgir na atribuição de graus de pertinência dos elementos a um conjunto fuzzy. Pode ser aplicado para resolver problemas de tomada de decisão, conforme o estudo de Xia e Xu (2011). Depois de fuzzificar o índice de sentimento e agregá-los no mesmo período de tempo, foi produzida uma série temporal fuzzificada de dados de sentimento, que pode ser usada como entrada adicional para modelos de previsão. Nesta dissertação, empregamos como modelo de aprendizado de máquina um método de Fuzzy Time Series (FTS) multivariado, o *Weighted Multivariate Fuzzy Time Series* (WMVFTS).

Para analisar a efetividade do método proposto, foram realizados experimentos para tentar prever os preços de fechamento diário dos índices americanos S&P 500 e Nasdaq. O índice de sentimento foi criado a partir de uma base de cerca de 400.000 tweets publicados pela Bloomberg do período de 2017-01-01 até 2020-05-31. Os resultados do método proposto tiveram sua efetividade comparada com diferentes métricas que foram comparados com métricas de modelos que não utilizaram o índice de sentimento.

A contribuição deste trabalho foi uma forma de lidar com as diferenças de periodicidade na análise de sentimentos para previsão de séries temporais financeiras. Como os sentimentos são informações subjetivas e com uma periodicidade não uniforme, agregamos os diferentes valores para uma frequência diária usando um método de agregação que tem como característica a capacidade de lidar com subjetividade, os Conjuntos Fuzzy Hesitantes. Com isso, foi proposta uma forma de contribuir com a previsão dos preços

utilizando o sentimentos de notícias .

## 1.2 Objetivo Geral

O principal objetivo desta pesquisa foi propor um método para a agregação de sentimentos de notícias e de postagens de redes sociais de diferentes periodicidades para fazer previsões no mercado financeiro.

## 1.3 Divisão do trabalho

O restante dessa dissertação está organizado da seguinte forma:

- Revisão da Literatura: são definidos importantes conceitos para o bom entendimento do trabalho, como a teoria por trás da previsibilidade do mercado financeiro, os conceitos de *Fuzzy Time Series*, *Conventional Multivariate Time Series*, *Weighted Multivariate Time Series*, *Hesitant Fuzzy Sets*, análise de sentimentos e algumas de suas técnicas. Nesse capítulo também são discutidos os resultados dos estudos de outros autores utilizando análise de Sentimentos em previsões no mercado financeiro;
- Metodologia: Nesse capítulo é apresentada a metodologia proposta e utilizada no desenvolvimento desse trabalho. É descrita a forma como os dados financeiros e as notícias foram obtidas, qual método foi aplicado para obter o sentimento das notícias, como esses sentimentos foram agregados e utilizados na previsão de séries temporais. São descritas as etapas de obtenção de dados e realização dos experimentos, de forma que o trabalho possa ser executado por outros pesquisadores, para a replicabilidade.
- Resultados: Esse capítulo apresenta os resultados obtidos para as diferentes aplicações realizadas através da abordagem proposta. É apresentado os dados utilizados nos experimentos, as bibliotecas, as métricas de avaliação, os parâmetros utilizados nas séries temporais e os seus resultados.
- Conclusão e Propostas Futuras: São fornecidas as considerações conclusivas, algumas limitações e indica oportunidades de novas pesquisas.

## 2 REFERENCIAL TEÓRICO

O presente capítulo apresenta um apanhado dos principais conceitos que alicerçam a metodologia proposta nesse trabalho. São apresentados conceitos, justificativas e características sobre o assunto abordado, além de trabalhos feitos por outros autores a respeito do tema.

A Seção 2.1 detalha as importantes teorias a respeito da previsibilidade do mercado. Na Seção 2.2 é explicado o funcionamento do *Fuzzy Time Series* e na Seção 2.3 detalhamos o funcionamento do método *Conventional Multivariate Fuzzy Time Series*. Na Seção 2.4 apresentamos o *Weighted Multivariate Time Series*, e na Seção 2.5 descrevemos o funcionamento de *Hesitant Fuzzy Sets*. Na Seção 2.6, apresentamos o conceito e alguns métodos de análise de sentimentos. Na Seção 2.7 são mencionados alguns trabalhos de previsão de séries temporais envolvendo sentimento extraído de textos, e por fim a Seção 2.8 fecha o capítulo sintetizando o que foi abordado.

### 2.1 Previsibilidade do Mercado

#### 2.1.1 Hipótese do Mercado Eficiente

A Hipótese do Mercado Eficiente (EMH) foi criada por Fama (1965) e sugere que os retornos do mercados não são previsíveis, ou seja, os preços em qualquer momento “refletem totalmente” as informações disponíveis. Ela pode ser dividida em três diferentes formas:

- A fraca, que sugere que os preços históricos já estão refletidos no preço de um ativo.
- A semiforte, que sugere que toda informação disponível publicamente está refletida no preço das ações.
- A forte, que afirma que todas informações estão refletidas nos preços de um ativo, mesmo as informações ocultas ou privilegiadas.

A maior parte dos estudos a respeito se dedicam a validar a EMH com base na forma fraca, considerando apenas os preços históricos (DOURADO; TABAK, 2014). Dessa forma, não é possível prever seus retornos baseando-se apenas nas informações passadas, como preço e volume. No estudo de Doran, Peterson e Wright (2010) foi feito uma pesquisa com mais de quatro mil professores universitários de finanças e tiveram como resultado que a maior parte deles acredita que o mercado é eficiente na forma fraca ou semiforte.

De acordo com [Grossman e Stiglitz \(1980\)](#), é impossível um mercado ser perfeitamente eficiente, uma vez que há informações que não estão refletidas nos preços. Dessa forma, existem pessoas interessadas em pagar por informações a fim de receberem vantagens.

### 2.1.2 Finanças Comportamentais

As Finanças Comportamentais são o estudo de como os investidores interpretam e agem de acordo com a informação para fazer decisões de investimento ([LINTNER, 1998](#)). É um estudo que considera que os investidores não são racionais o tempo todo ([THALER, 1999](#)). Um dos temas dentro dos estudos de Finanças Comportamentais são os vieses heurísticos ([SHEFRIN, 2002](#)). Alguns desses vieses são listados a seguir:

- Representatividade: Proposto por [Tversky e Kahneman \(1974\)](#), o Princípio da Representatividade se refere à tendência dos tomadores de decisão se basearem em representatividade como forma de simplificar a análise dos problemas. Ou seja, as pessoas os investidores tendem a assumir que eventos recentes irão continuar a acontecer no futuro;
- Excesso de confiança: Este viés se refere à tendência das pessoas de acreditar que são mais precisas em situações que envolvem incerteza do que realmente são ([TVERSKY; KAHNEMAN, 1974](#)). Em se tratando de investidores, significa que estes acreditam em sua habilidade de vencer o mercado acima da média;
- Ancoragem: Este princípio proposto por [Tversky e Kahneman \(1974\)](#) se refere ao fato de que decisões tomadas em contextos idênticos podem ser bastante diferentes em razão da presença de valores de referência distintos disponíveis para os decisores.

De acordo com [Lima \(2003\)](#), o grande desafio para os pesquisadores da área de Finanças Comportamentais está em provar que essas anomalias são realmente previsíveis e podem modificar o mercado de forma definida.

### 2.1.3 Hipótese do Mercado Adaptativo

A Hipótese do Mercado Adaptativo (AMH) é um *framework* proposto por [Lo \(2004\)](#), [Lo \(2005\)](#) que concilia o EMH e a economia comportamental. Essa proposta assume a existência de períodos com preços eficientes e períodos com preços ineficientes. Esses períodos ineficientes geram previsibilidade, devido a interferências governamentais, bolhas e outros fatores. O AMH é baseado em princípios da evolução como competição, adaptação e seleção natural, e na Teoria da Racionalidade Limitada de [Simon \(1955\)](#), na qual o agente possui como restrição as informações disponíveis, o tempo para agir e sua própria capacidade cognitiva, tendo assim um comportamento satisfatório ao invés de ótimo.

A análise da AMH é importante devido ao fato de que os acontecimentos fazem com que agentes tenham sua psicologia alterada e incorporem as informações nos preços de forma distinta, sendo gerada uma variação temporal na correlação dos retornos (KIM; SHAMSUDDIN; LIM, 2011). Durante crises financeiras, não houve previsibilidade estatisticamente significativa dos retornos, estando associada a alto grau de incerteza. Em crises políticas e guerra houve alta previsibilidade com grau moderado de incerteza. E durante bolhas econômicas, a previsibilidade dos retornos apresentou-se menor do que em tempos considerados normais.

Uma vez que a AMH assume a ineficiência do mercado financeiro em alguns momentos, podem então ser utilizados métodos para tentar fazer a previsão das séries temporais de preço. A sessão seguinte detalha o funcionamento das Fuzzy Time Series (FTS), uma família de métodos utilizados neste trabalho.

## 2.2 Fuzzy Time Series

Fuzzy Time Series (FTS) é uma família de métodos de previsão não paramétricos baseados em dados introduzidos pela primeira vez por Song e Chissom (1993b) e aprimorado por Song, Leland e Chissom (1997), baseados na Teoria de Conjuntos Fuzzy (FST) proposta por Zadeh (1965). Esses métodos são fáceis de implementar e muito flexíveis, proporcionando maneiras de lidar com dados numéricos e não numéricos (SILVA, 2019). Conforme descrito por Silva (2019), os principais componentes da metodologia FTS podem ser listados abaixo:

1. Pré-processamento: A transformação de pré-processamento de dados podem ser aplicadas aos dados da série temporal  $Y$  que se deseja prever, como redução de ruído, remoção de tendência ou dessazonalização, etc.
2. Particionamento: o universo de discurso  $U$  é dividido em  $k$  conjuntos fuzzy, criando a variável linguística definida como  $\tilde{A}$ .
3. Fuzzificação: A representação linguística  $F$  dos dados numéricos  $Y$  é criada usando a variável linguística  $\tilde{A}$ .
4. Extração e Representação de Regras: Um modelo de conhecimento  $\mathcal{M}$  realiza um reconhecimento de padrões sobre  $F$ , aprendendo os padrões temporais entre uma quantidade de defasagens definida como  $\Omega$ .

O seu processo de treinamento está resumido na Figura 1. Uma vez que as regras são geradas, o procedimento de previsão ocorre conforme listado abaixo:

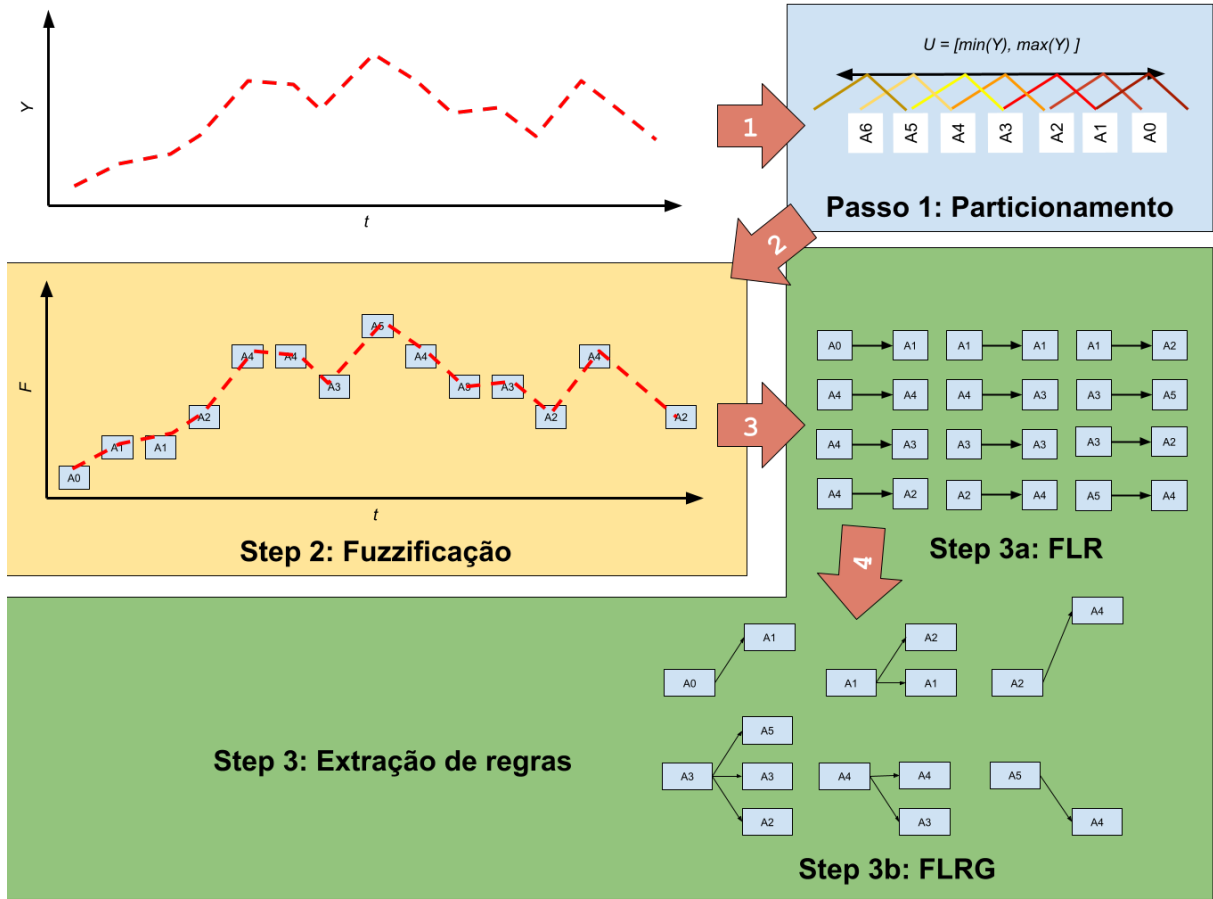


Figura 1 – Procedimentos do treinamento do FTS

1. Pré-processamento: Uma ou mais transformações de pré-processamento de dados podem ser aplicadas à amostra de entrada  $y(t)$ .
2. Fuzzificação: A representação linguística  $F$  dos dados numéricos  $Y$  é criada a partir da variável linguística  $\tilde{A}$ .
3. Inferência: O modelo  $\mathcal{M}$  usa os componentes  $\Omega$  de  $F$  para prever a estimativa de  $f(t + 1)$ .
4. Defuzzification: O  $f(t + 1)$  é transformado em uma estimativa numérica  $\hat{y}(t + 1)$
5. Pós-processamento: Finalmente, uma ou mais transformações de dados de pós-processamento podem ser aplicadas à previsão de saída  $\hat{y}(t + 1)$ .

Os diferentes valores dos hiperparâmetros do modelo afetam o processo de treinamento e os parâmetros do modelo, incluindo sua precisão e parcimônia. Os métodos FTS são comumente empregados para prever matrículas em universidades (SONG; CHISSOM, 1993b; SONG; CHISSOM, 1993a; SONG; CHISSOM, 1994; ISMAIL; EFENDI, 2011), demanda de turismo Lee, Javedani et al. (2011), consumo de energia elétrica (YASMEEN; SHARIF, 2015; SADA EI et al., 2017; ISMAIL; EFENDI; DERIS, 2015) e bolsas de valores

(SUN et al., 2015; CHEN, 2014; LEE; J.SADAEI; SUHARTONO, 2013; SADAEI et al., 2016; TALARPOSHTI et al., 2016), entre outros.

Uma importante categoria dos modelos FTS são os multivariados, ou seja, modelos que permitem a previsão tendo como entrada múltiplas variáveis. A próxima sessão apresenta o Conventional Multivariate Fuzzy Time Series (MVFTS), um modelo que possui como principal diferença ser multivariado.

### 2.3 Conventional Multivariate Fuzzy Time Series

O Conventional Multivariate Fuzzy Time Series (MVFTS) é um modelo de previsão baseado em regras Multiple Input-Single Output (MISO), conforme descrito por Silva (2019), como uma extensão multivariável do modelo do Chen (1996). O método MVFTS é composto de procedimentos de treinamento e previsão e contém extensões para modelos de regras ponderadas, muitos passos à frente e previsão de intervalo.

Uma série temporal multivariada nítida é uma matriz  $Y \in \mathbb{R}^{n \times T}$  onde  $y(t) \in \mathbb{R}^n$  são suas instâncias ordenadas pelo tempo  $t = 1 \dots T$ .  $Y$  contém um conjunto  $\mathcal{V}$  de  $n$  variáveis  $\mathcal{V}_j \in \mathbb{R}$ ,  $j = 1 \dots n$ , onde para cada variável o Universo de Discurso  $U_j = [\min(\mathcal{V}_j), \max(\mathcal{V}_j)]$  representa seus limites conhecidos. Em  $\mathcal{V}$ ,  $\mathcal{V}^*$  representa a variável endógena, ou a variável de destino, e as variáveis restantes são as variáveis exógenas ou explicativas. O procedimento de treinamento do MVFTS, ilustrado na Figura 2, é composto por três componentes principais listados abaixo:

1. **Particionamento:** para cada variável  $\mathcal{V}_j \in \mathcal{V}$ , a etapa de particionamento irá dividir o Universo do Discurso  $U_j$  em  $k_j$  intervalos sobrepostos  $u_{j,i}$  de igual comprimento para  $i = 1 \dots k_j$ . Para cada intervalo  $u_{j,i}$  um conjunto fuzzy  $\tilde{A}_{j,i}$  será criado com a função de pertinência  $\mu_{j,i}$ , de forma que  $U_j$  é totalmente coberto por mais de um conjunto fuzzy. O grupo de conjuntos fuzzy compõe a variável lingüística  $\tilde{\mathcal{V}}_j$  e cada conjunto fuzzy também é conhecido como um termo lingüístico.
2. **Fuzzificação:** a série temporal nítida  $Y$  é convertida em uma série temporal fuzzy  $F$ , onde  $f(t) \in F$  é a instância fuzzificada de  $y(t) \in Y$ . Cada  $f(t)$  contém os graus de associação de  $y(t)$  para todos os conjuntos fuzzy  $\tilde{A}_{j,i} \in \tilde{\mathcal{A}}$  de modo que  $f(t) = \{\mu_{j,i}(y(t)) \forall \tilde{A}_{j,i} \in \tilde{\mathcal{V}}_j\}$ .  $F$  também é conhecido como série temporal lingüística.
3. **Extração e Representação de Regras:** Um modelo de conhecimento  $\mathcal{M}$  transforma  $F$  em um conjunto de regras  $f(t) \rightarrow f(t+1)$ , onde o precedente (o lado esquerdo) representa os conjuntos fuzzy que ocorreram no tempo  $t$  para todas as variáveis e o conseqüente (lado direito) representa o grupo de conjuntos fuzzy da variável de destino  $\mathcal{V}^*$  que geralmente acontecem depois de  $y(t)$ . Cada regra  $f(t) \rightarrow f(t+1)$  representa um padrão temporal frequente em  $F$ .

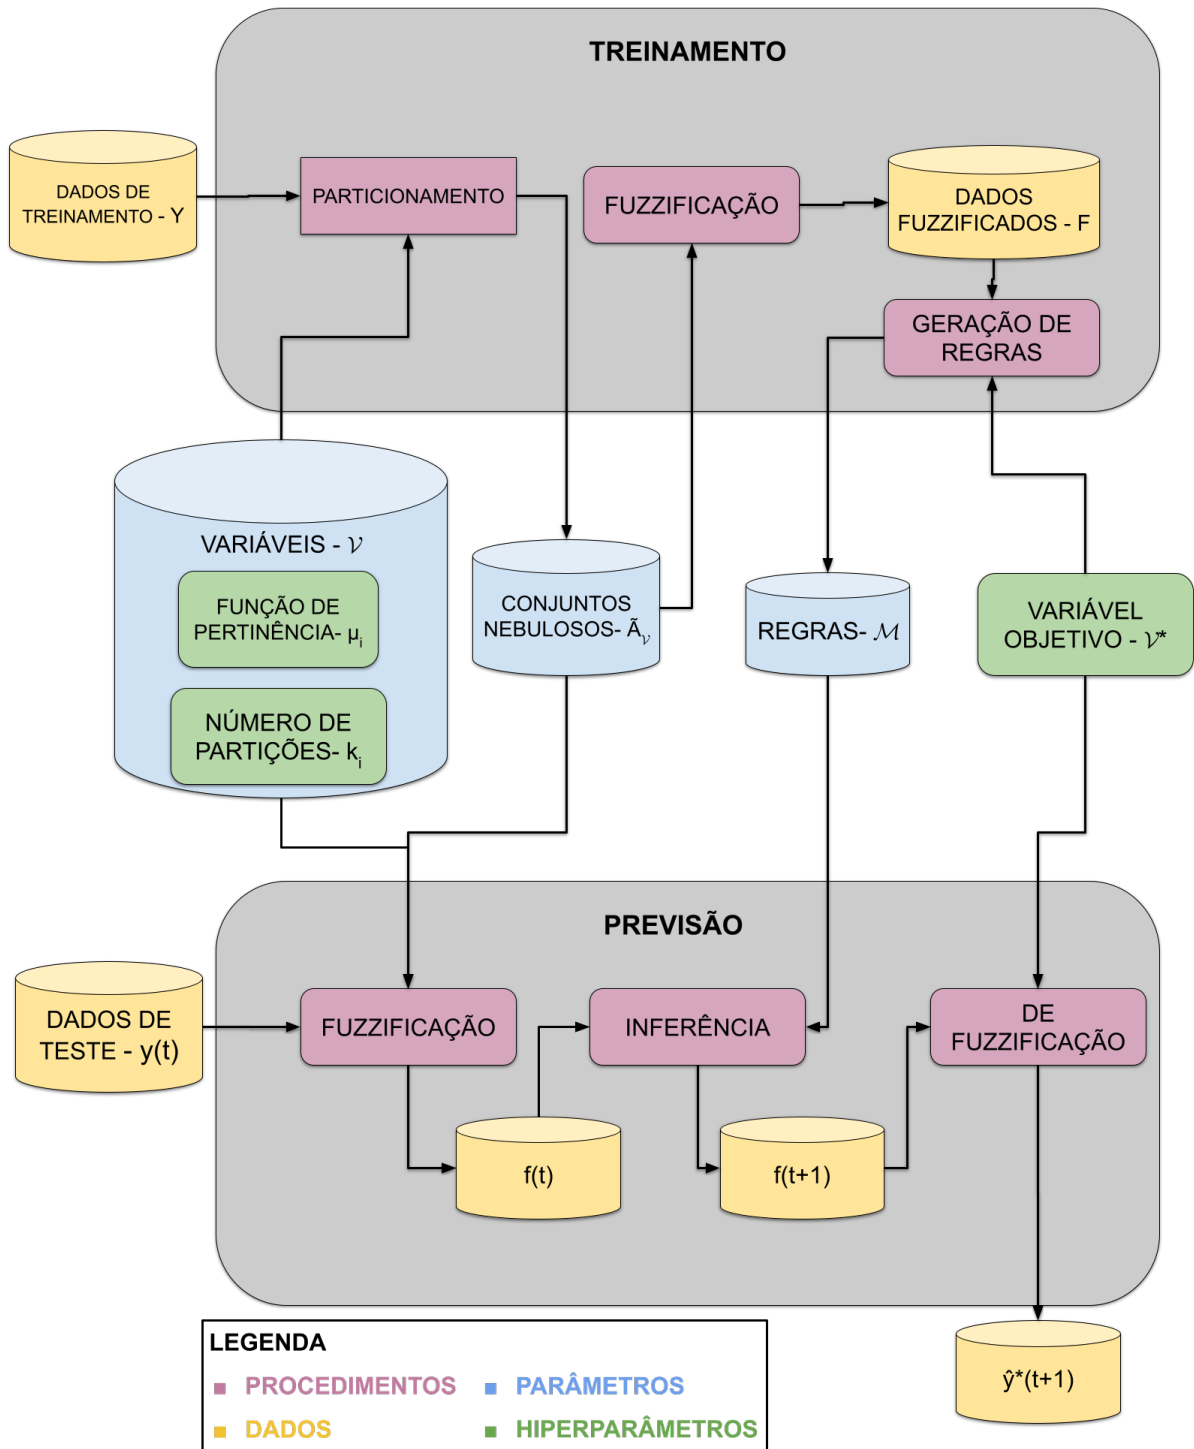


Figura 2 – Procedimentos do MVFTS



Uma vez que as regras  $\mathcal{M}$  são geradas e considerando os dados fora da amostra  $y(t) \in Y$ , o procedimento de previsão, também ilustrado na Figura 2, ocorre conforme listado abaixo de:

1. **Fuzzificação:** Calcule a representação linguística  $f(t)$  dos dados de entrada nítidos  $y(t)$  de modo que  $f(t) = \{\mu_{j,i}(y(t)) \mid \forall \tilde{A}_{j,i} \in \tilde{\mathcal{V}}_j\}$ .
2. **Inferência:** Encontre no modelo  $\mathcal{M}$  as regras  $R r_q$ , com  $q = 1 \dots R$ , cujo precedente coincide com a instância fuzzificada  $f(t)$ . A ativação da regra  $\mu_q$  é calculada como uma combinação dos graus de associação de cada conjunto fuzzy de  $y(t)$  contido no precedente, de modo que  $\mu_q = \cap \mu_{j,i}(y(t)) = \min \mu_{j,i}(y(t))$ . O centro de regra  $m_q$  é calculado como a média dos pontos médios de cada conjunto fuzzy da variável de destino  $\mathcal{V}^*$  contida no conseqüente  $f(t+1)$  da regra.
3. **Defuzzificação:** A estimativa numérica nítida  $\hat{y}(t+1)$  da variável de destino  $\mathcal{V}^*$  é calculada como a média dos centros de regra  $m_q$  ponderada pelas ativações  $\mu_q$ , para cada regra  $r_q$ , de modo que:

$$\hat{y}(t+1) = \frac{\sum_{q=1}^R \mu_q \cdot m_q}{\sum_{q=1}^R \mu_q} \quad (2.1)$$

Os diferentes valores dos hiperparâmetros FTS, como o número de partições  $k_j$  de cada variável e a função de pertinência  $\mu_{i,j}$ , afetam o processo de treinamento e o modelo resultante  $\mathcal{M}$ , incluindo sua precisão e parcimônia. É possível também dar um peso aos diferentes conjuntos fuzzy, conforme explicado na sessão seguinte.

## 2.4 Weighted Multivariate Fuzzy Time Series

O Weighted Multivariate Fuzzy Time Series (WMVFTS) foi proposto por [Silva et al. \(2020\)](#), e é uma extensão do modelo de [Yu \(2005\)](#) para o caso multivariado. A diferença está em adicionar pesos  $w_i \in [0, 1]$ , para cada conjunto fuzzy  $\tilde{A}_i \in \tilde{\mathcal{V}}^*$  no conseqüente da regra, representando sua importância. Cada peso  $w_i$  representa a frequência normalizada do conjunto fuzzy, tal que  $\sum w_i = 1$ . Os pesos afetam apenas o cálculo do ponto médio da regra, que se torna a média dos pontos médios dos conjuntos fuzzy ponderados por  $w_i$ .

Ele tem os mesmos passos do MVFTS, com um acréscimo na geração das regras. Depois que os padrões são gerados, eles são agrupados seguindo o formato  $\mathcal{V} \rightarrow w_k A_k^{*\mathcal{V}}, w_j A_j^{*\mathcal{V}}, \dots$ , onde  $w_j, w_k, \dots$ , são as frequências normalizadas de cada padrão temporal em que:

$$w_i = \frac{\#A_j^{*\mathcal{V}}}{\#RHS} \forall A_j^{*\mathcal{V}} \in RHS \quad (2.2)$$

onde  $\#A_j$  é o número de ocorrências de  $A_j$  em padrões temporais com o mesmo precedente e  $\#RHS$  é o número total de padrões temporais com o mesmo precedente.

Depois que as regras são geradas, para cada regra selecionada  $q$ , o ponto médio  $mp_q$  da variável alvo  $*\mathcal{V}$  é computado como abaixo, onde  $c_j$  é o parâmetro  $c$  da função  $\mu$  do conjunto  $A_j^{*\mathcal{V}}$ .

$$mp_q = \sum_{j \in \tilde{\mathcal{V}}^*_j} w_j \cdot c_j \quad (2.3)$$

O modelo WMVFTS é um modelo MISO, capaz de prever para um passo à frente o valor do preço da ação. É capaz de realizar previsões para múltiplos passos à frente, bem como previsões por intervalo (SILVA, 2019).

## 2.5 Hesitant Fuzzy Sets

Hesitant Fuzzy Sets (HFS) foram introduzidos por Torra e Narukawa (2009), Torra (2010) como uma especificação de conjuntos fuzzy em situações onde há dificuldades em determinar o pertencimento de um elemento a um conjunto causada por uma dúvida entre diferentes valores. É formalmente definido em um conjunto de referência  $X$  em termos de uma função  $h$  que, quando aplicada a  $X$ , retorna um subconjunto de  $[0, 1]$ .

Conforme afirmado por Xia e Xu (2011), o HFS pode ser aplicado em problemas de tomada de decisão, obtendo uma alternativa ótima em problemas com múltiplos atributos e pessoas. Em trabalhos como Zhu e Xu (2013), Liao e Xu (2013), HFS foi aplicado na resolução de problemas de *Multiple criteria decision making* (MCDM)

Nos estudos de Bisht e Kumar (2016), Bisht e Kumar (2019) foi proposto o *Hesitant Fuzzy Time Series* (HFTS), um método que aplicou HFS em séries temporais, fazendo previsão em um ambiente com informações hesitantes. O método foi utilizado na previsão de matrículas na *University of Alabama*, os valores do *Taiwan Futures Exchange* (TAIFEX) e o preço das ações do *State Bank of India*, uma ação listada na *Bombay Stock Exchange* (BSE). De acordo com os autores, a característica do agregador em lidar com a incerteza justifica o uso em aplicações do mercado financeiro, em que os dados possuem volatilidade alta.

Um dos vários métodos de agregação é a Hesitant Fuzzy Weighted Averaging (HFWA), detalhada na Equação (2.4).

$$HFWA = 1 - \prod_{i=1}^n (1 - x_i)^{w_i} \quad (2.4)$$

Aqui  $n$  é o número de elementos no subconjunto de  $[0, 1]$  e  $w_i$  é o peso de  $x_i$  onde  $i = 1, 2, \dots, n$ .

De acordo com [Torra \(2010\)](#), a maior dificuldade nos problemas de tomada de decisão é estabelecer um grau de adesão devido a vários valores possíveis, o que pode gerar dúvidas e incertezas. Dessa forma, o Hesitant Fuzzy Sets é uma boa escolha para agregar diferentes sentimentos de notícias a respeito de um determinado tema.

## 2.6 Análise de sentimentos

A análise de sentimentos ou mineração de opinião é o estudo computacional de opiniões, sentimentos e emoções expressos no texto ([LIU et al., 2010](#)). Tem como objetivo desenvolver técnicas automáticas de extração de informações subjetivas de textos, como opiniões e sentimentos, subsidiando a tomada de decisão ([BENEVENUTO; RIBEIRO; ARAÚJO, 2015](#)). Tem múltiplas aplicações em negócios, política, ações públicas e mercado financeiro. ([ALESSIA et al., 2015](#)). Nos mercados financeiros, diversos estudos previram os preços das ações utilizando diferentes fontes, como mídias sociais ([OLIVEIRA; CORTEZ; AREAL, 2017; NISAR; YEUNG, 2018](#)) e notícias ([OLIVEIRA; CORTEZ; AREAL, 2017; STAMBAUGH; YU; YUAN, 2012](#)). De acordo com [Shah, Isah e Zulkernine \(2019\)](#), a análise de sentimentos com base em várias fontes de dados pode fornecer *insights* sobre como os mercados de ações reagem a diferentes tipos de notícias. Assim, surgiu uma nova abordagem que mede o sentimento das fontes de dados ou o sentimento por trás das notícias para identificar seu impacto nos mercados.

Como afirmado por [Alessia et al. \(2015\)](#), pode ser supervisionado, não supervisionado ou híbrido. A abordagem supervisionada usa algoritmos de aprendizado de máquina. Requer dois conjuntos de documentos: um conjunto de treinamento e um conjunto de teste. O conjunto de treinamento é usado para aprender as características de um documento e o conjunto de teste para validá-lo. A abordagem não supervisionada ou baseada em léxico usa um dicionário de sentimento com palavras de opinião e as combina com os dados para determinar a polaridade. Não necessita de sentenças previamente classificadas para criar o modelo, e é uma das estratégias mais eficientes como afirmado por [Benevenuto, Ribeiro e Araújo \(2015\)](#). Finalmente, na abordagem híbrida, a combinação das abordagens de aprendizado de máquina e baseada em léxico tem o potencial de melhorar o desempenho da classificação de sentimento.

Nas subseções seguintes são detalhadas algumas técnicas de análise de sentimentos: a abordagem léxica, *word2vec* e o *Bidirectional Encoder Representations from Transformers* (BERT), em que o BERT é a técnica aplicada nesta dissertação.

### 2.6.1 Abordagens léxicas

Abordagens léxicas são métodos de análise de sentimentos não supervisionado baseadas em um dicionário léxico de sentimento, um tipo de dicionário de palavras que ao invés de possuir como conteúdo o significado de cada palavra um significado quantitativo. Esse significado quantitativo é por exemplo um número entre -1 a 1, em que -1 é o valor sentimental mais negativo e +1 é o valor sentimental mais positivo (BENEVENUTO; RIBEIRO; ARAÚJO, 2015). Esse método assume que a palavra possui uma polaridade prévia, ou seja, uma orientação semântica independente do contexto (TABOADA et al., 2011). A Figura 3 representa o funcionamento do método de análise de sentimentos léxico.

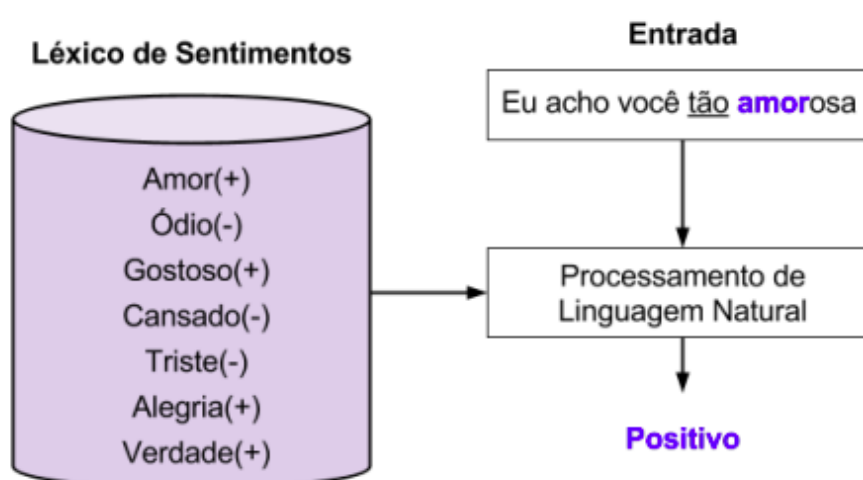


Figura 3 – Léxico de sentimentos (BENEVENUTO; RIBEIRO; ARAÚJO, 2015)

### 2.6.2 word2vec

O *word2vec* é um modelo proposto por Mikolov et al. (2013) e foi o primeiro modelo de *embedding*, que são uma forma de representação que consegue garantir significado semântico ao texto e o representa através de vetores densos de tamanho fixo, com dimensão menor quando comparado aos vetores gerados com métodos de contagem de palavra, por exemplo (CARVALHO, ).

Para gerar as *embeddings*, o *word2vec* tenta prever qual a probabilidade de uma palavra específica aparecer perto de outras palavras em um texto. Para isso, utiliza uma técnica conhecida como *skip-gram with negative sampling*. Essa técnica se trata de um classificador que usa uma palavra como entrada para prever as demais palavras em volta dela como exemplos positivos. Além disso utiliza as demais palavras do corpus como exemplos negativos. No caso, as demais palavras são amostradas aleatoriamente, a fim de não ter um altíssimo custo computacional e para gerar um problema de desbalanceamento (CARVALHO, ).

A Figura 4 apresenta o processo de treinamento para obtenção dos embeddings, através da técnica do *skip-gram with negative sampling*, contida no pacote *word2vec* Mikolov et al. (2013). Nela ocorre a multiplicação de uma matriz de contexto  $C$  e outra de *embeddings*  $W$ , onde  $W$  contém a representação vetorial da palavra central e  $C$  as palavras que se encontram próximas, em uma janela de tamanho  $k$  desta. Nela ocorre um processo de maximização da similaridade entre as palavras analisadas que se encontram na mesma janela de contexto  $k$ , e com a similaridade da palavra com os exemplo negativos minimizada.

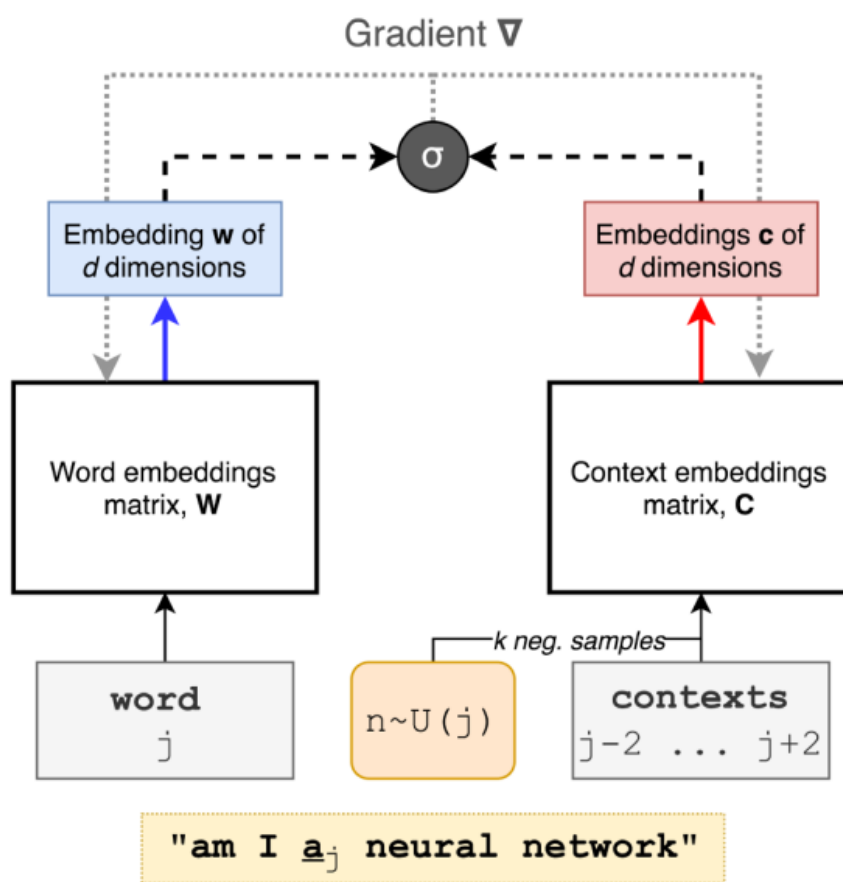


Figura 4 – Fluxograma de treinamento do modelo *Skip-gram with negative sampling* (MIKOLOV et al., 2013)

### 2.6.3 BERT

*Bidirectional Encoder Representations from Transformers* (BERT) é um modelo de linguagem baseado na arquitetura *transformer* de Vaswani et al. (2017). É um modelo pré treinado com textos não rotulados que pode ser refinado com uma camada adicional para criar modelos estado-da-arte pra diversas aplicações, como *Question Answering* (QA) e *Natural Language Inference* (NLI).

Uma das principais contribuições do BERT é o método de pré-treinamento chamado *Masked Language Modeling* (MLM). Essa técnica mascara alguns *tokens* de entrada, os substituindo por um *token* chamado [MASK]. Depois, se tenta prever esses *tokens* utilizando o contexto em que ele se encontra. Com isso, utilizando a parte do encoder da arquitetura *transformer* e essa função objetivo, o BERT gera um modelo de linguagem robusto que é bidirecional, ou seja, capaz de enxergar os *tokens* antecedentes e procedentes. Além do MLM, o BERT realiza um procedimento de Next Sentence Prediction (NSP). Neste procedimento, o BERT tenta prever se uma determinada sentença *A* é seguida de uma determinada sentença *B*. É uma etapa útil para melhorar o desempenho em tarefas de QA e NLI. A Figura 5 mostra as tarefas de MLM e de NSP no pré treinamento do BERT.

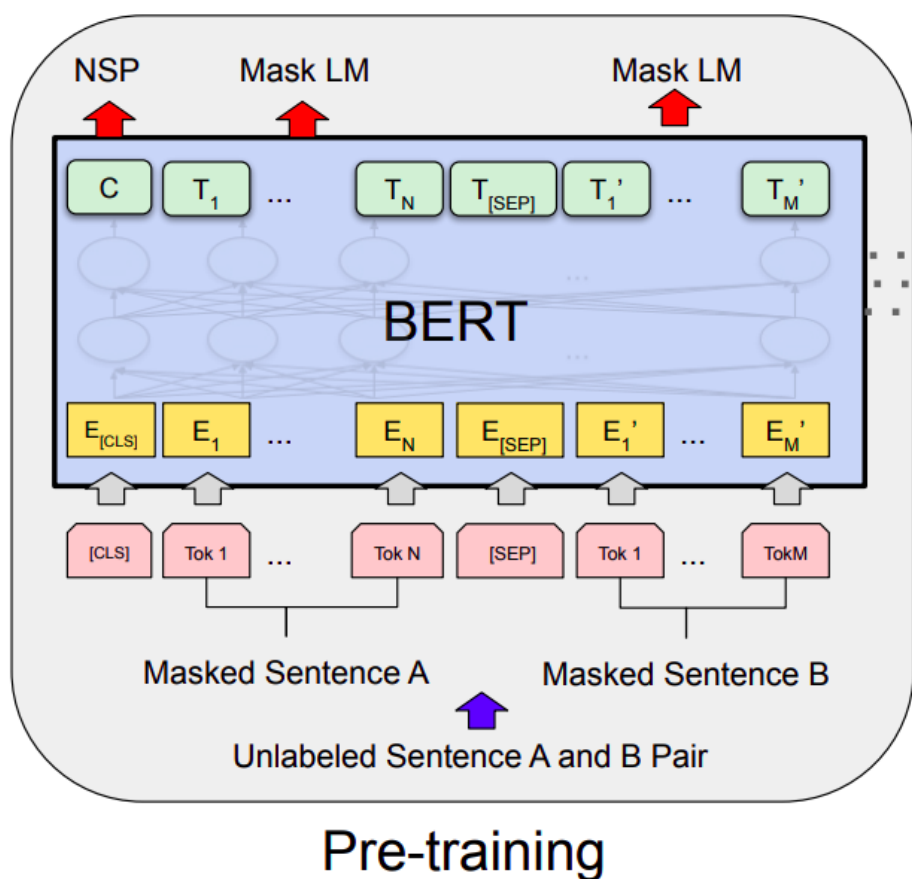


Figura 5 – *Pre-training* do BERT (DEVLIN et al., 2018)

Depois que ocorre o *pre-training*, o BERT deve passar pela etapa de *fine-tuning* de acordo com a tarefa e com os dados em questão. A Figura 6 ilustra o funcionamento de diversas tarefas. Na Figura 6b é possível ver o procedimento para a tarefas de classificação de texto. Nesta tarefa, o token [CLS] representado como *C* na saída é utilizado como *feature* na classificação da sentença. Isso é feito através da adição de uma camada de classificação contendo uma função *softmax* tendo uma função de custo. Com isso, os parâmetros da rede são ajustados para se adequarem ao problema (DEVLIN et al., 2018).

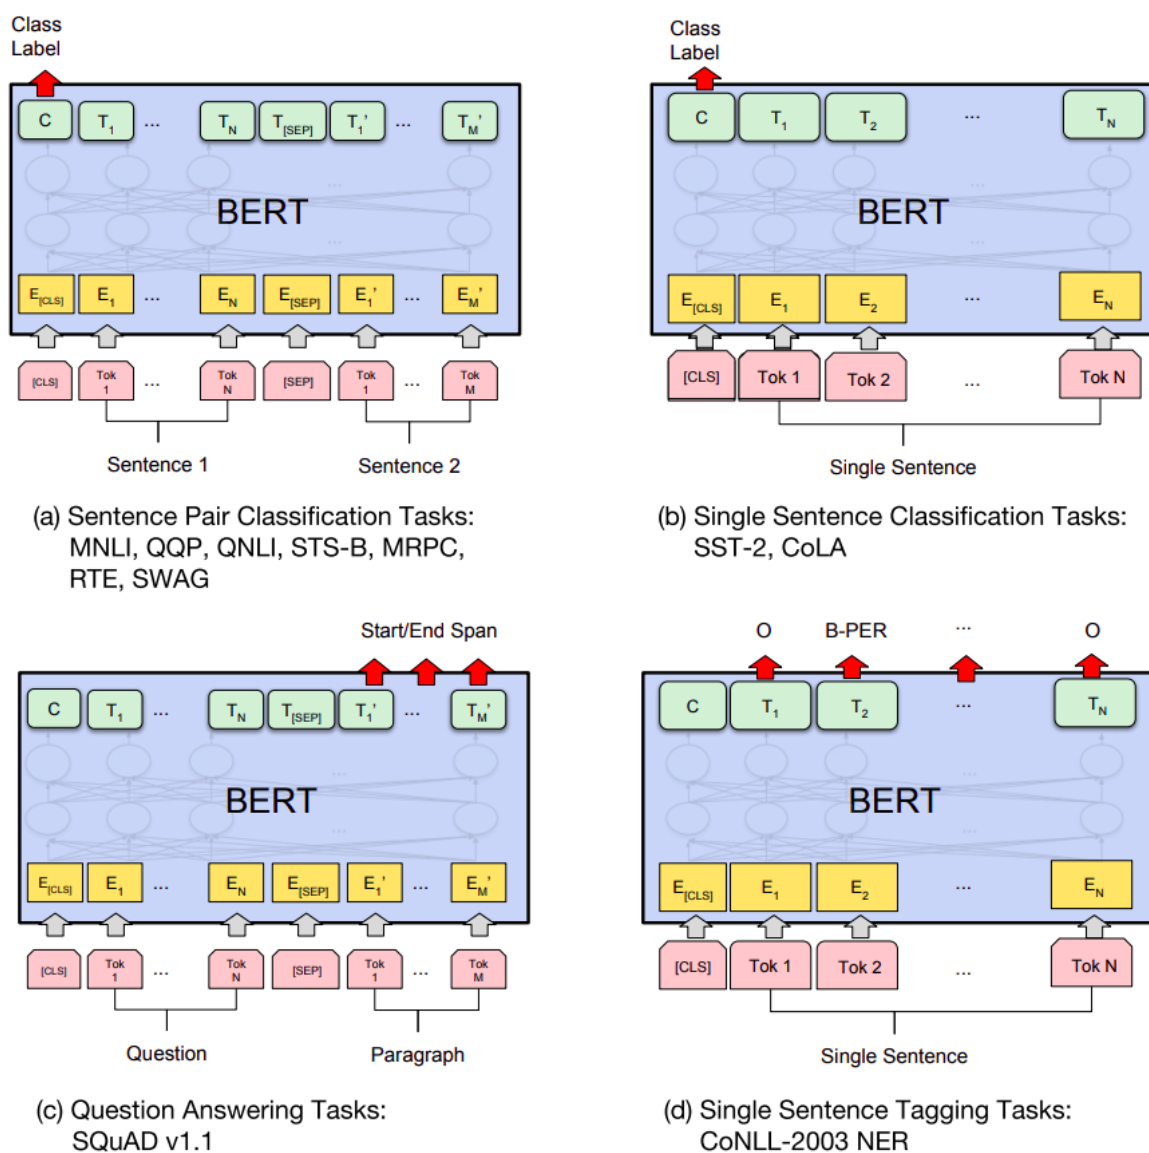


Figura 6 – *Fine-tuning* do BERT (DEVLIN et al., 2018)

O BERT é o método que foi utilizado nesta dissertação a fim de extrair o sentimento de tweets sobre o mercado financeiro.

## 2.7 Análises de sentimentos na previsão do mercado financeiro

A seguir, são apresentados alguns estudos de autores que fizeram previsões no mercado financeiro utilizando índices de sentimento.

Em (BOLLEN; MAO; ZENG, 2011), uma análise de sentimentos não supervisionada foi aplicada em tweets de fevereiro de 2008 a dezembro de 2008 para prever o Dow Jones Industrial Average (DJIA). Os autores extraíram a polaridade usando o OpinionFinder (OF) e o humor usando o Google-Profile of Mood States (GPOMS), que é um léxico derivado de um existente instrumento psicométrico chamado Profile of Mood

States (POMS-bi). Eles aplicaram Redes Neurais Fuzzy Auto Organizáveis para prever os valores da DJIA usando os valores anteriores. Seus resultados mostraram uma precisão de 87,6 % ao prever se o preço vai subir ou descer quando a dimensão do humor calmo é incluída.

Em outro estudo, uma análise de sentimentos supervisionada foi implementada em 250.000 tweets sobre a Microsoft de agosto de 2015 a agosto de 2016 (PAGOLU et al., 2016). Com 3.216 tweets rotulados, eles alcançaram uma precisão acima de 70% na classificação de dados não rotulados usando representações de n-gram e Word2vec. Eles alcançaram uma precisão de 71,82% na previsão das mudanças diárias para cima e para baixo aplicando uma classificação com Support Vector Machine (SVM).

Em (OLIVEIRA; CORTEZ; AREAL, 2017), os autores usaram índices de pesquisa a investidores e sentimentos extraídos do Twitter para prever retornos, volatilidade e volume de negociação de índices e carteiras. Para extrair o sentimento, eles aplicaram uma análise de sentimentos não supervisionada em tweets de dezembro de 2012 a outubro de 2015 usando um léxico criado em (OLIVEIRA; CORTEZ; AREAL, 2016). Para trabalhar com observações com frequências distintas, eles aplicaram um procedimento de Filtro de Kalman e exploraram cinco métodos diferentes de Aprendizado de Máquina para a previsão: Regressão Múltipla, Rede Neural, máquina de vetores de suporte, Floresta Aleatória e Ensemble.

Outros trabalhos aplicaram a análise de sentimentos sobre as notícias para prever a direção de outros índices. Por exemplo, em Shah, Isah e Zulkernine (2018), os autores alcançaram uma precisão direcional de 70,59% em ações do mercado farmacêutico indiano usando apenas sentimentos de notícias. As notícias foram extraídas por web scraping e pré-processadas, tendo seu sentimento extraído por meio de um dicionário de análise de sentimentos criado manualmente para o mercado farmacêutico.

## 2.8 Conclusão

Neste capítulo foram discutidas a previsibilidade do mercado, conceito de grande importância para fundamentar o uso da análise de sentimentos, a partir de notícias da área financeira, na previsão de séries temporais de mercado financeiro. Além disso foram descritos importantes conceitos, técnicas de previsão de séries temporais e de Análise de Sentimentos, que será utilizada na Metodologia deste trabalho, detalhada no próximo capítulo.



### 3 METODOLOGIA

Neste capítulo, é descrita cada etapa da metodologia para o uso de um índice de sentimento em uma FTS, utilizando os conceitos apresentados no capítulo anterior. Primeiro, é descrito na Seção 3.1 como os dados foram coletados e filtrados. Em seguida, na Seção 3.2, é apresentado o método utilizado para a análise de sentimentos dos tweets. A seguir, na Seção 3.3, é descrito o método usado para agregar os diferentes tweets. Depois, é descrito o método FTS para a previsão na Seção 3.4. Por fim, na Seção 3.5 é sintetizado o que foi feito no capítulo. O fluxograma da Figura 7 contém a metodologia do trabalho de forma resumida e visual.

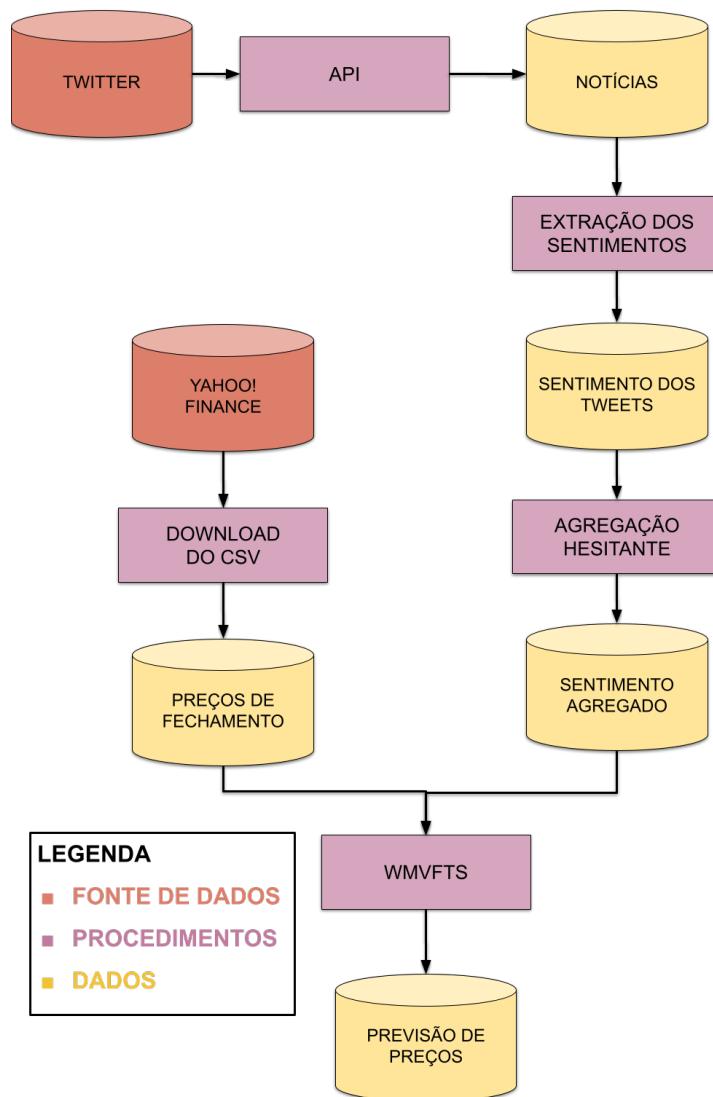


Figura 7 – Fluxograma da metodologia proposta

### 3.1 Coleta e processamento de dados

Os tweets usados para o mercado de ações dos EUA foram coletados usando a API do Twitter <sup>1</sup> e salvos em arquivos CSV. Vários tweets não foram considerados úteis para a análise e previsão de dados, e então foram removidos. Esses tweets eram por exemplo tweets patrocinados, retweets e tweets respondendo a mensagens de seguidores. A Tabela 1 contém uma amostra desses tweets removidos.

Tabela 1 – Amostra de tweets removidos

Conteúdo do tweet
@benpowell321 Hey, thanks for subscribing. We'll fill you in on the biggest moments from the event. Reply #stop to opt-out
@riskaamaliays Thanks for signing up and taking action. Reply #stop to opt out of updates this week
SPONSORED: What can an all-star coach teach an all-star investor?
SPONSORED: Can travel inspire greater you to be more creative?
@Silver Ze Geek We're sorry to see you go. You can re-join the #NewEconForum conversation at any time
@sailingmercury We're sorry to see you go. You can re-join the #NewEconForum conversation at any time
RT @technology: Our @reddit AMA on our Giant Leap video series about space is live now! Check it out here: <a href="https://t.co/Su7XQ239VL">https://t.co/Su7XQ239VL</a>

### 3.2 Obtenção de sentimentos

A fim de extrair o sentimento dos tweets, aplicamos Bidirectional Encoder Representations from Transformers (BERT) (DEVLIN et al., 2018), por ser um modelo pré-treinado que pode ser ajustado com apenas uma camada de saída adicional para criar modelos de estado da arte. Foi utilizada a versão *base* com 110M de parâmetros. Além disso, o conjunto de dados usado para a etapa de *fine-tuning* foi o Sentiment140 Go, Bhayani e Huang (2009), um conjunto de dados contendo 1.600.000 tweets com seus sentimentos rotulados. Com o modelo ajustado, uma pontuação de sentimento para cada tweet foi calculada, variando de 0 como a pontuação mais negativa a 1 como a pontuação mais positiva. A Tabela 2 contém uma amostra de tweets e seus sentimentos extraídos.

<sup>1</sup> <https://developer.twitter.com/en/docs>

Tabela 2 – Amostra de tweets e suas pontuações correspondentes

Conteúdo do tweet	Sentimento do tweet
British retailer Next raises its sales and profit outlook for the year	0.996
The trade truce will help markets recover and improve exports at a time when China needs more meat	0.941
Tesla is now worth more than Ford and GM combined	0.519
The president was actively involved in planning his inauguration, despite White House denials that he played any role in organizing the event	0.447
Coronavirus is the biggest setback for the travel industry in almost two decades	0.003
Tycoon's fund warns Indian real estate bad-loan crisis will get messier	0.003

### 3.3 Agregação

A fim de ter os sentimentos dos tweets na mesma periodicidade dos preços de fechamento, os sentimentos das notícias foram agregados diariamente. A data e hora dos tweets postados foram transformadas em um formato de data, removendo a informação de hora. Para evitar vazamento de dados, atribuímos um tweet a um dia específico apenas se fosse postado até às 16h00 caso o mercado estivesse aberto na data. Se fosse postado após as 16h do fuso horário de *New York*, o tweet era atribuído ao próximo preço de fechamento do dia. A Tabela 3 apresenta uma amostra de tweets com suas datas adaptadas às informações de fechamento do mercado. Com isso, evitamos usar um tweet para prever um preço anterior, evitando assim o vazamento de informação.

Em seguida, os dados foram agregados aplicando-se a fórmula do Hesitant Fuzzy Averaging (HFA) proposto por Xia e Xu (2011), que se baseia no HFWA quando  $w = (1/n, 1/n, \dots, 1/n)^T$  e detalhado na Equação (3.1). O operador HFWA apresentou bons resultados nas agregações envolvendo conjuntos hesitantes em séries temporais como em Bisht e Kumar (2016), Bisht e Kumar (2019). A escolha deste operador foi, portanto, pela simplicidade e efetividade existente na literatura. O método de agregação cria um índice de sentimentos entre 0 e 1, sendo 0 o valor mais negativo e 1 o valor mais positivo.

$$HFA = 1 - \prod_{i=1}^n (1 - x_i)^{\frac{1}{n}} \quad (3.1)$$

onde  $n$  é o número de elementos no subconjunto de  $[0, 1]$  e  $i = 1, 2, \dots, n$ .

A Tabela 4 mostra um exemplo de 6 tweets de dois dias diferentes, tendo seus sentimentos agregados utilizando a Equação (3.1). Os dados mostrados são para o horário de *New York*.

Tabela 3 – Amostra de tweets com suas datas ajustadas para o mercado

Conteúdo do tweet	Data de criação	Data ajustada
U.S. stock futures ticked lower after Alphabet...	2020-02-03 19:00:06	2020-02-04
The breakdown in reporting Democratic results from the...	2020-02-04 09:54:03	2020-02-04
The coronavirus outbreak is sending global nat...	2020-02-04 23:53:08	2020-02-05

Tabela 4 – Amostra de tweets com o sentimento agregado

Data ajustada	Conteúdo do tweet	Sentimento do tweet	Sentimento Agregado
2020-02-04	U.S. stock fu...	0.0047	0.1939
2020-02-04	Biogen inves...	0.0522	
2020-02-04	Investors in...	0.4448	
2020-02-05	Hong Kong is...	0.0028	0.0304
2020-02-05	Foxconn plans...	0.0556	
2020-02-05	After reporti...	0.0322	

A escolha do agregador hesitante foi feita devido à natureza dos dados. Uma vez que o processo de atribuição de sentimento de uma notícia é algo impreciso, além do desconhecimento do nível da contribuição de cada notícia para o sentimento final, foi utilizado um agregador que consegue lidar com essas características.

### 3.4 Previsão

Por fim, o índice de sentimento agregado foi usado para prever o fechamento do mercado no dia seguinte, obtido no Yahoo! Finance <sup>2</sup>. Aplicamos o método WMVFTS, devido ao seu bom desempenho conforme apresentado por [Silva et al. \(2020\)](#)

No WMVFTS cada uma das variáveis deve ser particionada em conjuntos nebulosos. A quantidade de conjuntos nebulosos influencia no balanço entre viés e variância do modelo. Se tiver um número muito alto de conjuntos nebulosos, o modelo pode sofrer um *overfitting* (sobreajuste), e se forem poucos conjuntos o modelo pode sofrer *underfitting* (sub-ajuste).

<sup>2</sup> <https://finance.yahoo.com/>

Tabela 5 – Amostra de *features* e variável *alvo* usados no treinamento do modelo

Data ajustada	Preço de fechamento $V_1$	Sentimento agregado $V_2$	Alvo $V^*$
21/02/2020	3337.75	0.4126	3225.89
24/02/2020	3225.89	0.3921	3128.21
25/02/2020	3128.21	0.3759	3116.38
26/02/2020	3116.39	0.4133	2978.76
27/02/2020	2978.76	0.3080	2954.22

O número correto de conjuntos deve ser definido empiricamente através de um processo de otimização de hiperparâmetros. Além disso o WMFVTS possui outros parâmetros, como a função de pertinência e o alfa-level, mas possuem um impacto menor sobre a performance do modelo (SILVA, 2019).

Uma vez definida a quantidade de conjuntos em cada variável é então definida qual é a variável endógena, que também será usada como saída, sendo as demais utilizadas como variáveis exógenas. No caso a variável exógena é a série de sentimento agregado, e a variável endógena é a série de fechamentos. E por fim, o modelo é treinado.

A Tabela 5 contém uma amostra dos preços de fechamento e séries temporais do índice de sentimento, que foram utilizados para treinar o modelo para prever o preço de fechamento do dia seguinte.

### 3.5 Conclusão

Este capítulo descreveu a obtenção de dados e os métodos utilizados nesse trabalho. Primeiramente, obtivemos os dados do *Twitter* utilizando a API disponibilizada pela própria empresa. Depois, extraímos o sentimento dos *tweets* utilizando o método BERT. Posteriormente, agregamos os dados utilizando a agregação *Hesitant Fuzzy Weighted Averaging*. E por último, aplicamos um método de *Weighted Multivariate Fuzzy Time Series* para fazer a previsão da série temporal utilizando a própria série de preços e a série de sentimentos agregados. Dessa forma, o próximo capítulo tem como objetivo apresentar os experimentos realizados nesse trabalho, aplicando a sequência de técnicas descritas na Metodologia.

## 4 EXPERIMENTOS

No presente capítulo descrevemos como ocorreram os experimentos desse estudo. Na Seção 4.1 são apresentados os dados coletados nessa pesquisa com a finalidade de aferir a eficácia da metodologia proposta, com as métricas descritas na Seção 4.2. Na Seção 4.3 são apresentados os métodos utilizados para a implementação da metodologia. Na Seção 4.5 são relatados os hiperparâmetros escolhidos empiricamente das arquiteturas dos classificadores. Na Seção 4.6 são apresentados os resultados obtidos utilizando as arquiteturas proposta, com suas respectivas discussões. Na Seção 4.7 sintetizamos o que foi abordado no capítulo.

### 4.1 Dados

Para a realização dessa pesquisa, foram coletados todos os *tweets* postados por Bloomberg <sup>1</sup> de 2017-01-01 a 2020-05-31 e salvos em arquivos CSV e usados para a análise de dados. Foram removidos *tweets* irrelevantes para o método de previsão. O volume por ano é apresentado na Tabela 6.




Figura 8 – Histograma com a frequência dos sentimentos dos *tweets* da Bloomberg's

A figura 8 mostra um gráfico de barras de frequência do sentimento dos *tweets* coletados. Para a maioria das notícias, o classificador BERT está confiante em detectar o

<sup>1</sup> <https://twitter.com/business>

Tabela 6 – Tweets postados anualmente

Year	2017	2018	2019	2020
Volume	102833	98359	146939	64560

sentimento positivo ou negativo, uma vez que a maioria dos pontos está na fronteira. Além disso, os tweets são balanceados entre negativos (pontuação baixa) e positivos (pontuação alta).

Para medir o desempenho do método proposto, foram utilizadas duas séries financeiras:

- The Standard & Poor's 500<sup>2</sup> (S&P 500): Um índice ponderado de capitalização de mercado das 500 maiores empresas americanas de capital aberto
- The Nasdaq Composite Index<sup>3</sup> (Nasdaq): Um índice ponderado por capitalização de mercado de mais de 2.500 ações ordinárias listadas na bolsa de valores Nasdaq.

A Figura 9 e a Figura 10 mostram os preços de fechamento ao longo do tempo e os preços de fechamento diferenciados para o índice Nasdaq e S&P 500, respectivamente. Há um período de alta volatilidade no ano de 2020, devido à pandemia Covid-19.

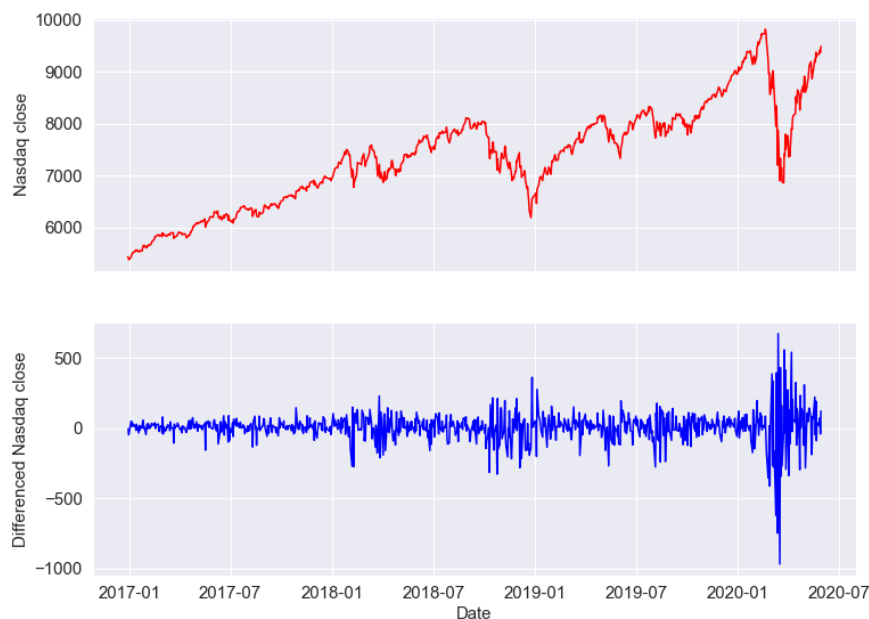


Figura 9 – Preços de fechamento e preços de fechamento diferenciados do índice Nasdaq

A Figura 11 e a Figura 12 mostram a correlação cruzada entre o sentimento calculado e o S&P 500 e o índice Nasdaq. A primeira correlação de defasagem de 0,10 indica uma associação entre as duas séries, validando seu uso como recurso para uma série temporal multivariada.

<sup>2</sup> <https://www.spglobal.com/>

<sup>3</sup> <https://www.nasdaq.com/>




Figura 10 – Preços de fechamento e preços de fechamento diferenciados do índice S&P 500

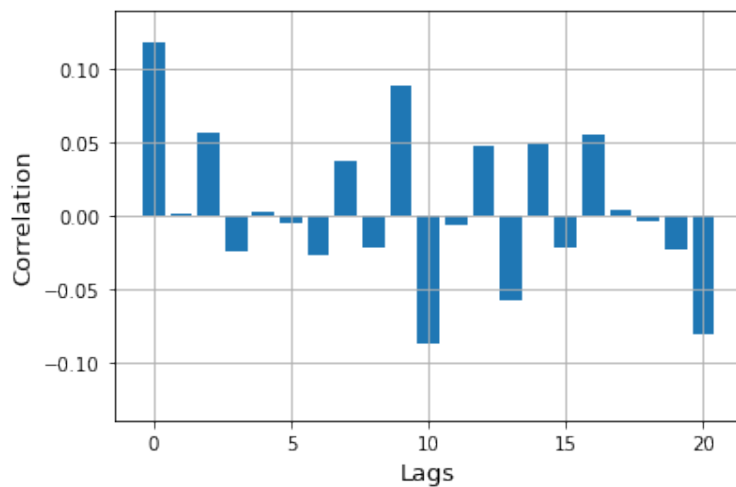


Figura 11 – Correlação cruzada entre a série diferenciada do S&P 500 e a série de sentimento hesitante

## 4.2 Métricas de avaliação

Como critérios de comparação foi utilizado o *Root Mean Squared Error* (RMSE) que está detalhado na Equação (4.1), o *Mean Absolute Percentage Error* (MAPE) que está detalhado na Equação (4.2) e o *Mean Directional Accuracy* (MDA), detalhado na Equação (4.3). Além disso foi utilizado o *Naive Normalized RMSE* (NN-RMSE), que é o valor do RMSE dividido pelo RMSE do modelo *Naive*. (MONTGOMERY; JENNINGS; KULAHCI, 2011).






Figura 12 – Correlação cruzada entre a série diferenciada da Nasdaq e a série de sentimento hesitante.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (4.1)$$

$$MAPE = n^{-1} \sum_{t=1}^n \left| \frac{e_t}{y_t} \right| \quad (4.2)$$

$$MDA = \frac{1}{N} \sum_t 1_{\text{sgn}(A_t - A_{t-1}) = \text{sgn}(A_t - A_{t-1})} \quad (4.3)$$

O RMSE é uma métrica que informa o erro na mesma unidade dos dados, de acordo com o preço da ação. É uma medida difícil de interpretar por não ser normalizado, e sim estar na escala da medida analisada. Por essa razão, foi utilizado o NN-RMSE, uma vez que é uma métrica normalizada pela performance do método Naive. Além disso, também foi utilizado o MAPE, que é um medida que informa um erro percentual facilmente interpretável. Essas métricas dão um módulo do erro, porém não informam a direção do erro. No mercado financeiro é de grande importancia entender se o modelo tem uma acurácia na direção, uma vez que é uma informação que impacta diretamente na decisão de compra ou venda, diferente das métricas que dão um módulo do erro. Por essa razão também foi considerado o MDA para prever o percentual de acerto da direção da previsão.

### 4.3 Métodos

A extração de API, a preparação de dados e os modelos rodaram usando Python 3.8. Para a extração de sentimento de textos em inglês usando o BERT, foi utilizado o modelo presente na biblioteca TensorFlow (TURC et al., 2019). Para o método de série temporal fuzzy foi utilizada a biblioteca PyFSTS (SILVA et al., 2018). E os estatísticos foram feitos

utilizando o *Statistical Tests for Algorithms Comparison* (STAC) (RODRÍGUEZ-FDEZ et al., 2015).

#### 4.4 Reprodutibilidade

Para garantir a reprodutibilidade dos resultados aqui apresentados e a transparência da pesquisa, os códigos dos experimentos, bem como os dados utilizados, estão disponíveis no endereço [https://github.com/dolabela/mestrado\\_ppgee](https://github.com/dolabela/mestrado_ppgee).

#### 4.5 Hiperparâmetros e configurações dos testes

Conduzimos vários experimentos para avaliar a eficácia do método proposto. Para cada teste, foi aplicado o WMVFTS usando como variáveis de entrada os preços de fechamento históricos diferenciados da série e o índice de sentimento e foi comparado com um modelo univariado, usando apenas os preços de fechamento diferenciados. Os experimentos foram realizados variando o número de partições para as variáveis, ou seja, os conjuntos difusos  $K$  para cada variável linguística  $\tilde{V}_i$ .

Para os testes do modelo proposto, foi aplicada uma metodologia de *rolling window cross validation* (validação cruzada de janela rolante), usando uma amostra fixa de 570 preços de fechamento para treinar o modelo para prever 30 preços de fechamento fora da amostra. E toda análise de resultados foi feita para o período out of sample (fora da amostra)




Figura 13 – Amostra de conjuntos hesitantes para as séries de preços utilizando 5 partições

Os testes para as séries de fechamento do índice utilizaram um *Grid partitioning* com uma função de pertinência triangular. A quantidade de Conjuntos Fuzzy variou, passando por 5, 10 e 15 partições. A apresentam exemplos dos conjuntos hesitantes utilizando 5, 10 e 15 partições para uma janela na série da Nasdaq e do S&P 500.

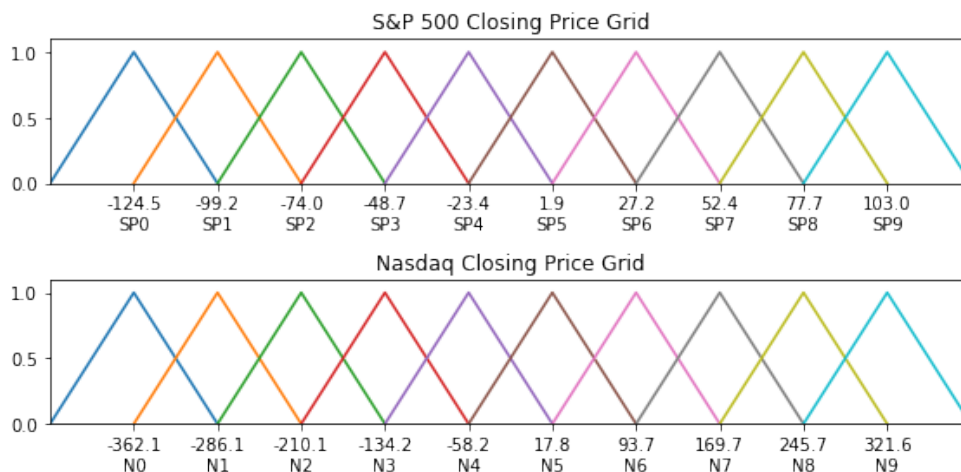


Figura 14 – Amostra de conjuntos hesitantes para as séries de preços utilizando 10 partições




Figura 15 – Amostra de conjuntos hesitantes para as séries de preços utilizando 15 partições

A série de sentimento agregado também utilizou um *Grid partitioning* com uma função de pertinência triangular. A quantidade de partições variou entre 3 e 5. A Figura 16 apresenta um exemplo do *grid* da série de sentimento com 3 partições, e a Figura 17 apresenta um exemplo do *grid* da série de sentimento com 5 partições.




Figura 16 – Amostra de conjuntos hesitantes para a série de sentimento hesitante utilizando 3 partições




Figura 17 – Amostra de conjuntos hesitantes para a série de sentimento hesitante utilizando 5 partições

Tabela 7 – Métricas para a predição do Nasdaq usando 570 dias de treinamento e 30 para prever 30 dias *out-of-sample*

Model	Sent. Partitions	Price Partitions	RMSE	NN RMSE	MAPE	MDA
Naive	-	-	125.57	1	1.18	-
WFTS	-	5	124.77	0.99	1.18	46.4
WMVFTS	3	5	120.04	0.96	1.12	<b>96.2</b>
WMVFTS	5	5	<b>117.71</b>	<b>0.94</b>	<b>1.11</b>	95.5
WFTS	-	10	125.98	1	1.2	47.5
WMVFTS	3	10	124.1	0.99	1.17	93.4
WMVFTS	5	10	122.94	0.98	1.16	92.8
WFTS	-	15	129.81	1.03	1.22	47.5
WMVFTS	3	15	124.49	0.99	1.17	93.8
WMVFTS	5	15	121.05	0.96	1.14	93.4

## 4.6 Resultados

Primeiro, foi analisado o desempenho do modelo para o índice Nasdaq, e os resultados são mostrados na Tabela 7. O índice de sentimento foi capaz de melhorar o RMSE e MAPE quando comparado aos métodos univariado e ingênuo. O MDA teve uma grande melhoria com o índice, tendo um desempenho superior a 90%. Foram obtidos os melhores resultados para o MAPE e RMSE usando 5 partições de sentimento e 5 partições de preço de fechamento, e os melhores resultados para o MDA usando 3 partições de sentimento e 5 partições de preço de fechamento.

A tabela 8 mostra o desempenho dos modelos de previsão do índice S&P 500. Novamente, o método proposto foi melhor na previsão das séries quando comparado aos modelos univariados e *Naive*, e foram obtidos novamente os melhores resultados para o MAPE e RMSE usando 5 partições de sentimento e 5 partições de preço de fechamento. Analisando a métrica MDA, foram alcançados ótimos resultados de mais de 93%, com os melhores resultados usando 3 partições de sentimento e 5 partições de preço de fechamento.

A fim de avaliar a significância estatística dos resultados, foi empregado o Teste de Friedman d (FRIEDMAN, 1937), um teste não paramétrico que avalia a equidade entre

Tabela 8 – Métricas para a predição do S&P 500 usando 570 dias de treinamento e 30 para prever 30 dias *out-of-sample*

Modelo	Partições do Sentimento	Partições do Preço	RMSE	NN RMSE	MAPE	MDA
Naive	-	-	40.28	1	1.08	-
WFTS	-	5	40.88	1.01	1.11	46.1
WMVFTS	3	5	39.63	0.98	1.03	<b>97.2</b>
WMVFTS	5	5	<b>38.2</b>	<b>0.95</b>	<b>0.99</b>	95.9
WFTS	-	10	41.37	1.03	1.12	47.8
WMVFTS	3	10	39.57	0.98	1.05	94.5
WMVFTS	5	10	38.49	0.96	1.02	93.8
WFTS	-	15	42.73	1.06	1.16	47.1
WMVFTS	3	15	39.8	0.99	1.03	94.5
WMVFTS	5	15	38.46	0.95	1.02	93.1

Tabela 9 – Resultados do teste de Friedman

Rank	Modelo
1	WMVFTS_5_5
2	WMVFTS_3_5
3	WMVFTS_5_15
4	WMVFTS_5_10
5	WMVFTS_3_10
6	WMVFTS_3_15
7	Naive
8	WFTS_0_5
9	WFTS_0_10
10	WFTS_0_15

as médias das métricas calculadas, para cada modelo e sua respectiva parametrização. Foi considerado um nível de significância de 0.05, em que a hipótese nula ( $H_0$ ) é a hipótese de que os testes possuem médias iguais, e a hipótese alternativa ( $H_1$ ) significa que não existem evidências estatísticas para afirmar que as médias são iguais. Os *ranks* do teste são apresentados na Tabela 9, em que foi considerado para o primeiro número após o nome do modelo significando a quantidade de partições da série de sentimentos, e o segundo número significando a quantidade de partições da série de fechamento de preços. Para os testes, foi obtida uma estatística de  $Q = 24.590$  e um  $p$ -value de 0.00. Com isso,  $H_0$  foi rejeitada, significando que não foi comprovado estatisticamente que as médias das métricas dos algoritmos são iguais. Sendo os resultados significativamente diferente, foi realizado então um comparativo entre cada modelo proposto com os modelos de *benchmark*.

A Tabela 10 mostra os testes *post-hoc* que foram feitos utilizando o teste de Finner (FINNER, 1993), comparando os modelos multivariados utilizando o índice de sentimento agregado proposto com as séries *Naive* e univariadas. O teste possui como hipótese nula

Tabela 10 – Testes de Finner comparando o modelo proposto com diferentes parâmetros com os testes de *benchmark*

Comparativo	Estatística	p-value	Resultado
WMVFTS_3_5 vs Naive	2.80746	0.01596	H0 foi rejeitado
WMVFTS_3_5 vs WFTS_0_5	3.30289	0.0043	H0 foi rejeitado
WMVFTS_3_5 vs WFTS_0_10	3.71575	0.0013	H0 foi rejeitado
WMVFTS_3_5 vs WFTS_0_15	4.29376	0.00026	H0 foi rejeitado
WMVFTS_3_10 vs Naive	1.44501	0.22761	H0 não foi rejeitado
WMVFTS_3_10 vs WFTS_0_5	1.94045	0.09981	H0 não foi rejeitado
WMVFTS_3_10 vs WFTS_0_10	2.35331	0.04351	H0 foi rejeitado
WMVFTS_3_10 vs WFTS_0_15	2.93132	0.01164	H0 foi rejeitado
WMVFTS_3_15 vs Naive	1.32116	0.2662	H0 não foi rejeitado
WMVFTS_3_15 vs WFTS_0_5	1.81659	0.12595	H0 não foi rejeitado
WMVFTS_3_15 vs WFTS_0_10	2.22945	0.05444	H0 não foi rejeitado
WMVFTS_3_15 vs WFTS_0_15	2.80746	0.01596	H0 foi rejeitado
WMVFTS_5_5 vs Naive	3.79832	0.00109	H0 foi rejeitado
WMVFTS_5_5 vs WFTS_0_5	4.29376	0.00026	H0 foi rejeitado
WMVFTS_5_5 vs WFTS_0_10	4.70662	0.00006	H0 foi rejeitado
WMVFTS_5_5 vs WFTS_0_15	5.28463	0.00001	H0 foi rejeitado
WMVFTS_5_10 vs Naive	2.06431	0.07813	H0 não foi rejeitado
WMVFTS_5_10 vs WFTS_0_5	2.55974	0.02749	H0 foi rejeitado
WMVFTS_5_10 vs WFTS_0_10	2.9726	0.01103	H0 foi rejeitado
WMVFTS_5_10 vs WFTS_0_15	3.55061	0.00216	H0 foi rejeitado
WMVFTS_5_15 vs Naive	2.60103	0.02592	H0 foi rejeitado
WMVFTS_5_15 vs WFTS_0_5	3.09646	0.00799	H0 foi rejeitado
WMVFTS_5_15 vs WFTS_0_10	3.50932	0.00224	H0 foi rejeitado
WMVFTS_5_15 vs WFTS_0_15	4.08733	0.00039	H0 foi rejeitado

(H0) a hipótese de que os dois métodos possuem médias iguais, e a hipótese alternativa (H1) de que as médias são diferentes. Novamente se deve considerar o primeiro número após o nome do modelo sendo a quantidade de partições da série de sentimentos, e o segundo número sendo a quantidade de partições da série de fechamento de preços. E também foi utilizado um nível de significância de 0.05, em que a hipótese nula significa que os testes possuem médias iguais para as diferentes métricas. Os modelos WMVFTS\_5\_5, WMVFTS\_3\_5 e WMVFTS\_3\_15 foram os únicos que foram estatisticamente superiores aos testes de *benchmark*. Com isso, foram feitos novos testes para comparar entre as diferentes parametrizações qual foi a que teve o melhor desempenho nos testes.

A Tabela 11 apresenta os testes de Finner comparando os modelos estatisticamente significativos em relação a todos *benchmarks*. Nele, todos *H0* foram aceitos, significando que não possuem desempenho diferente entre si.

Tabela 11 – Testes de Finner comparando as diferentes parametrizações com as melhores performances

Comparativo	Estatística	p-value	Resultado
WMVFTS_5_5 vs WMVFTS_3_5	0.99087	0.40181	H0 is accepted
WMVFTS_5_15 vs WMVFTS_3_5	0.20643	0.84305	H0 is accepted
WMVFTS_5_15 vs WMVFTS_5_5	1.1973	0.30907	H0 is accepted

## 4.7 Conclusão

Neste capítulo foram apresentados os dados utilizados para a previsão, as métricas utilizadas e os resultados com os experimentos realizados com a metodologia proposta. No próximo capítulo, serão descritas as conclusões encontradas após desenvolvimento deste trabalho, bem como as contribuições da pesquisa e os trabalhos futuros que podem vir a ser desenvolvidos com base no que foi desenvolvido.

## 5 CONCLUSÃO

Nessa dissertação foi proposta uma metodologia que permite utilizar o sentimento de notícias para a previsão de preços de índices e ações no mercado financeiro. O método proposto consistiu em uma agregação de sentimentos baseada em Hesitant Fuzzy Sets (HFS) e mostrou-se útil quando comparada ao método *naive* e à previsão univariada.

A abordagem proposta foi aplicada ao método Weighted Multivariate Fuzzy Time Series (WMVFTS), mas pode ser integrada a outros métodos FTS. Usamos um conjunto de dados da Bloomberg de cerca de 400.000 tweets de notícias para prever os preços de dois índices americanos, o índice Nasdaq e S&P 500, podendo também ser utilizado com outras fontes de dados e preços históricos.

A previsão usando o índice de sentimento obteve ótimos resultados ao analisar a métrica MDA. Foi muito preciso prever se os preços estão subindo ou descendo, com uma precisão de mais de 93%. O bom resultado da métrica é muito importante, uma vez que possibilita a tomada de decisão em relação à compra e venda valores mobiliários. No entanto, o método proposto não produziu uma grande melhoria em relação ao método ingênuo ao analisar o MAPE e RMSE, o que pode ser explicado por vários fatores. O primeiro deles é o fato de que o conjunto de dados utilizado não estava totalmente focado no mercado de ações e na política. Ele tinha todos os tweets da Bloomberg, então tinha tweets de vários assuntos. Outro fator é o conjunto de dados usado para o ajuste fino do modelo BERT, que continha vários tweets rotulados de vários assuntos, não estando necessariamente relacionados a notícias financeiras. Um conjunto de dados mais focado pode criar uma previsão mais precisa.

### 5.1 Limitações da metodologia proposta

Os resultados apresentados indicam algumas limitações. Apesar do bom rendimento em relação à métrica MDA, o modelo proposto não obteve uma grande melhora em relação ao MAPE e o RMSE. De um ponto de vista prático, uma melhora dessa métrica é útil para permitir tentar prever ganho de uma operação. Com a informação do módulo de um ganho, é possível entender melhor o lucro de uma operação dado os seus custos com corretagem.



## 5.2 Propostas de trabalhos futuros

Algumas melhorias devem ser desenvolvidas para otimizar a performance da metodologia proposta. Em trabalhos futuros, pretende-se:

- Aplicar um método de modelagem de tópico para separar os tweets em diferentes séries, criando assim uma série de sentimento para cada tópico.
- Utilizar diferentes fontes de dados para extrair sentimento. Por exemplo, notícias mais focadas no mercado financeiro ou *tweets* das pessoas em relação às notícias e às empresas;
- Utilizar a metodologia proposta para prever outras séries de preços;
- Explorar os diferentes modelos de *Fuzzy Time Series* e seus diferentes parâmetros possíveis de serem modificados;
- Explorar outros métodos de agregação para *Hesitant Fuzzy Sets*.

## 5.3 Contribuições do trabalho

O seguinte artigo foi publicado com base na pesquisa conduzida para esta dissertação:

- B. C. Dolabela Dias, H. J. Sadaei, P. C. de Lima e Silva and F. G. Guimarães, “Aggregation of Sentiment Analysis Index with Hesitant Fuzzy Sets for Financial Time Series Forecasting,” 2021 IEEE World AI IoT Congress (AIIoT), 2021, pp. 0433-0439, doi: 10.1109/AIIoT52608.2021.9454179.

## REFERÊNCIAS

- ABU-MOSTAFA, Y. S.; ATIYA, A. F. Introduction to financial forecasting. *Applied intelligence*, Springer, v. 6, n. 3, p. 205–213, 1996.
- ALESSIA, D. et al. Approaches, tools and applications for sentiment analysis implementation. *International Journal of Computer Applications*, Foundation of Computer Science, v. 125, n. 3, 2015.
- BENEVENUTO, F.; RIBEIRO, F.; ARAÚJO, M. *Métodos para análise de sentimentos em mídias sociais*. 2015.
- BISHT, K.; KUMAR, S. Fuzzy time series forecasting method based on hesitant fuzzy sets. *Expert Systems with Applications*, Elsevier, v. 64, p. 557–568, 2016.
- BISHT, K.; KUMAR, S. Hesitant fuzzy set based computational method for financial time series forecasting. *Granular Computing*, Springer, v. 4, n. 4, p. 655–669, 2019.
- BOLLEN, J.; MAO, H.; ZENG, X. Twitter mood predicts the stock market. *Journal of computational science*, Elsevier, v. 2, n. 1, p. 1–8, 2011.
- CARVALHO, F. F. de. Transferência de aprendizado com embeddings contextuais para classificação de texto em cenários de baixo volume de dados.
- CHEN, M.-Y. A high-order fuzzy time series forecasting model for internet stock trading. *Future Generation Computer Systems*, v. 37, p. 461 – 467, 2014. ISSN 0167-739X. Special Section: Innovative Methods and Algorithms for Advanced Data-Intensive Computing Special Section: Semantics, Intelligent processing and services for big data Special Section: Advances in Data-Intensive Modelling and Simulation Special Section: Hybrid Intelligence for Growing Internet and its Applications. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0167739X13002045>.
- CHEN, S.-M. Forecasting enrollments based on fuzzy time series. *Fuzzy sets and systems*, Elsevier, v. 81, n. 3, p. 311–319, 1996.
- DEVLIN, J. et al. Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*, 2018.
- DORAN, J. S.; PETERSON, D. R.; WRIGHT, C. Confidence, opinions of market efficiency, and investment behavior of finance professors. *Journal of Financial Markets*, Elsevier, v. 13, n. 1, p. 174–195, 2010.
- DOURADO, G. de A.; TABAK, B. M. Teste da hipótese de mercados adaptativos para o brasil. *Revista Brasileira de Finanças*, v. 12, n. 4, 2014.
- FAMA, E. F. The behavior of stock-market prices. *The journal of Business*, JSTOR, v. 38, n. 1, p. 34–105, 1965.
- FAMA, E. F. Random walks in stock market prices. *Financial analysts journal*, Taylor & Francis, v. 51, n. 1, p. 75–80, 1995.

- FINNER, H. On a monotonicity problem in step-down multiple test procedures. *Journal of the American Statistical Association*, Taylor & Francis, v. 88, n. 423, p. 920–923, 1993.
- FRIEDMAN, M. The use of ranks to avoid the assumption of normality implicit in the analysis of variance. *Journal of the American Statistical Association*, Taylor & Francis, v. 32, n. 200, p. 675–701, 1937.
- GO, A.; BHAYANI, R.; HUANG, L. Twitter sentiment classification using distant supervision. *CS224N project report, Stanford*, v. 1, n. 12, p. 2009, 2009.
- GROSSMAN, S. J.; STIGLITZ, J. E. On the impossibility of informationally efficient markets. *The American Economic Review*, JSTOR, v. 70, n. 3, p. 393–408, 1980.
- ISMAIL, Z.; EFENDI, R. Enrollment forecasting based on modified weight fuzzy time series. *Journal of Artificial Intelligence*, v. 4, n. 1, p. 110–118, 2011.
- ISMAIL, Z.; EFENDI, R.; DERIS, M. M. Application of fuzzy time series approach in electric load forecasting. *New Mathematics and Natural Computation*, World Scientific, v. 11, n. 03, p. 229–248, 2015.
- KAHNEMAN, D. *Thinking, fast and slow*. New York: Farrar, Straus and Giroux, 2011. ISBN 9780374275631 0374275637. Disponível em: [https://www.amazon.de/Thinking-Fast-Slow-Daniel-Kahneman/dp/0374275637/ref=wl\\_it\\_dp\\_o\\_pdT1\\_nS\\_nC?ie=UTF8&colid=151193SNGKJT9&coliid=I3OCESLZCVDFL7](https://www.amazon.de/Thinking-Fast-Slow-Daniel-Kahneman/dp/0374275637/ref=wl_it_dp_o_pdT1_nS_nC?ie=UTF8&colid=151193SNGKJT9&coliid=I3OCESLZCVDFL7).
- KIM, J. H.; SHAMSUDDIN, A.; LIM, K.-P. Stock return predictability and the adaptive markets hypothesis: Evidence from century-long us data. *Journal of Empirical Finance*, Elsevier, v. 18, n. 5, p. 868–879, 2011.
- LEE, M. H.; JAVEDANI, H. et al. A weighted fuzzy integrated time series for forecasting tourist arrivals. In: SPRINGER. *International Conference on Informatics Engineering and Information Science*. [S.l.], 2011. p. 206–217.
- LEE, M. H.; J.SADAEI, H.; SUHARTONO. Improving taieix forecasting using fuzzy time series with box–cox power transformation. *Journal of Applied Statistics*, Taylor & Francis, v. 40, n. 11, p. 2407–2422, 2013. Disponível em: <https://doi.org/10.1080/02664763.2013.817548>.
- LIAO, H.; XU, Z. A vikor-based method for hesitant fuzzy multi-criteria decision making. *Fuzzy Optimization and Decision Making*, Springer, v. 12, n. 4, p. 373–392, 2013.
- LIMA, M. V. Um estudo sobre finanças comportamentais. *RAE eletrônica*, SciELO Brasil, v. 2, n. 1, p. 0–0, 2003.
- LINTNER, G. Behavioral finance: Why investors make bad decisions. *The planner*, Cambridge, v. 13, n. 1, p. 7–8, 1998.
- LIU, B. et al. Sentiment analysis and subjectivity. *Handbook of natural language processing*, v. 2, n. 2010, p. 627–666, 2010.
- LO, A. W. The adaptive markets hypothesis. *The Journal of Portfolio Management*, Institutional Investor Journals Umbrella, v. 30, n. 5, p. 15–29, 2004.

- LO, A. W. Reconciling efficient markets with behavioral finance: the adaptive markets hypothesis. *Journal of investment consulting*, v. 7, n. 2, p. 21–44, 2005.
- MIKOLOV, T. et al. Distributed representations of words and phrases and their compositionality. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2013. p. 3111–3119.
- MONTGOMERY, D.; JENNINGS, C.; KULAHCI, M. *Introduction to Time Series Analysis and Forecasting*. Wiley, 2011. (Wiley Series in Probability and Statistics). ISBN 9781118211502. Disponível em: <https://books.google.com.br/books?id=-qaFi0oOPAYC>.
- NETO, A. A. *Mercado financeiro*. [S.l.]: Atlas, 2003.
- NISAR, T. M.; YEUNG, M. Twitter as a tool for forecasting stock market movements: A short-window event study. *The Journal of Finance and Data Science*, v. 4, n. 2, p. 101 – 119, 2018. ISSN 2405-9188. Disponível em: <http://www.sciencedirect.com/science/article/pii/S2405918817300247>.
- OLIVEIRA, N.; CORTEZ, P.; AREAL, N. Stock market sentiment lexicon acquisition using microblogging data and statistical measures. *Decision Support Systems*, v. 85, p. 62 – 73, 2016. ISSN 0167-9236. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0167923616300240>.
- OLIVEIRA, N.; CORTEZ, P.; AREAL, N. The impact of microblogging data for stock market prediction: Using twitter to predict returns, volatility, trading volume and survey sentiment indices. *Expert Systems with Applications*, Elsevier, v. 73, p. 125–144, 2017.
- PAGOLU, V. S. et al. Sentiment analysis of twitter data for predicting stock market movements. In: IEEE. *2016 international conference on signal processing, communication, power and embedded system (SCOPE5)*. [S.l.], 2016. p. 1345–1350.
- RODRÍGUEZ-FDEZ, I. et al. STAC: a web platform for the comparison of algorithms using statistical tests. In: *Proceedings of the 2015 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*. [S.l.: s.n.], 2015.
- SADAEI, H. J. et al. A hybrid model based on differential fuzzy logic relationships and imperialist competitive algorithm for stock market forecasting. *Applied Soft Computing*, v. 40, p. 132 – 149, 2016. ISSN 1568-4946. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1568494615007449>.
- SADAEI, H. J. et al. Short-term load forecasting method based on fuzzy time series, seasonality and long memory process. *International Journal of Approximate Reasoning*, Elsevier, v. 83, p. 196–217, 2017.
- SHAH, D.; ISAH, H.; ZULKERNINE, F. Predicting the effects of news sentiments on the stock market. In: IEEE. *2018 IEEE International Conference on Big Data (Big Data)*. [S.l.], 2018. p. 4705–4708.
- SHAH, D.; ISAH, H.; ZULKERNINE, F. Stock market analysis: A review and taxonomy of prediction techniques. *International Journal of Financial Studies*, Multidisciplinary Digital Publishing Institute, v. 7, n. 2, p. 26, 2019.
- SHEFRIN, H. *Beyond greed and fear: Understanding behavioral finance and the psychology of investing*. [S.l.]: Oxford University Press on Demand, 2002.

- SILVA, P. C. de Lima e et al. pyfts: Fuzzy time series for python. 2018. Disponível em: <https://doi.org/10.5281/zenodo.597359>.
- SILVA, P. C. L. *Scalable Models for Probabilistic Forecasting with Fuzzy Time Series*. Tese (Doutorado) — Universidade Federal de Minas Gerais, Belo Horizonte, 9 2019.
- SILVA, P. C. L. et al. Distributed evolutionary hyperparameter optimization for fuzzy time series. *IEEE Transactions on Network and Service Management*, v. 17, n. 3, p. 1309–1321, 2020.
- SIMON, H. A. A behavioral model of rational choice. *The quarterly journal of economics*, MIT Press, v. 69, n. 1, p. 99–118, 1955.
- SONG, Q.; CHISSOM, B. S. Forecasting enrollments with fuzzy time series—part i. *Fuzzy sets and systems*, Elsevier, v. 54, n. 1, p. 1–9, 1993.
- SONG, Q.; CHISSOM, B. S. Fuzzy time series and its models. *Fuzzy sets and systems*, v. 54, n. 3, p. 269–277, 1993.
- SONG, Q.; CHISSOM, B. S. Forecasting enrollments with fuzzy time series-part ii. *Fuzzy sets and systems*, Amsterdam: North-Holland, c1978-, v. 62, n. 1, p. 1–8, 1994.
- SONG, Q.; LELAND, R. P.; CHISSOM, B. S. Fuzzy stochastic fuzzy time series and its models. *Fuzzy Sets and Systems*, v. 88, n. 3, p. 333 – 341, 1997. ISSN 0165-0114. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0165011496000772>.
- STAMBAUGH, R. F.; YU, J.; YUAN, Y. The short of it: Investor sentiment and anomalies. *Journal of Financial Economics*, v. 104, n. 2, p. 288 – 302, 2012. ISSN 0304-405X. Special Issue on Investor Sentiment. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0304405X11002649>.
- SUN, B. et al. Prediction of stock index futures prices based on fuzzy sets and multivariate fuzzy time series. *Neurocomputing*, v. 151, p. 1528 – 1536, 2015. ISSN 0925-2312. Disponível em: <http://www.sciencedirect.com/science/article/pii/S092523121401176X>.
- TABOADA, M. et al. Lexicon-based methods for sentiment analysis. *Computational linguistics*, MIT Press One Rogers Street, Cambridge, MA 02142-1209, USA journals-info . . . , v. 37, n. 2, p. 267–307, 2011.
- TALARPOSHTI, F. M. et al. Stock market forecasting by using a hybrid model of exponential fuzzy time series. *International Journal of Approximate Reasoning*, v. 70, p. 79 – 98, 2016. ISSN 0888-613X. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0888613X15001991>.
- THALER, R. H. The end of behavioral finance. *Financial Analysts Journal*, Taylor & Francis, v. 55, n. 6, p. 12–17, 1999.
- TORRA, V. Hesitant fuzzy sets. *International Journal of Intelligent Systems*, Wiley Online Library, v. 25, n. 6, p. 529–539, 2010.
- TORRA, V.; NARUKAWA, Y. On hesitant fuzzy sets and decision. In: IEEE. *2009 IEEE International Conference on Fuzzy Systems*. [S.l.], 2009. p. 1378–1382.

TURC, I. et al. Well-read students learn better: On the importance of pre-training compact models. *arXiv preprint arXiv:1908.08962v2*, 2019.

TVERSKY, A.; KAHNEMAN, D. Judgment under uncertainty: Heuristics and biases. *science*, American association for the advancement of science, v. 185, n. 4157, p. 1124–1131, 1974.

VASWANI, A. et al. Attention is all you need. *CoRR*, abs/1706.03762, 2017. Disponível em: <http://arxiv.org/abs/1706.03762>.

XIA, M.; XU, Z. Hesitant fuzzy information aggregation in decision making. *International Journal of Approximate Reasoning*, v. 52, n. 3, p. 395 – 407, 2011. ISSN 0888-613X. Dependence Issues in Knowledge-Based Systems. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0888613X10001246>.

YASMEEN, F.; SHARIF, M. Functional time series (fts) forecasting of electricity consumption in pakistan. *International Journal of Computer Applications*, Foundation of Computer Science, v. 124, n. 7, 2015.

YU, H.-K. Weighted fuzzy time series models for taiex forecasting. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 349, n. 3-4, p. 609–624, 2005.

ZADEH, L. Fuzzy sets. *Information and Control*, v. 8, n. 3, p. 338 – 353, 1965. ISSN 0019-9958. Disponível em: <http://www.sciencedirect.com/science/article/pii/S001999586590241X>.

ZHU, B.; XU, Z. Hesitant fuzzy bonferroni means for multi-criteria decision making. *Journal of the Operational Research Society*, Taylor & Francis, v. 64, n. 12, p. 1831–1840, 2013.