



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Sylvia Emmanuelle Castelo Branco de Holanda Victor

NotWarning e DynamicWarning: Estratégias de Aprendizado em Fluxo de Dados com base na Análise dos Efeitos do Sinal de Detecção Warning

Recife

2022

Sylvia Emmanuelle Castelo Branco de Holanda Victor

NotWarning e DynamicWarning: Estratégias de Aprendizado em Fluxo de Dados com base na Análise dos Efeitos do Sinal de Detecção Warning

Tese de Doutorado apresentada ao Programa de Pós-graduação em Ciência da Computação do Centro de Informática da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de Doutora em Ciência da Computação.

Área de Concentração: Inteligência Computacional

Orientador: Prof. Dr. Silvio de Barros Melo

Coorientador: Prof. Dr. Bruno Iran Ferreira Maciel

Recife

2022

Catálogo na fonte
Bibliotecária Monick Raquel Silvestre da S. Portes, CRB4-1217

V642n Victor, Sylvia Emmanuelle Castelo Branco de Holanda
Notwarning e dynamicwarning: estratégias de aprendizado em fluxo de dados com base na análise dos efeitos do sinal de detecção warning / Sylvia Emmanuelle Castelo Branco de Holanda Victor. – 2022.
182 f.: il., fig.

Orientador: Silvio de Barros Melo.
Tese (Doutorado) – Universidade Federal de Pernambuco. CIn, Ciência da Computação, Recife, 2022.

Inclui referências e apêndice.

1. Inteligência computacional. 2. Fluxo de dados. I. Melo, Silvio de Barros (orientador). II. Título.

006.31

CDD (23. ed.)

UFPE - CCEN 2022-111

Sylvia Emmanuelle Castelo Branco de Holanda Victor

“NotWarning e DynamicWarning: Estratégias de Aprendizado em Fluxo de Dados com base na Análise dos Efeitos do Sinal de Detecção Warning”

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutora em Ciência da Computação.

Aprovado em: 08/03/2022.

Orientador: Prof. Dr. Sílvio de Barros Melo

BANCA EXAMINADORA

Prof. Dr. Cleber Zanchettin

Centro de Informática/UFPE

Prof. Dr. André Câmara Alves do Nascimento

Departamento de Computação/UFRPE

Prof. Dr. Francisco Madeiro Bernardino Junior

Departamento de Estatística e Informática/UNICAP

Prof. Dr. Sérgio de Carvalho Bezerra

Centro de Informática/UFPB

Prof. Dr. Emerson Alexandre de Oliveira Lima

Escola Politécnica de Pernambuco/UPE

Dedico esta tese a minha mãe Maria de Fátima e meus avós Cândida Maria e Paulo Holanda (*in memoriam*), que não puderam estar ao meu lado neste momento tão importante, mas que sempre torceram muito para que eu o alcançasse.

AGRADECIMENTOS

Agradeço a minha família por todo carinho, amor e força. Sou grata, particularmente, as minhas tias Ana Luisa e Catarina Holanda, e minha prima Cecília Nunes, grandes parceiras, incentivadoras e que me apoiaram bastante ao longo destes seis anos.

A todos os meus amigos que compartilharam comigo momentos de alegria e entretenimento, e que entenderam minha ausência nesta etapa tão desafiadora. Principalmente, a Caio Barbosa, que foi meu parceiro durante todo o tempo do doutorado, inclusive nas disciplinas, estudando, ensinando e sempre com palavras de apoio e incentivo. Assim como, a Erika Medeiros, que nos últimos momentos não mediu esforços para me ajudar e tranquilizar.

Agradeço a todos os professores que me inspiraram e contribuíram com a minha trajetória acadêmica, na UNICAP, UPE-POLI e UFPE-Cin. Em particular, ao professor Sílvio Barros Melo, pela oportunidade e confiança. Em especial, ao seu grande apoio para que eu não desistisse.

Minha eterna gratidão, especialmente, a meu companheiro, Bruno Maciel, pelo amor, carinho e, principalmente, paciência. Sendo o maior incentivador e responsável por me ajudar a concluir este doutorado. Agradeço toda a orientação, cumplicidade e persistência.

RESUMO

Muitos desafios de aplicações comerciais envolvem mineração de dados aplicado a classificação em fluxo de dados. Onde os classificadores são métodos incrementais de instâncias que aprendem com cada exemplo conforme chegam e são capazes de lidar com um fluxo teoricamente infinito, suscetível a mudanças de conceito, em um ambiente com severas restrições de tempo, processamento e quantidade de memória, além disso, também precisam ser capazes de prever um padrão a qualquer momento. Exemplos de aplicações deste tipo, incluem: detecção de spam em *e-mails*, detecções de fraudes em cartões de crédito e detecção de *logs* de sistemas. Assim sendo, diferentes modelos de classificação foram adaptados para manipular fluxos de dados nessas condições, destacando-se para este trabalho a estratégia de aprendizado adaptativo aplicado a classificação com detecção, na qual a adaptação do modelo de aprendizado leva em consideração sinais de detecção do método de detecção de mudança de conceito. Normalmente, os trabalhos da literatura de detecção de mudança de conceito escolhem essa estratégia. Entretanto, é comum nas avaliações de desempenho, métodos detectores não fazerem distinção entre métodos que consideram e os que não consideram os sinais de detecção *warning*. Neste trabalho, os experimentos foram implementados no *framework Massive Online Analysis* (MOA) e executados na ferramenta *MOAManager* para analisar os impactos do sinal de detecção *warning* na acurácia dos novos modelos de decisão, e para isso são fornecidas evidências empíricas, referências e justificativas para descrever os efeitos do *warning* na acurácia. Deste modo, sendo possível concluir que os sinais de detecção *warning* melhoram a generalização dos modelos e na maioria das situações analisadas, quando são omitidos degradam a acurácia *Prequential*, resultando em diferenças estatísticas. Baseando-se nesses resultados, foram desenvolvidas duas estratégias para melhor lidar com os efeitos do sinal de detecção *warning*: o *NotWarning* e o *DynamicWarning*. Estas estratégias possuem mecanismos capazes de garantir que novos modelos sejam treinados antes de serem testados; construir conjuntos de treinamento para os novos modelos sem depender dos sinais de detecção *warning* do método de detecção de mudança de conceito; e uma gestão mais eficaz da criação de novos modelos. Além disso, é questionado o atual método de avaliação de detectores, que são baseados na acurácia da classificação, propondo uma nova metodologia de avaliação mais justa. Assim sendo, foi possível fornecer uma análise aprofundada comparando os impactos dos sinais de detecção *warning* na acurácia *Prequential*, incluindo um estudo empírico para comparar várias versões diferentes de métodos de detecção de mudança de conceito em cada estratégia. Por fim, os experimentos empíricos com bases artificiais alcançaram resultados promissores com os novos algoritmos.

Palavras-chaves: aprendizado adaptativo; fluxo de dados; aprendizado online; detecção de mudança de conceito; sinais de detecção *warning*.

ABSTRACT

Much commercial application's challenges are related to data mining applied to data stream classification. The classifiers are instances' incremental methods that learn from each example as they arrive and can handle a theoretically infinite data stream of instances. So, they used to be susceptible to concept drift, with severe restrictions in time processing and amount of memory. In addition, they also need to be able to predict a pattern at any time. Applications examples of this type include: spam detection in e-mails, credit cards fraud detection and logs system detection. Therefore, different classification models were adapted to manipulate data streams under these conditions, highlighting for this work the adaptive learning strategy applied to classification with detection, in which the learning model's adaptation takes into account detection signals from the concept drift detection's method. Usually, works in the concept drift detection literature choose this strategy. However, it is common in performance evaluations among detection methods not to distinguish between methods that consider detection *warning* signals' from those that do not. In this work, the empirical experiments and the proposed algorithms were implemented in the *framework Massive Online Analysis* (MOA) and executed in the *MOAManager* tool to analyse the impacts of the *warning* detection signals' on the new models' accuracy were analyzed. For this, empirical evidence, references, and justifications are provided to describe the effects of *warning* on the accuracy. Thus, it is possible to conclude that *warning* detection signals' in most analyzed situations, when they are omitted, cause impacts on the degradation of accuracy, resulting in statistical differences. Based on these results, two strategies were developed to better deal with the *warning* detection signals' effects: the NotWarning and the DynamicWarning. They have mechanisms capable of guaranteeing that new models are trained before being tested without relying on the *warning* detection signals' of the concept drift detection method. Then, it was possible to provide an in-depth analysis comparing the impacts of *warning* detection signals' on *Prequential* accuracy, including an empirical study to compare several different versions of concept drift detection methods in each strategy. Finally, the empirical experiments in artificial datasets achieving good results in the new algorithms.

Keywords: adaptive learning; data stream; online learning; concept drift detection; warning signals detection.

LISTA DE FIGURAS

- Figura 1 – Problema da mudança de conceito. Ilustra as causas e efeitos das mudanças de conceito na avaliação do desempenho da classificação. Foram utilizados dois classificadores Naive Bayes incrementais: um deles possui abordagem adaptativa (SingleClassifierDrift - classificador adaptativo, possui embutido um detector de mudança de conceito para lidar com conjuntos de dados que contenham mudança de conceito - disponibilizado por Manuel Baena no MOA [Bifet et al. 2018]). Esses dois classificadores apresentam os respectivos desempenhos nas avaliações da acurácia da classificação. Ainda em relação a essas abordagens, a diferença nos valores de acurácia da classificação dá-se pela escolha do algoritmo que detecta a mudança de conceito. 39
- Figura 2 – Fluxograma da Abordagem Adaptativa de Classificação com Detecção Aprendizado Adaptativo aplicado a Classificação com Detecção (AACD), descrevendo seu passo a passo, desde o questionamento da existência de instância no fluxo de dados até a identificação do estado de detecção pelo detector. . 41
- Figura 3 – Representação de uma simulação de como são calculados e configurados os pontos de mudança de conceito em meio a um trecho de fluxo de dados. É associando um ponto de mudança de conceito ao ponto onde, de fato, a mudança de conceito foi detectada, por meio da definição da quantidade de instâncias entre estes pontos, w , onde w representa o próprio conjunto de treinamento do modelo simulado. No exemplo, é considerado o ponto da mudança de conceito, em azul, P_{MC} , a quantidade de instâncias em *Warning* para treinamento w ; e o ponto em vermelho, que representa o ponto de detecção da mudança de conceito, P_{Det} 61
- Figura 4 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do ADDM. 66
- Figura 5 – Fluxograma da Estratégia de Abordagem Adaptativa NotWarning, indicando desde o momento em que é verificado a existência de instâncias no fluxo de dados, até a identificação do estado de detecção pelo detector. A princípio, seguindo a estrutura da abordagem AACD, porém, agindo de maneira diferente a cada estado detectado. 76

Figura 6 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do NotWarning com o DDM.	82
Figura 7 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do NotWarning com o FHDDM.	85
Figura 8 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do NotWarning com o RDDM.	89
Figura 9 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do NotWarning com o USDD.	92
Figura 10 – Fluxograma da Estratégia de Abordagem Adaptativa DynamicWarning, indicando desde o momento em que é verificado a existência de instâncias no fluxo de dados, até a identificação do estado de detecção pelo detector. A princípio, seguindo a estrutura da abordagem AACD, porém, mesclando a ação do NotWarning ou sua própria estratégia, de acordo com cada estado detectado e as quantidades de instâncias previamente armazenadas no conjunto de treinamento.	94
Figura 11 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do DynamicWarning com o DDM.	101
Figura 12 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do DynamicWarning com o FHDDM.	104
Figura 13 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do DynamicWarning com o RDDM.	108
Figura 14 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do DynamicWarning com o USDD.	111
Figura 15 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações dos métodos tradicionais.	121
Figura 16 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações dos métodos tradicionais sem sinais de Warning.	127
Figura 17 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do método ADDM.	128
Figura 18 – Diferenças calculadas de acurácia Prequential para a comparação geral dos métodos tradicionais e variações com NotWarning (NW) e DynamicWarning (DW) para Hoeffding Tree (HT) e Naive Bayes (NB), individualmente.	130

Figura 19 – Resumo dos ranks de acurácia Prequential para a comparação geral dos métodos tradicionais e variações com NW e DW HT e NB normalizadas . . 131

LISTA DE TABELAS

Tabela 1 – Resumo descritivo da configuração de conjuntos de dados artificiais.	45
Tabela 2 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o ADDM com HT.	63
Tabela 3 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o ADDM com NB.	64
Tabela 4 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o DDM com HT na abordagem NotWarning.	80
Tabela 5 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o DDM com NB na abordagem NotWarning.	81
Tabela 6 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o FHDDM com HT na abordagem NotWarning.	83
Tabela 7 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o FHDDM com NB na abordagem NotWarning.	84
Tabela 8 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o RDDM com HT na abordagem NotWarning.	87
Tabela 9 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o RDDM com NB na abordagem NotWarning.	88
Tabela 10 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o USDD com HT na abordagem NotWarning.	90
Tabela 11 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o USDD com NB na abordagem NotWarning.	91
Tabela 12 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o DDM com HT na abordagem DynamicWarning.	99
Tabela 13 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o DDM com NB na abordagem DynamicWarning.	100
Tabela 14 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o FHDDM com HT na abordagem DynamicWarning.	102
Tabela 15 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o FHDDM com NB na abordagem DynamicWarning.	103

Tabela 16 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o RDDM com HT na abordagem DynamicWarning.	106
Tabela 17 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o RDDM com NB na abordagem DynamicWarning.	107
Tabela 18 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o USDD com HT na abordagem DynamicWarning.	109
Tabela 19 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o USDD com NB na abordagem DynamicWarning.	110
Tabela 20 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia dos detectores DDM, FHDDM, RDDM e USDD nas versões tradicionais para HT.	119
Tabela 21 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia dos detectores DDM, FHDDM, RDDM e USDD nas versões tradicionais para NB.	120
Tabela 22 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia dos detectores DDM, FHDDM, RDDM e USDD nas versões sem Warning com HT.	122
Tabela 23 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia dos detectores DDM, FHDDM, RDDM e USDD nas versões sem Warning com NB.	123
Tabela 24 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia na comparação geral do ADDM no ponto ideal e suas variações para HT. . .	123
Tabela 25 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia na comparação geral do ADDM no ponto ideal e suas variações para NB. . .	125
Tabela 26 – Análise das somas dos valores das hipóteses estatísticas de Wilcoxon em relação a acurácia na comparação geral do DDM, FHDDM, RDDM e USDD nas versões tradicionais e variações do NW e DW para HT.	132
Tabela 27 – Análise das somas dos valores das hipóteses estatísticas de Wilcoxon em relação a acurácia na comparação geral do DDM, FHDDM, RDDM e USDD nas versões tradicionais e variações do NW e DW para NB.	133
Tabela 28 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia na comparação geral do DDM, FHDDM, RDDM e USDD nas versões tradicionais e variações do NW e DW para HT.	147

Tabela 29 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia na comparação geral do DDM, FHDDM, RDDM e USDD nas versões tradicionais e variações do NW e DW para NB.	164
--	-----

LISTA DE ABREVIATURAS E SIGLAS

AACD	Aprendizado Adaptativo aplicado a Classificação com Detecção
AADE	Aprendizado Adaptativo com Detector Embutido
ADDM	Artificial Drift Detection Method
ADDMW008	ADDM com treinamento e distância de tamanho 8
ADDMW021	ADDM com treinamento e distância de tamanho 21
ADDMW055	ADDM com treinamento e distância de tamanho 55
ADDMWW008	ADDM sem treinamento e distância de tamanho 8
ADDMWW021	ADDM sem treinamento e distância de tamanho 21
ADDMWW055	ADDM sem treinamento e distância de tamanho 55
ADWIN	ADaptive WINdowing
AGRA	Agrawal
AM	Aprendizado de Máquina
BOLE	Boosting-like Online Learning Ensemble
BW	Basic Window
CUSUM	Page's CUmulative SUM Drifts
DDD	Diversity for Dealing with Drifts
DDM	Drift Detection Method
DDM001TRAD	DDM na versão tradicional
DDM008DW	DDM com treinamento de tamanho 8 aplicado ao DW
DDM008NW	DDM com treinamento de tamanho 8 aplicado ao NW
DDM021DW	DDM com treinamento de tamanho 21 aplicado ao DW
DDM021NW	DDM com treinamento de tamanho 21 aplicado ao NW
DDM055DW	DDM com treinamento de tamanho 55 aplicado ao DW
DDM055NW	DDM com treinamento de tamanho 55 aplicado ao NW
DDMC	Drift Detection Method Classifier

DW	DynamicWarning
ECDD	EWMA for Concept Drift Detection
FF	Fading Factors
FHDDM	Fast Hoeffding Drift Detection Method
FHDDM001TRAD	FHDDM na versão tradicional
FHDDM008DW	FHDDM com treinamento de tamanho 8 aplicado ao DW
FHDDM008NW	FHDDM com treinamento de tamanho 8 aplicado ao NW
FHDDM021DW	FHDDM com treinamento de tamanho 21 aplicado ao DW
FHDDM021NW	FHDDM com treinamento de tamanho 21 aplicado ao NW
FHDDM055DW	FHDDM com treinamento de tamanho 55 aplicado ao DW
FHDDM055NW	FHDDM com treinamento de tamanho 55 aplicado ao NW
FTDD	Fisher Test Drift Detector
HDDM_A	Hoeffding-based Drift Detection Method A-Test
HDDM_W	Hoeffding-based Drift Detection Method W-Test
HT	Hoeffding Tree
LED	Light Emitting Diode
MIX	Mixed
MOA	Massive Online Analysis
MOAM	MOAManager: A tool to support data stream experiments
NB	Naive Bayes
NW	NotWarning
PAC	Probably Approximately Correct
RDDM	Reactive Drift Detection Method
RDDM001TRAD	RDDM na versão tradicional
RDDM008DW	RDDM com treinamento de tamanho 8 aplicado ao DW
RDDM008NW	RDDM com treinamento de tamanho 8 aplicado ao NW
RDDM021DW	RDDM com treinamento de tamanho 21 aplicado ao DW

RDDM021NW	RDDM com treinamento de tamanho 21 aplicado ao NW
RDDM055DW	RDDM com treinamento de tamanho 55 aplicado ao DW
RDDM055NW	RDDM com treinamento de tamanho 55 aplicado ao NW
RRBF	Random Radial Basic Function
SINE	Sinusoid Signals
STEPD	Statistical Test of Equal Proportions
SW	Sliding Window
USDD	Ultimately Simple Drift Detector
USDD001TRAD	USDD na versão tradicional
USDD008DW	USDD com treinamento de tamanho 8 aplicado ao DW
USDD008NW	USDD com treinamento de tamanho 8 aplicado ao NW
USDD021DW	USDD com treinamento de tamanho 21 aplicado ao DW
USDD021NW	USDD com treinamento de tamanho 21 aplicado ao NW
USDD055DW	USDD com treinamento de tamanho 55 aplicado ao DW
USDD055NW	USDD com treinamento de tamanho 55 aplicado ao NW
WSTD	Wilcoxon Rank Sum Test Drift Detector

LISTA DE SÍMBOLOS

\geq	Maior ou Igual
δ	delta
Σ	Soma
Π	Produto
Δ	Delta
α	alfa
ϵ	épsilon
π	pi
\rightarrow	Setas para a direita
\leftarrow	Setas para a esquerda
ρ	rô
μ	mi

SUMÁRIO

1	INTRODUÇÃO	21
1.1	CONTEXTUALIZAÇÃO E MOTIVAÇÃO	21
1.2	DEFINIÇÃO DO PROBLEMA DE PESQUISA	25
1.3	PRINCIPAIS CONTRIBUIÇÕES	26
1.4	OBJETIVOS	27
1.5	ORGANIZAÇÃO DA TESE	27
2	APRENDIZADO EM FLUXO DE DADOS	29
2.1	PROBLEMA DE CLASSIFICAÇÃO EM APRENDIZADO SUPERVISIONADO	29
2.1.1	Formas de Aprendizado	31
2.1.1.1	<i>Aprendizado Offline</i>	32
2.1.1.2	<i>Aprendizado Incremental</i>	33
2.1.1.3	<i>Aprendizado Online</i>	33
2.1.2	Avaliação do Aprendizado	34
2.2	TEORIA DO APRENDIZADO ESTATÍSTICO	35
2.3	CLASSIFICADORES	36
2.3.1	Hoeffding Tree	36
2.3.2	Naive Bayes	37
2.4	PROBLEMA DA MUDANÇA DE CONCEITO	38
2.4.1	Detecção de Mudança de Conceito	38
2.4.2	Abordagem Adaptativa de Classificação com Detecção (AACD)	40
2.5	DETECTORES	43
2.6	GERADORES DE DADOS ARTIFICIAIS	45
2.7	CONSIDERAÇÕES FINAIS	46
3	ASPECTOS METODOLÓGICOS	48
3.1	AVALIAÇÃO DE DADOS	48
3.1.1	Pré-Análise	48
3.1.2	Execução dos Experimentos	51
3.1.3	Ambiente de execução	52
3.1.4	Estatística dos Resultados	52
3.2	AVALIAÇÃO EMPÍRICA	53

3.2.1	Ambiente de análise	53
3.2.2	Observações e Inferências	54
3.3	CONSIDERAÇÕES FINAIS	55
4	ANÁLISE DO SINAL DE DETECÇÃO WARNING	57
4.1	INTRODUÇÃO	57
4.2	OBJETIVO	58
4.3	CONFIGURAÇÃO EXPERIMENTAL E METODOLOGIA	59
4.4	RESULTADOS E ANÁLISE: SEM WARNING CONTRA COM WARNING	62
4.5	DISCUSSÃO	67
4.6	CONSIDERAÇÕES FINAIS	69
5	ESTRATÉGIAS DE CLASSIFICAÇÃO COM DETECÇÃO	71
5.1	INTRODUÇÃO	72
5.2	MOTIVAÇÃO	73
5.3	NOTWARNING: ADAPTAÇÃO SEM SINAL WARNING	74
5.3.1	Resultados e Análise: NotWarning contra Tradicional	78
5.3.1.1	$DDM_{NotWarning} \times DDM_{DDMC}$	79
5.3.1.2	$FHDDM_{NotWarning} \times FHDDM_{DDMC}$	83
5.3.1.3	$RDDM_{NotWarning} \times RDDM_{DDMC}$	86
5.3.1.4	$USDD_{NotWarning} \times USDD_{DDMC}$	88
5.4	DYNAMICWARNING: ADAPTAÇÃO COM SINAL WARNING	93
5.4.1	Resultados e Análise: DynamicWarning contra Tradicional	96
5.4.1.1	$DDM_{DynamicWarning} \times DDM_{DDMC}$	98
5.4.1.2	$FHDDM_{DynamicWarning} \times FHDDM_{DDMC}$	101
5.4.1.3	$RDDM_{DynamicWarning} \times RDDM_{DDMC}$	105
5.4.1.4	$USDD_{DynamicWarning} \times USDD_{DDMC}$	107
5.5	DISCUSSÃO	112
5.6	CONSIDERAÇÕES FINAIS	113
6	AVALIAÇÃO DE DESEMPENHO DOS DETECTORES	115
6.1	CONTEXTUALIZAÇÃO	115
6.2	CONFIGURAÇÃO EXPERIMENTAL E METODOLOGIA	116
6.3	RESULTADOS E ANÁLISE	117
6.3.1	Tradicional e Sem Warning	118
6.3.2	Comparação Exaustiva	122

6.4	DISCUSSÃO	134
6.5	CONSIDERAÇÕES FINAIS	136
7	CONSIDERAÇÕES FINAIS	137
7.1	CONCLUSÕES	137
7.2	PUBLICAÇÃO	139
7.3	LIMITAÇÕES	140
7.4	TRABALHOS FUTUROS	140
	REFERÊNCIAS	142
	APÊNDICE A – TABELAS DAS AVALIAÇÕES GERAIS	147

1 INTRODUÇÃO

O principal foco desta tese está na análise da metodologia de AACD, proposta por Gama et al. 2004 e utilizada em problemas de classificação com fluxo de dados. O algoritmo foi implementado e disponibilizado no *Framework* Massive Online Analysis (MOA) [Bifet et al. 2018], com classe de nome Drift Detection Method Classifier (DDMC) (*DriftDetectionMethodClassifier*) no pacote *moa.classifiers.drift*. Inclusive, há uma variedade de algoritmos que foram implementados e disponibilizados por diferentes autores. Em vista disso, essa ferramenta foi adotada por diversos trabalhos publicados na literatura da área de detecção de mudança de conceito e também será adotada neste trabalho.

O algoritmo DDMC aplica a estratégia de adaptação do aprendizado com detecção de mudança de conceito. Em caso de mudança de conceito, um novo modelo é construído e iniciada a tarefa de aprendizado. Isso se mostrou muito útil para remediar o problema da mudança de conceito.

A seguir, esta seção apresenta, em mais detalhes, uma visão geral deste trabalho. Primeiramente, é apresentado o contexto no qual a pesquisa está inserida e motivações, problemas em aberto, na Subseção 1.1. Em seguida, na Subseção 1.2, é delimitado o problema de pesquisa, e em sequência são apresentadas as contribuições e objetivos, nas Subseções 1.3 e 1.4, respectivamente. Por fim, é apresentado, na Subseção 1.5, um resumo da organização das outras seções desta tese.

1.1 CONTEXTUALIZAÇÃO E MOTIVAÇÃO

Desde quando os computadores foram inventados é questionado se eles poderiam ser feitos para aprender [Mitchell 1997]. Atualmente os computadores são utilizados para aprender, por exemplo, com registros médicos e sugerirem quais tratamentos podem ser mais eficientes para novas doenças e pacientes específicos. Há muitos programas de computadores com algoritmos que são eficazes para certos tipos de tarefas de aprendizado. No entanto, há inúmeros desafios para que os computadores aprendam tão bem quanto as pessoas.

O principal objetivo da área de Aprendizado de Máquina é lidar com algoritmos capazes de aprender a partir de dados [Mitchell 1997]. Para trabalhar com os mais variados tipos de tarefas de aprendizado, os algoritmos precisam ser robustos. Sendo assim, com base no tipo

de dados de entrada, os algoritmos de aprendizado de máquina podem ser categorizados como supervisionados ou não-supervisionados.

Esta tese limita-se a problemas de aprendizado supervisionado. A característica desse tipo de aprendizado é que os dados utilizados para treinamento possuem a resposta desejada a ser prevista, isto é, contém a variável dependente resultante das variáveis independentes analisadas. Nesse caso, o objetivo é prever uma variável dependente a partir de uma lista de variáveis independentes.

Em aprendizado supervisionado, os problemas podem ser de classificação ou regressão. Os problemas de classificação são aqueles em que o algoritmo prevê a variável dependente, ou seja, uma classe, dentro de um conjunto de possibilidades existentes. No caso dos problemas de regressão, é preciso prever um valor numérico específico e este valor pode ser, por exemplo, o preço de um refrigerante. Esta tese limita-se a problemas de classificação.

As técnicas e métodos de aprendizado de máquina são impulsionados pelo aumento da criação de dados e, conseqüentemente, o interesse em compreender, processar e sintetizá-los, isso faz com que mais domínios de aplicações explorem os métodos e técnicas de Aprendizado de Máquina (AM) [Domingos e Hulten 2000]. Em algumas aplicações reais, os dados entram e saem continuamente de um sistema e com diferentes velocidades de atualização. Esses dados podem fluir continuamente e são temporariamente ordenados, mas podem mudar rapidamente, são massivos e potencialmente infinitos, podendo ser impossível armazená-los por inteiro para depois analisar. Estas são particularidades de fluxos de dados.

Neste sentido, a aplicação de aprendizado em fluxos de dados surge da necessidade de se tomar decisões rápidas e, principalmente, por não haver tempo para analisar todas as informações disponíveis novamente. Tais situações estão presentes no cotidiano das pessoas, sendo comum as pessoas tomarem decisões com base no conhecimento mais recente. No aprendizado em fluxo de dados, fazer uso de informações sem levar em consideração o momento em que ela chegou (idade), poderá induzir o modelo a erros de inferência.

Os fluxos de dados possuem características como serem: não-estacionários, contínuos e potencialmente infinitos. Sendo assim, é um desafio lidar com o aprendizado em cenários com fluxos de dados, principalmente devido a característica de não-estacionariedade. Isto porque, para se ter boa generalização e garantias teóricas do aprendizado, os dados precisam ser estacionários [Vapnik e Chervonenkis 1971] [Vapnik e Chervonenkis 2015].

Uma alteração no padrão de uma fonte de dados pode implicar em mudanças que podem levar à necessidade de revisão do conceito aprendido [Bifet 2009]. Nestes casos, é considerado

que o fluxo de dados está suscetível à “mudança de conceito” [Gama et al. 2014, Barros e Santos 2018].

A mudança de conceito ocorre quando uma fonte de dados muda de comportamento inesperadamente e passa a publicar dados com um padrão diferente do que estava presente no fluxo de dados [Mitchell 1997]. Devido a isso, a estratégia de mineração para fluxos de dados precisa ser capaz de atualizar continuamente seu modelo de aprendizado com padrões novos [Gama et al. 2004]. Caso isso não seja realizado, o modelo de aprendizado passará a apresentar uma degradação contínua na acurácia e se tornará obsoleto para a tarefa de rastreamento de padrões.

Para exemplificar fluxos de dados com estas características, existem aplicações como: *logs de sistemas*, onde são registradas informações continuamente sobre acessos aos sistemas, no qual quanto mais clientes e acessos maior será esse registro; a *deteção de fraudes em cartões de crédito*, onde as informações de compra chegam o tempo todo, e cada cliente tem seu padrão de compra, então, se algo mudar, pode ser identificado como uma fraude; e o controle de *spam em e-mails* onde *e-mails* fora do padrão são detectados como suspeito.

De fato, o problema da mudança de conceito exige uma adaptação do modelo de aprendizado. Há diferentes maneiras disponíveis na literatura para lidar com esse problema. Entretanto, esta tese limita-se ao domínio da metodologia de AACD [Gama et al. 2004]. Nessa metodologia, após testar e treinar o modelo de aprendizado, a estratégia de adaptação do modelo é auxiliada por um método de detecção de mudança de conceito que guia a estratégia com base em três sinais de detecção: *In-Control* ou *Stable* (estável), *Warning* (em alerta) e *Out-of-Control* ou *Drift* (mudança de conceito).

A ideia é adaptar o modelo de aprendizado levando em consideração os sinais de detecção. No sinal *Warning*, é construído um classificador auxiliar que funciona em paralelo ao principal, sendo treinado a cada instância enquanto o sinal mantiver-se. No sinal *Out-of-Control*, o classificador principal é destruído e substituído por um novo que pode ou não ter recebido treinamento. Por fim, no sinal *In-Control*, o fluxo é considerado como estável e mantém-se o aprendizado.

Há diversos métodos detectores disponíveis na literatura da área desde a publicação do Drift Detection Method (DDM). Alguns desses detectores são: Statistical Test of Equal Proportions (STEPD) [Nishida e Yamauchi 2007], EWMA for Concept Drift Detection (ECDD) [Ross et al. 2012], Reactive Drift Detection Method (RDDM) [Barros et al. 2017], Hoeffding-based Drift Detection Method A-Test (HDDM_A) and Hoeffding-based Drift Detection Method W-

Test ($HDDM_W$) [Frías-Blanco et al. 2015], Fast Hoeffding Drift Detection Method (FHDDM) [Pesaranghader e Viktor 2016], Fisher Test Drift Detector (FTDD) [Cabral e Barros 2018], Wilcoxon Rank Sum Test Drift Detector (WSTD) [Barros, Hidalgo e Cabral 2018] e Ultimately Simple Drift Detector (USDD) [Maciel, Hidalgo e Barros 2021].

Vale ressaltar que, desde a publicação do DDM, os trabalhos citados anteriormente e vários outros utilizaram a metodologia tradicional de AACD. Entretanto, essa estratégia de adaptação do aprendizado ainda é pouco explorada, dada a comparação em relação aos trabalhos com outras estratégias para lidar com a mudança de conceito. Sendo assim, trata-se de um campo de investigação a ser explorado.

De certa forma, o ato de aprender pode ser encarado como um problema de otimização, no sentido de melhoria dos resultados. Pois a avaliação do modelo é feita em função do erro de predição, logo, a qualidade da generalização do algoritmo está atribuída a um menor erro de predição. Dessa forma, o processo de aprendizagem implica achar parâmetros nos dados que minimizem a função erro.

Neste sentido, vários trabalhos publicados na literatura de mudança de conceito utilizaram a metodologia de AACD proposta por Gama et al. 2004. Sendo assim, compreende-se a importância dessa metodologia, tradicionalmente utilizada na literatura. Até o presente momento da escrita desta tese, não foi localizada pela autora outra metodologia de AACD utilizada em trabalhos de classificação com detecção de mudança de conceito. Logo, pode-se entendê-lo como um problema com apenas uma solução. Dessa maneira, constitui-se como um campo em aberto e livre para novas propostas de melhorias.

Então, levando em consideração a teoria do aprendizado estatístico, o ideal é adaptar o aprendizado no momento em que ocorre a mudança de conceito. No entanto, os métodos de detecção de mudança de conceito, geralmente trabalham de forma reativa, ou seja, começam a agir somente depois que a mudança de conceito surge. A metodologia tradicional de AACD também tem este funcionamento reativo em relação aos sinais de detecção.

Diversos trabalhos da literatura atuam na melhoria da identificação das mudanças de conceito, e mesmo o sinal de detecção *Warning* tendo um papel atuante na metodologia tradicional de AACD, não há muito estudo sobre sua contribuição. Alguns métodos de detecção de mudança de conceito como o ADaptive WINdowing (ADWIN) [Bifet e Gavaldà 2007], Page's CUmulative SUM Drifts (CUSUM) [Bifet et al. 2010] e FHDDM [Pesaranghader e Viktor 2016] até ignoram o sinal de *Warning*.

Portanto, a grande motivação deste trabalho é investigar os efeitos do sinal de detecção

Warning na metodologia tradicional de AACD e seus impactos na acurácia *Prequential*. Além disso, também é investigada e proposta soluções proativas para melhor lidar com o treinamento de novos modelos após um sinal de mudança de conceito.

1.2 DEFINIÇÃO DO PROBLEMA DE PESQUISA

Diante do exposto até aqui, esta tese se propõe a responder o seguinte problema de pesquisa: *como melhorar aspectos do aprendizado em fluxo de dados?*

Primeiramente, é preciso explicar o que se deseja melhorar em relação aos aspectos do aprendizado. Em vista disso, o termo genérico “aspectos do aprendizado” foi utilizado para mencionar alguns pontos observados na abordagem de Aprendizado Adaptativo com Detector Embutido (AADE) [Maciel 2020] ou Aprendizado Adaptativo aplicado a Classificação com Detecção (AACD), que são nomenclaturas diferentes, mas sinônimas para representar uma estratégia igual.

Na investigação sobre esta estratégia foi observado que o método de detecção é responsável por armazenar, de acordo com os sinal de detecção *Warning*, um conjunto de instâncias para treinamento de um novo modelo de classificação, quando há uma mudança de conceito. Quando isto acontece, e o método de detecção não consegue detectar sinais de detecção *Warning*, este novo modelo de classificação é iniciado sem treinamento. Assim como, quando há a identificação de um sinal de detecção *Warning*, um novo classificador auxiliar é criado e treinado enquanto houver a detecção de tais sinais, porém, caso não seja detectada uma mudança de conceito, em seguida, este novo modelo é descartado sem uso.

Assim, foi possível propor novos procedimentos para obtenção de melhores resultados, sendo definidos os aspectos do aprendizado como: (1) retirar a responsabilidade do método de detecção de criar conjuntos de treinamento para novos modelos de aprendizado; (2) garantir ao novo modelo de decisão instâncias para treinamento, quando houver mudanças de conceito; (3) Utilizar um único modelo de aprendizado, substituído apenas quando houver, de fato, uma mudança de conceito.

Logo, a investigação do problema envolve explorar uma estratégia para minimizar a função erro da tarefa de classificação, implicando na qualidade da generalização do algoritmo. Ademais, vale considerar que não faz parte da investigação do problema propor novos métodos de classificação e detecção de mudança de conceito.

Para esta análise, a metodologia de avaliação *Prequential* [Dawid 1984] com a variação

Sliding Window [Sebastião e Gama 2009] foi considerada ser a mais apropriada para avaliar cenários de aprendizado em fluxo de dados [Hidalgo, Maciel e Barros 2019]. Em resumo, a estratégia dessa avaliação é somar um conjunto de erros que foram acumulados de uma quantidade de dados lidos (em uma janela deslizante) e calcular a perda entre as previsões e os valores analisados.

Assim sendo, a acurácia *Prequential* é uma métrica que calcula a proporção de estimativas corretas para o total de instâncias estimadas em uma classificação. Desta forma, deseja-se investigar técnicas e métodos para promover a melhoria da acurácia *Prequential* sem impactar em mudanças nos métodos utilizados para classificação e detecção de mudança de conceito.

Por fim, na literatura, é considerado que métodos de detecção de mudança de conceito são avaliados pela taxa de acurácia *Prequential*, possibilitando que detectores com melhores mecanismos de construção dos conjuntos de treinamento sejam mais favorecidos (como sendo melhores detectores de mudança de conceito). Portanto, esta tese também considera a avaliação dos métodos de detecção com uma mesma quantidade de treinamento para novos modelos quando há mudanças de conceito, assim, indicando uma avaliação mais justa do desempenho dos métodos.

1.3 PRINCIPAIS CONTRIBUIÇÕES

As principais contribuições desta tese são a análise sobre os efeitos do sinal de detecção *Warning* e as duas novas estratégias de variações da metodologia de AACD [Gama et al. 2004]. Essas contribuições são relevantes, pois, considerando o estado da arte, propõe-se de forma inovadora remover a dependência do sinal de detecção *Warning* do método de detecção de mudança de conceito para treinamento de novos modelos. Com isso, também permitir novas avaliações de desempenho de detectores com foco na eficiência da detecção de mudança de conceito, permitindo avaliações mais justas em relação à qualidade do rastreamento da mudança de conceito dos métodos de detecção de mudança de conceito.

A seguir, são apresentadas estas e outras contribuições:

- Alterações no algoritmo Artificial Drift Detection Method (ADDM) [Hidalgo, Maciel e Barros 2019] para considerar intervalos com sinais de detecção *Warning*;
- Questionamento aos trabalhos da literatura da área que avaliam os métodos de detecção de mudança de conceito por meio da acurácia da classificação e não por métricas de

detecção;

- Padronização do conjunto de treinamento para avaliações mais justas;
- Retirar do detector a responsabilidade de treinar o novo modelo de decisão;
- Garantia de uma quantidade mínima de treinamento para novos modelos de decisão;
- Evitar o treinamento de novos modelos em paralelo ao modelo principal e descarte sem serem utilizados para substituição do modelo principal;
- Melhoria na taxa de acurácia da classificação.

1.4 OBJETIVOS

Dado o exposto anteriormente, o principal objetivo desta tese é responder ao problema de pesquisa. Logo, para isso, é preciso propor e desenvolver melhorias na metodologia tradicional de AACD, que sejam auto adaptáveis e flexíveis em relação ao treinamento de novos modelos após uma mudança de conceito e com boa acurácia *Prequential*.

Como objetivos específicos a serem obtidos com o desenvolvimento deste trabalho, estão:

- Descrever a metodologia tradicional de AACD;
- Aplicar avaliações estatísticas em cenários artificiais que explorem os efeitos do sinal de detecção *Warning*;
- Desenvolver variações da metodologia de AACD;
- Comparar os resultados das diferenças das medições da acurácia *Prequential* obtidas nos experimentos, para melhor entender as diferenças em termos de superioridades estatísticas e, assim, identificar a variação mais apropriada para utilizar experimentalmente.

1.5 ORGANIZAÇÃO DA TESE

A organização das seções desta tese, assim como suas descrições são apresentadas a seguir:

- A Seção 2 revisa a literatura sobre aprendizado de máquina, classificação, aprendizado de conceitos estacionários, e o problema da mudança de conceito. Além disso, apresenta-se a metodologia tradicional de AACD e geradores de conjunto de dados artificiais.

- A Seção 3 reúne métodos, processo para organizar a pesquisa, parametrizações de métodos de classificação, detecção de mudança de conceito, geradores de dados e a metodologia de AACD.
- A Seção 4 descreve em detalhes a metodologia utilizada para avaliação dos efeitos do sinal de *Warning* na acurácia *Prequential*. Além disso, são apresentados os resultados e análises das evidências estatísticas encontradas nos experimentos empíricos. Sendo possível concluir que a metodologia tradicional de AACD tem seu desempenho degradado na ausência do sinal de *Warning*.
- A Seção 5 descreve em detalhes duas variações da metodologia de AACD propostas nesta tese. Além disso, são mostrados os algoritmos, resultados e análises das evidências estatísticas. Sendo possível concluir que as duas variações de metodologias de AACD possuem desempenho competitivo em relação à metodologia tradicional de AACD.
- A Seção 6 descreve a maneira como os resultados foram compreendidos, assim como, apresenta comparações entre os métodos tradicionais, os mesmos sem utilização de sinais *Warning* e uma comparação geral que engloba todas as variações experimentadas. Sendo possível observar o comportamento e o desempenho de cada um dos métodos avaliados.
- Seção 7 apresenta as conclusões, contribuições, limitações e, finalmente, as propostas para trabalhos futuros vislumbrados.

2 APRENDIZADO EM FLUXO DE DADOS

Esta seção descreve os conceitos do aprendizado em fluxo de dados. Desta forma, inicialmente são apresentados os conceitos do aprendizado de máquina e suas aplicações, assim como as bases para que este aprendizado aconteça, com a descrição dos graus de supervisão (supervisionado, semi-supervisionado e não supervisionado), e as formas de aprendizado (offline, incremental e online).

Em seguida, é abordada a teoria do aprendizado estatístico, que tem em suas premissas as diretrizes para que haja garantia do aprendizado em uma dada distribuição de probabilidade. E então, os algoritmos de classificação e detecção selecionados da literatura da área, assim como a metodologia de AACD, referência para o entendimento dos problemas de mudanças na distribuição de probabilidade, que geralmente ocorrem nos modelos de fluxo de dados.

A seção está organizada em 7 subseções. A Subseção 2.1 apresenta os problemas de classificação em aprendizado supervisionado, indicando dentre as técnicas, quais se aplicam a esta pesquisa. Na Subseção 2.2 são descritas as premissas da teoria do aprendizado estatístico. Na Subseção 2.3 são apresentados os classificadores utilizados para a investigação dos problemas desta tese. Em sequência, na Subseção 2.4 é explicado em detalhes o problema da mudança de conceito. Em seguida, são descritas as características dos detectores aplicados nesta pesquisa, na Subseção 2.5. Então, a Subseção 2.6 lista os geradores de conjuntos de dados artificiais selecionados. Por fim, são apresentadas, na Subseção 2.7, as considerações finais.

2.1 PROBLEMA DE CLASSIFICAÇÃO EM APRENDIZADO SUPERVISIONADO

O conceito de **Aprendizado de Máquina** explora a capacidade de um programa resolver problemas sem ser explicitamente programado [Samuel 1959]. Entretanto, há casos em que o programa de AM especializa-se em determinado problema (super ajustamento), apresentando alta capacidade de resolvê-los e baixa capacidade de resolver novos problemas (sub ajustamento).

No entanto, para algumas tarefas, não é trivial ter um algoritmo devido à complexidade dos casos e mudanças das condições ao longo do tempo. Neste contexto, não é viável a programação tradicional (utilizando “If” e “Else” - testando todas as situações previsíveis), para transformar a entrada em saída. Todavia, para algumas tarefas, é preciso de algum

mecanismo para que o computador (a máquina) consiga aprender. Em outras palavras, é preciso extrair automaticamente o algoritmo para essas tarefas. Para tanto, há dados de exemplo que podem ser utilizados para que a máquina aprenda. Então, é possível programá-los para aprender e melhorar automaticamente com a experiência.

Desta forma, na mineração de dados os algoritmos de AM são usados para descoberta de conhecimento em grandes conjuntos de dados, como, por exemplo, registros de compras em supermercados, sensores, pedidos de empréstimo, redes sociais, orçamentos governamentais, registros médicos e afins. Então, diversas empresas estão apostando nessas soluções e buscando isso com base na ciência [Maimon e Rokach 2010]. Esta tese apresenta o campo da AM (multidisciplinar), baseando-se em resultados de inteligência artificial, probabilidade e estatística, teoria da complexidade computacional, dentre outros.

Em resumo, o AM pode ser entendido como o estudo de métodos que produzem modelos de aprendizagem a partir de dados para descrever ou prever alguma tarefa. Esses métodos utilizam-se dos exemplos para produzir os padrões e rotular os exemplos como pertencentes a uma determinada classe.

Por sua vez, os algoritmos de aprendizado têm como procedimento de comparação para avaliação de desempenho, os tipos paramétricos (também chamados de clássicos) e não paramétricos (contextuais):

- **Paramétricos** - O modelo paramétrico faz uso de parâmetros, como por exemplo, média e covariância, para delimitar as regras do indutor para cada classe. Nele, o desempenho e a exatidão dos algoritmos de aprendizado estão diretamente ligados à simetria dos dados, ou seja, distribuição normal dos dados. O NB, por exemplo, é um método paramétrico de classificação baseado no *Teorema de Bayes*.
- **Não Paramétricos** - Os métodos não paramétricos diferenciam-se na medida em que podem ser adotados, independentemente da distribuição do dados, ou seja, que não obedecem aos parâmetros da curva normal. Portanto, eles podem utilizar características de vizinhança dos dados na classificação, a partir da aplicação de fatores de correção que resguardam a probabilidade de rotular uma instância de maneira duvidosa.

Segundo [Mitchell 1997], os algoritmos de AM podem ser classificados por diferentes critérios, como, por exemplo, o grau de supervisão presente no conjunto de treinamento. Levando em consideração esse critério, quanto maior a quantidade de exemplos rotulados,

maior o grau de supervisão. É possível distingui-los da seguinte maneira [Russell e Norvig 2013]:

- **Aprendizado Supervisionado** - O algoritmo indutor, no paradigma supervisionado, aprende a fazer um mapeamento entre entradas (atributos de classe) e saídas (dados rotulados). Essas saídas são previamente conhecidas e mostram ao indutor o que fazer e como melhorar o mapeamento. Há duas maneiras de resolver esse “problema de mapeamento” em aprendizado supervisionado: classificação, onde os rótulos das classes são discretas, e regressão, onde os rótulos das classes são contínuos.
- **Aprendizado Não Supervisionado** - O modelo aprende sobre a estrutura oculta dos dados, só existem os dados de entrada (dados não rotulados). Sendo assim, não há dados que confirmem e guiem o processo de aprendizado. Existem diferentes abordagens aplicadas no aprendizado não supervisionado, como agrupamento, estimativa de densidade e redução de dimensionalidade.
- **Aprendizado Semi-Supervisionado** - O modelo aprende por tentativa e erro ao atuar sobre um ambiente com características dinâmicas. O aprendizado ocorre a cada interação com o ambiente, cujo objetivo é maximizar seu desempenho geral. Dado dois pequenos conjuntos de observações, um rotulado e outro não rotulado, o objetivo é utilizar ambos os conjuntos para encontrar uma hipótese capaz de categorizar novas observações entre as classes já existentes.

Na parte de AM, esta tese tem como tarefa de aprendizado a classificação supervisionada, tendo como objetivo a construção de um classificador capaz de classificar uma lista de características em categorias (classes) de um domínio específico de conceito. Esse classificador é construído por um algoritmo de aprendizado a partir de um conjunto de exemplos do conceito. Após o treinamento, esse classificador deve ser avaliado e, se necessário, repetir o processo para melhorar o modelo induzido.

2.1.1 Formas de Aprendizado

Os algoritmos de aprendizado podem ser classificados pela maneira como uma nova informação é incorporada à estrutura. Há algumas nomenclaturas para defini-los como formas de aprendizado: não incremental, incremental, *offline* ou *online*. O aprendizado não incremental

e o *offline* têm o mesmo objetivo e é conhecido também pelo termo: aprendizado estático. Nele, o modelo não tem capacidade de agregar novos conhecimentos com o passar do tempo, ficando limitado ao que aprendeu durante a fase de treinamento. Já os aprendizados incremental e *online* permitem agregar novos conhecimentos ao longo do tempo, porém, têm uma diferença sutil entre eles. A compreensão e a diferença entre as três formas são definidas a seguir.

2.1.1.1 *Aprendizado Offline*

É comum em trabalhos de AM adotar o aprendizado supervisionado para avaliar o desempenho de modelos, pois, as classes são previamente conhecidas. O algoritmo iterativamente faz este aprendizado preguiçoso, realizando as previsões com base nas experiências (lembrança de outra instância, na qual, a classe seja conhecida), assumindo que a nova instância será da mesma classe, assim, os casos nunca vistos são classificados por meio de similaridade dos já vistos.

Assim, o aprendizado pode parar quando o algoritmo atingir um nível de desempenho aceitável ou o treinamento estiver encerrado. Então, utilizar aprendizado offline em cenários onde se conhece os dados é bastante comum para resolver problemas da área de mineração de dados. Uma vez que adotar esse tipo de abordagem pode ser uma vantagem, seja por questão de restrição de tempo, hardware, etc.

Por princípio, no *Aprendizado Offline* os dados são apresentados ao algoritmo em, no mínimo, dois distintos conjuntos de dados. No primeiro, os dados são utilizados para treinamento do conceito, conhecido como “conjunto de treinamento” (construção do modelo). No segundo, os dados são usados para classificação, sendo conhecido como “conjunto de teste” (uso do modelo). É possível haver mais um conjunto, o qual é usado para validação da classificação, conhecido como “conjunto de validação”, podendo ser usado após o conjunto de treinamento.

É importante ressaltar que os dados são particionados entre esses conjuntos de dados. Neste sentido, não é eficaz adotar aprendizado *offline* em cenários nos quais o conceito a ser aprendido possui muitos dados, com potencial tamanho ilimitado.

Em resumo, algumas aplicações possuem requisitos funcionais que afetam o modelo de aprendizado não incremental devido a suas restrições. Portanto, neste modelo de aprendizado, assume-se que o conhecimento adquirido não muda. Entretanto, para uma grande parcela dos problemas reais, o conhecimento pode mudar.

2.1.1.2 *Aprendizado Incremental*

No modo incremental, conhecido também por aprendizado dinâmico, o modelo agrega treinamento a cada nova interação. Este tipo de aprendizado permite que o conceito (conhecimento) aprendido seja evoluído, isto é, o modelo criado seja incrementado com a informação de um novo caso, sem que para isso seja preciso treiná-lo por completo novamente. No entanto, os dados são estacionários (mas o conceito aprendido não é esquecido, pois ele pode mudar ao longo em que novas instâncias são lidas e treinadas).

2.1.1.3 *Aprendizado Online*

Atualmente, a demanda por armazenamento cresce progressivamente, impulsionada pelos avanços tecnológicos e pela redução dos custos para armazenamento e processamento. Neste ritmo, corporações, governos e cidadãos produzem e armazenam milhares de novos registros.

Contudo, sistemas de aprendizado *offline*, ou seja, não incrementais, apresentam limitações. Estas limitações tornam-se maiores quando é preciso incorporar novos conhecimentos de maneira rápida e eficiente. Por isso, existem muitas situações reais que exigem aprendizado contínuo, onde possa haver aprendizado após uma mudança na distribuição dos dados.

Desta maneira, o conceito de aprendizado *online* pode ser interpretado de forma diferente, pois, neste caso, qualquer algoritmo deve ser capaz de aprender com fluxos de dados. Para [Babcock, Datar e Motwani 2002] e [Gama et al. 2014], os *fluxos de dados* possuem algumas características particulares:

1. Os exemplos de dados são recebidos de maneira contínua e potencialmente ilimitados;
2. Não é possível ter controle da ordem em que os exemplos são recebidos;
3. O exemplo deve ser processado e posteriormente descartado ou arquivado, mas só pode ser recuperado da memória principal;
4. A taxa de chegada dos exemplos é rápida, em relação ao poder de processamento do sistema;
5. O fluxo está suscetível a mudanças na distribuição de probabilidade.

Desta forma, um algoritmo de *Aprendizado Online* deve poder acessar dados somente uma vez e sequencialmente, ter uma complexidade de tempo e espaço não escalonada com o número de exemplos, e deve ser capaz de se autoadaptar.

Portanto, tais algoritmos são usados para realizar a tarefa de classificação ao mesmo tempo em que ocorre o aprendizado, por serem incrementais. Mas, vale ressaltar que o aprendizado incremental [Carpenter et al. 1992] não deve ser confundido com aprendizado *online* [Bottou 1998]. Pois, somente no aprendizado *online* é possível cumprir todos os requisitos dos fluxos de dados.

2.1.2 Avaliação do Aprendizado

Em pesquisas na área de aprendizado de máquina algoritmos são submetidos a avaliações empíricas, no qual, são extraídas métricas de desempenho como, por exemplo, a acurácia *Prequential*.

A metodologia de avaliação *Prequential* é aplicada em ambientes dinâmicos que podem conter mudanças de conceito [Dawid 1984]. Esta metodologia considera a soma consecutiva dos erros ao longo do tempo, possuindo três variações comuns: Basic Window (BW), Sliding Window (SW) e Fading Factors (FF) [Gama, Sebastião e Rodrigues 2013]. A SW foi identificada como a melhor estratégia para estimar a acurácia *Prequential* em fluxo de dados com mudanças de conceito [Hidalgo, Maciel e Barros 2019].

A acurácia *Prequential* [Dawid e Vovk 1999] é uma métrica utilizada para medir o desempenho de métodos, de acordo com alguma das metodologias de avaliação *Prequential*. Esta, apresenta o cálculo em tempo real de uma acurácia média (obtida pela proporção dos acertos e erros de predição pela quantidade de dados lidos antes de ser aprendida). O cálculo da acurácia no tempo t é definido pela Equação 2.1.

$$acc(t) = \begin{cases} acc_{instancia}(t), t = f \\ acc(t-1) + \frac{acc_{instancia}(t) - acc(t-1)}{t-f+1} \end{cases} \quad (2.1)$$

Note-se que $acc_{instancia}(t)$ é 1 se a instância atual for corretamente classificada e 0 caso contrário; e f é a primeira fixação do tempo de cada cálculo, ou seja, a primeira fixação do tempo para cada mudança de conceito detectada [Baena-Garcia et al. 2006] [Du, Song e Jia 2014].

2.2 TEORIA DO APRENDIZADO ESTATÍSTICO

A *Teoria do Aprendizado Estatístico* embasa o aprendizado de máquina oferecendo garantias teóricas de que é possível um algoritmo aprender a partir de exemplos. Este aprendizado tem como objetivo encontrar garantias teóricas para que a classificação seja realizada da melhor maneira, além de contabilizar os dados que são necessários para conseguir aplicar esse aprendizado [Vapnik e Chervonenkis 1971] [Vapnik 1999] [Cortes e Vapnik 1995].

Logo, as premissas deste aprendizado consideram que o classificador modela a distribuição de probabilidade dada uma função $f(x) = y$. Então, a premissa **P1** da *Teoria do Aprendizado Estatístico* assume que é possível se considerar qualquer distribuição conjunta de $p(x, y)$. Isto significa que, as entradas/exemplo em x e saída/rótulo em y são construídos dentro de um espaço de possibilidades. Se existirem todas as frequências dos possíveis valores de entrada e saídas associadas, cada possível resultado terá seu valor de probabilidade associado. Assim, os conjuntos mais prováveis serão os que têm a maior probabilidade associada.

Em sequência, a premissa **P2** da *Teoria do Aprendizado Estatístico* considera que as instâncias têm que ser amostradas de forma igualmente distribuídas, isto quer dizer que dentro de qualquer distribuição de probabilidade é possível amostrar exemplos. Supondo, por exemplo, que uma primeira instância foi classificada como sendo $P(A)$, a segunda não será necessariamente da mesma distribuição de probabilidade $P(A)$, pode ser de $P(B)$, $P(C)$ ou até mesmo da própria $P(A)$.

Sobre a premissa **P3** da *Teoria do Aprendizado Estatístico*, é dito que os exemplos têm que ser independentes entre si, revelando que não é possível induzir que a classificação de uma próxima instância esteja dentro de uma mesma distribuição de probabilidade, ou em qualquer outra. Assim, a premissa P3 ressalta que ter uma amostra em qualquer espaço de amostras a torna independente. Então, a probabilidade de amostragem das instâncias não muda, selecionando ou não a mesma distribuição. Caso contrário, as probabilidades seriam dependentes. Exemplificando, caso haja quatro classes no conceito, cada classe sempre tem 1/4 de chance de ser a escolhida.

Por conseguinte, a premissa **P4** da *Teoria do Aprendizado Estatístico* afirma que as classes podem ter ruídos. Isso significa que é possível que algumas instâncias tenham passado para serem classificadas erroneamente e, de certa forma, não haverá aprendizado correto destas. Por isso, o aprendizado precisa perceber que existem erros na classificação. De fato, essa identificação só é feita caso a parcela de instâncias classificadas incorretamente for pequena

em relação ao todo, assim, não dominando a distribuição em questão.

Então, na premissa **P5** da *Teoria do Aprendizado Estatístico*, é assumido que a distribuição de probabilidade $P(x, y)$ tem que ser estática, estacionária. Nestes casos, não há mudanças na distribuição ao longo do tempo. Esta premissa considera que só existe uma boa estimativa dos dados coletados se não houver mudanças na distribuição, portanto, na teoria do aprendizado estatístico o aprendizado só é garantido para uma única distribuição de probabilidade, mesmo em fluxo de dados.

E, por fim, a premissa **P6** da *Teoria do Aprendizado Estatístico* considera que a distribuição probabilidade $P(x, y)$ é supostamente desconhecida durante a fase de treinamento, sendo somente uma amostra desta distribuição conhecida. Assim, entende-se que se todas as distribuições fossem conhecidas, não seria necessário estimá-las. Então, a coleta dos dados é feita para haver estimação da distribuição de probabilidade.

2.3 CLASSIFICADORES

A *Teoria do Aprendizado Estatístico* descreve algumas premissas, como citado na Seção 2.2, assim oferecendo garantias teóricas de que há aprendizado em conjunto de dados estacionários. Desta forma, objetiva mostrar que há garantias de que haverá minimização da taxa de erro de classificação ao longo do aprendizado.

Logo, existem algoritmos de classificação que seguem essas definições, e para avaliação nesta tese foram selecionados dois deles: HT e NB.

2.3.1 Hoeffding Tree

O HT [Manapragada, Webb e Salehi 2018] é um classificador em árvore de decisão incremental aplicada a fluxos de dados, porém, considerando distribuições estacionárias. Então, seu funcionamento é dado por uma única varredura dos dados o mais rápido possível, acumulando estatísticas suficientes de exemplos em um nó até o ponto em que podem ser usadas para tomar uma decisão de divisão sensata [Pfahring, Holmes e Kirkby 2007].

Este assume que a geração de distribuição dos exemplos não é constante e explora o fato de que uma pequena amostra pode ser suficiente para escolher um atributo com boa separação entre as classes, o que é matematicamente suportado pelo conceito de *Hoeffding Bound* [Hoeffding 1963] [Maron e Moore 1993]. Este conceito afirma que, com probabilidade

$1 - \delta$, a verdadeira média da variável é de pelo menos $\bar{r} - \varepsilon$, onde \bar{r} é o valor médio calculado a partir de n observações independentes e ε está determinado pela Equação 2.2.

$$\varepsilon = \sqrt{\frac{R^2(\ln 1/\delta)}{2n}} \quad (2.2)$$

Hoeffding Bound quantifica o número de observações quando é necessário estimar o quão bom um atributo é [Domingos e Hulten 2000]. O que o torna atrativo é a sua capacidade de encontrar os mesmos resultados, independentemente, da distribuição de probabilidade gerando, assim, estas observações. Porém, o número de observações necessárias para atingir certos valores de δ e ε são diferentes entre as distribuições de probabilidade.

2.3.2 Naive Bayes

O NB [Duda e Hart 1973] é um classificador que simplifica muito o aprendizado por assumir que os recursos são independentes. Embora a independência seja geralmente uma suposição, na prática, muitas vezes ele compete bem com classificadores mais sofisticados. Este, atribui à classe mais provável um determinado exemplo descrito por seu vetor de características [Rish et al. 2001].

O NB utiliza uma variação da regra de *Bayes* para prever a classe para uma instância de teste, assumindo que as características são condicionalmente independentes umas das outras, dada a classe. Sua regra é descrita na Equação 2.3.

$$c_{NB} = \arg \max_{c_j \in C} p(c_j) \prod_{i=1}^n p(x_i | c_j) \quad (2.3)$$

Observa-se que c_{NB} representa o valor da categoria prevista pelo classificador NB para uma instância de teste. A probabilidade de características discretas é estimada a partir dos dados usando a estimativa da probabilidade máxima [Žliobaitė et al. 2015]. Valores desconhecidos na instância de teste são ignorados. Apesar de sua simplicidade, seu baixo custo computacional e sua suposição de independência condicional entre as variáveis, a literatura mostra que o classificador NB retorna precisões notavelmente altas, em muitos domínios [John e Langley 1995] [Bifet et al. 2010].

2.4 PROBLEMA DA MUDANÇA DE CONCEITO

Como visto na Seção 2.1, a descrição de fluxos de dados pode ser vista como uma ininterrupta sucessão de uma grande quantidade de dados em alta velocidade. Por isso, é comum considerar em fluxo de dados que a maneira como a classificação dos dados é feita pode ser modificada.

[Gama et al. 2014] dizem que uma mudança de conceito é equivalente a uma mudança na distribuição condicional de saída, dada uma entrada, mesmo que a distribuição de entrada não seja alterada. Portanto, mudança de conceito é o termo usado para uma mudança nas regras que alteram o entendimento sobre os fatos de um domínio. Assim como na estatística, este conceito é entendido como uma mudança na distribuição de probabilidade dos dados, ou função de densidade, ao longo do tempo.

Em particular, existe mais de uma maneira de se observar as mudanças de conceito. Isto significa dizer que elas têm velocidades diferentes para acontecer, e essa relação é atribuída à quantidade de informação do novo conceito. Assim, elas são classificadas como abruptas ou graduais [Gama et al. 2004]:

- **Abruptas** - Nas mudanças abruptas, a transição entre os dois conceitos (distribuição de probabilidade) muda rapidamente;
- **Graduais** - Nas mudanças graduais, existe uma transição suave entre os dois conceitos (entre as distribuições), pois há uma mistura entre eles.

Portanto, como a mudança abrupta é imediata, não há variações em sua velocidade. Porém, as mudanças graduais podem ser lentas ou rápidas, de acordo com os parâmetros escolhidos para este tipo de mudança de conceito no ambiente artificial. No ambiente real não é possível identificar tais características.

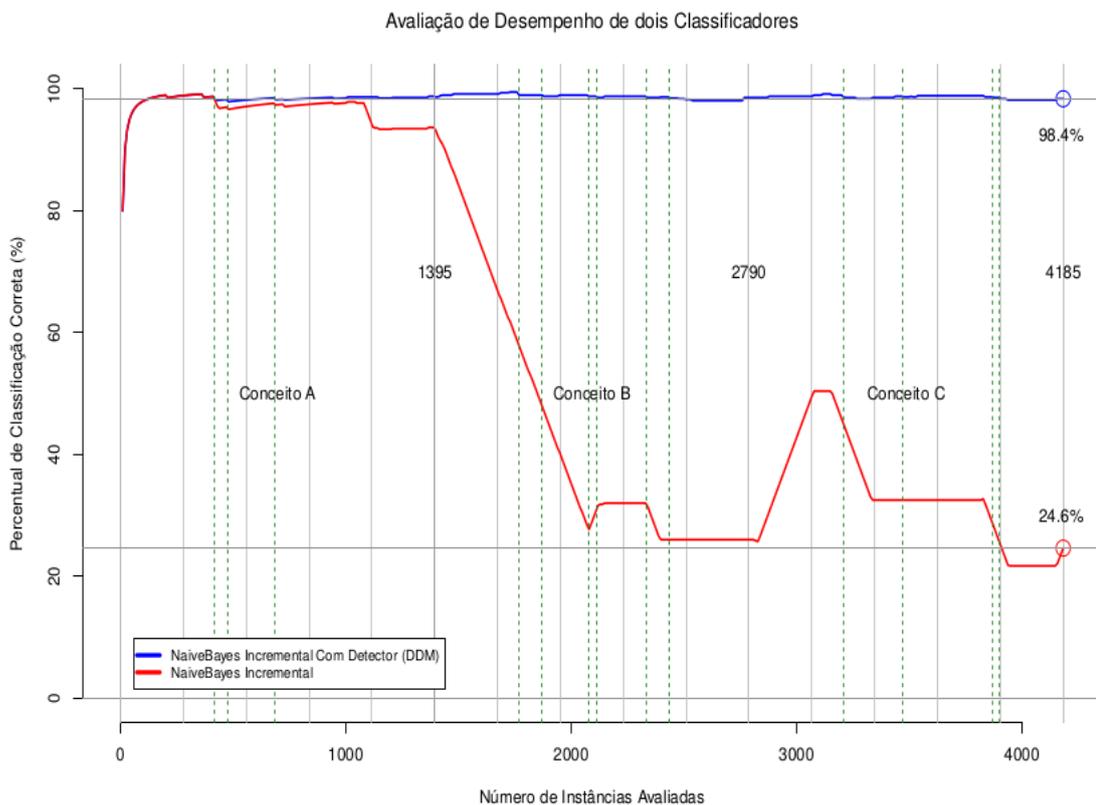
2.4.1 Detecção de Mudança de Conceito

Uma mudança na distribuição dos dados não tratada pode causar efeitos perturbadores na análise de dados. O aprendizado *online* refere-se justamente à capacidade de evoluir o modelo de classificação em tempo real, permitindo reagir à mudança de conceito durante a operação de aprendizado [Gama et al. 2014]. Nessa perspectiva de aprendizado, uma rápida reação

do indutor a uma mudança de conceito identificada pode contribuir bastante para reduzir os efeitos causados por essa mudança na qualidade da classificação, como visto na Figura 1.

A Figura 1 apresenta uma avaliação de desempenho entre dois classificadores por meio de um sistema de coordenadas cartesianas. Sendo assim, os eixos são representado por (x) número de instâncias avaliadas em relação ao (y) percentual de classificação correta.

Figura 1 – Problema da mudança de conceito. Ilustra as causas e efeitos das mudanças de conceito na avaliação do desempenho da classificação. Foram utilizados dois classificadores Naive Bayes incrementais: um deles possui abordagem adaptativa (SingleClassifierDrift - classificador adaptativo, possui embutido um detector de mudança de conceito para lidar com conjuntos de dados que contenham mudança de conceito - disponibilizado por Manuel Baena no MOA [Bifet et al. 2018]). Esses dois classificadores apresentam os respectivos desempenhos nas avaliações da acurácia da classificação. Ainda em relação a essas abordagens, a diferença nos valores de acurácia da classificação dá-se pela escolha do algoritmo que detecta a mudança de conceito.



Fonte: a autora (2022).

Ainda em relação a Figura 1, o algoritmo NB, representado pela linha de cor azul, foi executado com o método de detecção DDM. Já a linha vermelha é representada pelo classificador NB incremental sem adição de métodos de detecção.

Em suma, no exemplo, observa-se a dificuldade do método de classificação (sem detector) de recuperar o percentual de classificações corretas, em relação ao mesmo com classificador aplicado ao método de detecção DDM por meio da Abordagem Adaptativa de Classificação

com Detecção, que é descrita na Seção 2.4.2.

2.4.2 Abordagem Adaptativa de Classificação com Detecção (AACD)

Mesmo que existam algumas abordagens de adaptação projetadas para lidar com a mudança de conceito, há poucos trabalhos que tratam especificamente com apenas um modelo de classificação e um de detecção. Logo, esses trabalhos revelam que diferentes detectores podem ser úteis para lidar com mudanças de conceitos. Além disso, alguns de tais trabalhos utilizam sinais de *Warning* antes de uma mudança de conceito para se obter uma melhor generalização do novo conceito.

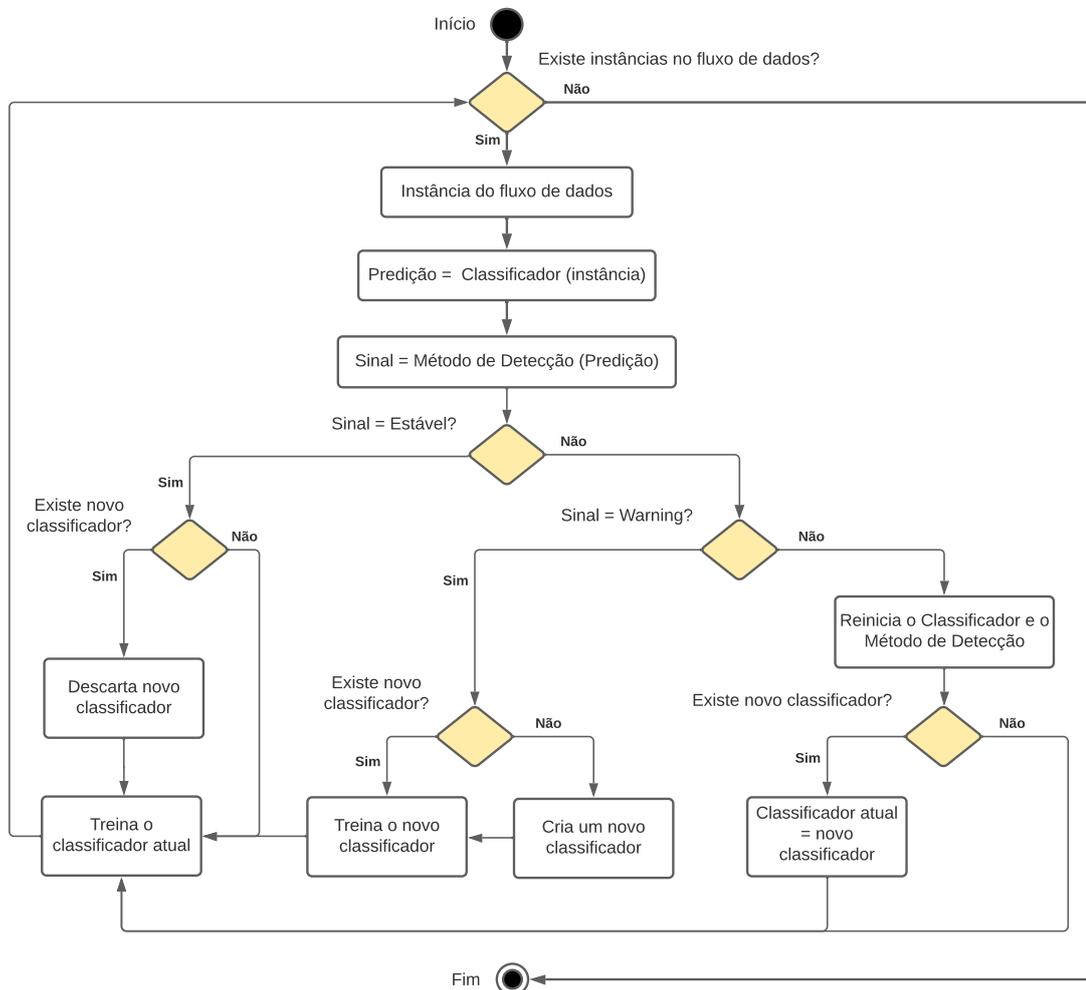
Assim, para uma melhor compreensão, nesta subseção é descrita a abordagem tradicionalmente utilizada pelos detectores: a AACD [Gama et al. 2004], comumente encontrado em trabalhos na literatura da área de mudança de conceito, e também referenciada nesta tese como a classe presente no MOA (DDMC).

Na Seção 2.1.1.3, foi mencionado que algoritmos de aprendizado *online* lidam com classificação em fluxo de dados com distribuição não estacionária. Então, é considerado que os exemplos chegam um de cada vez. Após recebê-los, cada exemplo individual é utilizado para testar o modelo e depois é usado para treiná-lo. Assim, a análise de fluxo de dados pode ser aplicada a um bem conhecido esquema para lidar com mudanças de conceito em dois módulos [Gama et al. 2004], [Baena-Garcia et al. 2006], [Bifet e Gavaldà 2007]: o detector de mudanças de conceito e o algoritmo de aprendizado.

Então, a comunicação destes dois módulos é feita por uma estrutura, a metodologia de aprendizado adaptativo. Embora existam algumas abordagens de adaptação projetadas para lidar com as mudanças de conceito, este trabalho apresenta análises com modelo único de classificação e detecção. Desta maneira, esta abordagem é responsável por interligar as instâncias do fluxo ao algoritmo de aprendizado, em seguida ao método de detecção de mudança de conceito, e a partir do resultado desta detecção, tomar as decisões necessárias.

De fato, há detectores com diferentes características, como o ADWIN [Bifet e Gavaldà 2007], FHDDM [Pesaranghader e Viktor 2016] e CUSUM [Page 1963], que podem alternar entre dois estados: *In-Control*, onde é estimado que o conceito está estável e *Out-of-Control* acionado quando há a estimativa de uma mudança de conceito. No entanto, o DDM [Gama et al. 2004], referência da área, também considera o sinal de detecção chamado de *Warning*, no qual, os exemplos assim identificados são antecipadamente armazenados para serem utilizados

Figura 2 – Fluxograma da Abordagem Adaptativa de Classificação com Detecção AACD, descrevendo seu passo a passo, desde o questionamento da existência de instância no fluxo de dados até a identificação do estado de detecção pelo detector.



Fonte: a autora (2022).

para treinamento de novos modelo quando houver a detecção de uma mudança de conceito, além de indicarem a estimativa de uma proximidade da mudança de conceito.

Ou seja, o funcionamento desta abordagem tradicional pode ser visto na Figura 2. No primeiro momento, as instâncias são recebidas do fluxo de dados e classificadas, então, posteriormente, são avaliadas as respostas da classificação pelo detector, não havendo diferenças entre os dois tipos de métodos de detecção (que consideram ou não os sinais de *Warning*).

Quando o fluxo é classificado como estável, a instância atual é treinada no modelo principal. A partir daí, caso o método considere os sinais de detecção *Warning*, quando o detectam, a abordagem tradicional cria um novo modelo de decisão em paralelo, que será treinado com a instância atual (em *Warning*), e as demais que venham, consecutivamente, ter a mesma

identificação.

Então, ainda para os detectores que consideram os sinais de detecção *Warning*, caso seja detectado um estado de mudança de conceito, após os sinais de *Warning*, este novo modelo treinado com essas instâncias em *Warning*, substituirá o modelo atual (que é iniciado com algum treinamento). Porém, se o fluxo voltar à estabilidade antes de ser detectada uma mudança de conceito, este novo modelo de decisão, previamente treinado, é descartado. Após este descarte, caso seja detectado um estado de mudança de conceito, um novo modelo sem treinamento substituirá o modelo atual. Caso não haja nenhuma identificação de instâncias em *Warning* e seja detectada uma mudança de conceito, o modelo atual vai ser substituído por um novo modelo sem treinamento.

Algoritmo 1: Pseudo-código da abordagem de Aprendizado Adaptativo de Classificação com Detecção (AACD), adaptado de [Gama et al. 2004]. Detalha a estratégia de única classificação e detecção, comumente utilizada na literatura de detecção de mudança de conceito para criação e treinamento de modelos quando há uma mudança de conceito no fluxo de dados.

```

Input: fluxo
1 reiniciarClassificadorAuxiliar ← falso
2 classificador.reset()
3 classificadorAuxiliar.reset()
4 detector.reset()
5 for (instancia in fluxo) do
6   predição {acerto,erro} ← classificador.testarInstancia(instancia)
7   estado {stable,warning,drift} ← detector.analisar(predição)
8   if estado = stable then
9     reiniciarClassificadorAuxiliar ← falso
10  else
11    if estado = warning then
12      if reiniciarClassificadorAuxiliar = falso then
13        classificadorAuxiliar.reset()
14        reiniciarClassificadorAuxiliar ← verdadeiro
15        classificadorAuxiliar.treina(instancia)
16      else
17        classificador ← classificadorAuxiliar
18        reiniciarClassificadorAuxiliar ← falso
19        classificadorAuxiliar.reset()
20        detector.reset()
21  classificador.treina(instancia)

```

Fonte: Gama et al. (2004)

Da mesma forma, quando não são considerados os sinais de *Warning* pelo detector, o modelo não tem nenhuma possibilidade de ter um conjunto de treino. E tal como acontece em detectores que consideram os sinais *Warning*, quando o detector identifica uma mudança de conceito após uma identificação de estabilidade, o modelo atual é substituído por um novo modelo sem treinamento.

Ainda, é possível observar a ideia da abordagem de AACD por meio de sua implementação no Algoritmo 1, mostrando a verificação de instâncias no fluxo de dados, a classificação da instância atual e a avaliação das respostas da classificação pelo detector, nas linhas 5, 6 e 7, respectivamente. De qualquer maneira, independentemente do sinal detectado, a instância atual é treinada na linha 21. Porém, na linha 8, caso seja detectado um sinal de *Stable*, o classificador auxiliar é reiniciado. Na linha 11, caso seja detectado um sinal de *Warning*, verifica-se a ativação do classificador auxiliar, caso não esteja, na linha 14, ele é ativado. E em seguida, na linha 15, o classificador auxiliar é treinado com a instância atual. Por fim, caso seja detectada uma mudança de conceito, o classificador auxiliar se torna o classificador principal, então, o classificador auxiliar é desativado e ele e o estado de detecção são reiniciados, nas linhas 17, 18, 19 e 20, respectivamente.

2.5 DETECTORES

Métodos de detecção normalmente analisam os resultados da predição do classificador e os aplicam a um modelo de decisão para lidar com as detecções de mudança na distribuição dos dados [Barros et al. 2017], como foi visto na Subseção 2.4.2. De acordo com este objetivo, é muito comum vermos a sugestão de novos detectores avaliando seu desempenho comparativamente com seus antecedentes na literatura da área.

Nesta tese, para entender realmente o comportamento de um método de detecção de mudança de conceito, percebeu-se que seria interessante, além dos métodos reais, também a aplicação de um detector artificial (que simula um detector real), assim, o ADDM [Hidalgo, Maciel e Barros 2019] foi utilizado com a finalidade de obter referências sobre dados de detectores reais. Portanto, foram selecionados cinco métodos de detecção de mudança de conceito, quatro reais (DDM [Gama et al. 2004], FHDDM [Pesaranghader e Viktor 2016], RDDM [Barros et al. 2017], USDD [Maciel, Hidalgo e Barros 2021]) e o artificial (ADDM). A descrição deles é dada a seguir:

- **Artificial Drift Detection Method (ADDM)** - A sua implementação simula em geradores de dados artificiais a detecção do ponto exato onde aconteceu a mudança de conceito em um fluxo de dados. Desta forma, o método consegue evitar a presença de falsos positivos e falsos negativos em sua avaliação, simulando o comportamento de um detector perfeito. O ADDM é configurado para ter parâmetros iguais de pontos de

mudança de conceito e o pontos de detecção de mudança de conceito. Então, todas as mudanças no fluxo de dados vão ter uma detecção sem nenhuma instância de atraso.

- **Drift Detection Method (DDM)** - Detecta mudanças de conceito em fluxo de dados pela análise de erros na taxa de classificação e desvio padrão. Para cada posição i no fluxo de dados, o DDM define a taxa de erro p_i como a probabilidade de fazer uma predição incorreta e o desvio padrão é dado por $s_i = \sqrt{p_i(1 - p_i)/i}$. Baseado no modelo de aprendizado do Probably Approximately Correct (PAC) [Mitchell 1997], os autores do DDM argumentam que, quando a distribuição dos exemplos permanece estacionária, a taxa de erro p_i deve diminuir com o aumento do número de exemplos i . Assim, um aumento significativo no erro sugere que a distribuição das classes mudou e, portanto, o modelo de decisão atual se torna inapropriado.
- **Fast Hoeffding Drift Detection Method (FHDDM)** - Sinaliza sinais de detecção de mudança de conceito baseados na desigualdade de *Hoeffding*, utilizando uma janela de deslocamento com tamanho n (por padrão, $n = 200$), e detecta uma mudança de conceito quando existe uma diferença significativa entre o máximo e as probabilidades mais recentes das predições corretas. Este método calcula a diferença entre essas probabilidades (ΔP) e um limite (ϵ), o qual é achado usando a probabilidade de erro na desigualdade de *Hoeffding* (δ , por padrão 10^{-7}). Então, uma mudança de conceito é detectada quando $\Delta P \geq \epsilon$.
- **Reactive Drift Detection Method (RDDM)** - Periodicamente diminui o número de instâncias de um conceito longo e estável para lidar com um conhecido problema de perda de desempenho do DDM. Ele descarta as velhas instâncias de conceitos muito grandes com o objetivo de detectar mudanças de conceitos mais cedo, melhorando a precisão das suas detecções e especialmente a taxa de acurácia final. Além disso, utilizando a configuração padrão recomendada, o RDDM apresenta um desempenho especialmente forte em geradores de dados com mudanças de conceito graduais e quando os tamanhos dos conceitos tem milhares de instâncias.
- **Ultimately Simple Drift Detector (USDD)** - Retem uma amostra de dados da taxa de erro da classificação, de tamanho n , que é atualizada quando são detectados sinais de *Warning* (α_w) e *Drift* (α_d), e então o estado de detecção é alterado. Da mesma forma que outros detectores, o USDD monitora as previsões do algoritmo de classificação em

tempo real de acordo com as amostras de dados, assumindo que quando a precisão cair para abaixo de 50% (mais erros do que respostas corretas) há uma mudança de conceito. Assim, o USDD assume que qualquer indicação de diminuição significativa na taxa de erro da classificação é considerada uma mudança de conceito.

2.6 GERADORES DE DADOS ARTIFICIAIS

Os geradores artificiais, como o nome já sugere, simula modelos para ser possível verificar situações reais. Cada um dos geradores escolhidos para esta pesquisa tem a vantagem de que qualquer comportamento de desvio desejado pode ser explicitamente especificado. Portanto, nesta tese consideramos *benchmarks* publicados ou geradores usados no MOA [Bifet, Holmes e Pfahringer 2010] com parametrização comum. A Tabela 1 mostra as principais características dos geradores selecionados.

Tabela 1 – Resumo descritivo da configuração de conjuntos de dados artificiais.

Gerador	Conceitos	Atributos	Classes
Agrawal	10	9	2
Led	7	24	10
Mix	2	4	2
Random RBF	n	10	2
Sine	4	2	2

Fonte: a autora (2022).

Ainda sobre a Tabela 1, pode-se observar a relação entre os geradores *Agrawal*, Light Emitting Diode (LED), Mixed (MIX), Random Radial Basic Function (RRBF) e *Sine* e a quantidade de conceitos, atributos e classes pertencentes a cada um deles. Além disso, uma breve descrição de cada um desses geradores de dados artificiais pode ser vista a seguir:

- O **Agrawal** [Agrawal, Imielinski e Swami 1993, Santos et al. 2014] armazena informações de pessoas com o objetivo de receber um empréstimo, que são classificadas como grupo A ou B. Os atributos são: salário, comissão, idade, nível educacional, CEP, etc. Os autores propuseram 10 funções, cada uma com diferentes formas de avaliação, sendo possível adicionar ruído.

- O gerador **Light Emitting Diode (LED)** [Goncalves Jr. e Barros 2013, Frías-Blanco et al. 2015] representa o problema de prever o dígito de um *display* de LED. Tem 24 atributos categóricos (17 são irrelevantes) e uma classe categórica. Cada atributo tem 10% de probabilidade de ser invertido (ruído). Os desvios de conceito são simulados alterando a posição dos atributos relevantes.
- O **Mixed (MIX)** [Gama et al. 2004] é um gerador que cria os dados de acordo com quatro atributos. Dois deles são do tipo numéricos, representados por ' x' ' e ' y' ', e dois são booleanos ' w' ' e ' v' '. Estes atributos são responsáveis por indicar a classificação das instâncias como ("negativas" e "positivas"). Uma classificação é positiva quando duas das três condições são satisfeitas $v, w, y < 0,5 + 0,3 * \sin(3\pi x)$; e negativa quando $v, w, y \geq 0,5 + 0,3 * \sin(3\pi x)$. Com a inversão das classes, simula-se as mudanças de conceito.
- Gerador aleatório **Random Radial Basic Function (RRBF)** [Bifet et al. 2009, Santos, Barros e Gonçalves Jr. 2015] usa centroides de n com seus centros, rótulos e pesos definidos aleatoriamente e uma distribuição Gaussiana para determinar os valores de m atributos. Desvios de conceito são simulados mudando as posições dos centroides. Este conjunto de dados tem duas classes para gerar, 10 atributos, 20 centroides no modelo e 20 centroides com mudanças de conceito.
- O gerador **Sinusoid Signals (SINE)** [Gama et al. 2004, Santos et al. 2014] usa dois atributos numéricos (x, y) , duas classes ("negativo" e "positivo") e duas funções de gerar contextos. Em $Sine_1$, cada instância é positiva se o ponto (x, y) estiver abaixo da curva $y = \sin(x)$, enquanto $Sine_2$ usa $y < 0,5 + 0,3 * \sin(3\pi x)$. Mudanças de conceito podem ser simulados alternando entre $Sine_1$ e $Sine_2$ ou invertendo os resultados, ou seja, pontos abaixo das curvas tornam-se negativos.

2.7 CONSIDERAÇÕES FINAIS

Esta seção teve como objetivo descrever o estado da arte do aprendizado de máquina, direcionando a fundamentação para o aprendizado em fluxo de dados. Assim, foram apresentadas as definições do aprendizado *offline* e incremental para se compreender a diferença entre eles e o aprendizado *online*, que é o foco desta pesquisa.

O aprendizado *online* é uma técnica vastamente utilizada atualmente para resolver certos

tipos de problemas que têm abrangido um número crescente de aplicações de mineração de dados e aprendizado de máquina. Em tais aplicações, os exemplos de dados utilizados para treinamento são recebidos de maneira contínua e potencialmente ilimitados, como redes de sensores [Cohen et al. 2008], filtragem de spam [Delany et al. 2005], detecção de intrusão [Lane e Brodley 1998] e detecção de fraude de cartão de crédito [Wang et al. 2003], que geram dados que chegam constantemente, conhecidos como fluxo de dados [Aggarwal 2007].

Consequentemente, foi visto que estes fluxos de dados possibilitam a ocorrência de mudanças nas suas distribuições de probabilidades, portanto, podem ter seus conceitos alterados. No entanto, por mais que a representatividade destes tipos de problemas venham aumentando, a literatura não é tão vasta. Tanto que a base para guiar tais soluções estão na Teoria do Aprendizado Estatístico que, mesmo não abrangendo diferentes distribuições, possibilita o direcionamento de algumas garantias para que haja a convergência do aprendizado em tais problemas.

Por fim, esta seção mostrou a metodologia de AACD, tradicionalmente aplicada a problemas de única classificação com detecção, apresentando seu funcionamento, seus pontos favoráveis e dificuldades encontradas. Foram apresentadas e descritas, também, as funcionalidades e objetivos de cinco algoritmos e cinco geradores de dados artificiais que são utilizados nas próximas seções para realizar simulações que avaliam o comportamento dos algoritmos propostos nesta tese, baseados na metodologia de AACD.

3 ASPECTOS METODOLÓGICOS

Esta seção apresenta o percurso metodológico da pesquisa, assim como as fases da pesquisa. Essas fases contemplam a seleção de algoritmos e parametrizações, organização dos experimentos, coleta de dados e análise dos resultados. Desta maneira, foram realizados muitos procedimentos experimentais e posterior análise de dados, em conformidade com técnicas estatísticas de descrição, inferência e análise de dados que permitem avaliar afirmações e fazer conclusões sobre as amostras.

Os procedimentos metodológicos adotados para a coleta de dados se caracterizam por uma abordagem quantitativa, pois envolveu técnicas (execução de experimentos) associadas a pesquisas empíricas. Para análise dos resultados foram utilizados procedimentos estatísticos que permitem realizar inferências e conclusões sobre as amostras.

A seção está organizado em 3 subseções. A Subseção 3.1 apresenta a análise dos dados indicando como os experimentos foram parametrizados, coletados e analisados. A Subseção 3.2 descreve a avaliação empírica realizada em cima dos dados coletados e, por fim, a Subseção 3.3 traz as considerações finais acerca desta seção.

3.1 AVALIAÇÃO DE DADOS

A fase de análise de dados reúne várias etapas para que seja possível extrair significado dos resultados com teor científico. Essas etapas estão organizadas em três fases: (1) pré-análise; (2) exploração dos resultados; e (3) tratamento dos resultados, inferência e interpretação.

Desta forma, são apresentados a seguir a Subseção 3.1.1 que apresenta os algoritmos, parametrizações e configurações dos experimentos. A Subseção 3.1.2 que mostra as ferramentas e técnicas usadas para a execução dos experimentos. A Subseção 3.1.3 que descreve as características da máquina que executou os experimentos. E a Subseção 3.1.4 que descreve as técnicas e os métodos pelos quais os resultados são tratados estatisticamente.

3.1.1 Pré-Análise

Esta subseção detalha os conjuntos de dados artificiais escolhidos para os experimentos descritos neste trabalho. Desta maneira, foram selecionados cinco geradores de conjuntos

de dados artificiais, em três versões diferentes, totalizando 15 conjuntos de dados artificiais. Assim, cada um deles têm a vantagem de que qualquer comportamento de desvio desejado pode ser explicitamente especificado. Então, os geradores de dados artificiais selecionados são:

- **Agrawal** [Agrawal, Imielinski e Swami 1993, Santos et al. 2014] - Os conceitos são definidos por meio de funções. Foram adotadas e concatenadas para simular as mudanças de conceitos, as funções de geração F1, F2, F3, F4 e F5, respectivamente;
- **Light Emitting Diode (LED)** [Goncalves Jr. e Barros 2013, Frías-Blanco et al. 2015] - Os conceitos também são definidos por meio de funções. Assim, foram adotadas e concatenadas para simular as mudanças de conceitos, as funções de geração F5, F1, F2, F3 e F4, respectivamente;
- **Mixed (MIX)** [Gama et al. 2004] - Assim como nos geradores anteriores, os conceitos são definidos por meio de funções. No entanto, só há duas funções de conceitos disponíveis no MOA para ele: F1 e F2. Então, foram adotadas e concatenadas para simular as mudanças de conceitos, as funções F2, F1, F2, F1 e F2, respectivamente;
- **Random Radial Basic Function (RRBF)** [Bifet et al. 2009, Santos, Barros e Goncalves Jr. 2015] - Diferentemente dos geradores anteriores, o RRBF tem os conceitos definidos mudando o número de centroides. Há muitas possibilidades de parametrizações para criação de conceitos. Então, foram adotadas e concatenadas para simular as mudanças de conceito, as parametrizações fixas de duas classes, cinco atributos, vinte centroides e vinte centroides com *drift*, sendo os conceitos definidos variando as sementes de inicialização de cada conceito. Dessa forma, as sementes utilizadas foram 6, 7, 8, 9 e 10, respectivamente;
- **Sinusoid Signals (SINE)** [Gama et al. 2004, Santos et al. 2014] - Gerador que também tem os conceitos definidos por meio de funções de conceitos. Dada as quatro funções disponíveis no MOA, foram adotadas e concatenadas para simular as mudanças de conceito, as funções de geração de conceitos F4, F3, F2, F1 e F4, respectivamente.

Em particular, os tamanhos dos geradores de dados artificiais foram definidos com base na sequência de Fibonacci (0, 1, 1, **2**, 3, 5, **8**, **13**) e multiplicado por 10.000 para definir os tamanhos totais das bases. Os valores foram escolhidos afim de representar tamanhos crescentes, não proporcionais e não aleatórios. Então as versões seriam de 20.000, 80.000 e

130.000. Do mesmo modo, cada versão dos geradores foi configurada com quatro mudanças de conceito distribuídas em intervalos regulares:

- **20k** (com pontos de mudança de conceito nas instâncias 4k, 8k, 12k, 16k);
- **80k** (com pontos de mudança de conceito nas instâncias 16k, 32k, 48k, 64k);
- **130k** (com pontos de mudança de conceito nas instâncias 26k, 52k, 78k, 104k).

Para permitir uma comparação justa, a estratégia de adaptação utilizou dois classificadores base (frequentemente usados em experimentos na área), por serem simples, rápidos, eficientes e disponíveis gratuitamente no MOA. Sendo eles:

- **Hoeffding Tree (HT)** [Hoeffding 1963];
- **Naive Bayes (NB)** [Duda e Hart 1973].

Por conseguinte, as mudanças de conceito podem ser classificadas em dois tipos. Nesta tese são construídas as configurações destes dois tipos de mudanças de conceito: graduais e abruptas. Além do tipo da mudança, atribui-se as velocidades nas quais estas mudanças devem acontecer, sendo:

- **Abruptas = 0 (zero)** instâncias;
- **Graduais = 500** instâncias.

Assim como, para executar os experimentos foram selecionados cinco métodos de detecção de mudança de conceito, um artificial e quatro reais, que são aplicados de acordo com os direcionamentos desta tese. Sendo eles:

- **Artificial Drift Detection Method (ADDM)** [Hidalgo, Maciel e Barros 2019];
- **Drift Detection Method (DDM)** [Gama et al. 2004];
- **Fast Hoeffding Drift Detection Method (FHDDM)** [Pesaranghader e Viktor 2016];
- **Reactive Drift Detection Method (RDDM)** [Barros et al. 2017];
- **Ultimately Simple Drift Detector (USDD)** [Maciel, Hidalgo e Barros 2021].

Ao longo da tese, estes métodos são referenciados com a identificação de sua sigla, acrescidos da configuração que representa a variação avaliada. No caso do ADDM, tem a variação indicando a aplicação do conjunto de treinamento (ADDMW0 - ADDM com *Warning*) e o conjunto sem a utilização do treinamento (ADDMWW0 - ADDM *without warning*), como exemplo, respectivamente, ADDMW021 e ADDMWW055.

Em relação aos demais métodos, a representação referente a sua versão tradicional é dada unicamente pela sigla ou concatenada a referência (001TRAD), como exemplo, RDDM001TRAD. Nas variações das abordagens propostas, a sigla é seguida da quantidade de treinamento e do código NW ou DW, indicando o NW ou DW, respectivamente. Adicionalmente incluindo o tamanho deste treinamento, como exemplo, respectivamente, FHDDM008NW e USDD055DW.

3.1.2 Execução dos Experimentos

A avaliação da acurácia foi realizada pela metodologia *Prequential* [Hidalgo, Maciel e Barros 2019, Dawid 1984] com uma janela deslizante de tamanho 1000 com seu mecanismo de esquecimento [Gama, Sebastião e Rodrigues 2013]. Por meio desta, cada instância recebida é usada, inicialmente, para teste e, subsequentemente, para treinamento do modelo. A SW foi a variação aplicada nos experimentos desta tese por ser a estratégia mais apropriada em avaliações experimentais para estimar a acurácia de classificação em fluxo de dados com mudanças de conceito [Hidalgo, Maciel e Barros 2019].

Em relação a execução dos experimentos selecionados, nesta pesquisa foi utilizado o Massive Online Analysis (MOA) [Bifet, Holmes e Pfahringer 2010]. Esta ferramenta permite que os seus *scripts* de parametrização de comandos (*scripts* MOA) sejam formatados, configurados e executados.

Porém, com o intuito de otimizar e agilizar a organização das configurações e execuções dos *scripts* MOA, adicionalmente foi utilizado a ferramenta MOAManager: A tool to support data stream experiments (MOAM) [Maciel 2019]. O MOAM é uma ferramenta *open-source* para auxiliar na criação, execução e formatação de experimentos no ambiente *on-line*. Este sistema de gerenciamento fornece uma estrutura para automação de experimentos (gerados na ferramenta MOA), determinados pelas configurações estipuladas pelos usuários, de acordo com as necessidades das execuções. A ferramenta permite desde a execução de *scripts*, até a análise dos experimentos, proporcionando uma maior eficiência na etapa de execução e análise [Maciel 2019].

Portanto, o MOAM, como o nome sugere, gerencia todo o processo repetitivo e manual do MOA de forma automática. Assim, podendo considerar sua aplicação nesta tese, uma otimização no processo de execução dos experimentos em função do tempo e confiabilidade. Os dados com as configurações utilizadas para execução dos experimentos desta tese estão disponível no GitHub em <<https://github.com/sylviaholanda/tese.git>>.

3.1.3 Ambiente de execução

Em relação aos meios para a realização dos experimentos, foi utilizada uma única máquina:

- Sistema Operacional: Ubuntu 18.1/64-bit
- Processador: i7-8700K/4.7GHz
- Memória Principal: 48GB/2333MHz
- Memória Secundária: 250GB/SSD/NVMe

3.1.4 Estatística dos Resultados

Em relação a execução dos experimentos, foi especificado que em todos os conjuntos de dados artificiais, os experimentos são executados 30 vezes para calcular as precisões dos métodos na métrica avaliada: acurácia *Prequential*. Assim, para cada execução das 30 repetições foi utilizado a sequência de 1 à 30 para gerar a pseudo aleatoriedade do gerador de dados, ou seja, a semente que deu origem aos dados gerados foi a partir de um dos valores dentro de 1 à 30. Vale salientar que, foram executados de maneira crescente para todos os experimentos. No entanto, para entendimento amplo do comportamento dos dados, a análise é inteiramente estatística.

Subsequente as execuções, para verificar este comportamento entre os dados, são avaliadas as variações dos algoritmos de acordo com as diferenças estatísticas entre os cenários selecionados. Portanto, uma avaliação não paramétrica foi adotada, aplicando-se testes para determinar qual deles proporcionam o ganho mais significativo em relação a métrica avaliada. Especificamente, a avaliação é realizada pela comparação pareada de amostras do teste de *Wilcoxon*, o **Wilcoxon signed-rank** [Benavoli, Corani e Mangili 2016], [Demšar 2006].

Assim, como o teste é entre um par de variação de cenários, o resultado indica três possíveis respostas: se eles são estatisticamente iguais, superiores ou inferiores, expressados pelos valores de H_0 , H_1 e H_2 , respectivamente. Então, utilizando a mesma estratégia, as Seções 4, 5 e 6 têm suas comparações realizadas para cada contexto no qual é abordado. No entanto, para todos os casos, cada uma tem $H_1: \mu_1 > \mu_2$ e $H_2: \mu_1 < \mu_2$, considerando μ_1 e μ_2 cenários divergentes e avaliados sempre nesta ordem. Com exceção somente a análise que se encaixa na hipótese nula, H_0 , entre os pares, isto significa que $H_0: \mu_1 = \mu_2$, a superioridade de um método em comparação com outro sempre será observada.

Note que, a maioria dos trabalhos executam as hipóteses estatísticas na literatura com a média dos resultados de cada experimento, por exemplo, 60 amostras (1 média x 5 geradores de dados x 3 tamanho de geradores de dados x 2 tipos de mudança de conceito x 2 classificadores). Observe que o exemplo está com a mesma quantidade de parametrizações referenciadas na Subseção 3.1.1. Porém, seguindo as mesmas parametrizações, as comparações, nesta tese, são realizadas com 70.200 amostras (30 execuções x 5 geradores de dados x 3 tamanho de geradores de dados x 2 tipos de mudança de conceito x 2 classificadores x 39 variações). Em relação ao número de comparações realizadas com o teste de *Wilcoxon*, foram executadas 26.760 combinações (3 ADDM + 16 NW + 16 DW + 6 métodos tradicionais + 6 métodos tradicionais sem *Warning* + 21 ADDM geral + 378 todos métodos) pares x (5 geradores de dados x 3 tamanho de geradores de dados x 2 tipos de mudança de conceito x 2 classificadores).

3.2 AVALIAÇÃO EMPÍRICA

A Seção 3.1 mostrou toda a estratégia escolhida na seleção, execução e testes estatísticos utilizados. Nesta seção, a parte abstrata da avaliação dos experimentos é abordada. Assim, são apresentadas a seguir a Subseção 3.2.1 que mostra a maneira como os resultados dos experimentos no MOAM foram coletados. E a Subseção 3.2.2 que descreve os meios utilizados para se analisar estes resultados, juntamente com algumas técnicas de inferência de resultados para interpretar os dados obtidos da análise do *Wilcoxon*.

3.2.1 Ambiente de análise

Assim como citado na Subseção 3.1.2, a ferramenta utilizada para realizar a execução dos experimentos, o MOAM, também foi utilizado para a coleta dos resultados. Portanto, após a

extração dos dados brutos pela ferramenta MOAM, foi possível realizar as inferências sobre os resultados tanto por sua própria interface, MOAM, para alguns casos, quanto fora. As análises completas das 30 repetições dos experimentos por meio dos dados extraídos do MOAM com o teste de *Wilcoxon* não foram executados pelo MOAM.

3.2.2 Observações e Inferências

Após seleções, configurações, execuções e coletas, os resultados são extraídos e anexados a planilhas para decomposição e padronização dos dados. O objetivo deste procedimento é organizar e visualizar estes resultados da melhor maneira possível, assim, tendo uma maior confiança no resultados das interpretações.

Como mencionado anteriormente, a execução do teste de *Wilcoxon* com todas as médias não foi executado pelo MOAM, pois o mesmo faz o cálculo com a média das médias. Portanto, o algoritmo do *Wilcoxon* foi executado por meio de um *script* para obter todas as médias. A vasta interpretação dos dados, contando com as comparações entre parte e total das variações dos métodos, gerou as conclusões apresentadas nas Seções 4, 5 e 6. Para uma interpretação visual, mais abrangente do comportamento dos resultados das tabelas do *Wilcoxon* foram coloridos os dados de superioridade, inferioridade e igualdade estatísticas com as cores verde, vermelha e amarela, respectivamente.

De acordo com os dados extraídos, inicialmente, foi realizado o somatório individual dos valores de igualdade ($\sum H_0$), superioridade ($\sum H_1$) e inferioridade ($\sum H_2$) estatística de cada variação por tipo de mudança de conceito (abruptas e graduais). Esse somatório é realizado por cada linha da tabela referente a variação do método analisado. Primeiro as linhas abruptas, depois as graduais, e no final é feita a soma das duas linhas equivalentes. A análise exibida ao fim da tabela, conclui os dados dos cenários apontados (μ_1 ou μ_2), a interpretação deles, depende dos objetivos de cada seção, portanto, nelas há uma descrição de qual cenário foi selecionado para ser expressado na análise.

Em seguida, é calculada a diferença entre esses somatórios ($\sum H_1 - \sum H_2$), e montado um *rank* individual para mudanças abruptas e graduais. Por fim, é calculada uma análise geral destes dados, realizando o somatório do somatório dos valores de igualdade ($\sum \sum H_0$), superioridade ($\sum \sum H_1$) e inferioridade ($\sum \sum H_2$) estatística. Que resultam, semelhantemente, em uma diferença entre superioridades e inferioridades estatísticas ($\sum \sum H_1 - \sum \sum H_2$), para gerar um *rank* geral. Vale salientar que, esses dados são gerados para HT e NB, separadamente.

Estes *ranks* são determinados pelo cálculo dos postos. O *rank* aplicado é decrescente, no qual, o maior valor de diferença define o ponto mais alto do *rank*. E o menor valor de diferença, o ponto mais baixo. A partir dos valores dos *ranks* gerais de HT e NB, é calculada uma média aritmética, para indicar qual variação é a melhor no geral, para então, serem gerados gráficos gerais. Desta forma, esta configuração auxilia na leitura dos resultados, pois o ponto mais alto indicado no gráfico, exibe a variação mais bem colocada, no geral, daquela avaliação.

$$N = \frac{H_1 - H_2}{H_0 + H_1 + H_2} \quad (3.1)$$

Além dos gráficos que exibem uma avaliação geral por *rank*, há também a construção de gráficos em barras para uma avaliação individual por classificador. Nela, são colocados, agrupadamente, por variação/método as diferenças entre os somatórios gerais de HT e NB, com o objetivo de observar o desempenho de cada classificador. Porém, os dados exibidos nas imagens não são exatamente iguais aos das tabelas, porque os valores foram normalizados no intervalo entre [-1;1], dada a Equação 3.1. Portanto, tanto as planilhas, tabelas e gráficos gerados, a partir destes dados, foram extremamente importantes para a compreensão parcial e total dos questionamentos desta pesquisa.

3.3 CONSIDERAÇÕES FINAIS

Esta seção teve como objetivo descrever detalhadamente a metodologia e as estruturas seguidas por esta tese para apresentar a veracidade e possibilitar a replicação e verificação das experimentações propostas. Para entender como se organiza o trabalho foi definida a natureza da pesquisa, a avaliação teórica e a análise empírica dos dados.

Em relação a seleção dos dados, cinco geradores de dados artificiais foram escolhidos para representar a variedade da aplicação de problemas, assim como, três diferentes e abrangentes tamanhos de conceitos para simular tais problemas. De acordo com a dependência das mudanças de conceito para a avaliação do estudo, quatro delas foram estipuladas em cada simulação.

Da mesma forma, com a intenção de representar a realidade, os dois classificadores selecionados são vastamente utilizados na literatura da área. Assim como, os tipos de mudança de conceito experimentados, abruptas e graduais, e os quatro métodos de detecção de mudança de conceito reais escolhidos que mostram as reais representações e possibilidades das propostas

desta tese. Além do método de detecção artificial que abrange demais inferências.

Por fim, para garantir a verificação do exposto, as ferramentas MOA e MOAM foram escolhidas dada a disponibilidade, facilidade e praticidade. Para a avaliação dos resultados, o teste pareado de *Wilcoxon* dominou as análises das simulações pela precisa avaliação entre pares de algoritmos, possibilitando conclusões assertivas.

4 ANÁLISE DO SINAL DE DETECÇÃO WARNING

Conforme explicado na Seção 2, a metodologia de AACD [Gama et al. 2004] é uma abordagem de aprendizado adaptativo com detecção de mudança de conceito que depende diretamente dos sinais de detecção do método detector para minimizar a função erro de classificação. Ela utiliza um único classificador e um detector em sua execução. No entanto, ela também é utilizada em comitês como um classificador básico, apesar de possuir o detector associado. Portanto, é relevante melhorar o entendimento sobre os impactos do seu funcionamento, em especial, do sinal de detecção *Warning* na função erro de classificação, pois, os sinais de detecção de estabilidade e mudança de conceito são largamente explorados na literatura.

A seção está organizado em 6 subseções. A Subseção 4.1 apresenta uma contextualização da metodologia tradicional de AACD, com foco na estratégia de utilização do sinal de detecção *Warning* e no mecanismo de construção e treinamento de um modelo auxiliar. A Subseção 4.2 é dedicada a questionamentos sobre a metodologia de AACD que motivaram o desenvolvimento deste trabalho. A Subseção 4.3 descreve métodos e procedimentos de análise estatística, ou seja, o passo a passo adotado para a avaliação de desempenho dos efeitos dos sinais de detecção *Warning* na acurácia *Prequential*. A Subseção 4.4 apresenta os resultados dos experimentos empíricos com cenários que permitem avaliar os efeitos da detecção dos sinais de *Warning* na acurácia *Prequential*. Em sequência, a Subseção 4.5, traz discussões relevantes sobre os efeitos dos sinais de detecção *Warning*. Por fim, a Subseção 4.6 aponta as considerações finais.

4.1 INTRODUÇÃO

Esta seção visa apresentar uma análise dos efeitos da detecção do sinal de *Warning* na acurácia *Prequential* por meio da estratégia de AACD implementado pela classe DDMC (*Drift-DetectionMethodClassifier*) [Gama et al. 2004, Bifet et al. 2018]. Basicamente, a análise tem como objetivo determinar e discutir os pontos fortes e fracos do sinal de detecção de *Warning*. Estes resultados serão obtidos a partir de evidências empíricas de métodos parametrizados com geradores de conjuntos de dados artificiais, métodos de aprendizado de máquina e método gerador de sinais de detecção *Stable*, *Warning* e *Drift*. A análise dos resultados será útil para melhorar o nível de informações detalhadas para se apoiar na decisão de determinar quando um método (técnica) é superior a outro ou não, sendo relevante, principalmente, para

avaliar de forma mais justa detectores em relação ao rastreamento da detecção de mudança de conceito.

A metodologia tradicional de AACD utilizada para lidar com a classificação em tempo real de qualquer método de AM e detector de mudança de conceito em fluxo de dados precisa calibrar a indução de padrões com os sinais de detecção. Assim sendo, a qualidade e desempenho do modelo produzido pela técnica de AM depende do ajuste da técnica de adaptação do aprendizado que leva em consideração os sinais de detecção para manter o bom desempenho da classificação. Logo, os sinais de detecção induzem a estratégia de AACD, de tal forma, que o modelo possa continuar a ser utilizado para prever resultados de situações futuras ou, então, ser descartado e substituído por um novo modelo que pode iniciar com ou sem treinamento, dependendo dos sinais de detecção que recebeu, como descrito na Subseção 2.4.2.

É possível classificar as estratégias para enfrentar o problema da mudança de conceito em duas categorias: (1) que consideram a mudança de conceito; e (2) que não consideram detecção de mudança de conceito. Na primeira, na qual a estratégia de AACD se encontra, primeiro é detectada a mudança de conceito e, em seguida, o aprendizado é adaptado à mudança. Na segunda, a adaptação do aprendizado ocorre em intervalos regulares sem considerar que ocorreu alguma mudança de conceito.

Alguns comitês são geralmente incluídos na segunda estratégia, pois possuem mecanismos como, por exemplo, o Diversity for Dealing with Drifts (DDD) [Minku e Yao 2012], que elimina classificadores com baixo desempenho e inserir novos classificadores, permitindo sua evolução sem a necessidade de detectar diretamente os pontos de mudança de conceito. Porém, há comitês como, por exemplo, o Boosting-like Online Learning Ensemble (BOLE) Barros, Santos e Gonçalves Jr. 2016 que inserem mecanismos para detecção de mudanças de conceito diretamente nos classificadores básicos do comitê ou para o comitê, sendo assim, estes também são incluídos na segunda estratégia. Uma das vantagens de associar detectores em comitês é aproveitar a capacidade dos comitês de se adaptarem às mudanças graduais e dos detectores para rastrear mudanças abruptas.

4.2 OBJETIVO

Para compreender melhor a motivação desta seção, alguns pontos são descritos como objetivos, analisando:

- Se o sinal de detecção *Warning* melhora a generalização quando há mudança de conceito.
- Se é relevante ter uma pequena quantidade de instâncias, identificadas como sinal de detecção *Warning* para serem treinadas no novo modelo, após uma mudança de conceito.
- Identificar os pontos fortes e fracos do uso do sinal de detecção *Warning* na metodologia de AACD;
- Se o sinal de detecção *Warning* pode confundir a real eficiência de métodos detectores ao rastrear a mudança de conceito nas avaliações de desempenho.

A partir da análise desses pontos, é possível determinar os pontos fortes e fracos do uso do sinal de detecção *Warning* na metodologia de AACD. Sendo assim, foram parametrizados um conjunto de experimentos com objetivo de analisar três variações para cada cenário experimentado. Os cenários contemplam ter ou não ter o sinal de detecção *Warning*, desta forma, deseja-se analisar os efeitos causados pelo sinal de detecção *Warning* na acurácia *Prequential*.

Para auxiliar na criação das variações, foi utilizado o método detector ADDM [Hidalgo, Maciel e Barros 2019]. O algoritmo original do ADDM possui como limitação a necessidade de especificar todos os pontos no qual deve ocorrer a detecção do sinal *Warning*. Sendo assim, foi implementado uma melhoria ao algoritmo original que permite definir faixas de intervalos de sinais de detecção *Warning*. A seguir, na Subseção 4.3, é mostrado em detalhes como foram realizadas as configurações das variações, e procedimentos experimentais e estatísticos para análise dos resultados.

4.3 CONFIGURAÇÃO EXPERIMENTAL E METODOLOGIA

Dado o exposto anteriormente, para realizar a análise do sinal de detecção *Warning* é necessário algumas parametrizações para cada variação de cenário (sem e com sinal de detecção *Warning*). Por variação é possível compreender como a combinação de parametrizações do método detector, nos tamanhos de conjunto de treinamento, e classificador. Entretanto, nas bases de dados artificiais, também é preciso definir o tamanho da base de dados e velocidade da mudança de conceito, assim como as parametrizações específicas para cada gerador de dados.

Para representar as amostras provenientes dos cenários sem e com sinal de detecção *Warning*, foram adotadas as notações μ_1 e μ_2 , respectivamente. A representação das hipóteses

testadas são $H_0: \mu_1 = \mu_2$ (hipótese nula), $H_1: \mu_1 > \mu_2$ (μ_1 é estatisticamente superior a μ_2) e $H_2: \mu_1 < \mu_2$ (μ_1 é estatisticamente inferior a μ_2). O procedimento de análise dos resultados tem interesse especificamente em observar os valores de H_1 e H_2 , pois deseja-se investigar se $\sum H_1 < \sum H_2$, onde o $\sum H_1$ significa a quantidade de vezes que a H_1 foi encontrada e o $\sum H_2$ a quantidade de vezes que a H_2 foi encontrada nas análises.

Os métodos ADDM e DDMC foram utilizado para representar os sinais de detecção e a metodologia de AACD, respectivamente. Sendo assim, foram parametrizadas as localizações onde devem ocorrer os detecções de sinais de *Warning* e as detecções de mudança de conceito. Em vista disso, foi possível controlar com precisão os sinais de detecção *Warning* que se deseja isolar e analisar.

Para uma melhor compreensão, a notação P_{MC} é utilizada para representar o **Ponto da Mudança de Conceito**. No caso dos sinais de detecção *Warning*, responsáveis pelo treinamento do novo modelo, foram consideradas três variações de parametrizações, representadas pela notação w e com tamanhos 8, 21 e 55 (a escolha dos números foi feita de forma baseada na sequência de *Fibonacci* (0, 1, 1, 2, 3, 5, **8**, 13, **21**, 34, **55**, 89, ...), com valores diversos. Por fim, o valor de w é utilizado para determinar o **Ponto de Detecção de Mudança de Conceito**, representado pela notação P_{Det} . Conseqüentemente, nota-se que para cada ponto de mudança de conceito, P_{MC} , haverá três variações de ponto de detecção de mudança de conceito, P_{Det} , equivalente a cada variação de w .

Portanto, o cálculo para determinar este ponto de detecção da mudança de conceito é dado pela adição ao ponto de mudança de conceito mais uma instância em relação a quantidade de instâncias em *Warning* escolhida, como pode ser visto na equação 4.1:

$$P_{Det} = P_{MC} + w + 1 \quad (4.1)$$

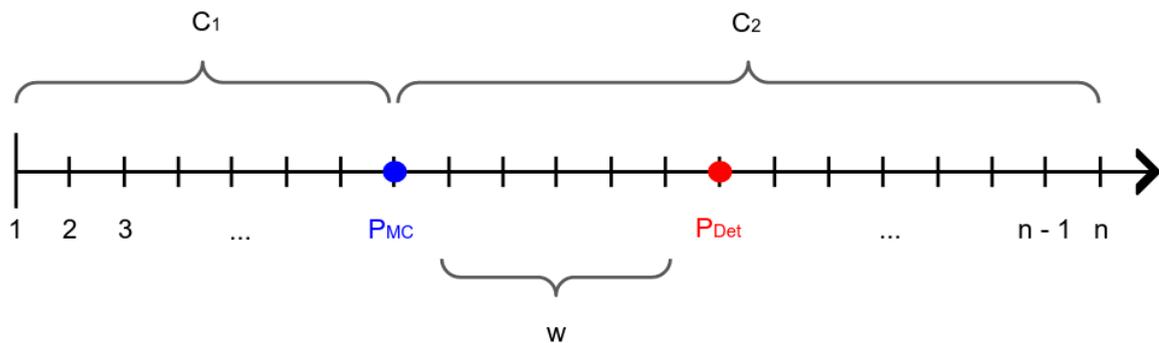
Desta forma, esta abordagem assume que a detecção ocorre, exatamente, depois da quantidade de instâncias em *Warning* w estabelecida, e na prática o novo modelo fica com w instâncias treinadas no conceito atual. Vale salientar, também, que a estratégia de identificação dos pontos de detecção de mudança de conceito para o cenário sem *Warning* é a mesma utilizada para o cenário com *Warning*. A diferença entre os dois cenários se dá somente pelo fato de que as w instâncias, no cenário sem *Warning*, não são utilizadas para treinar do novo modelo.

Seguindo estas configurações e as parametrizações apresentadas na Seção 3, os experi-

mentos desta seção são elaborados. Por fim, especificamente para esta experimentação, houve um pequeno ajuste na implementação do método ADDM, para que as w instâncias fossem manipuladas em um intervalo, e não individualmente. Isto porque, o método tem em suas especificações que serão determinados pontos de mudança de conceito e pontos de detecção de mudança de conceito, não necessitando de intervalos de pontos, o que é ideal no caso das instâncias para conjunto de treinamento.

É possível observar melhor a ideia da simulação dos pontos de mudança e detecção de mudança de conceito, juntamente com as w instâncias em *Warning* estipuladas para treinamento no método ADDM, por meio de um exemplo baseado na Figura 3.

Figura 3 – Representação de uma simulação de como são calculados e configurados os pontos de mudança de conceito em meio a um trecho de fluxo de dados. É associando um ponto de mudança de conceito ao ponto onde, de fato, a mudança de conceito foi detectada, por meio da definição da quantidade de instâncias entre estes pontos, w , onde w representa o próprio conjunto de treinamento do modelo simulado. No exemplo, é considerado o ponto da mudança de conceito, em azul, P_{MC} , a quantidade de instâncias em *Warning* para treinamento w ; e o ponto em vermelho, que representa o ponto de detecção da mudança de conceito, P_{Det} .



Fonte: a autora (2022).

Assim, na Figura 3, é representado um gerador de dados artificiais com n instâncias a serem aprendidas. Nele, é determinado um ponto de mudança de conceito, P_{MC} , em azul. Supondo que o $P_{MC} = 100$ (a mudança de conceito ocorre na instância 100 do fluxo) e considerando que a quantidade de instâncias em *Warning* para treinamento é $w = 5$. Então, dada a equação 4.1, e com as informações já conhecidas, pode-se calcular o ponto de detecção. Logo, o ponto de detecção de mudança de conceito seria $P_{Det} = 100 + 5 + 1 = 106$.

Note que a delimitação dos conceitos é dada pelo ponto de mudança de conceito, tendo o primeiro conceito, C_1 até o P_{MC} , e a partir dele o segundo conceito, C_2 . Portanto, mesmo que o detector ainda não tenha detectado a mudança, o conjunto w de instâncias em *Warning* utilizadas para treinamento, nesta simulação, já faz parte do novo conceito.

$$\begin{cases} w_{início} = P_{MC} + 1 \\ w_{fim} = P_{Det} - 1 \end{cases} \quad (4.2)$$

Portanto, fica claro observar na equação 4.2 que a variação de w está entre o ponto exatamente uma instância após o ponto de mudança de conceito P_{MC} , até uma instância anterior ao ponto de detecção de mudança de conceito P_{Det} .

4.4 RESULTADOS E ANÁLISE: SEM WARNING CONTRA COM WARNING

Esta subseção apresenta e analisa os resultados dos experimentos realizados nos cenários anteriormente descritos. O objetivo é analisar a influência do efeito do sinal de detecção *Warning* para a melhoria da acurácia *Prequential* de modelos reconstruídos. Os experimentos usaram dois classificadores, cinco geradores de dados, duas velocidades para representar mudanças de conceito e três quantidades de sinais de detecção *Warning*.

Desta forma, são apresentadas as análises baseadas nas evidências dos resultados das médias de acurácia *Prequential* observadas pelos testes estatísticos de *Wilcoxon* nas Tabelas 2 e 3.

As Tabelas 2 e 3 apresentam o resumo dos resultados obtidos das hipóteses testadas para HT e NB, respectivamente. Tomando como base os geradores *Agrawal*, LED, MIX, RRBF e *Sine*, os dois tipos de mudanças de conceito, abruptas e graduais, e os três tipos de tamanho de $w = 8, 21$ e 55 para sinalizar as detecções de *Warning*. Na Seção 3 é descrito como, a partir dos valores de H_0 , H_1 e H_2 das tabelas, é realizado esses somatórios. Os valores de referência na análise dos dados são os de μ_1 , cenário sem sinais de *Warning*, portanto H_1 representa suas vitórias e H_2 , suas derrotas. No entanto, na análise das Tabelas 2 e 3, para esta seção, é acrescentada mais três linhas referentes a μ_2 , com o objetivo de gerar os gráficos da Figura 4 e ter uma melhor visualização do resultado como um todo.

Assim, é possível observar que os resultados dos somatórios de $\sum H_2$ são maiores do que $\sum H_1$. Logo, conclui-se que, no geral, as variações de w que receberam as parametrizações para sinalizar detecção de *Warning* obtiveram mais vantagens estatísticas quando comparado as variações de w sem sinalizar detecção de *Warning*.

Baseado nos resultados é possível responder que o sinal de detecção *Warning* contribuiu para melhoria da generalização do modelo. Especificamente, observa-se na Tabela 2, referente ao classificador HT, que as variações com a presença de sinal de detecção *Warning* apresenta-

Tabela 2 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o ADDM com HT.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
ADDMWW008	ADDMW008	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂
ADDMWW021	ADDMW021	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂
ADDMWW055	ADDMW055	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₂	H ₀	H ₀
		Graduais														
ADDMWW008	ADDMW008	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
ADDMWW021	ADDMW021	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
ADDMWW055	ADDMW055	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum \sum H_0$	$\sum \sum H_1$	$\sum \sum H_2$	$\sum \sum H_1 - \sum \sum H_2$	Rank
	ADDMWW008	9	0	6	-6	3	13	0	2	-2	3	22	0	8	-8	3
	ADDMWW021	5	0	10	-10	1	11	0	4	-4	1	16	0	14	-14	1
	ADDMWW055	6	0	9	-9	2	12	0	3	-3	2	18	0	12	-12	2
	ADDMW008	9	6	0	6	4	13	2	0	2	4	22	8	0	8	4
	ADDMW021	5	10	0	10	6	11	4	0	4	6	16	14	0	14	6
	ADDMW055	6	9	0	9	5	12	3	0	3	5	18	12	0	12	5

Fonte: a autora (2022).

ram um somatório de superioridade estatística maior do que sem o sinal de detecção *Warning* em todos os casos avaliados nos dois tipos de mudança de conceito, abrupta e gradual. Especificamente com HT, a $\sum \sum H_1 = 0$, enquanto o $\sum \sum H_2 = 34$, percebendo-se o bom desempenho e uma significativa contribuição com a presença de sinal de detecção *Warning*.

Isto significa que, na comparação apenas de superioridades e inferioridades estatísticas, a variação com sinal de detecção *Warning* (μ_2) foi 100% superior estatisticamente a variação sem sinal de detecção *Warning* (μ_1). Nas mudanças do tipo abruptas e graduais o $\sum H_2 > \sum H_1$ nos três tamanhos testados $ADDMW008 > ADDMWW008$, $ADDMW021 > ADDMWW021$ e $ADDMW055 > ADDMWW055$. Tendo como destaque o tamanho $w = 21$, com $ADDMW021 = 10$ contra $ADDMWW021 = 0$ nas mudanças abruptas, e $ADDMW021 = 4$ contra $ADDMWW021 = 0$ nas mudanças graduais. Assim, a quantidade de instâncias em *Warning*, $w = 21$, teve o maior valor de diferença entre superioridades e inferioridades estatísticas nos dois tipos de mudança. Consequentemente, a variação do ADDM com instâncias

Tabela 3 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o ADDM com NB.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
ADDMWW008	ADDMW008	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀
ADDMWW021	ADDMW021	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂
ADDMWW055	ADDMW055	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂
		Graduais														
ADDMWW008	ADDMW008	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₁	H ₀	H ₀				
ADDMWW021	ADDMW021	H ₀	H ₀	H ₁	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂
ADDMWW055	ADDMW055	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₂	H ₂
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
ADDMWW008		7	0	8	-8	3	10	1	4	-3	3	17	1	12	-11	3
ADDMWW021		3	0	12	-12	2	8	1	6	-5	1	11	1	18	-17	1,5
ADDMWW055		2	0	13	-13	1	9	1	5	-4	2	11	1	18	-17	1,5
ADDMW008		7	8	0	8	4	10	4	1	3	4	17	12	1	11	4
ADDMW021		3	12	0	12	5	8	6	1	5	6	11	18	1	17	5,5
ADDMW055		2	13	0	13	6	9	5	1	4	5	11	18	1	17	5,5

Fonte: a autora (2022).

em *Warning* com tamanho de $w = 21$ foi a melhor colocada do *rank* para HT.

Em relação a análise dos geradores de dados, nota-se que o $\sum H_2$ foi maior que o $\sum H_1$ nas mudanças de tipo abruptas, destacando-se $LED_{(20k,80k,130k)}$ nos tamanhos $w = 8, 21$ e 55 ; $MIX_{(20k,80k,130k)}$ nos tamanhos $w = 21$ e 55 ; $Sine_{(20k,80k,130k)}$ com $w = 8$ e 21 ; e $Sine_{(20k)}$ com $w = 55$. Nas mudanças graduais $\mu_2 > \mu_1$ em $LED_{(20k,80k,130k)}$ nos tamanhos $w = 21$ e 55 e $LED_{(20k)}$ com $w = 21$ e 55 . Nos demais casos prevaleceu empates entre as duas variações.

A Tabela 3 mostra a análise com NB, apresentando um resultado semelhante ao visto com HT, no qual o cenário com sinal de detecção *Warning* tem um somatório de superioridades maior do que no cenário sem sinal de detecção *Warning* em todos os casos. No entanto há um destaque maior para as mudanças abruptas que, assim como, para HT teve 100% das superioridades estatísticas. No total, com NB tem-se $\sum \sum H_1 = 3$ contra $\sum \sum H_2 = 48$.

Mesmo não tendo 100% das superioridades estatísticas nas mudanças graduais, o $\sum H_2 > \sum H_1$ nos três tamanhos avaliados, com $ADDMW008 > ADDMWW008$, $ADDMW021 >$

ADDMWW021 e ADDMW055 > ADDMWW055. Destacando-se novamente a quantidade de instâncias em *Warning* para treinamento $w = 21$, com ADDMW021 = 6 contra ADDMWW021 = 1 nas mudanças graduais, e para $w = 55$ com ADDMW055 = 13 contra ADDMWW055 = 0 nas mudanças abruptas. Assim, a quantidade de instâncias em *Warning*, para $w = 21$ e 55, empataram com o maior valor de diferença entre superioridades e inferioridades estatísticas no geral. Consequentemente, a variação do ADDM com instâncias em *Warning* com tamanho de $w = 21$ e 55 foram as melhores colocadas do *rank* para NB.

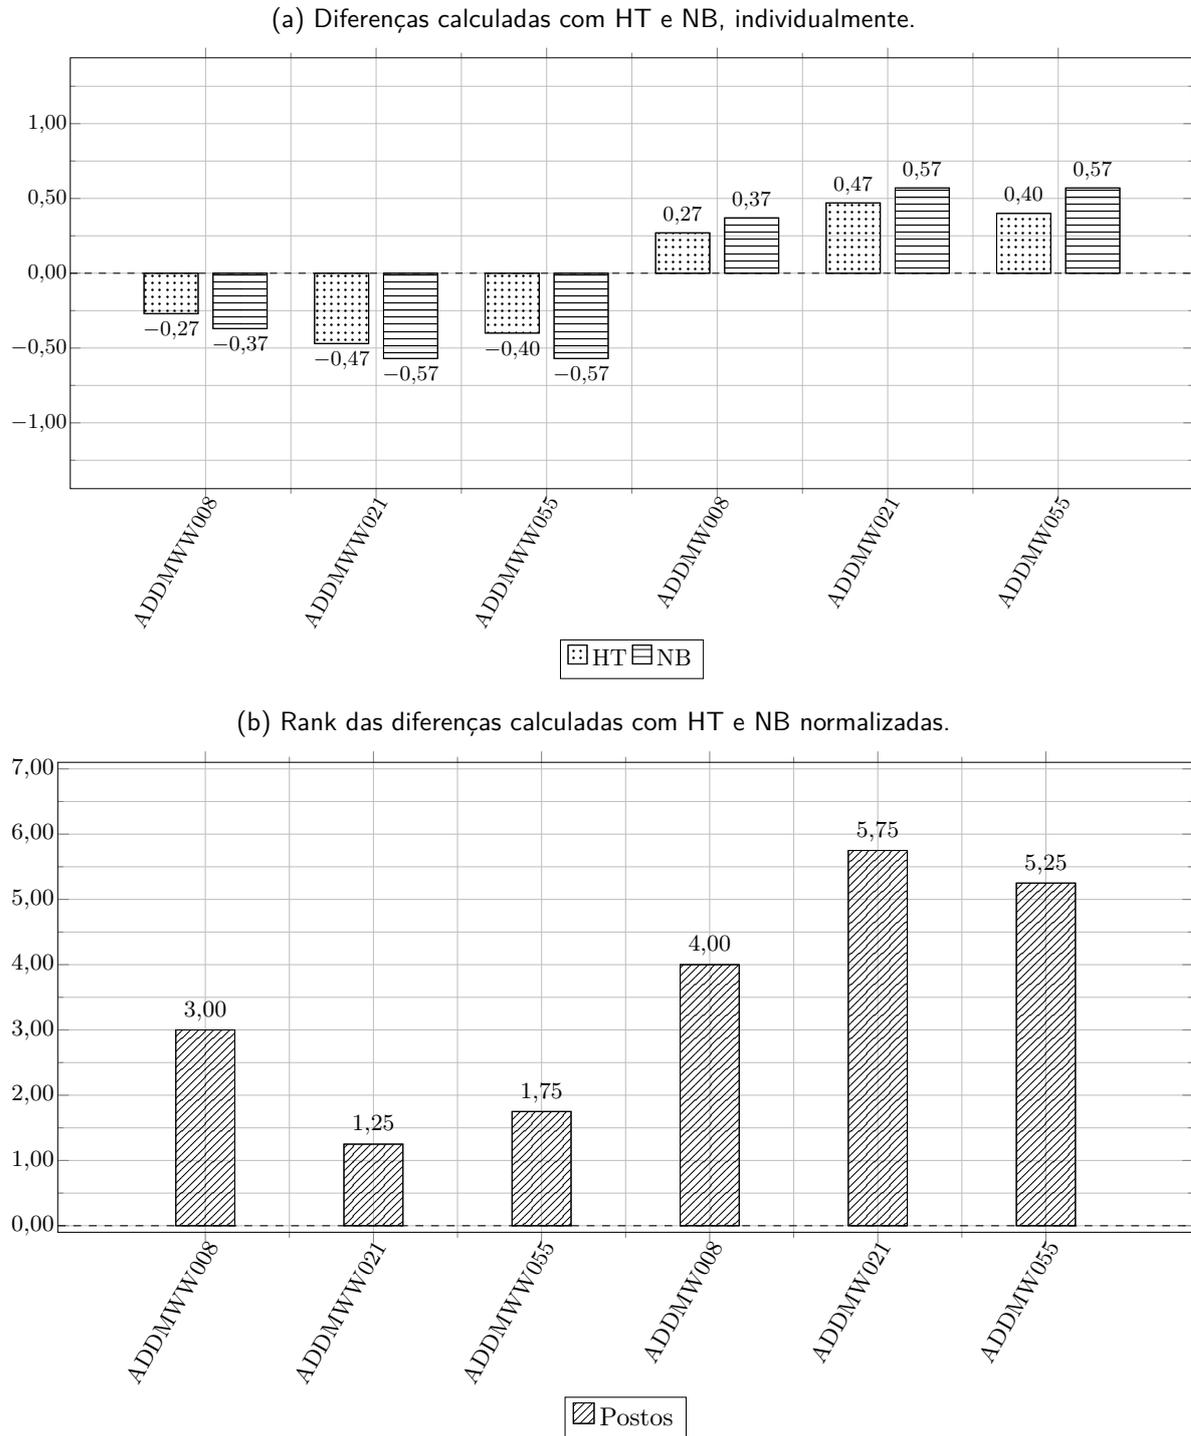
Semelhantemente, para NB a análise dos geradores de bases de dados artificiais, mostrou que o cenário com sinal de detecção *Warning* tem um somatório de superioridades maior do que o cenário sem sinal de detecção *Warning* nas mudanças do tipo abruptas, destacando-se com Agrawal (AGRA)_(20k,80k,130k) nos tamanhos $w = 8, 21$ e 55; para LED_(20k,80k,130k) nos tamanhos $w = 21$ e 55; para MIX_(20k,80k,130k) nos tamanhos $w = 8, 21$ e 55; e para *Sine*_(20k,80k,130k) com $w = 21$, *Sine*_(20k,80k) com $w = 8$ e *Sine*_(20k,130k) com $w = 55$. No caso das mudanças graduais, com LED_(20k,80k,130k) nos tamanhos $w = 8, 21$ e 55; e para *Sine*_(80k,130k) nos tamanhos $w = 21$ e 55.

Em suma, a Figura 4 apresenta dois gráficos. Na Figura 4(a) as comparações entre as diferenças do $\sum \sum H_1$ (cenário das variações do ADDM sem instâncias em *Warning*) e $\sum \sum H_2$ (cenário das variações do ADDM com $w = 8, 21$ e 55 instâncias em *Warning* para treinamento) com HT e NB, individualmente analisadas, para cada uma das variações. Para expressar as variações com e sem sinais de detecção *Warning* foram incorporados os complementos das variações, a mudança na ordem de avaliação das variações gera um espelho do resultado oposto.

No entanto, nota-se que os valores dos resultados não são de fato os mesmos encontrados nas Tabelas 2 e 3, pois estes valores foram normalizados. Como os resultados com a estratégia foram superiores, suas variações aparecem no intervalo entre $[0,1]$, e seu espelho entre $[-1,0]$. Assim, é possível observar que para as variações sem sinais de *Warning* o classificador NB apresentou uma maior degradação, e no cenário com sinais de *Warning* ele teve o melhor desempenho. Dentre as variações avaliadas, o ADDM com $w = 21$ e 55 instâncias em *Warning* para treinamento tiveram os melhores resultados para NB e $w = 21$ para HT, e o ADDM sem instâncias em *Warning* com distância de $w = 21$ e 55 ficaram com os piores resultados.

Na Figura 4(b) é apresentado um *rank* geral dos resultados da média do cálculo dos postos de HT e NB. Portanto, observa-se que, no geral, o melhor cenário foi o com instâncias em *Warning*. Estando no topo a variação de tamanho $w = 21$. Por fim, é discutida na Seção 6

Figura 4 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do ADDM.



Fonte: a autora (2022).

uma comparação geral entre todas as variações do ADDM aqui experimentadas, incluindo a avaliação no ponto ideal ($w = 0$).

4.5 DISCUSSÃO

Dado o exposto anteriormente, é visto nos resultados que as simulações que aplicaram conjuntos de treinamento com instâncias em *Warning* à reconstrução dos novos modelos obtiveram a maior parte das superioridade estatística se comparados àqueles que não receberam este tipo de treinamento com instâncias em *Warning*.

Assim, foi visto que, em relação a acurácia *Prequential* para as variações do ADDM onde há sinal de detecção *Warning*, o modelo alcançou melhores ou igualou os resultados estatisticamente avaliados em relação a variação sem sinal de detecção *Warning*, na maior parte dos casos. Então, o primeiro ponto indagado nos objetivos desta seção, que questiona se o sinal de detecção *Warning* melhora a generalização quando há mudança de conceito, é respondido: *o sinal de detecção Warning melhora, de fato, a generalização quando há mudança de conceito*. Além disso, considera-se que houve uma melhoria nos resultados para ambos os tipos de mudança de conceito e classificadores avaliados.

Embora tenha se observado bons resultados nos dois tipos de mudança de conceito, nas mudanças abruptas as variações com sinal de detecção *Warning* não obtiveram nenhuma derrota estatística para as suas respectivas variações quando não existem sinais de detecção *Warning*. Esse comportamento é mais suscetível de ocorrer nas mudanças abruptas pois não há misturas de conceitos, como acontece em mudanças graduais.

O comportamento analisado nos dados, desta seção, vai de encontro a teoria do aprendizado estatístico [Vapnik 1999], que explica sobre a convergência dos dados de uma mesma distribuição de probabilidade. Neste sentido, cada instância causa uma transição do estado do modelo atual para o próximo estado, fazendo com que o modelo evolua. Nesse exemplo, um estado é uma configuração particular representada pelo modelo. Sendo assim, mesmo uma quantidade pequena de instâncias para treinamento faz com que o estado atual do modelo evolua para um estado diferente.

Desta forma, em relação ao segundo ponto dos objetivos desta seção, que questiona se é relevante ter uma pequena quantidade de instâncias, identificadas como sinal de detecção *Warning* para serem treinadas no novo modelo após uma mudança de conceito, é notado nas análises dos resultados que: *quando há uma mudança de conceito e o modelo precisa ser reconstruído, uma pequena quantidade de treinamento tende a aumentar a taxa de acerto da classificação deste novo modelo, como esperado na teoria do aprendizado estatístico*. Então, quanto maior for o conjunto de treinamento, maior é a probabilidade da predição da

classificação está correta.

Na prática, um classificador com modelo de decisão sem treinamento faz a previsão da classe com base em uma medida proporcional a quantidade de classes que possui para mapear. Por exemplo, um modelo binário sem treinamento inicia-se com 50% de chance de acerto para cada uma das classes. No entanto, se apenas uma instância for utilizada para ser treinada no modelo, a probabilidade de uma delas vai ser maior que a outra. No caso, uma única instância utilizada para treinar o modelo pode modificar esta proporção, aumentando a convergência do modelo. Vale ressaltar, também, que a distribuição de probabilidade entre as classes será afetada, independentemente, se as instâncias utilizadas para treinamento pertencerem ao conceito atual ou não.

Referente ao terceiro objetivo pontuado, que questiona a identificação dos pontos fortes e fracos do uso do sinal de detecção *Warning* na metodologia de AACD, foi observado que: *como pontos fortes, nota-se que a maneira como a abordagem tradicional lida com os sinais de Warning é muito importante para remediar a mudança de conceito. E foi visto que quando é preciso, essa abordagem substitui o modelo principal e o seu treinamento para adaptar-se ao novo conceito. Se tratando dos pontos fracos, observou-se que, essa substituição do modelo não depende, exclusivamente, das instâncias em Warning, pois se não houver instâncias em Warning, ainda sim, esse modelo será substituído por um sem treinamento prévio.*

Outro ponto fraco analisado é pontuado como o quarto ponto levantado nos objetivos, que questiona se o sinal de detecção *Warning* pode confundir a real eficiência de métodos detectores ao rastrear a mudança de conceito nas avaliações de desempenho. A resposta para este ponto é observada por meio das análises apresentadas na Seção 6.

Por fim, com o objetivo de avaliar os efeitos do sinal de detecção *Warning* na acurácia *Prequential*, os experimentos realizados nesta seção, não assumiram como uma suposição, mas sim, como uma premissa que as instâncias sinalizadas em *Warning* pertençam ao novo conceito. O que pode não ser verdade em uma avaliação real. Portanto, foram parametrizadas situações, nas quais, as instâncias detectadas como *Warning* pertençam ao conceito atual. Pois, para lidar com os problemas do mundo real, ainda não há como oferecer garantias teóricas em relação a detecção da mudança de conceito, mas há evidências empíricas de que a detecção de mudança de conceito contribui para melhoria da generalização do modelo quando há mudança de conceito.

4.6 CONSIDERAÇÕES FINAIS

De acordo com o que foi discutido e apresentado nesta seção, constata-se que nos experimentos realizados, a acurácia *Prequential* mostrou, na maioria dos casos, ser estatisticamente superior nos cenários em que existem o sinal de detecção *Warning* para treinamento do novo modelo. De fato, nota-se ser vantajoso utilizar o sinal de detecção *Warning*. No entanto, estas simulações não refletem totalmente a realidade das execuções dos métodos no mundo real. Isto porque, os métodos de detecção não podem garantir que os modelos, reconstruídos no momento de uma detecção de mudança de conceito, recebam treinamento com a metodologia tradicional, AACD.

Entretanto, é possível afirmar que o sinal de detecção *Warning* é essencial para: um melhor entendimento sobre lidar com mudanças de conceito; com seus impactos no aprendizado; e na capacidade dos métodos de detecção de mudança de conceito para detectar as mudanças de conceito; na capacidade dos mecanismos de adaptação do aprendizado em se ajustar quando ocorre a mudança de conceito; e, inclusive, para projetar mecanismos mais eficazes para detectar e responder às mudanças de conceito. Essas afirmações foram fundamentadas com um simples estudo de caso, que fornece percepções significativas que não seriam possíveis sem tal estudo.

Desta maneira, o sinal de detecção *Warning*, também atribuído aos métodos detectores, se mostrou crítico para acelerar a adaptação do aprendizado na presença de mudança de conceito. Entretanto, percebe-se que há uma sobrecarga para os detectores.

A sobrecarga em si é percebida em relação as avaliações de desempenho de métodos detectores que misturam métodos que consideram sinal de detecção *Warning* com métodos que não os consideram. Sendo assim, naturalmente os métodos que não consideram o sinal de detecção *Warning* vão ser prejudicados na avaliação de desempenho da tarefa de rastreamento das corretas mudanças de conceito. Por fim, essas afirmações também são fundamentadas com o estudo de caso, e mais discutidas na Seção 6.

Este estudo de caso mostrou ser promissor em relação a dar atenção ao sinal de detecção *Warning*. Porém, estes resultados devem ser considerados apenas preliminares. Eles mostram apenas o desempenho das variações parametrizadas com um método de detecção de mudança de conceito artificial, em um ambiente controlado. Apesar dos esforços para evidenciar a importância do sinal de detecção *Warning* na abordagem de AACD, nenhuma tentativa foi feita para entender como métodos de comitês de classificadores responderiam a tal forma.

Sendo assim, há claramente muito trabalho a ser feito para desenvolver uma compreensão abrangente de como os diferentes algoritmos podem ser utilizados para remediar a mudança de conceito, no contexto de diferentes tipos de mudança de conceito. Além disso, pode ser interessante ter uma estratégia que se adapta dinamicamente ao contexto dos dados e algoritmo de aprendizado para ajustar a quantidade de treinamento prevista para melhorar a recuperação.

Os resultados deste simples experimento com os dois cenários, com e sem sinal de detecção *Warning*, forneceram evidências convincentes da importância do sinal de detecção *Warning* na metodologia de AACD. No *rank* de avaliação das variações, a maioria das variações com sinais de *Warning* para treinamento do novo modelo ficaram melhores colocadas do que as variações sem sinais de *Warning*. Além disso, também foi possível melhorar a compreensão do sinal de detecção *Warning* e a sua importância para os mecanismos de detecção em auxiliar a remediação da mudança de conceito na tarefa do aprendizado. Inclusive, os resultados ajudam a projetar novos detectores e estratégias para remediar a mudança de conceito, e para o desenvolvimento de uma compreensão teórica do aprendizado em fluxo de dados com mudança de conceito.

5 ESTRATÉGIAS DE CLASSIFICAÇÃO COM DETECÇÃO

Nesta seção são apresentadas duas variações de estratégias adaptativas inspiradas no algoritmo DDMC (*DriftDetectionMethodClassifier*) da metodologia de AACD [Gama et al. 2004, Bifet et al. 2018]. As variações do algoritmo são chamadas de NotWarning (NW) e DynamicWarning (DW). A primeira traz uma metodologia que ignora os sinais de detecção *Warning* e aplica um controle interno para garantir que novos modelos sejam treinados antes de serem testados quando ocorrer uma mudança de conceito. A segunda variação, traz a vantagem do controle interno apresentado anteriormente, mas não ignora os sinais de detecção *Warning* do método detector, flexibilizando o treinamento com uma quantidade variável de instâncias, isso acontece combinando a estratégia do controle interno mencionada anteriormente com os sinais de detecção *Warning*.

Estes novos tipos de abordagens ao sinal de detecção *Warning* salientam um dos pontos centrais desta tese, que é garantir o treinamento para novos modelos quando ocorrer uma mudança de conceito. Resultados empíricos com base nas análises estatísticas, demonstraram que os métodos NW e DW são competitivos em relação ao tradicional DDMC. Vale ressaltar que, na maioria dos resultados, os métodos NW e DW apresentaram evidências de superioridades estatísticas em relação a variação tradicional DDMC.

A seção está organizado em 6 subseções. A Subseção 5.1 apresenta algumas considerações sobre o método DDMC, com foco nas limitações, efeitos do sinal de detecção *Warning* e implicações em utilizar o método em avaliações de desempenho de métodos de detecção de mudança de conceito. A Subseção 5.2 é dedicada a questionamentos sobre melhorias ao método DDMC que motivaram o desenvolvimento deste trabalho. A Subseção 5.3 apresenta o método NW e os resultados dos experimentos empíricos de uma avaliação de desempenho contra o método DDMC. A Subseção 5.4 apresenta o método DW e, também, os resultados dos experimentos empíricos de uma avaliação de desempenho contra o método DDMC. Em sequência, a Subseção 5.5, discute os resultados dos experimentos empíricos das duas abordagens. Por fim, são apontadas as considerações finais na Subseção 5.6.

5.1 INTRODUÇÃO

Os métodos de AM são guiados por dados, no sentido de que o sucesso da tarefa de aprendizado depende do objetivo e quantidade de dados disponíveis. Com a crescente popularidade da inteligência artificial, impulsionada por empresas que se destacam ao aplicar mineração de dados para lidar com seus problemas, surgem novas fontes de dados sobre, por exemplo, perfis de compra na Internet, comportamento e análise de fraude de grandes volumes de dados. Isso muitas vezes acontece porque, frequentemente, empresas coletam dados de várias maneiras e diariamente. Além disso, alguns desses dados são analisados automaticamente, logo em seguida ao chegarem, para uma tomada de decisão em tempo real. Devido a esses fatores, o campo do AM tem se desenvolvido e fomentado meios para analisar diferentes tipos e quantidades de dados para resumi-los de forma inteligente, produzindo informações valiosas que são utilizadas para alavancar o faturamento das empresas.

A oportunidade de obter informações continuamente é formidável, mas traz responsabilidades. A chegada contínua de dados é um desafio quando se trata de tomar decisões em tempo real, pois, exige o processamento de novos exemplos de dados imediatamente após a sua chegada. Esses novos exemplos podem sofrer evoluções no padrão de classificação que alterem a distribuição de probabilidade do conceito aprendido. Assim, os métodos utilizados para aprender a partir da chegada contínua de dados, precisam ser capazes de lidar com a mudança de conceito e remedia-la de alguma maneira.

A não-estacionariedade, característica inerente aos problemas de fluxo de dados (chegada contínua de dados), exige no AM alguma estratégia para remediar a mudança de conceito. Na literatura são conhecidas algumas abordagens de comitês, como por exemplo DDD [Minku e Yao 2012] e BOLE [Barros, Santos e Gonçalves Jr. 2016], o primeiro lida com um comitê de classificadores e não utiliza método detector, já o segundo manipula um comitê de classificadores com detector, respectivamente. Nesta tese, há um especial interesse pelo algoritmo DDMC, que utiliza um classificador básico e sinais de detecção de um método de detecção de mudança de conceito para adaptar o modelo a nova condição do fluxo de dados.

O DDMC tem sua abordagem de adaptação de acordo com sinais de detecção. Sendo assim, esses sinais são responsáveis por guiar a estratégia de adaptação e, devido à essas reações, efeitos são causados por eles. Para melhor entender esses efeitos, a Seção 4, apresentou um estudo de caso no qual mostra que o sinal de detecção *Warning* quando omitido é responsável por uma perda na eficiência do modelo em remediar a mudança de conceito.

A ação tomada pelo DDMC ao sinal de detecção *Warning* é muito importante para remediar a mudança de conceito. Essa afirmação é fundamentada com o estudo de caso apresentado na Seção 4. Embora a reação seja com base na ação do sinal de detecção *Warning*, o resultado obtido com a reação não depende do sinal de detecção *Warning* para acontecer. Em outras palavras, este resultado é, literalmente, o “treinamento ao novo modelo que substituirá o modelo atual”, quando ocorrer uma mudança de conceito. Porém, a substituição do modelo não depende do sinal de detecção *Warning*. Apesar disso, este treinamento ao novo modelo, na abordagem de AACD, só ocorre se houver sinais de detecção *Warning* e, isso é entendido neste trabalho, como um ponto de melhoria ao algoritmo DDMC.

Em vista disso, o sinal de detecção *Warning*, também, pode causar implicações em avaliações de desempenho de métodos detectores. Na literatura de mudança de conceito, especificamente nos trabalhos de detectores, é comum avaliar o desempenho dos métodos de detecção com base em análises da acurácia *Prequential*. Sendo assim, a eficiência dos detectores em rastrear a mudança de conceito pode ser injustamente desqualificada, por motivos como o método não emitir sinal de detecção *Warning* ou não ser bom na tarefa de detectar sinais de *Warning*.

Assim, na Subseção 5.2 são apresentados alguns pontos que motivaram o desenvolvimento desta seção.

5.2 MOTIVAÇÃO

A motivação para este trabalho surgiu da necessidade de investigar algumas oportunidades de trabalhos identificadas ao analisar o método DDMC. Além disso, também do interesse de criar uma abordagem de fácil aplicação para auxiliar as pesquisas que embasam técnicas de detecção de mudança de conceito, cujo interesse é (entre outras coisas) verificar se a estratégia de rastreamento da mudança de conceito é um fator determinante para sua competitividade. Em várias pesquisas de autores da literatura da área, foram apresentados resultados da métrica de acurácia *Prequential* nas avaliações de desempenho para determinar a eficiência de métodos, reunindo os métodos mais competitivos e outros menos competitivos.

Nestes trabalhos, não foram avaliados separadamente métodos detectores com e sem sinais de detecção *Warning*, podendo-se levar a conclusões equivocadas em relação a eficiência do rastreamento da mudança de conceito. Inclusive, frequentemente, a eficiência de detectores é avaliada em relação a capacidade deles de melhorar a métrica de acurácia *Prequential* ao

invés de métricas para avaliar sua capacidade em rastrear corretamente os locais de mudança de conceito.

Na Seção 4, foi apresentando um estudo de caso mostrando evidências empíricas e garantias teóricas sobre os efeitos do sinal de detecção *Warning*. Apesar de apresentar resultados empíricos com poucos cenários, as considerações sobre as garantias teóricas da generalização e convergência do modelo, permite concluir que, adicionar novos cenários aos experimentos pouco acrescentaria em termos de contribuições e análise de resultados. Portanto, foi observado que o efeito do sinal de detecção *Warning* na adaptação do aprendizado é essencial para remediar uma mudança de conceito e proporcionar a aceleração da recuperação do desempenho da classificação.

Especificamente alguns pontos motivam esta seção:

- Lidar com o efeito dos sinais de detecção *Warning* de uma maneira que seja possível ignorar ou padronizar a quantidade de instâncias que serão utilizadas para treinamento, em caso de mudança de conceito. É visado promover resultados mais justos em avaliações de desempenho de métodos detectores, objetivando focar a análise da acurácia *Prequential* com base no rastreamento da mudança de conceito.
- Proposta de variação da metodologia de AACD que possa superar pontos de melhorias apontados do método DDMC (os aspectos do aprendizado) e que apresente uma acurácia *Prequential* competitiva em relação ao DDMC.

5.3 NOTWARNING: ADAPTAÇÃO SEM SINAL WARNING

Até o momento, é sabido que a maior parte dos detectores entram no escopo do processamento de três sinais de detecção para influenciar na adaptação do modelo. Esses detectores acabam lidando com a identificação do sinal *Warning* e estimativa do modelo, separadamente, e, portanto, as soluções nem sempre são satisfatórias, especialmente, na presença de mudanças de conceito do tipo abrupta.

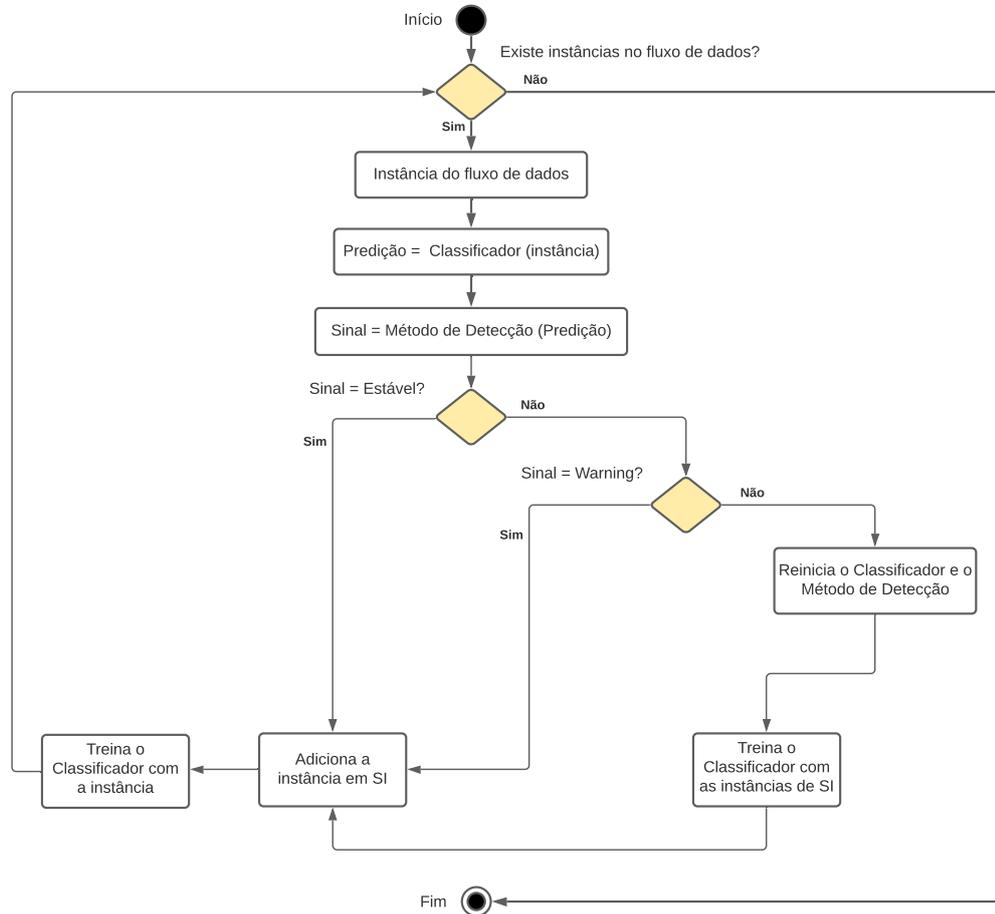
Dentro do escopo de classificação com detecção, é proposto nesta seção, melhorias (como para o acúmulo de responsabilidades dos detectores) para alguns pontos da abordagem tradicionalmente utilizada para adaptação dos modelos de decisão. A primeira dinâmica proposta, o NW, tem como principal característica o fato dos sinais de *Warning* dos detectores serem ignorados. No entanto, o funcionamento do NW não modifica a implementação dos detecto-

res. Os sinais de detecção continuam a ser emitidos pelo detector, e a dinâmica só lida com cada uma de suas respostas de forma diferente da conhecida no AACD.

Entretanto, não se descarta a aplicação do treinamento do novo modelo quando há uma mudança de conceito, ou seja, o novo modelo é treinado, porém, esse treinamento não depende dos sinais de detecção de *Warning*, e não é mais responsabilidade do detector a indicação de instâncias em *Warning* para serem utilizadas na adaptação do modelo. Então, ao invés de utilizar as instâncias em *Warning*, a estratégia proposta implementa uma janela deslizante que garante instâncias para treinamento do novo modelo quando houver uma mudança de conceito. Esta janela armazena as últimas w instâncias do fluxo de dados, onde w , por enquanto, pode ser entendido como um número qualquer. Diferentemente da abordagem tradicional, que não pode garantir que haverá instâncias em *Warning* em seu modelo.

Um outro ponto de melhoria da abordagem tradicional também tratada pelo NW é que quando disparado um sinal de *Warning*, um modelo adicional é criado e treinado (enquanto houver, consecutivas, instâncias em *Warning*), com observado na Figura 2 da Seção 2.4.2. Caso o detector acione um sinal de estabilidade após a criação e treinamento deste modelo adicional, o mesmo é descartado, tendo assim, um custo computacional desnecessário, pois o modelo criado não foi utilizado para substituir o modelo principal. Além disso, após esse descarte, se for identificado um sinal de mudança de conceito, o novo modelo não terá instâncias para treinamento, assim, tendo que recomeçar o aprendizado do zero. O mesmo acontece caso não haja, em nenhum momento, a indicação de sinais de *Warning* e uma mudança de conceito seja detectada.

Figura 5 – Fluxograma da Estratégia de Abordagem Adaptativa NotWarning, indicando desde o momento em que é verificado a existência de instâncias no fluxo de dados, até a identificação do estado de detecção pelo detector. A princípio, seguindo a estrutura da abordagem AACD, porém, agindo de maneira diferente a cada estado detectado.



Fonte: a autora (2022).

Por isso, o NW garante, além das instâncias em *Warning* para treinamento, também, que um novo modelo será treinado apenas quando ocorrer uma mudança de conceito, configurando o meio para se ter somente um modelo de decisão por vez. Desta maneira, no momento em que houver uma detecção de mudança de conceito, o modelo atual é reiniciado e o aprendizado se iniciará com o treinamento das w instâncias armazenadas na janela deslizante. A representação do NW é ser vista na Figura 5, onde seu fluxograma apresenta alguns pontos semelhantes ao DDMC, porém ficando evidente os pontos divergentes se comparado a Figura 2.

Assim, a implementação do NW, no Algoritmo 2, mostra que as instâncias são recebidas do fluxo de dados e classificadas, então, posteriormente, são avaliadas as respostas da classificação pelo detector, como pode ser visto nas linhas 3, 4 e 5, respectivamente, de maneira semelhante ao que acontece no DDMC. De qualquer maneira, independentemente do sinal

detectado, a instância atual será armazenada na janela deslizante "armazenInstancia", na linha 15 e treinada na linha 16. No entanto, se for detectado um *Drift*, o estado do detector e o classificador são reiniciados, nas linhas 7 e 8, respectivamente, e na linha 10 são treinadas as instâncias armazenadas na janela deslizante "armazenInstancia", caso haja instâncias a serem treinadas. Na linha 11 o modelo aprende a instância atual. Porém, se for identificado um sinal de *Stable* ou *Warning*, a ação do algoritmo é somente verificar se a posição atual da janela é a última, pois caso seja, ela vai apontar para a primeira posição, observado nas linhas 13 e 14.

Algoritmo 2: Pseudo-código do NotWarning apresentando uma nova dinâmica de treinamento sem considerar os sinais de warning do detector.

```

Input: fluxo, minTreinamento
1 classificador.reset()
2 detector.reset()
3 for (instancia in fluxo) do
4   predição {acerto,erro} ← classificador.testarInstancia(instancia)
5   estado {stable,warning,drift} ← detector.analisar(predição)
6   if estado = drift then
7     detector.reset()
8     classificador.reset()
9     for sI em armazenInstancia do
10      classificador.treina(sI)
11    classificador.treina(instancia)
12  else
13    if armazenInstancia.length ≥ minTreinamento then
14      armazenInstancia.shift()
15  armazenInstancia.push(instancia)
16  classificador.treina(instancia)

```

Fonte: a autora (2022).

Em suma, métodos de detecção de mudança de conceito são reativos as mudanças de conceito. Portanto, a detecção da mudança de conceito se dá algumas instâncias após a mudança do conceito, de fato, acontecer. Então, dependendo da quantidade, w , representada pela quantidade de instâncias na janela deslizante, o NW considera que as instâncias utilizadas para treinamento, nos casos de mudanças do tipo abruptas, tendem a ser somente do novo conceito e o aprendizado vai ser mais assertivo.

5.3.1 Resultados e Análise: NotWarning contra Tradicional

Esta subsecção fornece o resultado do desempenho da dinâmica NW comparada a abordagem tradicional DDMC com as configurações de geradores de bases de dados artificiais apresentados na Seção 3 de metodologia. Neste momento, é apresentada uma avaliação estatística baseada no teste pareado de Wilcoxon, analisando os resultados dos dados de acurácia *Prequential*.

Assim como na Seção 4, aqui são assumidos dois cenários para a avaliação estatística e os tamanhos utilizados para a janela deslizante de treino no NW são $w = 0, 8, 21$ e 55 . O tamanho zero assume a comparação entre o método tradicional e a sua variação na ausência de instâncias em sinal de detecção *Warning* para treinamento do modelo. Portanto, esta avaliação é realizada para se ter um referencial do comportamento do método sem o conjunto de treinamento para modelos reconstruídos, não sendo este tamanho, diretamente, levado em consideração para avaliar o desempenho do NW.

Nesta seção, considera-se μ_1 como sendo a estratégia proposta NW e μ_2 a abordagem tradicional DDMC. Então, entende-se que $\sum H_1$ representa a soma das vitórias estatísticas do NW em relação ao DDMC, e $\sum H_2$ a soma das vitórias estatísticas do DDMC em relação ao NW. Detalhes sobre o entendimento da avaliação estatística são descritos na Subsecção 3.1.4 da Seção de metodologia. A análise dos resultados das tabelas, desta subsecção, vão levar como referência os valores somente de μ_1 , da estratégia NW. Pois a partir deles, serão montados os gráficos representando cada um dos métodos, para avaliação das melhores variações executadas, separadamente.

Vale salientar que, nas análises são feitas comparações dos casos individuais e baseada na diferença entre $\sum H_1$ e $\sum H_2$, para representar da melhor forma os melhores desempenhos entre os métodos e as variações do NW. Ainda podendo ser avaliado a $\sum \sum H_1$ ou $\sum \sum H_2$ para uma visão geral do cenário.

As Tabelas 4, 5, 6, 7, 8, 9, 10 e 11 apresentam os resultados da métrica de acurácia dos testes de hipóteses estatísticas para cada um dos tamanhos de w , com os classificadores HT e NB, e os detectores DDM, FHDDM, RDDM e USDD, nas mudanças de conceito abruptas e graduais. De certa forma, a análise inferida dos dados não tem como objetivo comparar os quatro métodos de detecção avaliados entre si, indicando qual deles é melhor ou não. No entanto, na Seção 6 uma avaliação neste sentido é realizada. Então, a atenção, nesta seção, é dada ao quanto a dinâmica NW consegue melhorar a acurácia *Prequential* com os métodos

e variações selecionados se comparada a contribuição que é dada pela abordagem tradicional.

Portanto, observa-se que para o FHDDM e o DDM, com NB, nas mudanças de conceito dos tipos abruptas, graduais e no geral, o NW proporcionou as melhores contribuições para a acurácia *Prequential*. Nos tamanhos avaliados de $w = 8, 21$ e 55 , o NW teve a $\sum H_1 > \sum H_2$ nos dois tipos de mudanças, assim como, no geral $\sum \sum H_1 > \sum \sum H_2$.

Particularmente, é visto que para o FHDDM e o DDM com HT, o NW também proporcionou uma contribuição significativa. Obtendo na maioria dos casos $\sum H_2 > \sum H_1$. No caso do DDM se destacando as mudanças graduais e o geral. E, para o FHDDM, alguns tamanhos específicos de w . Assim como, para o USDD, com HT e NB, que se sobressaiu em uma das variações.

Porém, houve pouca contribuição do NW para o método RDDM. A dinâmica proposta para melhoria da acurácia *Prequential* não contribuiu para NB nos tamanhos de w e tipos de mudança de conceitos avaliados. Entretanto para HT, uma das variações se equivaleu nos dois tipos de mudança e no geral.

Em relação a análise dos métodos tradicionais versus sua variação sem sinais de detecção *Warning*, no caso, o $w = 0$, para os dois classificadores avaliados e os dois tipos de mudança e conceito, observou-se que o DDM foi o único método que apresentou melhor desempenho com sua versão sem os sinais de *Warning*. Já como o FHDDM, há empate sem vitórias/derrotas para nenhum cenário, isso porque, o método FHDDM não possui o sinais de detecção *Warning*, portanto, o método tradicional que não tem sinais de *Warning* e a avaliação sem sinais de *Warning* teriam que, realmente, apresentar desempenho semelhante. No caso do RDDM e do USDD, ambos apresentaram melhor desempenho em sua versão tradicional corroborando com a avaliação da Seção 4.

5.3.1.1 $DDM_{NotWarning} \times DDM_{DDMC}$

Nas avaliações do DDM, com HT, na Tabela 4, os $\sum \sum H_1$ foram superiores os $\sum \sum H_2$ para $w = 8, 21$ e 55 . Nos casos das avaliações nas mudanças abruptas o DDM021NW empatou com o DDM na versão tradicional (DDM001TRAD) com $\sum H_1 = \sum H_2 = 2$ e o DDM055NW perdeu com $\sum H_1 = 0$ e $\sum H_2 = 1$. No entanto, a quantidade de vitórias nas mudanças graduais superaram estes casos, totalizando para DDM008NW o $\sum \sum H_1 = 7$ e para DDM021NW o $\sum \sum H_1 = 5$ contra DDM001TRAD com o $\sum \sum H_2 = 4$ nos dois casos; e para DDM055NW o $\sum \sum H_1 = 2$ contra DDM001TRAD com o $\sum \sum H_2 = 1$.

Tabela 4 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o DDM com HT na abordagem NotWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
DDMN _o W	DDM001TRAD	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀
DDM008NW	DDM001TRAD	H ₁	H ₀	H ₀	H ₂	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₂	H ₀	H ₁	H ₀	H ₀
DDM021NW	DDM001TRAD	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₂	H ₁	H ₀	H ₀
DDM055NW	DDM001TRAD	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀				
		Graduais														
DDMN _o W	DDM001TRAD	H ₁	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀
DDM008NW	DDM001TRAD	H ₁	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀
DDM021NW	DDM001TRAD	H ₀	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀
DDM055NW	DDM001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₀				
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
	DDMN _o W	12	2	1	1	3,5	9	4	2	2	3	21	6	3	3	3,5
	DDM008NW	10	3	2	1	3,5	9	4	2	2	3	19	7	4	3	3,5
	DDM021NW	11	2	2	0	2	10	3	2	1	1	21	5	4	1	1,5
	DDM055NW	14	0	1	-1	1	13	2	0	2	3	27	2	1	1	1,5

Fonte: a autora (2022).

A maior contribuição do NW em termos de quantidades de vitórias totais, foi para o DDM. Dentre as parametrizações avaliadas, com NB, visto na Tabela 5, nas mudanças graduais e abruptas o NW teve para DDM008NW e DDM021NW um $\sum \sum H_1 = 19$; e para e DDM055NW o $\sum \sum H_1 = 17$ enquanto o $\sum \sum H_2 = 0$ para $w = 8, 21$ e 55 , tendo assim, o $\sum \sum H_1 > \sum \sum H_2$. Destaca-se, então, a ausência de superioridades estatísticas do DDM, com NB, aplicados à abordagem tradicional nos dois tipos de mudanças de conceito para os tamanhos de $w = 8, 21$ e 55 .

Por fim, nota-se que o DDM, com NB, aplicado ao NW teve um excelente desempenho com 100% das superioridades estatísticas com os geradores de dados artificiais *Sine* e *MIX* nas mudanças abruptas e graduais, respectivamente, para $w = 8, 21$ e 55 . Assim como, obteve a maioria das superioridades estatísticas nos resultados em *LED* e *Agrawal* nas mudanças abrupta; e *RRBF* e *LED* nas mudanças graduais. Com HT, a maioria das superioridades

Tabela 5 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o DDM com NB na abordagem NotWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
DDMNoW	DDM001TRAD	H ₀	H ₁	H ₁	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁
DDM008NW	DDM001TRAD	H ₀	H ₁	H ₁	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁
DDM021NW	DDM001TRAD	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁
DDM055NW	DDM001TRAD	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁
		Graduais														
DDMNoW	DDM001TRAD	H ₀	H ₁	H ₁	H ₂	H ₁	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀				
DDM008NW	DDM001TRAD	H ₀	H ₁	H ₁	H ₀	H ₁	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀				
DDM021NW	DDM001TRAD	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀				
DDM055NW	DDM001TRAD	H ₀	H ₁	H ₀	H ₀	H ₁	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀				
		Totais														
		Abruptas				Graduais				Geral						
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
	DDMNoW	6	9	0	9	3	4	10	1	9	1,5	10	19	1	18	2
	DDM008NW	6	9	0	9	3	5	10	0	10	3,5	11	19	0	19	3,5
	DDM021NW	6	9	0	9	3	5	10	0	10	3,5	11	19	0	19	3,5
	DDM055NW	7	8	0	8	1	6	9	0	9	1,5	13	17	0	17	1

Fonte: a autora (2022).

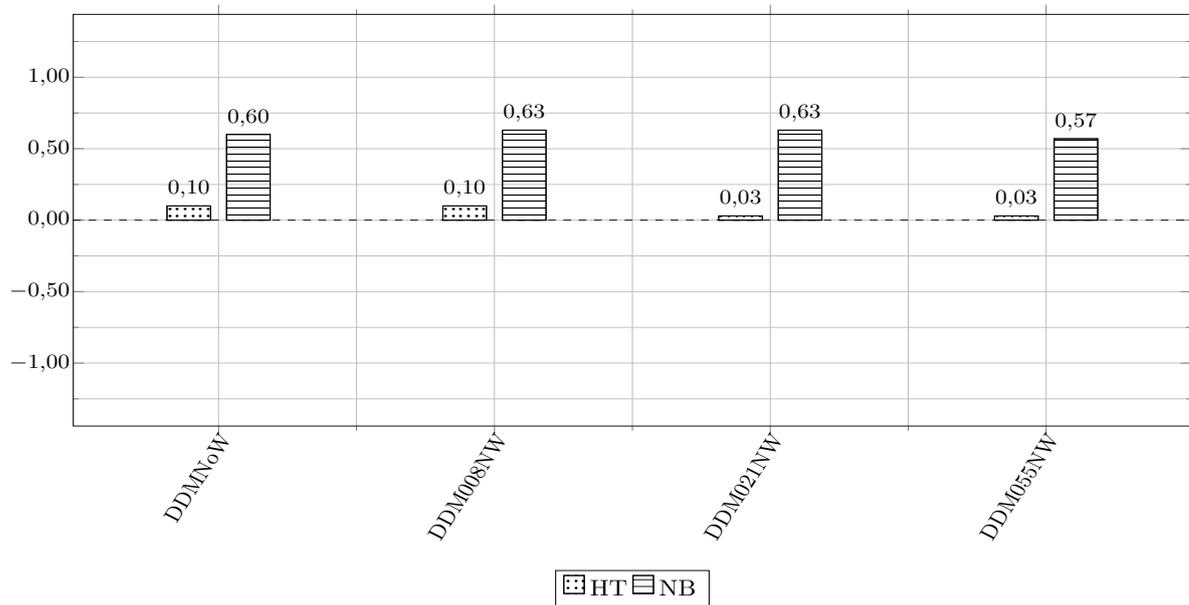
estatísticas foi para MIX nas mudanças graduais.

A Figura 6 apresenta dois gráficos referentes ao DDM aplicado ao NW, com o objetivo de mostrar a análise de desempenho entre as variações analisadas. Na Figura 6(a) são exibidas as comparações entre as diferenças do $\sum \sum H_1$ (cenário do DDM aplicado ao NW com tamanhos de $w = 0, 8, 21$ e 55 instâncias em *Warning*) e $\sum \sum H_2$ (resultados da versão tradicional do método DDM) com HT e NB, individualmente analisadas, em um gráfico de barras.

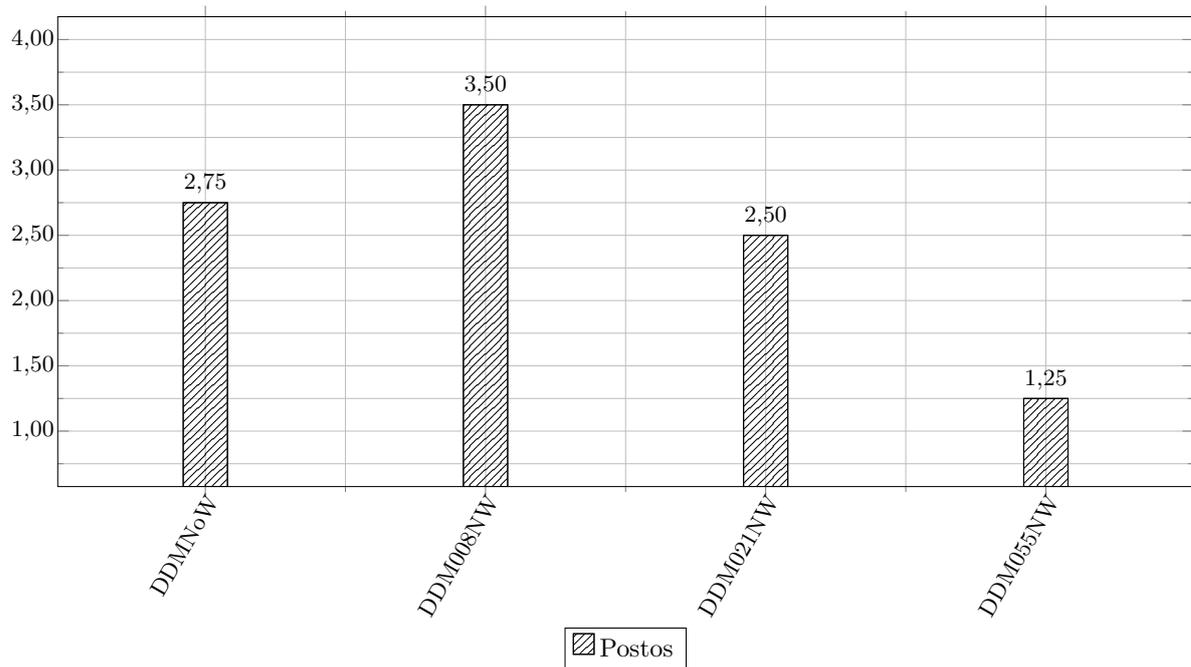
No entanto, nota-se que os valores dos resultados não são de fato os mesmos encontrados nas Tabelas 4 e 5, pois estes valores foram normalizados. Os dados são exibidos no intervalo entre $[0,1]$, indicando que a estratégia NW foi superior a tradicional, no geral. Assim, também, é possível observar que o classificador NB apresentou um melhor desempenho para o DDM aplicado ao NW. Dentre as variações avaliadas, o DDM, com NB, nos tamanhos de $w = 8$ e 21 instâncias em *Warning* para treinamento tiveram os melhores resultados e, com HT, foram

Figura 6 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do NotWarning com o DDM.

(a) Diferenças calculadas com HT e NB, individualmente.



(b) Rank das diferenças calculadas com HT e NB normalizadas.



Fonte: a autora (2022).

as variações com $w = 0$ e 8.

Na Figura 6(b) é apresentado um *rank* geral dos resultados da média do cálculo dos postos de HT e NB para o DDM aplicado ao NW. Portanto, observa-se que no *rank* geral, a melhor variação foi o DDM com $w = 8$ e a pior foi $w = 55$. Mas, vale salientar que, a variação $w = 55$ obteve resultados melhores quando comparado a abordagem tradicional.

5.3.1.2 FHDDM_{NotWarning} × FHDDM_{DDMC}

A contribuição do NW para o FHDDM, com HT, foi bem significativa. Tendo o método um $\sum \sum H_1 > \sum \sum H_2$ para $w = 8$ e 21. Na Tabela 6 é observado que para FHDDM008NW o $\sum \sum H_1 = 10$ e para FHDDM021NW o $\sum \sum H_1 = 8$ contra o FHDDM001TRAD com $\sum \sum H_2 = 0$; no entanto para FHDDM055NW o $\sum \sum H_1 = 6$ contra o FHDDM001TRAD com $\sum \sum H_2 = 11$, configurando um melhor resultado para a abordagem tradicional neste tamanho de w para os dois tipos de mudança de conceito.

Tabela 6 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o FHDDM com HT na abordagem NotWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
FHDDMNoW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
FHDDM008NW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀
FHDDM021NW	FHDDM001TRAD	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
FHDDM055NW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂
		Graduais														
FHDDMNoW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
FHDDM008NW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
FHDDM021NW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀
FHDDM055NW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₀	H ₂
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
FHDDMNoW		15	0	0	0	2	15	0	0	0	2	30	0	0	0	2
FHDDM008NW		8	7	0	7	4	12	3	0	3	3	20	10	0	10	4
FHDDM021NW		11	4	0	4	3	11	4	0	4	4	22	8	0	8	3
FHDDM055NW		6	3	6	-3	1	7	3	5	-2	1	13	6	11	-5	1

Fonte: a autora (2022).

O FHDDM, com NB, assim como o DDM, foram os métodos que mais melhoraram os valores de acurácia *Prequential* referentes as quantidades de superioridades estatísticas dos métodos avaliados. A Tabela 7 mostra que, o FHDDM aplicado ao NW tem uma quantidade de superioridades estatísticas tanto para as mudanças graduais quanto abruptas maior que com o DDMC para $w = 8, 21$ e 55. Para FHDDM008NW o $\sum \sum H_1 = 11$ e para FHDDM021NW

Tabela 7 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o FHDDM com NB na abordagem NotWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
FHDDMN _o W	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
FHDDM008NW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁
FHDDM021NW	FHDDM001TRAD	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁
FHDDM055NW	FHDDM001TRAD	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁
		Graduais														
FHDDMN _o W	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
FHDDM008NW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₀	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀
FHDDM021NW	FHDDM001TRAD	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁
FHDDM055NW	FHDDM001TRAD	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₁	H ₁
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
FHDDMN _o W		15	0	0	0	1	15	0	0	0	1	30	0	0	0	1
FHDDM008NW		8	7	0	7	4	11	4	0	4	3	19	11	0	11	3
FHDDM021NW		9	6	0	6	3	9	6	0	6	4	18	12	0	12	4
FHDDM055NW		5	7	3	4	2	4	7	4	3	2	9	14	7	7	2

Fonte: a autora (2022).

o $\sum \sum H_1 = 12$ contra o FHDDM001TRAD com $\sum \sum H_2 = 0$; e para FHDDM055NW o $\sum \sum H_1 = 14$ enquanto FHDDM001TRAD teve $\sum \sum H_2 = 7$.

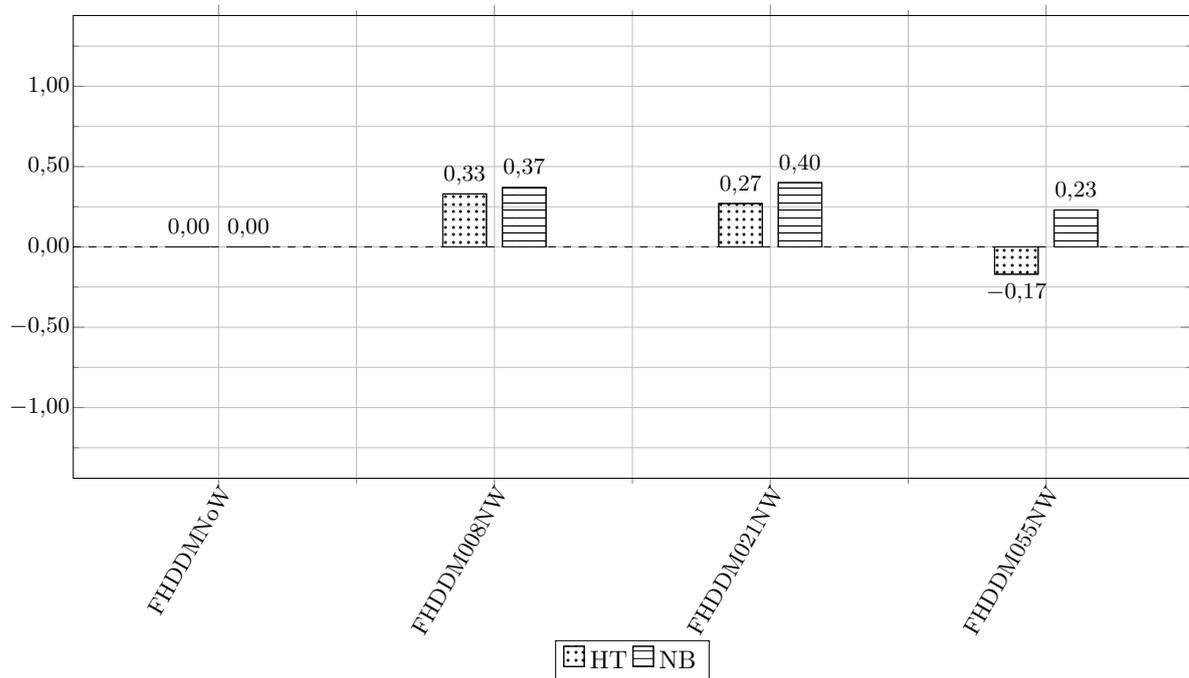
Logo, nota-se que se sobressai a ausência de superioridades estatísticas do FHDDM com a abordagem tradicional, para os dois classificadores avaliados, nos dois tipos de mudanças de conceito para os tamanhos $w = 8$ e 21.

Enfim, se tratando da avaliação das bases de dados, o FHDDM, com NB, aplicado ao NW teve um bom desempenho tendo a maioria das superioridades estatísticas para LED e Sine nos dois tipo de mudança de conceito com $w = 8, 21$ e 55; para $Agrawal_{Abrupta;(w=55);(80k,130k)}$; $Agrawal_{Gradual;(w=55);(80k,130k)}$; e para $MIX_{Abrupta;(w=8);(20k,80k,130k)}$. No caso do HT, o FHDDM teve um excelente desempenho conquistando 100% das superioridades estatísticas com a base LED nas mudanças abruptas e graduais para $w = 8, 21$ e 55.

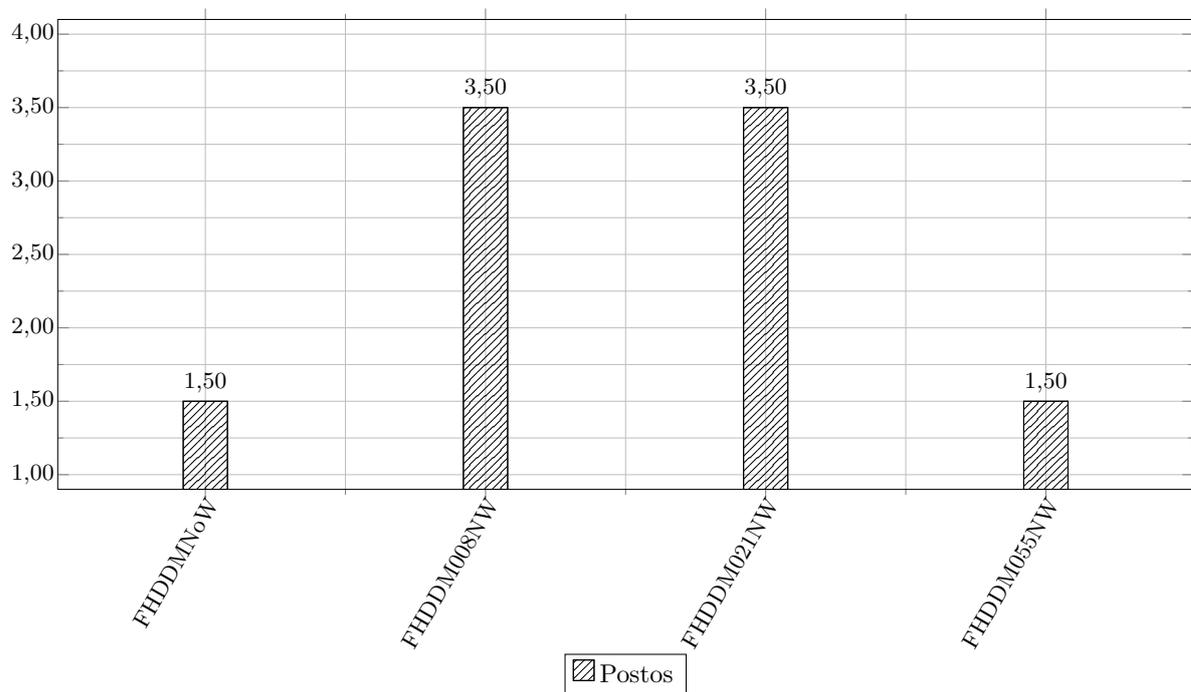
A Figura 7, também, apresenta dois gráficos referentes ao FHDDM aplicado ao NW, com o objetivo de mostrar a análise de desempenho entre as variações analisadas. Na Figura 7(a)

Figura 7 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do NotWarning com o FHDDM.

(a) Diferenças calculadas com HT e NB, individualmente.



(b) Rank das diferenças calculadas com HT e NB normalizadas.



Fonte: a autora (2022).

são exibidas as comparações entre as diferenças do $\sum \sum H_1$ (cenário do FHDDM aplicado ao NW com tamanhos de $w = 0, 8, 21$ e 55 instâncias em *Warning*) e $\sum \sum H_2$ (resultados da versão tradicional do método FHDDM) com HT e NB, individualmente analisadas, em um

gráfico de barras.

Porém, observa-se que os valores dos resultados não são de fato os mesmos encontrados nas Tabelas 6 e 7, pois estes valores foram normalizados. Apresentando os dados em sua maioria no intervalo entre $[0,1]$, indicando uma melhor representatividade do NW. Assim, é possível observar que o classificador NB apresentou um melhor desempenho para o FHDDM aplicado ao NW. Dentre as variações avaliadas, o FHDDM, com HT e NB, nos tamanhos de $w = 8$ e 21 instâncias em *Warning* para treinamento tiveram os melhores resultados. Se destacando $w = 21$ para NB e $w = 8$ para HT.

Na Figura 7(b) é apresentado um *rank* geral dos resultados da média do cálculo dos postos de HT e NB para o FHDDM aplicado ao NW. Assim, nota-se que no *rank* geral, a melhor variação foi um empate entre o FHDDM com $w = 8$ e 21 e as piores também empatadas, foram $w = 0$ e 55.

5.3.1.3 $RDDM_{NotWarning} \times RDDM_{DDMC}$

Diferentemente das análises vistas com o DDM e o FHDDM, os resultados relativos ao RDDM, com HT, apresentados na Tabela 8, não demonstraram grande contribuição do NW, o método teve o $\sum \sum H_1 < \sum \sum H_2$ para $w = 8, 21$. Ainda nestes casos, o NW aplicado ao RDDM só obteve uma superioridade estatística para RDDM021NW nas mudanças graduais, tendo as demais zerado. Então, para RDDM008NW o $\sum \sum H_1 = 0$ contra o RDDM001TRAD com $\sum \sum H_2 = 12$; para RDDM021NW o $\sum \sum H_1 = 1$ contra o RDDM001TRAD com $\sum \sum H_2 = 11$. No entanto, para RDDM055NW o $\sum \sum H_1 = 6$ contra o RDDM001TRAD também com $\sum \sum H_2 = 6$, tendo para os dois tipos de mudança, nas duas abordagens o $\sum H_1 = \sum H_2$, e conseqüentemente, o $\sum \sum H_1 = \sum \sum H_2$.

Especificamente, o RDDM, com NB, não obteve contribuições da abordagem proposta NW, resultando em um $\sum \sum H_1 < \sum \sum H_2$. Os resultados referentes ao NB, na Tabela 9, foram completamente favoráveis a abordagem tradicional. Tem-se que para RDDM008NW, RDDM021NW e RDDM055NW o $\sum \sum H_1 = 0$ contra o RDDM001TRAD com $\sum \sum H_2 = 19, 14$ e 12 respectivamente.

Por conseguinte, em relação as avaliações das bases de dados, o RDDM, com NB, não teve destaque com o NW, mas sim com o DDMC, principalmente em LED nos dois tipos de mudança, que teve 100% de superioridades para a abordagem tradicional, e bons resultados com *Agrawal* nas mudanças abruptas, MIX e *Sine* nas graduais. Semelhantemente, com HT,

Tabela 8 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o RDDM com HT na abordagem NotWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
RDDMN ₀ W	RDDM001TRAD	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀	H ₀
RDDM008NW	RDDM001TRAD	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀	H ₀
RDDM021NW	RDDM001TRAD	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₀
RDDM055NW	RDDM001TRAD	H ₀	H ₂	H ₀	H ₁	H ₁	H ₁	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀
		Graduais														
RDDMN ₀ W	RDDM001TRAD	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₂
RDDM008NW	RDDM001TRAD	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₀
RDDM021NW	RDDM001TRAD	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀
RDDM055NW	RDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀	H ₀
		Totais														
		Abruptas				Graduais				Geral						
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum \sum H_0$	$\sum \sum H_1$	$\sum \sum H_2$	$\sum \sum H_1 - \sum \sum H_2$	Rank
RDDMN ₀ W		7	0	8	-8	1,5	8	0	7	-7	1	15	0	15	-15	1
RDDM008NW		7	0	8	-8	1,5	11	0	4	-4	2	18	0	12	-12	2
RDDM021NW		8	0	7	-7	3	10	1	4	-3	3	18	1	11	-10	3
RDDM055NW		9	3	3	0	4	9	3	3	0	4	18	6	6	0	4

Fonte: a autora (2022).

os melhores resultados foram vistos para o DDMC, obtendo a maioria das superioridades para *Agrawal* nas mudanças abruptas e LED nos dois tipos de mudança de conceito. Porém, houve bons resultados para o NW com LED nas mudanças abruptas e graduais para $w = 55$.

A Figura 8, semelhantemente as demais, apresenta dois gráficos referentes ao RDDM aplicado ao NW, com o objetivo de mostrar a análise de desempenho entre as variações analisadas. Na Figura 8(a) são exibidas as comparações entre as diferenças do $\sum \sum H_1$ (cenário do RDDM aplicado ao NW com tamanhos de $w = 0, 8, 21$ e 55 instâncias em *Warning*) e $\sum \sum H_2$ (resultados da versão tradicional do método RDDM) com HT e NB, individualmente analisadas, em um gráfico de barras.

Entretanto, nota-se que os valores dos resultados não são de fato os mesmos encontrados nas Tabelas 8 e 9, pois estes valores foram normalizados. Exibindo os dados no intervalo entre $[-1,0]$, por estes serem favoráveis a abordagem tradicional, e sem valores no intervalo entre $[0,1]$, pois não houve contribuição do NW para o RDDM. Para este método, como não houve

Tabela 9 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o RDDM com NB na abordagem NotWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
RDDMN _o W	RDDM001TRAD	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂
RDDM008NW	RDDM001TRAD	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₀	H ₂	H ₀	H ₂	H ₀	H ₀
RDDM021NW	RDDM001TRAD	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
RDDM055NW	RDDM001TRAD	H ₀	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
		Graduais														
RDDMN _o W	RDDM001TRAD	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂
RDDM008NW	RDDM001TRAD	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂
RDDM021NW	RDDM001TRAD	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂
RDDM055NW	RDDM001TRAD	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₂
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum \sum H_0$	$\sum \sum H_1$	$\sum \sum H_2$	$\sum \sum H_1 - \sum \sum H_2$	Rank
	RDDMN _o W	2	0	13	-13	1	4	0	11	-11	1	6	0	24	-24	1
	RDDM008NW	5	0	10	-10	2	6	0	9	-9	2	11	0	19	-19	2
	RDDM021NW	9	0	6	-6	3	7	0	8	-8	3	16	0	14	-14	3
	RDDM055NW	10	0	5	-5	4	8	0	7	-7	4	18	0	12	-12	4

Fonte: a autora (2022).

contribuição do NW, os resultados são todos negativos ou zero, indicando melhor desempenho do método tradicional. Desta maneira, é possível notar que o classificador HT apresentou um melhor desempenho para o RDDM aplicado ao NW. Dentre as variações avaliadas, o RDDM com HT no tamanho de $w = 55$ instâncias em *Warning* para treinamento teve o melhor resultado, e com NB foi a variação com $w = 21$.

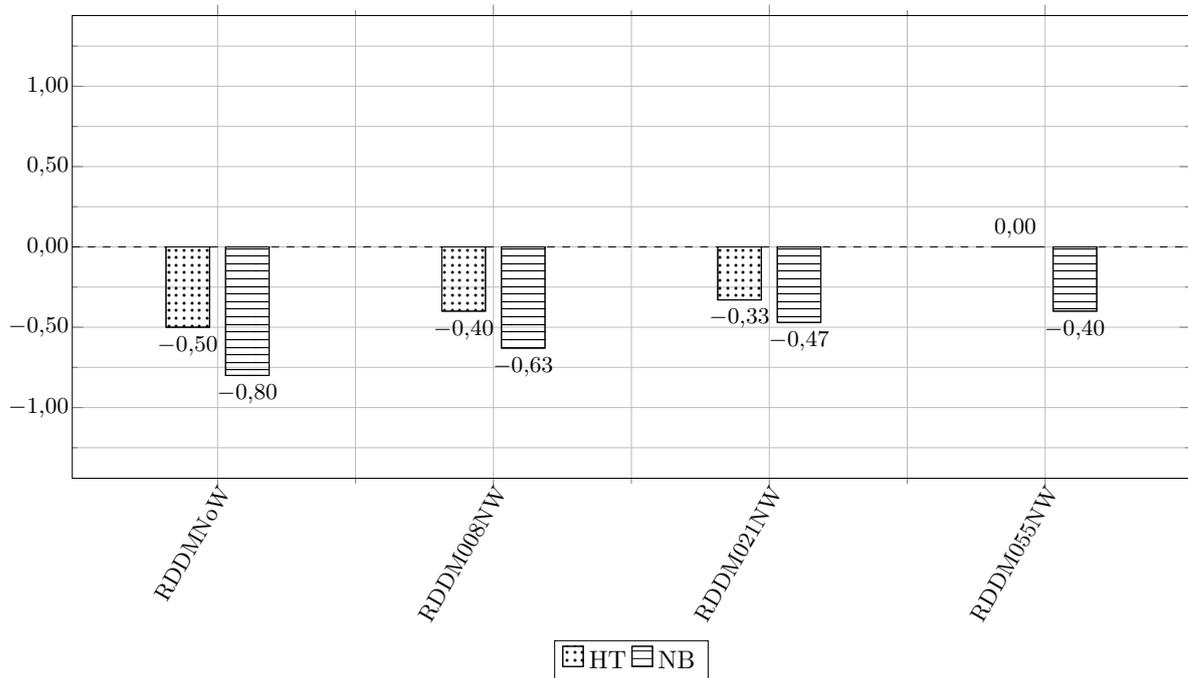
Então, na Figura 8(b) é apresentado um *rank* geral dos resultados da média do cálculo dos postos de HT e NB para o RDDM aplicado ao NW. Observando-se que no *rank* geral, a melhor variação foi o RDDM com $w = 55$ e a pior foi $w = 0$.

5.3.1.4 $USDD_{NotWarning} \times USDD_{DDMC}$

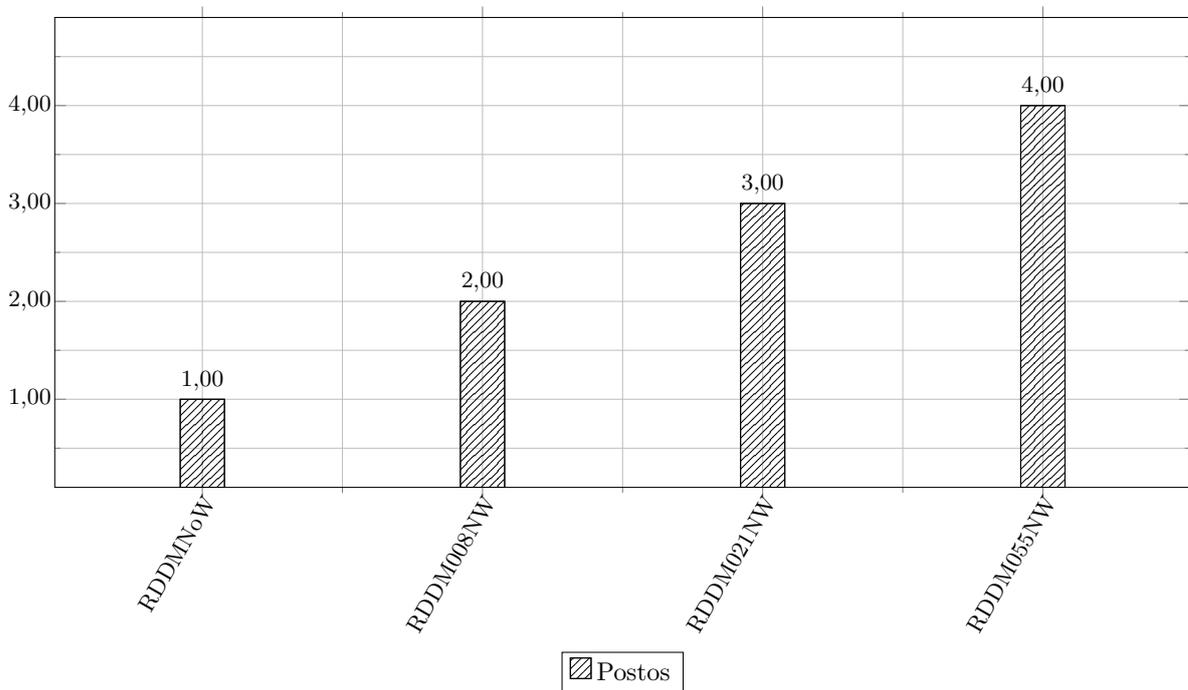
A contribuição da aplicação do NW para o USDD, com HT, foi interessante para o tamanho $w = 55$, configurando um $\sum \sum H_1 > \sum \sum H_2$. Neste caso, na Tabela 10 tem-se para

Figura 8 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do NotWarning com o RDDM.

(a) Diferenças calculadas com HT e NB, individualmente.



(b) Rank das diferenças calculadas com HT e NB normalizadas.



Fonte: a autora (2022).

USDD008NW o $\sum \sum H_1 = 1$ e para USDD021NW o $\sum \sum H_1 = 3$ contra o USDD001TRAD com $\sum \sum H_2 = 7$, configurando melhor aplicação do DDMC; e para USDD055NW o $\sum \sum H_1 = 8$ contra o USDD001TRAD com $\sum \sum H_2 = 0$. Destacando-se para o USDD, com

HT, para o tamanho de $w = 55$, nos dois tipos de mudança de conceito a não existência de superioridades estatísticas para a abordagem tradicional.

Tabela 10 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o USDD com HT na abordagem NotWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
USDDNoW	USDD001TRAD	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₂	H ₀	H ₀	H ₂	H ₀	H ₀
USDD008NW	USDD001TRAD	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
USDD021NW	USDD001TRAD	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
USDD055NW	USDD001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀
		Graduais														
USDDNoW	USDD001TRAD	H ₀	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀
USDD008NW	USDD001TRAD	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
USDD021NW	USDD001TRAD	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
USDD055NW	USDD001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum_{H_1} \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum_{H_1} \sum H_2$	Rank	$\sum \sum H_0$	$\sum \sum H_1$	$\sum \sum H_2$	$\sum \sum_{H_1} \sum H_2$	Rank
	USDDNoW	7	0	8	-8	1	9	1	5	-4	1	16	1	13	-12	1
	USDD008NW	11	0	4	-4	2	11	1	3	-2	2	22	1	7	-6	2
	USDD021NW	10	1	4	-3	3	10	2	3	-1	3	20	3	7	-4	3
	USDD055NW	10	5	0	5	4	12	3	0	3	4	22	8	0	8	4

Fonte: a autora (2022).

A análise referente ao método USDD aplicado a abordagem NW, com o NB, se mostrou semelhante ao visto com HT, obtendo este, o $\sum \sum H_1 < \sum \sum H_2$, com os resultados não favoráveis para $w = 8$ e 21, porém, favoráveis para $w = 55$. Então na Tabela 11 nota-se que, para USDD008NW o $\sum \sum H_1 = 3$ contra o USDD001TRAD com $\sum \sum H_2 = 14$; e para USDD021NW o $\sum \sum H_1 = 5$ contra o USDD001TRAD com $\sum \sum H_2 = 13$; e para USDD055NW o $\sum \sum H_1 = 6$ contra o USDD001TRAD com $\sum \sum H_2 = 2$.

Em suma, referente as bases de dados para o USDD, com NB, observa-se bons resultados para a maioria dos casos com a abordagem DDMC em *Agrawal* e LED nos dois tipos de mudança de conceito, além de, *Sine* nas mudanças graduais. No entanto, é destacado a base MIX com a maioria das superioridades estatísticas pelo NW, nas mudanças graduais. Assim como, para $Sine_{Abrupta;(w=55);(20k,80k,130k)}$ e $MIX_{Abrupta;(w=21);(20k,130k)}$. No caso com HT, nota-

Tabela 11 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o USDD com NB na abordagem NotWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
USDDNoW	USDD001TRAD	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₂	H ₂	H ₀	H ₂
USDD008NW	USDD001TRAD	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
USDD021NW	USDD001TRAD	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₀	H ₁	H ₀	H ₀				
USDD055NW	USDD001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁
		Graduais														
USDDNoW	USDD001TRAD	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₀	H ₂	H ₂	H ₀	H ₂	H ₂
USDD008NW	USDD001TRAD	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂
USDD021NW	USDD001TRAD	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₀	H ₀	H ₂	H ₀	H ₂	H ₂
USDD055NW	USDD001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₂	H ₀
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum_{H_1} H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum_{H_1} H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum_{H_1} H_2$	Rank
	USDDNoW	3	0	12	-12	1	2	3	10	-7	1	5	3	22	-19	1
	USDD008NW	9	0	6	-6	2	4	3	8	-5	2,5	13	3	14	-11	2
	USDD021NW	8	2	5	-3	3	4	3	8	-5	2,5	12	5	13	-8	3
	USDD055NW	10	4	1	3	4	12	2	1	1	4	22	6	2	4	4

Fonte: a autora (2022).

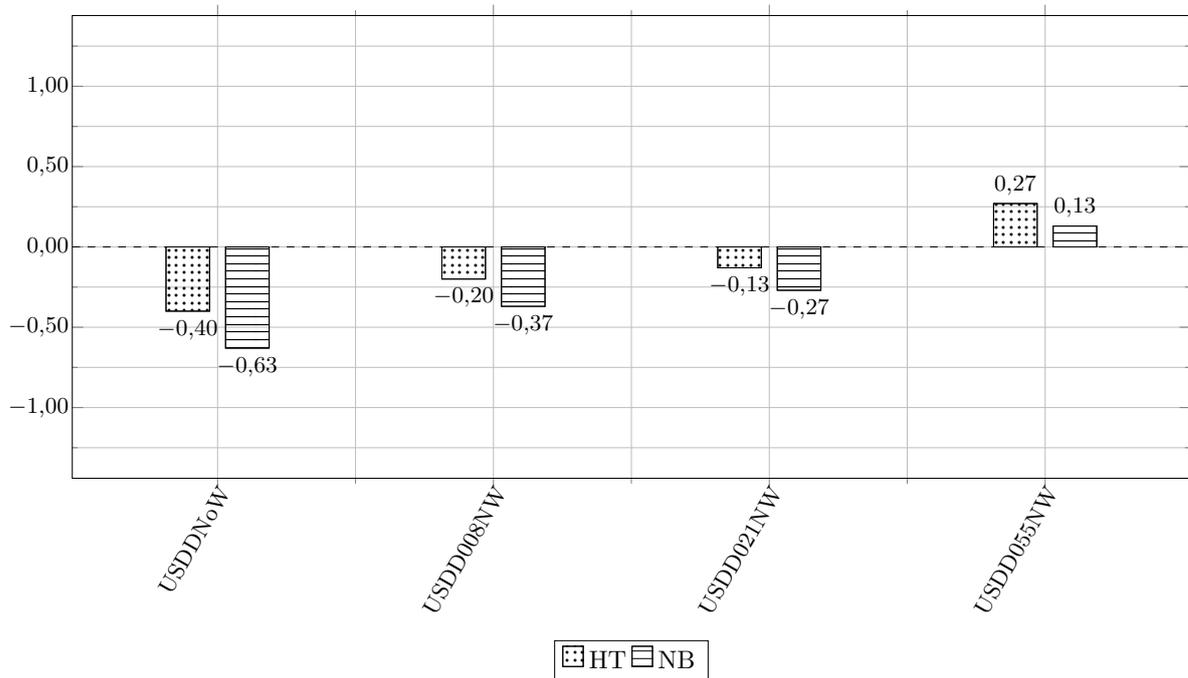
se a maioria das superioridades estatísticas em LED para o DDMC, nos dois tipos de mudanças de conceito. No entanto, há um destaque para o NW para $LED_{Abrupta;(w=55);(20k,80k,130k)}$; $LED_{Gradual;(w=55);(20k,80k,130k)}$; e $MIX_{Gradual;(w=21);(20k,80k)}$.

Por fim, a Figura 9 apresenta, igualmente aos outros métodos, os dois gráficos referentes ao USDD aplicado ao NW, com o objetivo de mostrar a análise de desempenho entre as variações analisadas. Na Figura 9(a) são exibidas as comparações entre as diferenças do $\sum \sum H_1$ (cenário do USDD aplicado ao NW com tamanhos de $w = 0, 8, 21$ e 55 instâncias em *Warning*) e $\sum \sum H_2$ (resultados da versão tradicional do método USDD) com HT e NB, individualmente analisadas, em um gráfico de barras.

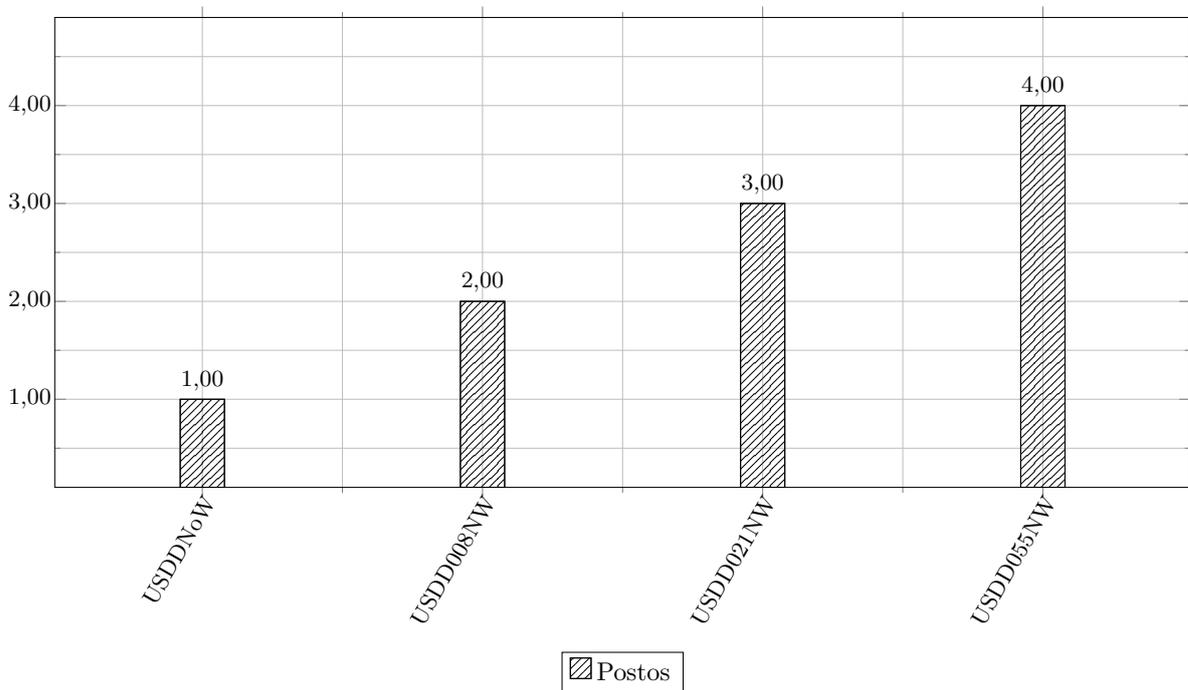
Porém, nota-se que os valores dos resultados não são, de fato, os mesmos encontrados nas Tabelas 10 e 11, pois estes valores foram normalizados. Mostrando os dados no intervalo entre $[-1,1]$, sendo o $w = 55$, melhor resultado do USDD aplicado ao NW no intervalo entre $[0,1]$. Assim, é possível observar que o classificador HT apresentou um melhor desempenho para o

Figura 9 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do NotWarning com o USDD.

(a) Diferenças calculadas com HT e NB, individualmente.



(b) Rank das diferenças calculadas com HT e NB normalizadas.



Fonte: a autora (2022).

USDD aplicado ao NW. Dentre as variações avaliadas, o USDD, com HT e NB, no tamanho de $w = 55$ instâncias em *Warning* para treinamento tiveram os melhores resultados.

Na Figura 9(b) é apresentado um *rank* geral dos resultados da média do cálculo dos postos

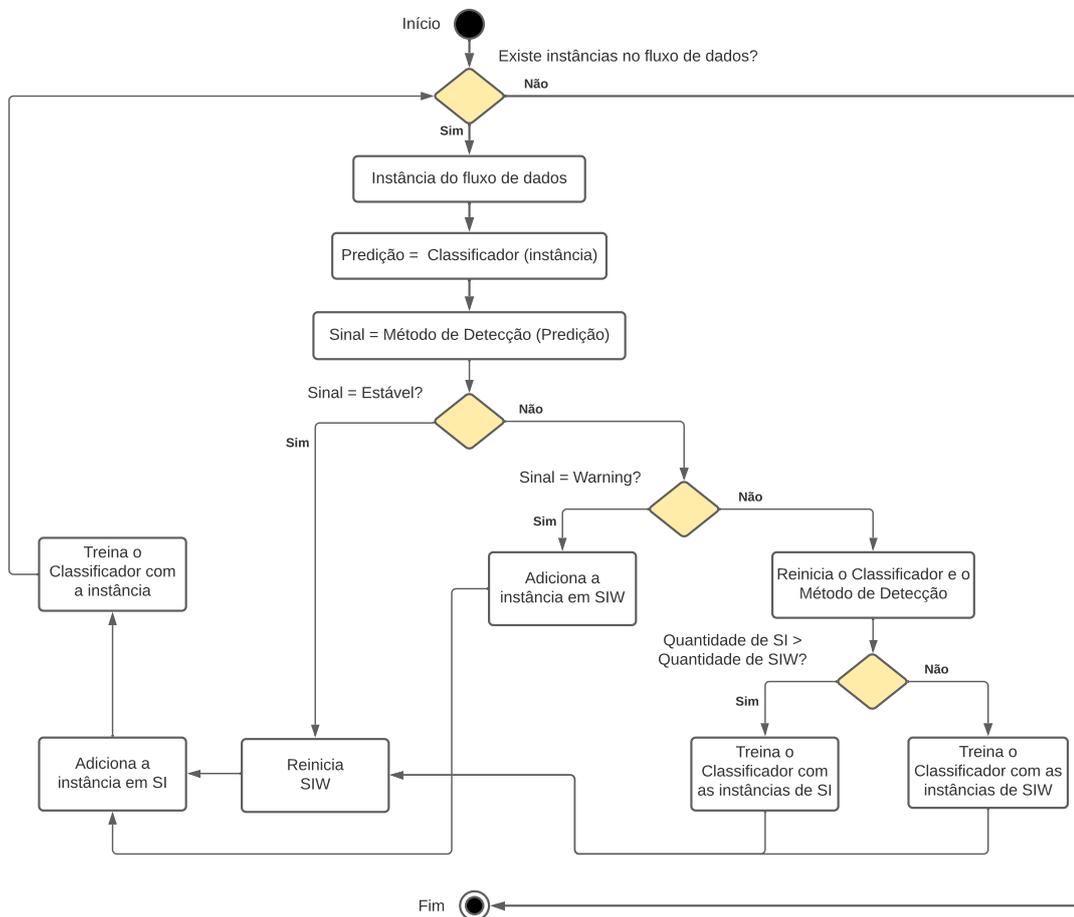
de HT e NB para o USDD aplicado ao NW. Portanto, observa-se que no *rank* geral, a melhor variação foi o USDD com $w = 55$ e a pior foi $w = 0$.

5.4 DYNAMINCPWARNING: ADAPTAÇÃO COM SINAL WARNING

Na Seção 4 foi observado que o comportamento da taxa de acurácia *Prequential* em modelos que tinham instâncias em sinal de *Warning* para treinar seu modelo, tiveram um desempenho melhor, obtendo a maioria das superioridades estatísticas quando comparados a modelos que não tinham instâncias em sinal de *Warning* para treinar o novo modelo após uma detecção de mudança de conceito. Assim, foi possível determinar a importância e a contribuição destas instâncias. No entanto, com o intuito de sugerir uma nova forma de garantir treinamento aos novos modelos quando há detecções de mudanças de conceito, na Seção 5.3, foi apresentada uma maneira diferente de se manter um conjunto de treinamento sem, de fato, utilizar os sinais de detecção *Warning*.

Porém, percebeu-se que havia a possibilidade de não desperdiçar estes sinais de detecção *Warning* disparados pelos detectores e, sim, combiná-las com a aplicação da técnica proposta anteriormente, que os simula. Desta forma, foi sugerida a segunda estratégia adaptativa desta tese, o DW [Victor, Melo e Maciel 2021]. Esta dinâmica tem como objetivo otimizar a ideia proposta no algoritmo do NW e sugerir uma maneira de utilizar os sinais de detecção *Warning* dos detectores. No caso, as duas técnicas podem ser aplicadas na execução do algoritmo, ficando a escolha entre eles em função da maior quantidade de instâncias previamente armazenadas.

Figura 10 – Fluxograma da Estratégia de Abordagem Adaptativa DynamicWarning, indicando desde o momento em que é verificada a existência de instâncias no fluxo de dados, até a identificação do estado de detecção pelo detector. A princípio, seguindo a estrutura da abordagem AACD, porém, mesclando a ação do NotWarning ou sua própria estratégia, de acordo com cada estado detectado e as quantidades de instâncias previamente armazenadas no conjunto de treinamento.



Fonte: o autor

Logo, estas duas opções são claramente observadas na Figura 10, que representa o fluxograma do DW. Uma vez que foi detectada uma mudança de conceito (um *Drift*), há uma última condição a ser testada, que é o momento em que o algoritmo decide qual a melhor estratégia a se aplicar naquela situação - a simulação dos sinais de *Warnings* do NW ou os sinais de detecção *Warning* disparados pelo detector. Esta decisão é tomada de acordo com a quantidade de instâncias que foram previamente armazenadas.

Em particular, a ideia de se manter as últimas w instâncias treinadas armazenadas, no NW, é mantida da mesma maneira. No entanto, são armazenadas em uma outra janela deslizante somente as instâncias com sinal de detecção *Warning* do detector. Consequentemente, nota-se que no caso dos detectores que não emitem sinais de *Warning*, como o FHDDM, cujo

experimentos são avaliados ainda nesta seção, o comportamento do DW é igual ao NW. Além disso, nota-se que a estrutura inicial do fluxograma do DW é visualmente semelhante ao DDMC e ao NW, porém, evidenciam-se os pontos divergentes das duas outras abordagens.

Algoritmo 3: Pseudo-código do DynamicWarning apresentando uma nova dinâmica de treinamento optando pela técnica que proporciona um maior número de instâncias para treinamento do modelo em reconstrução.

```

Input: fluxo, minTreinamento, minTreinamentoW
1 classificador.reset()
2 detector.reset()
3 for (instancia in fluxo) do
4   predição {acerto,erro} ← classificador.testarInstancia(instancia)
5   estado {stable,warning,drift} ← detector.analisar(predição)
6   if estado = stable then
7     | armazenalInstanciaW.reset()
8   else
9     | if estado = warning then
10    |   | if armazenalInstanciaW.length ≥ minTreinamentoW then
11    |   |   | armazenalInstanciaW.shift()
12    |   |   | armazenalInstanciaW.push(instancia)
13    |   | else
14    |   |   | classificador.reset()
15    |   |   | detector.reset()
16    |   |   | if armazenalInstancia.length > armazenalInstanciaW.length then
17    |   |   |   | sI ← armazenalInstancia
18    |   |   |   | else
19    |   |   |   |   | sI ← armazenalInstanciaW
20    |   |   |   |   | for i em sI do
21    |   |   |   |   |   | classificador.treina(i)
22    |   |   |   |   | armazenalInstanciaW.reset()
23    |   | if armazenalInstancia.length ≥ minTreinamento then
24    |   |   | armazenalInstancia.shift()
25    |   | armazenalInstancia.push(instancia)
26    |   | classificador.treina(instancia)

```

Fonte: a autora (2022).

Por outras palavras, pode-se entender melhor o funcionamento do DW por meio do Algoritmo 3. Inicialmente as instâncias são recebidas do fluxo de dados, então classificadas, e em seguida, são avaliadas as respostas da classificação pelo detector, como indicado nas linhas 3, 4 e 5, respectivamente. O mesmo é visto no NW e no DDMC.

Assim como no NW, independentemente do sinal indicado pelo detector, a instância recebida será armazenada na janela deslizante "armazenalInstancia", na linha 25 e treinada no modelo, na linha 26. Semelhantemente ao que acontece no NW, o objetivo é garantir que haja instâncias em *Warning* para serem treinadas no momento em que for detectada uma mudança de conceito, já citado que não acontece na abordagem tradicional.

As divergências entre as abordagens são vistas a partir deste momento. No caso do DW, o algoritmo utiliza duas janelas deslizantes. A "armazenalInstancia" com tamanho "minTre-

namento", que armazena as últimas w instâncias treinadas do fluxo (como o NW) e a "armazenInstanciaW" com tamanho "minTreinamentoW", que armazena somente as instâncias identificadas como em sinal de detecção *Warning* pelo detector.

Então, caso seja disparado um sinal de *Stable* pelo detector, na linha 6, o fluxo está estável, e assim como no DDMC, as instâncias anteriormente identificadas em sinal de *Warning* precisam ser descartadas, assim, a lista "armazenInstanciaW" é reiniciada na linha 7.

No entanto, se for detectado um sinal de *Warning*, visto na linha 9, o algoritmo adiciona a instância na janela "armazenInstanciaW", na linha 12. Assim como o NW, neste caso, o DW está evitando a criação de um segundo modelo de decisão treinado com as instâncias em *Warning* do detector e que pode ser descartado caso seja identificado em seguida um estado de *Stable*, como acontece no DDMC.

Caso contrário, se for disparado um sinal de *Drift*, o modelo de decisão do classificador e o estado do detector são reiniciados, nas linhas 14 e 15, respectivamente. A mesma situação pode ser vista nos três algoritmos. Então, a quantidade de instâncias nas duas janelas são comparadas, a que contiver uma quantidade maior de instâncias, visto na linha 16, é a janela que vai proporcionar um maior treinamento para o novo modelo, e é escolhida para treinar este modelo, visto na linha 21. E, por fim, na linha 22, a janela "armazenInstanciaW" é reiniciada, independentemente de ter sido utilizada para treinar o modelo ou não. Esta janela armazena as instâncias em *Warning* do detector e, portanto, são descartadas usando a mesma lógica da abordagem tradicional, quando há sinais de *Stable* e de *Drift*.

Vale ressaltar que, assim como no NW, o DW mantém a originalidade e a implementação dos métodos de detecção. Além disso, foi considerado interessante o aproveitamento de todas as opções de respostas de detecção dos detectores.

5.4.1 Resultados e Análise: DynamicWarning contra Tradicional

Nesta subseção são apresentados os resultados referentes ao desempenho das variações dos métodos selecionados nesta tese aplicados à estratégia DW, comparativamente, com a abordagem de adaptação tradicional DDMC. As parametrizações de geradores de bases de dados artificiais, tamanhos de conceito e pontos de mudança são os mesmos utilizados para o NW. Desta forma, segue-se com a avaliação dos resultados de acurácia *Prequential* por meio da estatística baseada no teste em pares de Wilcoxon.

Da mesma maneira como explanado na Subseção 5.3.1, tem-se a avaliação da estraté-

gia proposta nesta subsecção comparada a abordagem adaptativa tradicionalmente aplicada a modelos de única classificação e única detecção mediante a dois cenários μ_1 e μ_2 , sendo o DW e o DDMC, respectivamente. De acordo com a implementação do algoritmo DW, é utilizada a técnica da janela deslizante do NW, e os tamanhos aplicados continuam $w = 0, 8, 21$ e 55 . Além disso, incorpora-se a janela deslizante que contém os sinais em *Warning* do detector com tamanho máximo de 200 instâncias. Ainda assim, a análise do tamanho $w = 0$ se mantém como entendimento do desempenho do método da maneira tradicional versus sua própria versão sem sinais de *Warning* para treinamento do novo modelo. Então, este tamanho não é avaliado, diretamente, como métrica de contribuição para o DW.

Assim como para a avaliação do NW, nesta subsecção considera-se $\sum H_1$ as hipóteses com vitórias estatísticas para o DW contra o DDMC, como $\sum H_2$ sendo as vitórias estatísticas do método tradicional DDMC contra o DW. Particularidades sobre a montagem das análises da avaliação estatística são descritos na Subsecção 3.1.4 da Seção de metodologia. Diferentemente do apresentado na Seção 4 e semelhante ao apresentado na Subsecção 5.3, a análise das tabelas desta subsecção utilizam como referência os valores somente de μ_1 , da dinâmica DW. Assim, os gráficos representando cada um dos métodos são gerados, para avaliar, separadamente, as melhores variações.

Vale ressaltar que, nas análises são feitas comparações dos casos individuais e baseadas na diferença entre $\sum H_1$ e $\sum H_2$, para representar da melhor forma os melhores desempenhos entre os métodos e as variações do DW. Ainda podendo ser avaliado o $\sum \sum H_1$ ou $\sum \sum H_2$ para uma visão geral do cenário. Igualmente, considera-se a comparação dos casos individuais e/ou as diferenças entre $\sum H_1$ e $\sum H_2$, também referenciando o somatório total das hipóteses $\sum \sum H_1$ e/ou $\sum \sum H_2$ para análises gerais.

Logo, as Tabelas 12, 13, 14, 15, 16, 17, 18 e 19 apresentam os resultados dos testes de hipóteses estatísticas para cada um dos tamanhos de w , com os classificadores HT e NB, e os detectores DDM, FHDDM, RDDM e USDD, nas mudanças de conceito abruptas e graduais. É evidente ao decorrer das descrições da Seção 4 e desta seção, que o objetivo é analisar as possíveis melhorias nos valores de acurácia *Prequential* das abordagens adaptativas em sua aplicação conjunta aos métodos de detecção. Nesta subsecção, os detectores, também não são comparados entre si. Porém, na Seção 6 é realizada uma discussão que levanta algumas características destes métodos para explicar e/ou justificar comportamentos observados.

Logo, nota-se que para o DDM e FHDDM, com NB, e o USDD, com HT e NB, nos tipos de mudanças de conceito abruptas, graduais e no geral, o DW contribuiu da melhor forma

para a melhoria da acurácia *Prequential*. Especificamente para estes casos, o DW conseguiu contribuir, tendo o $\sum H_1 > \sum H_2$, nos tamanhos de $w = 8, 21$ e 55 avaliados, assim como, os totais com o $\sum \sum H_1 > \sum \sum H_2$.

Efetivamente, observa-se que para DDM e FHDDM com HT, há uma significativa contribuição do DW. Nestes casos, o $\sum H_1 > \sum H_2$ na maioria dos casos. Os dois métodos se destacaram por ter o somatório das superioridades estatísticas totais favorável ao DW contra o DDMC.

Em relação ao RDDM, com o DW houve uma pequena, mas interessante contribuição do método tanto com NB quanto com HT. Apesar dos resultados com RDDM não serem tão significativos quanto os demais métodos detectores, pode-se afirmar que houve uma melhoria em relação a contribuição do NW com o RDDM, pelo DW.

Referente a avaliação do métodos contra suas versões sem sinais de *Warning* do detector, $w = 0$, os resultados foram semelhantes aos encontrados na análise da abordagem NW, visto na Subseção 5.3.1. Isto porque a diferença entre o NW e o DW é o tratamento dos sinais de detecção *Warning*, e uma vez que eles não existem os resultados dos métodos tendem a ser iguais em relação a métrica avaliada.

5.4.1.1 $DDM_{DynamicWarning} \times DDM_{DDMC}$

Os resultados vistos com HT, na Tabela 12 no DDM foram bem significativos. No geral, o $\sum \sum H_1 > \sum \sum H_2$ para os tamanhos de $w = 8, 21$ e 55 . Então, a aplicação do DW ao DDM resultou para o DDM008DW um $\sum \sum H_1 = 11$ e para o DDM021DW um $\sum \sum H_1 = 8$ enquanto o $\sum \sum H_2 = 4$ nos dois casos; e para o DDM055DW o $\sum \sum H_1 = 6$ contra o $\sum \sum H_2 = 3$. Nota-se que, nas mudanças graduais se manteve este padrão de vitórias, porém, nas mudanças abruptas o DDM021DW perdeu com $\sum H_1 = 2$ contra o DDM021DW com o $\sum H_2 = 3$; e o DDM055DW perdeu com $\sum H_1 = 0$ e o DDM055DW com o $\sum H_2 = 1$.

A análise referente ao DDM aplicado a dinâmica DW, com o NB, observado na Tabela 13, apresentou uma ótima contribuição para a acurácia *Prequential*, tendo o método nessa condição, em mudanças graduais e abruptas o $\sum \sum H_1 > \sum \sum H_2$ para $w = 8, 21$ e 55 . Assim, o DW teve para DDM008DW um $\sum \sum H_1 = 16$ contra DDM001TRAD um $\sum \sum H_2 = 3$; e para DDM021DW o $\sum \sum H_1 = 13$ e DDM055DW o $\sum \sum H_1 = 10$ enquanto o $\sum \sum H_2 = 2$ nos dois casos. Salienta-se, ainda, nas mudanças do tipo abruptas a ausência de superioridades estatísticas da abordagem tradicional DDMC.

Tabela 12 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o DDM com HT na abordagem DynamicWarning.

Pares		Geradores de fluxo de dados															
		Agrawal			LED			Mix			RRBF			Sine			
		Tamanhos das bases de dados vezes 10k															
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13	
		Abruptas															
DDMNoW	DDM001TRAD	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀
DDM008DW	DDM001TRAD	H ₀	H ₂	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀
DDM021DW	DDM001TRAD	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀
DDM055DW	DDM001TRAD	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
		Graduais															
DDMNoW	DDM001TRAD	H ₁	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₁	H ₀				
DDM008DW	DDM001TRAD	H ₀	H ₂	H ₂	H ₁	H ₀	H ₁	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁
DDM021DW	DDM001TRAD	H ₀	H ₀	H ₂	H ₁	H ₀	H ₁	H ₀	H ₁	H ₁	H ₀	H ₁	H ₁				
DDM055DW	DDM001TRAD	H ₀	H ₀	H ₂	H ₁	H ₀	H ₁	H ₂	H ₁	H ₁	H ₀	H ₁	H ₁				
		Totais															
		Abruptas					Graduais					Geral					
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	
	DDMNoW	12	2	1	1	3	9	4	2	2	1	21	6	3	3	1,5	
	DDM008DW	9	4	2	2	4	6	7	2	5	3,5	15	11	4	7	4	
	DDM021DW	10	2	3	-1	1,5	8	6	1	5	3,5	18	8	4	4	3	
	DDM055DW	14	0	1	-1	1,5	7	6	2	4	2	21	6	3	3	1,5	

Fonte: a autora (2022).

Portanto, a avaliação das bases de dados para o DDM, com NB, mostrou um excelente desempenho com LED nas mudanças abruptas, obtendo 100% das superioridades estatísticas para o DW. Bons resultados também são vistos com MIX e *Sine* nas mudanças abruptas tendo a maioria das superioridades estatísticas; e LED nas graduais. Porém, o DDM se destacou nas mudanças graduais com a base MIX na maioria dos casos. No caso do DDM com HT, somente o DW se sobressaiu para LED, MIX e *Sine* nas mudanças do tipo gradual; e $MIX_{Abrupta;(w=8);(20k,80k)}$.

A Figura 11 apresenta dois gráficos referentes ao DDM aplicado ao DW, com o objetivo de mostrar a análise de desempenho entre as variações analisadas. Na Figura 11(a) são exibidas as comparações entre as diferenças do $\sum \sum H_1$ (cenário do DDM aplicado ao DW com tamanhos de $w = 0, 8, 21$ e 55 instâncias em *Warning*) e $\sum \sum H_2$ (resultados da versão tradicional do método DDM) com HT e NB, individualmente analisadas, em um gráfico de barras.

Entretanto, observa-se que os valores dos resultados não são de fato os mesmos encontra-

Tabela 13 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o DDM com NB na abordagem DynamicWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
DDMN ₀ W	DDM001TRAD	H ₀	H ₁	H ₁	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁
DDM008DW	DDM001TRAD	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁
DDM021DW	DDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁
DDM055DW	DDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁
		Graduais														
DDMN ₀ W	DDM001TRAD	H ₀	H ₁	H ₁	H ₂	H ₁	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀				
DDM008DW	DDM001TRAD	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀
DDM021DW	DDM001TRAD	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
DDM055DW	DDM001TRAD	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₂	H ₁	H ₂	H ₀	H ₀				
		Totais														
		Abruptas				Graduais					Geral					
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
	DDMN ₀ W	6	9	0	9	2	4	10	1	9	4	10	19	1	18	4
	DDM008DW	4	11	0	11	4	7	5	3	2	2,5	11	16	3	13	3
	DDM021DW	5	10	0	10	3	10	3	2	1	1	15	13	2	11	2
	DDM055DW	9	6	0	6	1	9	4	2	2	2,5	18	10	2	8	1

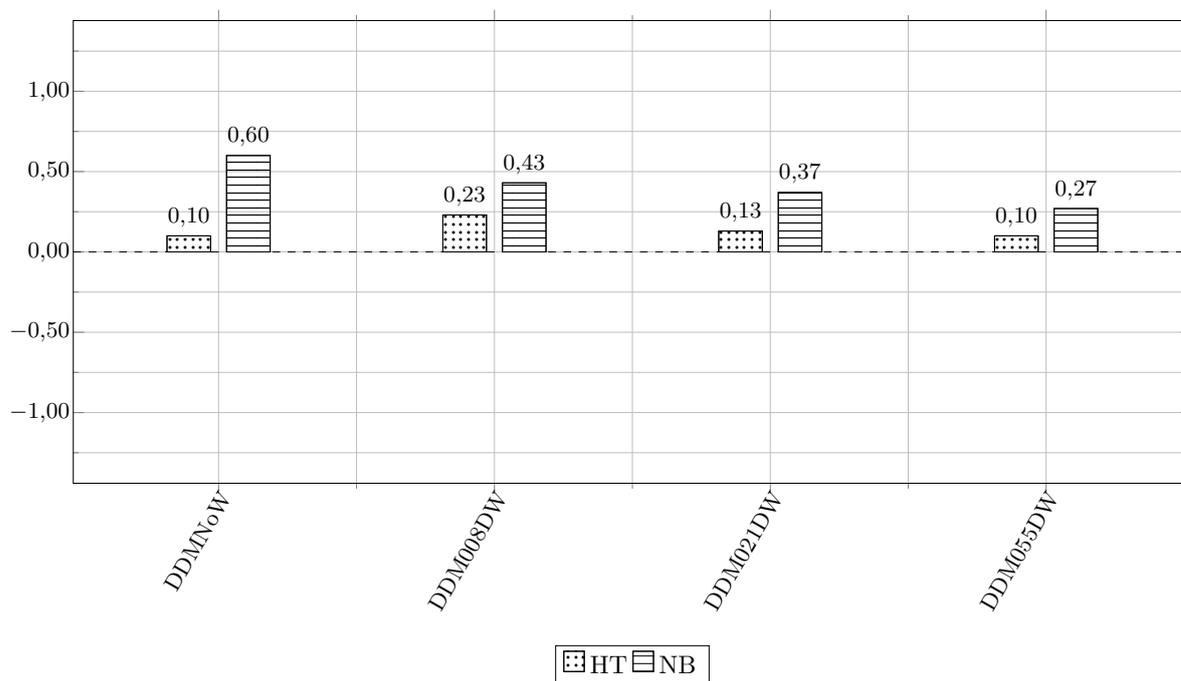
Fonte: a autora (2022).

dos nas Tabelas 12 e 13, pois estes valores foram normalizados. No caso do DDM, os dados estão no intervalo somente entre [0,1], por causa dos bons resultados proporcionados pelo DW. Não havendo valores negativos, mostrando o bom desempenho do DW. Desta forma, é possível notar que o classificador NB apresentou um melhor desempenho para o DDM aplicado ao DW. Dentre as variações avaliadas, o DDM com NB, no tamanho de $w = 0$ instâncias em *Warning* para treinamento teve o melhor resultado e, com HT, foi a variação com $w = 8$.

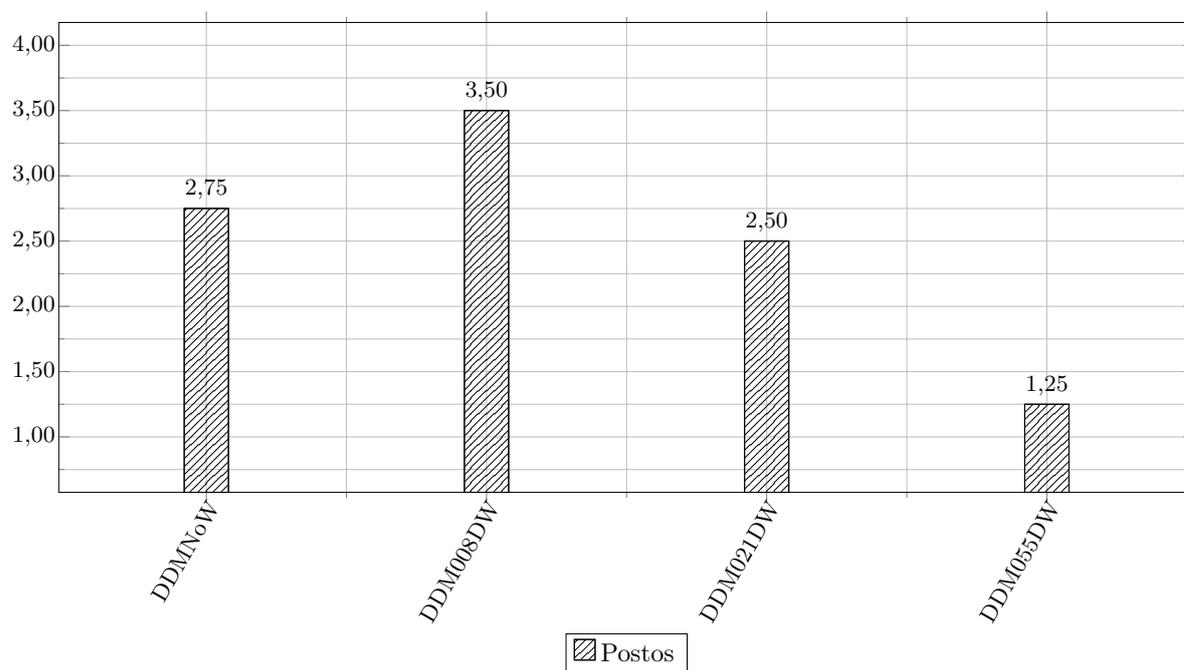
Na Figura 11(b) é apresentado um *rank* geral dos resultados da média do cálculo dos postos de HT e NB para o DDM aplicado ao DW. Então, observa-se que no *rank* geral, a melhor variação foi o DDM com $w = 8$ e a pior foi $w = 55$.

Figura 11 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do DynamicWarning com o DDM.

(a) Diferenças calculadas com HT e NB, individualmente.



(b) Rank das diferenças calculadas com HT e NB normalizadas.



Fonte: a autora (2022).

5.4.1.2 $FHDDM_{DynamicWarning} \times FHDDM_{DDMC}$

No caso dos resultados do FHDDM, com HT, apresentados na Tabela 14, houve melhorias em dois dos três tamanhos avaliados, $w = 8$ e 21 . Isto ocorreu tanto nas mudanças do

tipo abruptas quanto graduais e, de modo geral o $\sum \sum H_1 > \sum \sum H_2$. Então, foi visto que para FHDDM008DW o $\sum \sum H_1 = 10$ e para FHDDM021DW o $\sum \sum H_1 = 8$ contra o FHDDM001TRAD com $\sum \sum H_2 = 0$; e para FHDDM055DW o $\sum \sum H_1 = 6$ contra o FHDDM001TRAD com $\sum \sum H_2 = 11$, sendo superior o método tradicional.

Tabela 14 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o FHDDM com HT na abordagem DynamicWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
FHDDMNoW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
FHDDM008DW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀
FHDDM021DW	FHDDM001TRAD	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
FHDDM055DW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂
		Graduais														
FHDDMNoW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
FHDDM008DW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
FHDDM021DW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀
FHDDM055DW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₀	H ₂
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
FHDDMNoW		15	0	0	0	2	15	0	0	0	2	30	0	0	0	2
FHDDM008DW		8	7	0	7	4	12	3	0	3	3	20	10	0	10	4
FHDDM021DW		11	4	0	4	3	11	4	0	4	4	22	8	0	8	3
FHDDM055DW		6	3	6	-3	1	7	3	5	-2	1	13	6	11	-5	1

Fonte: a autora (2022).

A análise do FHDDM, com NB, aplicado ao DW foi semelhante ao descrito no DDM. Os métodos apresentaram uma ótima contribuição do DW para a melhoria da acurácia *Prequential*, tendo a maioria dos casos avaliados com o somatório de superioridades estatísticas maior do que para o DDMC. Na Tabela 15 observa-se que, com NB, o FHDDM aplicado ao DW é superior ao DDMC nas mudanças graduais e abruptas para os tamanhos de $w = 8, 21$ e 55 , assim, teve para o FHDDM008DW o $\sum \sum H_1 = 11$ e para FHDDM021DW o $\sum \sum H_1 = 12$ contra o FHDDM001TRAD com $\sum \sum H_2 = 0$; e para FHDDM055DW o $\sum \sum H_1 = 14$ enquanto FHDDM001TRAD teve o $\sum \sum H_2 = 7$.

Destaca-se neste detector, para os dois classificadores nas mudanças abruptas e graduais

Tabela 15 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o FHDDM com NB na abordagem DynamicWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
FHDDMNoW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
FHDDM008DW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁
FHDDM021DW	FHDDM001TRAD	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁
FHDDM055DW	FHDDM001TRAD	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁
		Graduais														
FHDDMNoW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
FHDDM008DW	FHDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₀	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀
FHDDM021DW	FHDDM001TRAD	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁
FHDDM055DW	FHDDM001TRAD	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₁	H ₁
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
FHDDMNoW		15	0	0	0	1	15	0	0	0	1	30	0	0	0	1
FHDDM008DW		8	7	0	7	4	11	4	0	4	3	19	11	0	11	3
FHDDM021DW		9	6	0	6	3	9	6	0	6	4	18	12	0	12	4
FHDDM055DW		5	7	3	4	2	4	7	4	3	2	9	14	7	7	2

Fonte: a autora (2022).

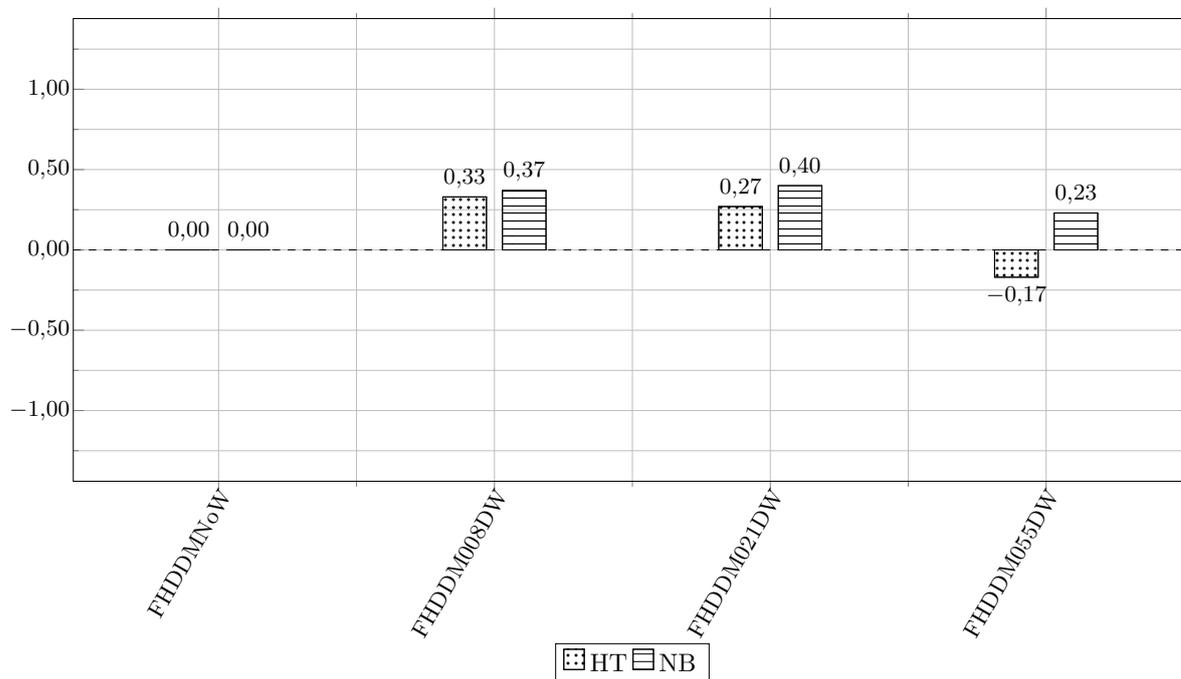
para os tamanhos $w = 8$ e 21 , que há uma ausência de superioridades estatísticas da abordagem adaptativa tradicional em relação a dinâmica proposta nesta seção.

Por fim, nota-se que o FHDDM, com NB, aplicado ao DW teve a maioria das superioridades estatísticas para LED e Sine nos dois tipos de mudança. Assim como, obteve bons resultados com $MIX_{Abrupta;(w=8);(20k,80k,130k)}$. Para o FHDDM, com HT, foi visto um excelente desempenho do DW, conquistando 100% das superioridades estatísticas com LED nas mudanças abruptas e graduais e $Sine_{Abrupta;(w=8);(20k,80k)}$.

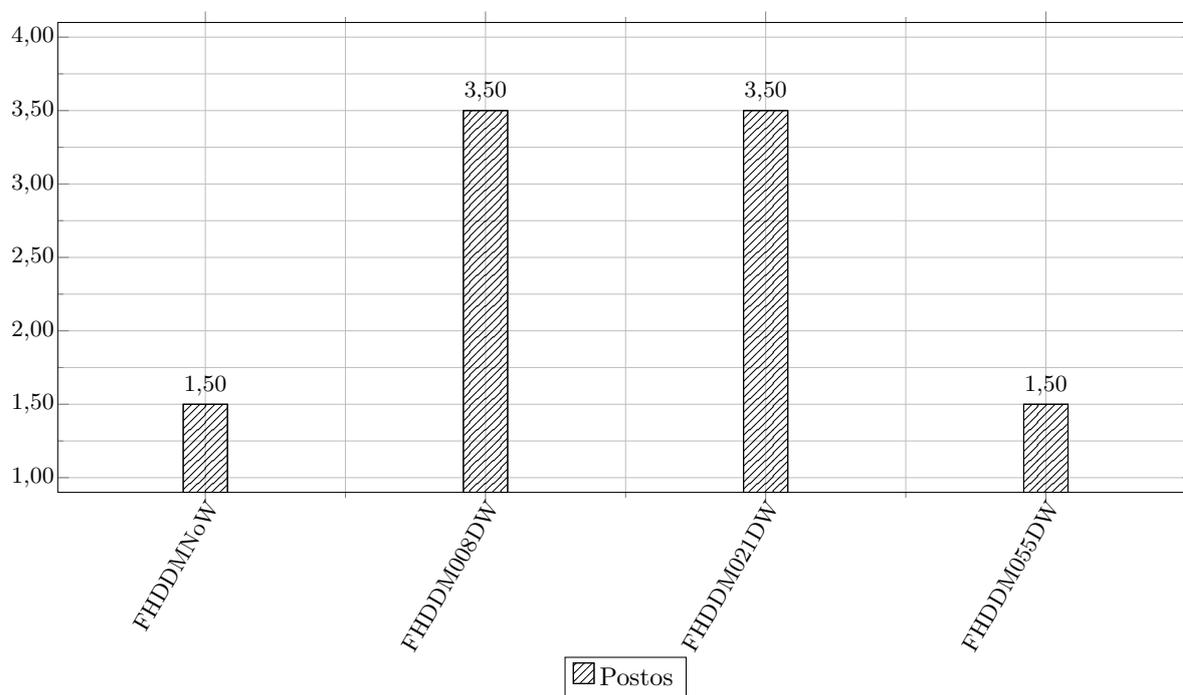
A Figura 12 também mostra dois gráficos referentes ao FHDDM aplicado ao DW, com o objetivo de mostrar a análise de desempenho entre as variações analisadas. Na Figura 12(a) são exibidas as comparações entre as diferenças do $\sum \sum H_1$ (cenário do FHDDM aplicado ao DW com tamanhos de $w = 0, 8, 21$ e 55 instâncias em Warning) e $\sum \sum H_2$ (resultados da versão tradicional do método FHDDM) com HT e NB, individualmente analisadas, em um gráfico de barras.

Figura 12 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do DynamicWarning com o FHDDM.

(a) Diferenças calculadas com HT e NB, individualmente.



(b) Rank das diferenças calculadas com HT e NB normalizadas.



Fonte: a autora (2022).

Porém, observa-se que os valores dos resultados não são, de fato, os mesmos encontrados nas Tabelas 14 e 15, pois estes valores foram normalizados. Mostrando os dados entre $[-1,1]$, assim como no NW, a parte negativa indica que em uma das variações ($w = 55$), o resultado

foi favorável ao método tradicional. Assim, é possível notar que o classificador NB apresentou um melhor desempenho para o FHDDM aplicado ao DW. Dentre as variações avaliadas, o FHDDM com NB no tamanho de $w = 21$ instâncias em *Warning* para treinamento teve o melhor resultado, e com HT foi a variação com $w = 8$.

Na Figura 12(b) é apresentado um *rank* geral dos resultados da média do cálculo dos postos de HT e NB para o FHDDM aplicado ao DW. Então, observa-se que no *rank* geral, a melhor variação foi um empate entre o FHDDM com $w = 8$ e 21 e as piores foram $w = 0$ e 55.

5.4.1.3 $RDDM_{DynamicWarning} \times RDDM_{DDMC}$

Contrariamente as análises inferidas nos demais detectores, os resultados do RDDM, com HT, visto na Tabela 16, aplicado ao DW conquistou superioridades estatísticas, com $w = 55$, em relação ao DDMC de modo geral. Não houve contribuição geral com os demais tamanhos de w , assim, teve para RDDM008DW o $\sum \sum H_1 = 6$ contra o RDDM001TRAD com $\sum \sum H_2 = 10$; e para RDDM021DW o $\sum \sum H_1 = 1$ contra o RDDM001TRAD com $\sum \sum H_2 = 5$. No entanto, sobressai-se o fato do RDDM aplicado ao DDMC nas mudanças graduais não ter superioridades estatísticas, com RDDM021DW o $\sum H_1 = 1$ e com RDDM055DW o $\sum H_1 = 3$ contra o RDDM001TRAD com o $\sum H_2 = 0$ nos dois casos.

Seguindo a mesma linha, a aplicação do RDDM ao DW proporcionou uma contribuição parcial em termos de melhoria da acurácia *Prequential*. Em relação ao RDDM, com NB, visto na Tabela 17, não houve superioridade estatística do DW no geral com os tamanhos $w = 8$ e 55. Assim, tendo para RDDM008DW o $\sum \sum H_1 = 5$ contra o RDDM001TRAD com $\sum \sum H_2 = 11$; e para RDDM055DW o $\sum \sum H_1 = 2$ contra o RDDM001TRAD com $\sum \sum H_2 = 4$. Mas houve um maior somatório de superioridades do RDDM055DW nas mudanças abruptas para o DW, com RDDM021DW o $\sum \sum H_1 = 4$ contra o RDDM001TRAD com $\sum \sum H_2 = 3$. Além disso, com $w = 21$, observou-se que nas mudanças abruptas houve um empate com $\sum H_1 = \sum H_2 = 3$ e uma vitória com RDDM055DW o $\sum H_1 = 2$ contra o RDDM001TRAD com $\sum H_2 = 1$. Nas mudanças graduais, uma vitória, com RDDM021DW o $\sum H_1 = 1$ enquanto para RDDM001TRAD o $\sum H_2 = 0$.

Concluindo, referente as bases de dados do RDDM, observa-se prioritariamente bons resultados do DDMC para o NB, com a maioria das superioridades estatísticas para LED e MIX nas mudanças abruptas e graduais, respectivamente. Mas houve um destaque para o DW

Tabela 16 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o RDDM com HT na abordagem DynamicWarning.

Pares		Geradores de fluxo de dados																			
		Agrawal			LED			Mix			RRBF			Sine							
		Tamanhos das bases de dados vezes 10k																			
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13					
		Abruptas																			
RDDMN ₀ W	RDDM001TRAD	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀	H ₀					
RDDM008DW	RDDM001TRAD	H ₀	H ₂	H ₂	H ₂	H ₁	H ₂	H ₂	H ₁	H ₀	H ₂	H ₀	H ₀	H ₀	H ₁	H ₁	H ₂				
RDDM021DW	RDDM001TRAD	H ₀	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₀	H ₂	H ₂	H ₀									
RDDM055DW	RDDM001TRAD	H ₀	H ₂	H ₀	H ₁	H ₁	H ₁	H ₂	H ₀	H ₂	H ₀	H ₂									
		Graduais																			
RDDMN ₀ W	RDDM001TRAD	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₂	H ₂				
RDDM008DW	RDDM001TRAD	H ₂	H ₀	H ₀	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀								
RDDM021DW	RDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₀															
RDDM055DW	RDDM001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀													
		Totais																			
		Abruptas				Graduais				Geral											
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1$	$\sum H_2$	$\sum H_1$	$\sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1$	$\sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1$	$\sum H_2$	Rank
RDDMN ₀ W		7	0	8	-8	1	8	0	7	-7	1	15	0	15	-15	1					
RDDM008DW		4	4	7	-3	3	10	2	3	-1	2	14	6	10	-4	2,5					
RDDM021DW		10	0	5	-5	2	14	1	0	1	3	24	1	5	-4	2,5					
RDDM055DW		8	3	4	-1	4	12	3	0	3	4	20	6	4	2	4					

Fonte: a autora (2022).

com $Agrawal_{Abrupta;(20k)}$. Em relação aos resultados, com HT, a abordagem tradicional com $Agrawal$ nas mudanças abruptas teve a maioria das superioridades estatísticas. No entanto, o DW obteve bons resultados para LED nas mudanças abruptas e graduais para $w = 55$, $Sine_{Abrupta;(w=8);(20k,80k)}$ e $Sine_{Gradual;(w=8);(20k,80k)}$.

Em sequência, a Figura 13 exibe dois gráficos referentes ao RDDM aplicado ao DW, com o objetivo de mostrar a análise de desempenho entre as variações analisadas. Na Figura 13(a) são exibidas as comparações entre as diferenças do $\sum \sum H_1$ (cenário do RDDM aplicado ao DW com tamanhos de $w = 0, 8, 21$ e 55 instâncias em *Warning*) e $\sum \sum H_2$ (resultados da versão tradicional do método RDDM) com HT e NB, individualmente analisadas, em um gráfico de barras.

No entanto, observa-se que os valores dos resultados não são, de fato, os mesmos encontrados nas Tabelas 16 e 17, pois estes valores foram normalizados. Exibindo os dados no intervalo entre $[-1,1]$, sendo a porção negativa resultados favoráveis ao método tradicional, e

Tabela 17 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o RDDM com NB na abordagem DynamicWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
RDDMN _o W	RDDM001TRAD	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂
RDDM008DW	RDDM001TRAD	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₂	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀
RDDM021DW	RDDM001TRAD	H ₁	H ₀	H ₀	H ₂	H ₀	H ₂	H ₀	H ₀	H ₂	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀
RDDM055DW	RDDM001TRAD	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
		Graduais														
RDDMN _o W	RDDM001TRAD	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂
RDDM008DW	RDDM001TRAD	H ₀	H ₀	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₁	H ₀	H ₂				
RDDM021DW	RDDM001TRAD	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
RDDM055DW	RDDM001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀				
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
RDDMN _o W		2	0	13	-13	1	4	0	11	-11	1	6	0	24	-24	1
RDDM008DW		5	4	6	-2	2	9	1	5	-4	2	14	5	11	-6	2
RDDM021DW		9	3	3	0	3	14	1	0	1	4	23	4	3	1	4
RDDM055DW		12	2	1	1	4	12	0	3	-3	3	24	2	4	-2	3

Fonte: a autora (2022).

a positiva para o DW. Percebe-se uma escala diferente da vista no NW, pois o desempenho do RDDM foi melhor com DW do que com o NW. Então, é possível notar que o classificador HT apresentou um melhor desempenho para o RDDM aplicado ao DW. Dentre as variações avaliadas, o RDDM com HT no tamanho de $w = 55$ instâncias em *Warning* para treinamento teve o melhor resultado, e com NB foi a variação com $w = 21$.

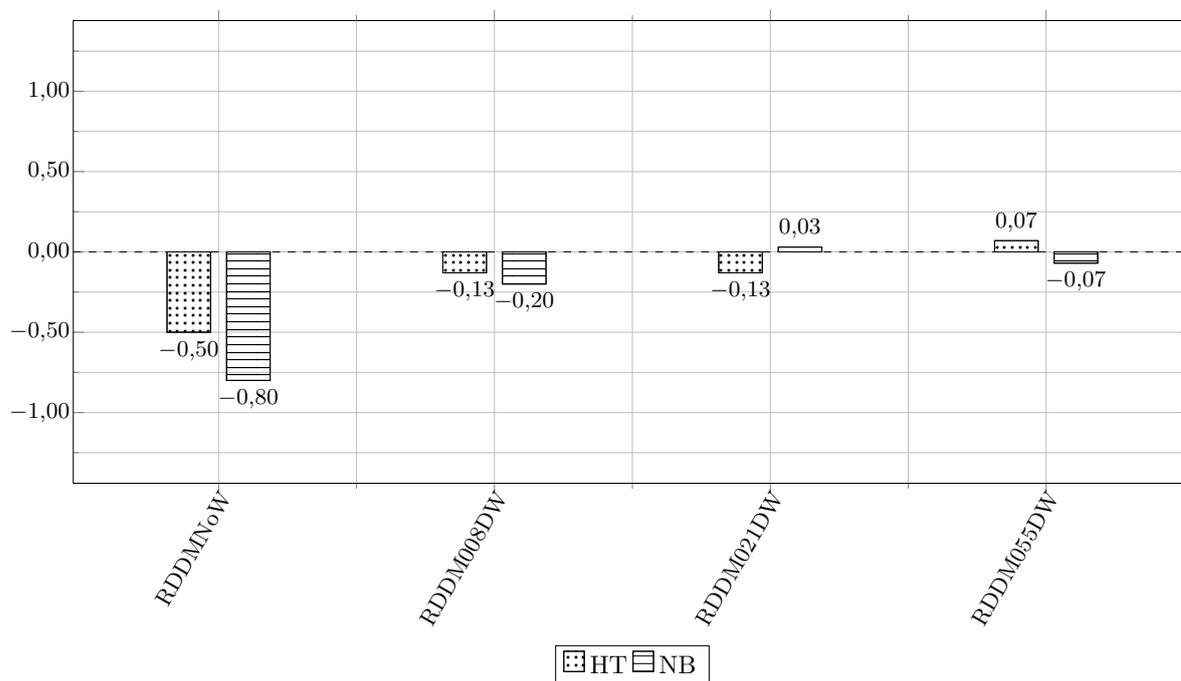
Logo, na Figura 13(b) é apresentado um *rank* geral dos resultados da média do cálculo dos postos de HT e NB para o RDDM aplicado ao DW. Então, nota-se que no *rank* geral, a melhor variação foi o RDDM com $w = 55$ e a pior foi $w = 0$.

5.4.1.4 $USDD_{DynamicWarning} \times USDD_{DDMC}$

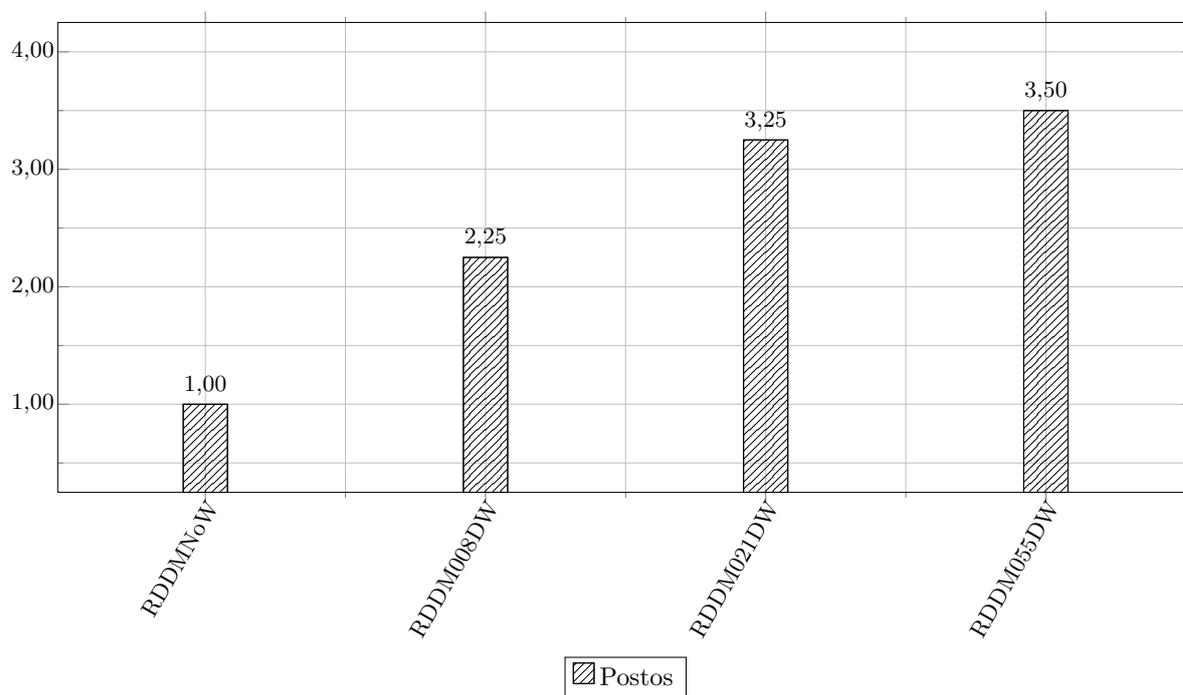
A maior contribuição na melhoria da acurácia *Prequential*, vista com a abordagem adaptativa sugerida nesta seção, o DW, em termos de quantidades de vitórias totais, com HT, foi

Figura 13 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do DynamicWarning com o RDDM.

(a) Diferenças calculadas com HT e NB, individualmente.



(b) Rank das diferenças calculadas com HT e NB normalizadas.



Fonte: a autora (2022).

para o USDD. Nas avaliação do USDD com HT, é visto na Tabela 18 que, igualmente ao NB, os $\sum \sum H_1$ foram superiores os $\sum \sum H_2$ para os tamanhos de $w = 8, 21$ e 55 . Então o DW teve para USDD008DW o $\sum \sum H_1 = 6$ enquanto a para USDD001TRAD o $\sum \sum H_2 =$

0; para USDD021DW o $\sum \sum H_1 = 9$ enquanto para USDD001TRAD o $\sum \sum H_2 = 1$; e para USDD055DW o $\sum \sum H_1 = 9$ enquanto para USDD001TRAD o $\sum \sum H_2 = 0$. Destaca-se para o USDD, com HT e NB, nas mudanças graduais, o fato da abordagem tradicional DDMC ter somente uma superioridade estatística e nas mudanças abruptas, nenhuma.

Tabela 18 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o USDD com HT na abordagem DynamicWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
USDDNoW	USDD001TRAD	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₂	H ₀	H ₀	H ₂	H ₀	H ₀
USDD008DW	USDD001TRAD	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
USDD021DW	USDD001TRAD	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀
USDD055DW	USDD001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀
		Graduais														
USDDNoW	USDD001TRAD	H ₀	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀
USDD008DW	USDD001TRAD	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀
USDD021DW	USDD001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀
USDD055DW	USDD001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀
		Totais														
		Abruptas				Graduais					Geral					
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum \sum H_0$	$\sum \sum H_1$	$\sum \sum H_2$	$\sum \sum H_1 - \sum \sum H_2$	Rank
	USDDNoW	7	0	8	-8	1	9	1	5	-4	1	16	1	13	-12	1
	USDD008DW	13	2	0	2	2	11	4	0	4	3	24	6	0	6	2
	USDD021DW	11	4	0	4	3	9	5	1	4	3	20	9	1	8	3
	USDD055DW	10	5	0	5	4	11	4	0	4	3	21	9	0	9	4

Fonte: a autora (2022).

Em sua avaliação, com NB, observa-se na Tabela 19 que nas parametrizações avaliadas no geral, o DW teve para USDD008DW o $\sum \sum H_1 = 6$ enquanto para USDD001TRAD o $\sum \sum H_2 = 0$; para USDD021DW o $\sum \sum H_1 = 11$ contra USDD001TRAD com o $\sum \sum H_2 = 3$; e para USDD055DW o $\sum \sum H_1 = 6$ enquanto o $\sum \sum H_2 = 2$. Vale ressaltar que, o USDD com a abordagem tradicional DDMC não teve nenhuma superioridade estatística, o $\sum \sum H_1 = 0$, para o tamanho $w = 8$ em relação ao DW.

Em suma, se tratando da avaliação das bases de dados, o USDD com NB aplicado ao DW obteve ótimos resultados. Conquistando a maioria das superioridades estatísticas com LED nas mudanças graduais. Assim como bons resultados com LED_{Abrupta;(w=21);(20k,130k)};

Tabela 19 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia para o USDD com NB na abordagem DynamicWarning.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
USDDNoW	USDD001TRAD	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₂	H ₂	H ₀	H ₂
USDD008DW	USDD001TRAD	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
USDD021DW	USDD001TRAD	H ₀	H ₀	H ₁	H ₁	H ₂	H ₁	H ₁	H ₀	H ₁	H ₀	H ₀				
USDD055DW	USDD001TRAD	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁
		Graduais														
USDDNoW	USDD001TRAD	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₀	H ₂	H ₂	H ₀	H ₂	H ₂
USDD008DW	USDD001TRAD	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀
USDD021DW	USDD001TRAD	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₂	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀
USDD055DW	USDD001TRAD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₁
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
	USDDNoW	3	0	12	-12	1	2	3	10	-7	1	5	3	22	-19	1
	USDD008DW	14	1	0	1	2	10	5	0	5	4	24	6	0	6	3
	USDD021DW	9	5	1	4	4	7	6	2	4	3	16	11	3	8	4
	USDD055DW	12	3	0	3	3	10	3	2	1	2	22	6	2	4	2

Fonte: a autora (2022).

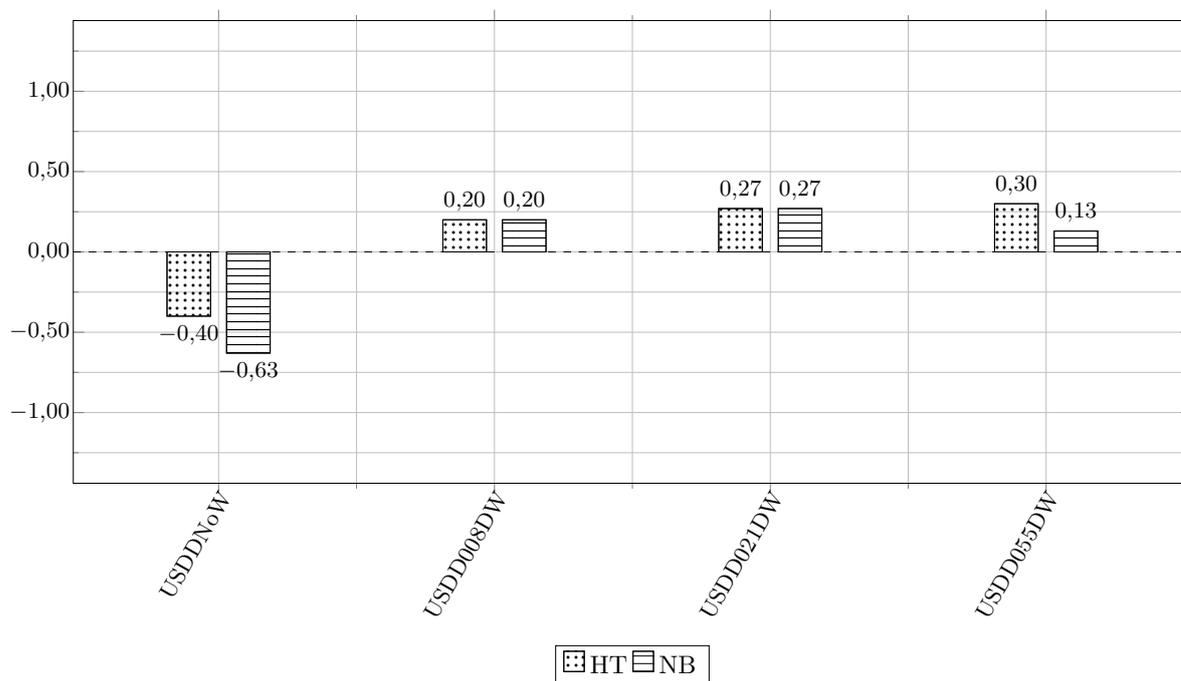
MIX_{Abrupta;(w=21);(20k,130k)}; e Sine_{Abrupta;(w=55);(20k,80k,130k)}. Os resultados observados com HT, se mantiveram favoráveis ao DW, obtendo a maioria das superioridades com LED nas mudanças abruptas e graduais, e com Sine nas mudanças graduais.

Concluindo, a Figura 14 apresenta os últimos dois gráficos de resultados da seção, referentes ao USDD aplicado ao DW, com o objetivo de mostrar a análise de desempenho entre as variações analisadas. Na Figura 14(a) são exibidas as comparações entre as diferenças do $\sum \sum H_1$ (cenário do USDD aplicado ao DW com tamanhos de $w = 0, 8, 21$ e 55 instâncias em Warning) e $\sum \sum H_2$ (resultados da versão tradicional do método USDD) com HT e NB, individualmente analisadas, em um gráfico de barras.

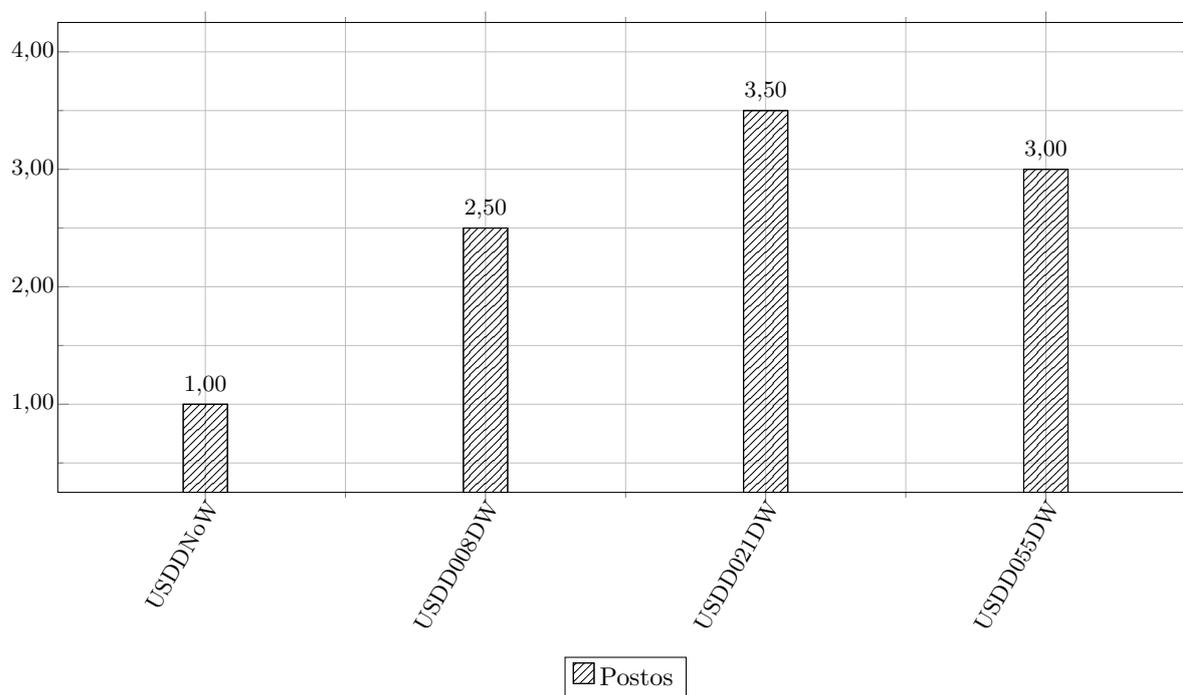
No entanto, nota-se que os valores dos resultados também não são os mesmos encontrados nas Tabelas 18 e 19, pois estes valores foram normalizados. Apresentando os dados no intervalo entre [-1,1], tirando o $w = 0$, prevalece as barras no intervalo entre [0,1], indicando melhor desempenho do DW. Desta maneira, é possível notar que o classificador HT apresentou um

Figura 14 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do DynamicWarning com o USDD.

(a) Diferenças calculadas com HT e NB, individualmente.



(b) Rank das diferenças calculadas com HT e NB normalizadas.



Fonte: a autora (2022).

melhor desempenho para o USDD aplicado ao DW. Dentre as variações avaliadas, o USDD com HT no tamanho de $w = 55$ instâncias em *Warning* para treinamento teve o melhor resultado, e com NB foi a variação com $w = 21$.

Na Figura 14(b) é apresentado um *rank* geral dos resultados da média do cálculo dos postos de HT e NB para o USDD aplicado ao DW. Portanto, observa-se que no *rank* geral, a melhor variação foi o USDD com $w = 21$ e a pior foi $w = 0$. Por fim, é discutida na Seção 6 uma comparação geral entre todas as variações dos quatro métodos aqui experimentados.

5.5 DISCUSSÃO

De acordo com as evidências extraídas das análises dos resultados ao longo desta seção, *as estratégias propostas contribuíram para a melhoria da acurácia Prequential*. Tais proposições corroboraram com as conclusões observadas na Seção 4, sobre a importância e contribuição das instâncias em *Warning* para a melhoria da taxa de acurácia *Prequential* de modelos reconstruídos após mudanças de conceito.

No entanto, a investigação deixou claro que não havia garantias de treinamento para modelos reconstruídos no escopo da abordagem tradicional, no qual, envolvem problemas de única classificação com detecção. Assim, como motivação desta seção, *a criação das estratégias NW e DW utilizaram como base uma técnica que promove a garantia de um conjunto de treinamento aos novos modelos e a retirada da responsabilidade do detector em criar um conjunto de treinamento para novos classificadores após uma mudança de conceito*.

No caso do NW, foi experimentado o uso desta nova técnica que garante um conjunto fixo de treinamento. Esta condição ajuda, principalmente, nos casos onde o modelo não consegue criar e manter um conjunto de instâncias no momento da reconstrução dos modelos. Entretanto, no DW identificou-se que seria relevante também manter as instâncias detectadas como sinal de *Warning* naqueles modelos que contém um conjunto maior do que o proposto pela técnica, mesclando a nova técnica, proposta pelo NW, e a tradicionalmente utilizada pelo DDMC.

Outro questionamento levantado na seção foi a falta de uniformidade de avaliação de desempenho dos métodos de detecção em relação a acurácia. Isto porque métodos que não têm o sinal de detecção *Warning* em sua implementação, usualmente, são comparados com métodos que têm o sinal de detecção *Warning* e que detectam bem estes sinais.

Assim, *a técnica aplicada as propostas abrangem a possibilidade de padronizar a quantidade de instâncias que serão utilizadas para treinamento em caso de mudança de conceito, assim, proporcionando avaliações de desempenho mais justas de métodos detectores direcionada a análise da acurácia Prequential em relação ao rastreamento da mudança de conceito*. Desta

forma, a estratégia de rastreamento, em si, da mudança de conceito é o que deve ser levado em consideração pelos métodos de detecção de mudança de conceito.

Um outro ponto questionado e que mereceu atenção das estratégias propostas foi a não aplicação de mais de um modelo de decisão por vez. Assim, *somente quando há a detecção de uma mudança de conceito, o NW e o DW reiniciam o treinamento do modelo atual, utilizando as instâncias armazenadas na janela deslizante para treinar esse modelo do zero*. Não havendo a necessidade de criar um modelo adicional e treiná-lo, sabendo que ele pode ser descartado sem ser utilizado, caracterizando um custo computacional desnecessário, como observado na AACD.

Portanto, há, de fato, evidências de melhorias da acurácia *Prequential* em modelos previamente treinados. E as otimizações propostas nesta seção corroboraram para obter estas melhorias, dados os resultados apresentados nas avaliações.

5.6 CONSIDERAÇÕES FINAIS

Esta seção teve como objetivo propor diferentes estratégias a fim de melhorar os valores de acurácia *Prequential* dos modelos de decisão quando existe a detecção de mudanças de conceito em fluxo de dados. Além de contribuir para melhor alguns aspectos da metodologia de AACD.

Mais especificamente, as estratégias tiveram o intuito de propor maneiras de realizar melhorias nos aspectos do aprendizado em fluxo de dados. Além disso, com o desenvolvimento de tais propostas, foi possível aumentar as possibilidades de escolha de metodologia de aprendizado para os problemas da área.

Dentre estes aspectos do aprendizado, inclui-se a garantia de uma quantidade mínima de treinamento para os novos modelos de decisão após a detecção de uma mudança de conceito pelos métodos detectores. A retirada da responsabilidade de treinar os novos modelos destes métodos detectores, já que a tarefa é associada a classificação, podendo assim, esses métodos de detecção focarem no ato de detectar, de fato, a mudança de conceito. Como também, evitar a criação e treinamento de modelos auxiliares, que dependendo da ordem dos sinais de detecção disparados, são descartados sem serem utilizados na estratégia de AACD.

Portanto, observou-se que as estratégias NW e DW conseguiram cumprir com o proposto, garantindo melhorias nos aspectos sugeridos e na acurácia *Prequential*. No caso do NW, obteve-se as melhores contribuições para o FHDDM e para o DDM nos dois classificadores

avaliados. Também houve contribuição, especificamente para um caso, com o USDD nos dois classificadores. No entanto, não houve melhorias com o RDDM aplicado ao NW, em relação a acurácia *Prequential*.

Referente ao DW, houve uma significativa contribuição dessa estratégia para a acurácia *Prequential* para três dos quatro algoritmos avaliados: DDM, FHDDM e USDD tanto para HT quanto para NB. Além disso, houve contribuição para o RDDM em alguns casos específicos, diferentemente do resultado visto no NW.

Por fim, observou-se que para o DDM e o FHDDM os melhores resultados foram relativos ao classificador NB. Contrariamente, para os métodos RDDM e USDD, os melhores resultados foram com o HT. Em relação aos tamanhos de treinamento (w), também não houve um consenso entre os métodos, com o DDM sendo melhor para $w = 8$, FHDDM empatando em $w = 8$ e 21, e RDDM e USDD na maior parte dos casos para $w = 55$.

6 AVALIAÇÃO DE DESEMPENHO DOS DETECTORES

De acordo com os questionamentos levantados no decorrer desta tese e, juntamente, com os resultados alcançados nas Seções 4 e 5, esta seção apresenta uma análise dos métodos de detecção de mudança de conceito na modalidade tradicional e retirando os seus sinais de detecção *Warning* para entender o comportamento de seus desempenhos. Além disso, é realizada uma avaliação geral com as variações do ADDM, incluindo a avaliação no ponto ideal, com e sem instâncias em *Warning* para treinamento, e outra com todos os detectores na abordagem tradicional e todos os detectores com o NW e o DW em suas variações de tamanho de treinamento já experimentadas.

A seção está organizado em 5 subseções. Inicialmente, na Subseção 6.1 é apresentada as indagações e justificativas para se utilizar as abordagens propostas nesta tese. Em sequência, a Subseção 6.2 descreve as configurações utilizadas para encontrar as inferências sobre as avaliações tradicional, sem *Warning* e gerais. Na Seção 6.3 são apresentados os resultados e as análises referentes as quatro avaliações propostas nesta seção. Em seguida, a Subseção 6.4 traz as discussões sobre a relevância destas inferências. Por fim, a Subseção 6.5 apresenta as conclusões sobre estas análises.

6.1 CONTEXTUALIZAÇÃO

Ao longo das seções desta tese, foi questionado a responsabilidade que os detectores têm de gerenciar o conjunto de treinamento que é utilizado para treinar os novos modelos de decisão quando é detectada uma mudança de conceito. Enquanto eles deveriam focar, de fato, na detecção da mudança de conceito. Por este motivo, avaliar os detectores por meio da acurácia *Prequential* pode não ser uma boa prática, porém, é a forma utilizada na literatura hoje.

Assim, para se compreender melhor o comportamento (de costume) e verificar qual o melhor resultado de uma avaliação entre os métodos de detecção, da forma semelhante como é feita tradicionalmente pelas publicações da literatura da área, nesta seção, é elaborada experimentações com os quatro detectores avaliados nesta pesquisa: DDM, FHDDM, RDDM e USDD.

Com estes resultados é possível analisar, por meio das novas estratégias propostas na Seção 5, que questionam a metodologia de AACD, o porquê destes questionamentos. Em suma, é

realizada uma avaliação retirando os sinais de *Warning* dos métodos de detecção avaliados e é observado as mudanças em seu comportamento, assim como expressado na narrativa da Seção 4. Portanto, admite-se que, *as estratégias propostas são viáveis para aplicar uma nova, diferente e mais justa maneira de avaliação de desempenho dos métodos de detecção de mudança de conceito, além do fato destas melhorarem as suas taxas de acurácia Prequential.*

A motivação destas propostas é devida as diversas características encontradas nas implementações de cada detector e que nas avaliações tradicionais não são levadas em consideração. Quer dizer, os métodos de detecção são avaliados sem levar em consideração implicações como, haver detectores que são melhores em rastrear mudanças de conceito e outros são melhores em rastrear os sinais de detecção *Warning*. Inclusive, a (provável injusta) avaliação de métodos que não utilizam o *Warning*, sendo avaliados competitivamente com aqueles que os utilizam.

Naturalmente, nas avaliações artificiais, os parâmetros dos métodos de detecção, as bases de dados e os ponto de mudança de conceito são dados controlados. Porém, para o rastreamento da mudança de conceito, não há uma padronização e controle do conjunto de treinamento. Portanto, pode não ser interessante usar a abordagem tradicional, mas sim, uma abordagem que tenha o controle deste rastreamento das mudanças de maneira semelhante para todos os métodos.

Por fim, é importante ressaltar que a escolha dos parâmetro de rastreamento das mudanças de conceito são independentes, e devem ser avaliados de acordo com cada situação. Tanto que, nas avaliações da Seção 5 não há determinação do melhor tamanho de w , pois foi visto que não há um padrão nos resultados evidenciados. No entanto, a pesquisa por um tamanho padrão pode ser elaborada futuramente.

6.2 CONFIGURAÇÃO EXPERIMENTAL E METODOLOGIA

De acordo com os resultados extraídos dos experimentos baseados nas configurações da Seção 3 de metodologia, em relação a geradores de bases de dados artificiais, pontos e velocidades de mudança de conceito, além das configurações definidas na Seção 4 sobre as novas estratégias, esta seção demanda uma explicação adicional sobre a forma como estes resultados foram analisados para afirmar as suas conclusões. Para esta análise são apresentados os resultados avaliativos dos desempenhos dos quatro métodos de detecção de mudança de conceito reais e o artificial, selecionados nesta pesquisa.

São observadas quatro análises: (1) comparação dos quatro métodos reais entre si; (2)

comparação destes mesmos métodos entre si, só que com o tratamento dos sinais de *Warning* desativados; (3) comparação do método artificial em sua versão convencional (ponto de mudança igual ao ponto de detecção) e as variações de w com e sem utilizar instâncias para treinamento; e (4) comparação dos quatro métodos reais, em sua versão tradicional, e as variações de w para o NW e DW.

Assim, é apresentada uma avaliação estatística, como mostrado nas seções anteriores, baseadas no teste pareado de *Wilcoxon* em relação aos classificadores HT e NB, analisando os resultados de acurácia *Prequential* para as mudanças de conceito do tipo abruptas e graduais. Como as comparações não têm cenários fixos para a avaliação estatística dos detectores, envolvendo os diversos métodos e suas variações, as combinações são organizadas da seguinte forma: o método/variação da esquerda é considerado μ_1 e o da direita μ_2 .

Por exemplo, DDM x FHDDM, neste caso, DDM é μ_1 , portanto $\sum H_1$ representa o somatório das superioridades estatísticas do DDM em relação ao FHDDM, e $\sum H_2$ o somatório das superioridades estatísticas do FHDDM em relação ao DDM; No entanto quando for FHDDM x RDDM, o FHDDM é μ_1 , sendo o $\sum H_1$ representada pelo somatório das superioridades estatísticas do FHDDM em relação ao RDDM, e $\sum H_2$ o somatório das superioridades estatísticas do RDDM em relação ao FHDDM.

Nesta subseção, especificamente, as tabelas apresentam em suas linhas repetições dos métodos ou variações, já que a análise é dada em função das suas combinações. Portanto, não é possível fazer a contabilização das somas equivalente a cada linha, como proposto na Seção 3 e utilizado nas outras seções. Para tanto, aqui, é listado na análise de cada tabela somente uma única vez o nome do método/variação. Então, o somatório é feito contabilizando as H_0 , H_1 e H_2 referente a cada linha no qual o método foi comparado. Lembrando que a inversão da ordem de comparação em pares, inverte a referência de H_1 e H_2 dos métodos ou variações.

Portanto, por mais que a configuração para leitura dos resultados desta seção sejam diferentes, a análise final pode ser compreendida da mesma maneira como é realizada nas Seções 4 e 5. Baseadas nas diretrizes metodológicas da Seção 3.

6.3 RESULTADOS E ANÁLISE

Esta seção tem como objetivo apresentar e analisar os resultados das avaliações de forma geral. Assim, está organizada em duas subseções que mostram, primeiramente, a avaliação dos métodos tradicionais utilizados ao longo da tese, na Subseção 6.3.1 e as avaliações gerais,

referentes as Seções 4 e 5, na Subseção 6.3.2.

6.3.1 Tradicional e Sem Warning

Nesta subseção são apresentados os resultados das combinações de comparações dos métodos de detecção de mudança de conceito DDM, FHDDM, RDDM e USDD em sua versão tradicional, utilizando o DDMC. Da mesma maneira, são apresentados os resultados das combinações de comparações destes mesmos detectores, porém, executados com o NW, com $w = 0$, para simular uma versão sem sinais de detecção *Warning*, igualmente comparados entre si.

Assim, as Tabelas 20 e 21 apresentam os resultados e análises das comparações das versões tradicionais dos métodos, com HT e NB, respectivamente. O método mais bem avaliado para os dois classificadores, nota-se que foi o RDDM, com uma diferença entre o somatório geral $RDDM001TRAD = 17$ para HT e $RDDM001TRAD = 32$ para NB. Parcialmente, observa-se que o USDD foi melhor nas mudanças graduais de HT e NB, e nas mudanças abruptas de NB, o FHDDM foi melhor. Porém no geral, o RDDM os superou.

A Figura 15 exibe os dois gráficos referentes a esta análise dos métodos tradicionais, com o objetivo de mostrar o desempenho entre eles, como é visto na literatura. Na Figura 15(a) são exibidas as comparações de desempenho de cada um dos métodos em um gráfico de barras entre HT e NB, individualmente analisadas.

No entanto, observa-se que os valores dos resultados não são, de fato, os mesmos encontrados nas Tabelas 20 e 21, pois estes valores foram normalizados. Na imagem é observado que somente o DDM fica no intervalo entre $[-1,0]$, indicando um mal desempenho do método. Em relação aos classificadores, é possível notar que o NB apresentou melhores resultados para os métodos FHDDM, RDDM e USDD; e o pior resultado para o DDM. E o método que teve o melhor desempenho para HT e o NB foi o RDDM.

Logo, na Figura 15(b) é apresentado o *rank* geral (entre HT e NB) dos resultados da média do cálculo dos postos para esta avaliação entre os métodos tradicionais. Então, nota-se que no *rank* geral, a melhor variação foi o RDDM e a pior foi DDM.

Com relação as avaliações sem sinais de detecção *Warning*, as Tabelas 22 e 23 mostram os resultados e análises das combinações das comparações dos detectores, com HT e NB, respectivamente. Neste caso, o FHDDM foi o método de detecção com o melhor comportamento, tendo uma diferença entre o somatório geral $FHDDM001TRAD = 28$ para HT e NB. Inclusive, o FHDDM se manteve como o melhor método para quase todos os casos particulares

Tabela 20 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia dos detectores DDM, FHDDM, RDDM e USDD nas versões tradicionais para HT.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
DDM	FHDDM	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM	RDDM	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₂	H ₀	H ₂
DDM	USDD	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
FHDDM	RDDM	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁
FHDDM	USDD	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁
RDDM	USDD	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁	H ₂	H ₂	H ₁	H ₁	H ₁	H ₀	H ₂	H ₂
		Graduais														
DDM	FHDDM	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM	RDDM	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀
DDM	USDD	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
FHDDM	RDDM	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁
FHDDM	USDD	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀
RDDM	USDD	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
		Totais														
		Abruptas				Graduais				Geral						
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum_{H_1} H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum_{H_1} H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum_{H_1} H_2$	Rank
DDM		8	10	27	-17	1	11	10	24	-14	1	19	20	51	-31	1
FHDDM		7	22	16	6	3	12	17	16	1	2	19	39	32	7	2,5
RDDM		9	24	12	12	4	10	20	15	5	3	19	44	27	17	4
USDD		6	19	20	-1	2	11	21	13	8	4	17	40	33	7	2,5

Fonte: a autora (2022).

(abruptas e graduais), perdendo para o USDD somente na mudanças graduais com NB.

A Figura 16 exibe os dois gráficos referentes a esta análise dos métodos tradicionais sem seus sinais de detecção *Warning* (para os que contemplam), com o objetivo de mostrar o desempenho entre eles, em relação ao desempenho somente do rastreamento da mudança de conceito. Na Figura 16(a) são exibidas as comparações de desempenho de cada um dos métodos em um gráfico de barras entre HT e NB, individualmente analisadas.

Porém, observa-se que os valores dos resultados não são, de fato, os mesmos encontrados nas Tabelas 22 e 23, pois estes valores foram normalizados. Na imagem é observado que o

Tabela 21 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia dos detectores DDM, FHDDM, RDDM e USDD nas versões tradicionais para NB.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
DDM	FHDDM	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂
DDM	RDDM	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂
DDM	USDD	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂
FHDDM	RDDM	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁
FHDDM	USDD	H ₀	H ₀	H ₂	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁
RDDM	USDD	H ₁	H ₁	H ₁	H ₁	H ₁	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₀	H ₂
		Graduais														
DDM	FHDDM	H ₂	H ₂	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂
DDM	RDDM	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂
DDM	USDD	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂				
FHDDM	RDDM	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₀	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀
FHDDM	USDD	H ₀	H ₀	H ₂	H ₀	H ₂	H ₂	H ₁	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀
RDDM	USDD	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
DDM		2	0	43	-43	1	3	0	42	-42	1	5	0	85	-85	1
FHDDM		4	30	11	19	4	14	18	13	5	2	18	48	24	24	2
RDDM		3	28	14	14	3	9	27	9	18	3	12	55	23	32	4
USDD		9	23	13	10	2	12	26	7	19	4	21	49	20	29	3

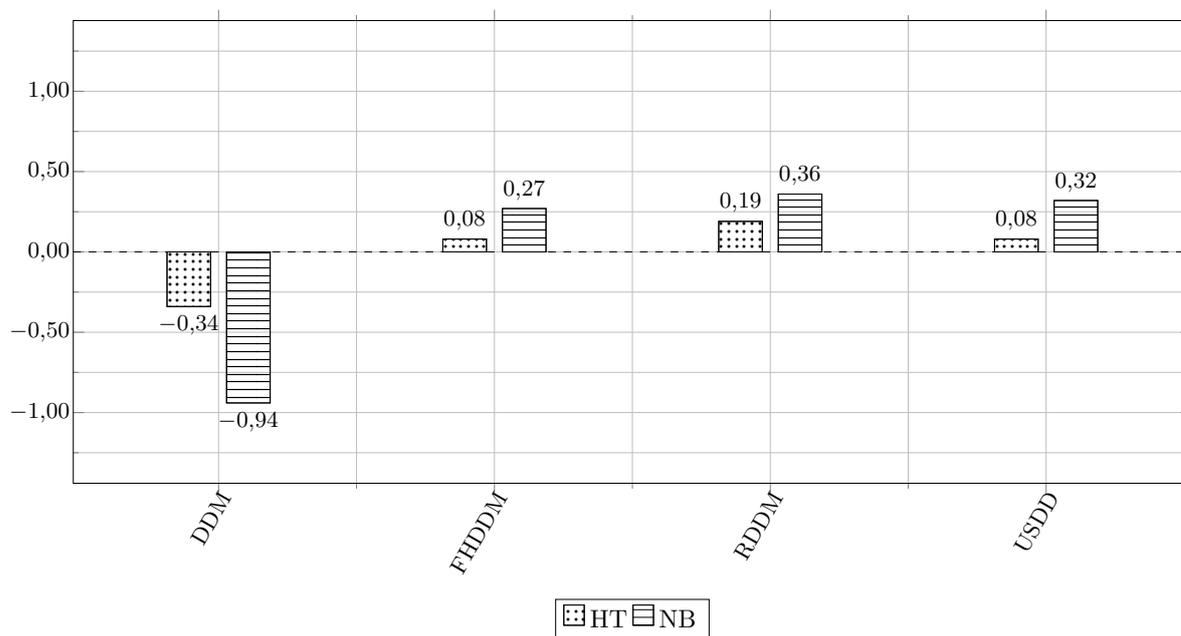
Fonte: a autora (2022).

DDM se mantém como o método com pior desempenho, ficando no intervalo entre [-1,0], comportamento visto também com o RDDM e USDD com HT. Referente aos classificadores, é possível notar que para o RDDM e USDD, obviamente para o NB, apresentou melhores resultados. E o DDM se manteve com pior desempenho para o NB. E o melhor desempenho, para HT e NB, foi para o FHDDM que ficou empatado o resultado para os dois classificadores.

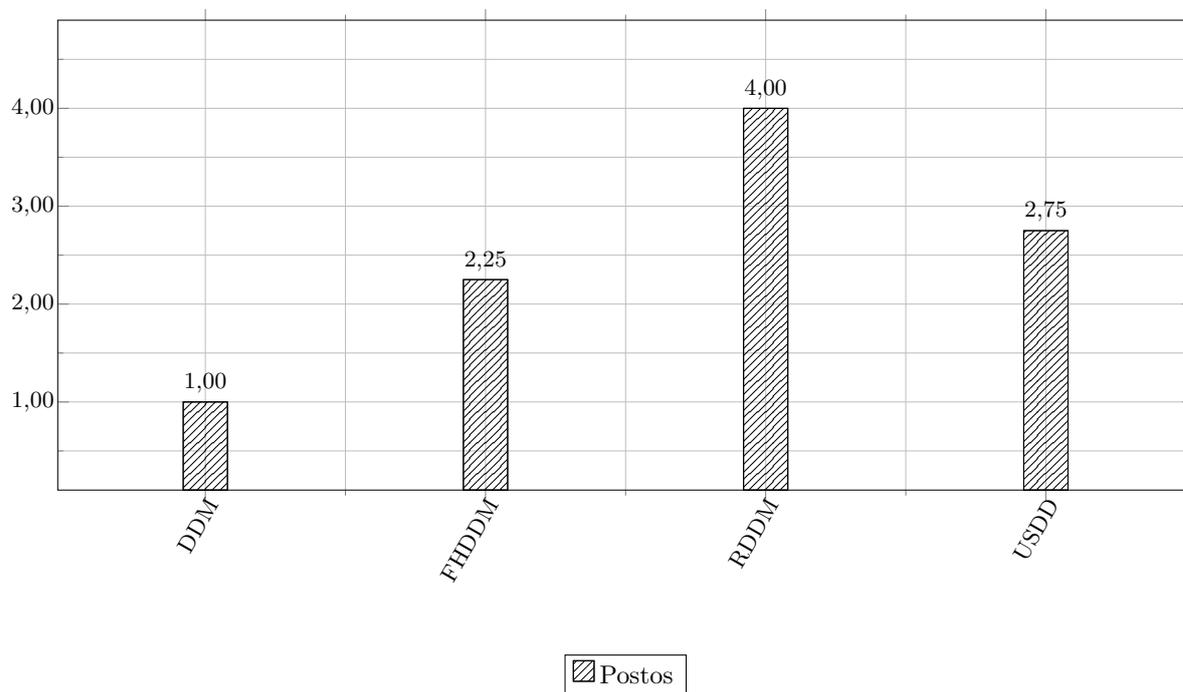
Assim, na Figura 16(b) é apresentado o *rank* geral (entre HT e NB) dos resultados da média do cálculo dos postos para esta avaliação entre os métodos tradicionais sendo retirados os sinais de *Warning*. Portanto, observou-se que no *rank* geral, o melhor método foi o FHDDM

Figura 15 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações dos métodos tradicionais.

(a) Diferenças calculadas com HT e NB, individualmente.



(b) Rank das diferenças calculadas com HT e NB normalizadas.



Fonte: a autora (2022).

e o pior, ainda, foi DDM.

Tabela 22 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia dos detectores DDM, FHDDM, RDDM e USDD nas versões sem Warning com HT.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
DDM	FHDDM	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂
DDM	RDDM	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	H ₂
DDM	USDD	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
FHDDM	RDDM	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁
FHDDM	USDD	H ₀	H ₀	H ₀	H ₁	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁
RDDM	USDD	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁	H ₂	H ₂	H ₁	H ₁	H ₁	H ₀	H ₂	H ₂
		Graduais														
DDM	FHDDM	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₁	H ₁	H ₂	H ₀	H ₂
DDM	RDDM	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀
DDM	USDD	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₁	H ₁	H ₂	H ₀	H ₂
FHDDM	RDDM	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁
FHDDM	USDD	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₀	H ₂	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀
RDDM	USDD	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum_{H_1} - \sum_{H_2}$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum_{H_1} - \sum_{H_2}$	Rank	$\sum \sum H_0$	$\sum \sum H_1$	$\sum \sum H_2$	$\sum \sum_{H_1} - \sum \sum_{H_2}$	Rank
DDM		11	10	24	-14	1	15	13	17	-4	2	26	23	41	-18	1
FHDDM		7	29	9	20	4	13	20	12	8	4	20	49	21	28	4
RDDM		10	19	16	3	3	9	15	21	-6	1	19	34	37	-3	3
USDD		6	15	24	-9	2	11	18	16	2	3	17	33	40	-7	2

Fonte: a autora (2022).

6.3.2 Comparação Exaustiva

Nesta subsecção são apresentados os resultados das comparações com as combinações das variações do ADDM com e sem treinamento para $w = 8, 21$ e 55 , incluindo o ADDM com $w = 0$, que representa a detecção de mudança no ponto perfeito (sem atrasos e ruídos). Assim como, é apresentada as combinações comparando os quatro métodos tradicionais e as 24 variações deles com tamanhos de $w = 8, 21$ e 55 para as duas abordagens propostas, NW e DW. As tabelas com os valores de resultados destas comparações são muito longas, portanto,

Tabela 23 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia dos detectores DDM, FHDDM, RDDM e USDD nas versões sem Warning com NB.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
DDM	FHDDM	H ₂	H ₀	H ₀	H ₂	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂
DDM	RDDM	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂
DDM	USDD	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂
FHDDM	RDDM	H ₀	H ₂	H ₂	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁
FHDDM	USDD	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁
RDDM	USDD	H ₁	H ₁	H ₁	H ₁	H ₀	H ₂	H ₁	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₂	H ₂
		Graduais														
DDM	FHDDM	H ₀	H ₀	H ₀	H ₂	H ₁	H ₁	H ₂	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂
DDM	RDDM	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂
DDM	USDD	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂
FHDDM	RDDM	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁	H ₀	H ₁	H ₁	H ₁	H ₁	H ₁
FHDDM	USDD	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₁
RDDM	USDD	H ₁	H ₁	H ₁	H ₁	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂
		Totais														
		Abruptas					Graduais					Geral				
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
DDM		7	2	36	-34	1	11	8	26	-18	1	18	10	62	-52	1
FHDDM		8	29	8	21	4	12	20	13	7	3	20	49	21	28	4
RDDM		3	25	17	8	3	4	21	20	1	2	7	46	37	9	2
USDD		10	20	15	5	2	13	21	11	10	4	23	41	26	15	3

Fonte: a autora (2022).

estão presentes no Apêndice A.

Tabela 24 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia na comparação geral do ADDM no ponto ideal e suas variações para HT.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
ADDMW0	ADDMW008	H ₀	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁								
ADDMW0	ADDMW021	H ₁	H ₀	H ₁	H ₂	H ₂	H ₂	H ₁								

ADDMW0	ADDMW055	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁								
ADDMW0	ADDMWW008	H ₀	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁				
ADDMW0	ADDMWW021	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁						
ADDMW0	ADDMWW055	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁						
ADDMW008	ADDMW021	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁								
ADDMW008	ADDMW055	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁								
ADDMW008	ADDMWW008	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₁	H ₁	H ₁					
ADDMW008	ADDMWW021	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁						
ADDMW008	ADDMWW055	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁						
ADDMW021	ADDMW055	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁								
ADDMW021	ADDMWW008	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂
ADDMW021	ADDMWW021	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁					
ADDMW021	ADDMWW055	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁						
ADDMW055	ADDMWW008	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂
ADDMW055	ADDMWW021	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂
ADDMW055	ADDMWW055	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀						
ADDMWW008	ADDMWW021	H ₁	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁							
ADDMWW008	ADDMWW055	H ₁	H ₀	H ₀	H ₁	H ₀	H ₁	H ₁	H ₁							
ADDMWW021	ADDMWW055	H ₁	H ₀	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁						

		Graduais														
ADDMW0	ADDMW008	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁					
ADDMW0	ADDMW021	H ₂	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₀					
ADDMW0	ADDMW055	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁	H ₁	H ₀					
ADDMW0	ADDMWW008	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₁	H ₀							
ADDMW0	ADDMWW021	H ₀	H ₁	H ₀												
ADDMW0	ADDMWW055	H ₀	H ₁	H ₁	H ₀											
ADDMW008	ADDMW021	H ₂	H ₀	H ₁	H ₂	H ₂	H ₀	H ₂	H ₂	H ₁	H ₂					
ADDMW008	ADDMW055	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁	H ₁	H ₀					
ADDMW008	ADDMWW008	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀								
ADDMW008	ADDMWW021	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₀	H ₁	H ₀						
ADDMW008	ADDMWW055	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₁	H ₁	H ₀						
ADDMW021	ADDMW055	H ₂	H ₁	H ₁	H ₁	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁					
ADDMW021	ADDMWW008	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₀	H ₁	H ₀				
ADDMW021	ADDMWW021	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₁	H ₀						
ADDMW021	ADDMWW055	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₀							
ADDMW055	ADDMWW008	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₀	H ₁	H ₀	H ₀	H ₂	H ₀	H ₂
ADDMW055	ADDMWW021	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₀							
ADDMW055	ADDMWW055	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀								
ADDMWW008	ADDMWW021	H ₀	H ₁	H ₀	H ₂	H ₀										
ADDMWW008	ADDMWW055	H ₀	H ₁	H ₁	H ₀											
ADDMWW021	ADDMWW055	H ₀	H ₁	H ₀												

Totais

Abruptas

Graduais

Geral

	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
ADDMW0	19	61	10	51	7	47	15	28	-13	2	66	76	38	38	6
ADDMW008	19	56	15	41	6	42	24	24	0	5	61	80	39	41	7
ADDMW021	16	42	32	10	4	39	38	13	25	7	55	80	45	35	5
ADDMW055	16	24	50	-26	3	31	38	21	17	6	47	62	71	-9	3
ADDMW008	34	37	19	18	5	68	9	13	-4	4	102	46	32	14	4
ADDMW021	25	18	47	-29	2	74	3	13	-10	3	99	21	60	-39	2
ADDMW055	25	0	65	-65	1	75	0	15	-15	1	100	0	80	-80	1

Fonte: a autora (2022).

Tabela 25 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia na comparação geral do ADDM no ponto ideal e suas variações para NB.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
ADDMW0	ADDMW008	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁								
ADDMW0	ADDMW021	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁								
ADDMW0	ADDMW055	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁								
ADDMW0	ADDMW008	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁
ADDMW0	ADDMW021	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₁								
ADDMW0	ADDMW055	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁
ADDMW008	ADDMW021	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁								
ADDMW008	ADDMW055	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁								
ADDMW008	ADDMW008	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀
ADDMW008	ADDMW021	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁
ADDMW008	ADDMW055	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁
ADDMW021	ADDMW055	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁								
ADDMW021	ADDMW008	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂								
ADDMW021	ADDMW021	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁
ADDMW021	ADDMW055	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁
ADDMW055	ADDMW008	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂								
ADDMW055	ADDMW021	H ₁	H ₁	H ₀	H ₁	H ₁	H ₁	H ₂								
ADDMW055	ADDMW055	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₀	H ₁	H ₁	H ₁	H ₀	H ₁
ADDMW008	ADDMW021	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁
ADDMW008	ADDMW055	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁
ADDMW021	ADDMW055	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁	H ₁
		Graduais														
ADDMW0	ADDMW008	H ₂	H ₂	H ₂	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁

ADDMW0	ADDMW021	H ₂	H ₀	H ₁	H ₁	H ₂	H ₀	H ₂	H ₀	H ₁	H ₀					
ADDMW0	ADDMW055	H ₂	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁					
ADDMW0	ADDMWW008	H ₀	H ₁	H ₁	H ₀	H ₁	H ₁									
ADDMW0	ADDMWW021	H ₂	H ₀	H ₂	H ₀	H ₁	H ₀	H ₀	H ₁	H ₀	H ₁	H ₁				
ADDMW0	ADDMWW055	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₂	H ₁	H ₁	H ₁
ADDMW008	ADDMW021	H ₂	H ₀	H ₁	H ₂	H ₂	H ₁	H ₂	H ₀	H ₁	H ₂					
ADDMW008	ADDMW055	H ₂	H ₁	H ₁	H ₁	H ₀	H ₁	H ₀	H ₁	H ₁	H ₁					
ADDMW008	ADDMWW008	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₀	H ₂	H ₀					
ADDMW008	ADDMWW021	H ₀	H ₀	H ₂	H ₁	H ₁	H ₁	H ₀	H ₁	H ₀	H ₁	H ₁				
ADDMW008	ADDMWW055	H ₀	H ₂	H ₂	H ₀	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₂	H ₁	H ₁	H ₁
ADDMW021	ADDMW055	H ₂	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁					
ADDMW021	ADDMWW008	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₂	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁
ADDMW021	ADDMWW021	H ₀	H ₀	H ₂	H ₁	H ₁	H ₁	H ₀	H ₁	H ₀	H ₁	H ₁				
ADDMW021	ADDMWW055	H ₀	H ₂	H ₂	H ₁	H ₀	H ₀	H ₀	H ₂	H ₁	H ₁	H ₁				
ADDMW055	ADDMWW008	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀
ADDMW055	ADDMWW021	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₂	H ₁	H ₁
ADDMW055	ADDMWW055	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₀	H ₁	H ₁				
ADDMWW008	ADDMWW021	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₁
ADDMWW008	ADDMWW055	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₂	H ₁	H ₁	H ₁
ADDMWW021	ADDMWW055	H ₀	H ₂	H ₀	H ₂	H ₀	H ₀	H ₁	H ₀	H ₁	H ₀	H ₀	H ₂	H ₁	H ₁	H ₁

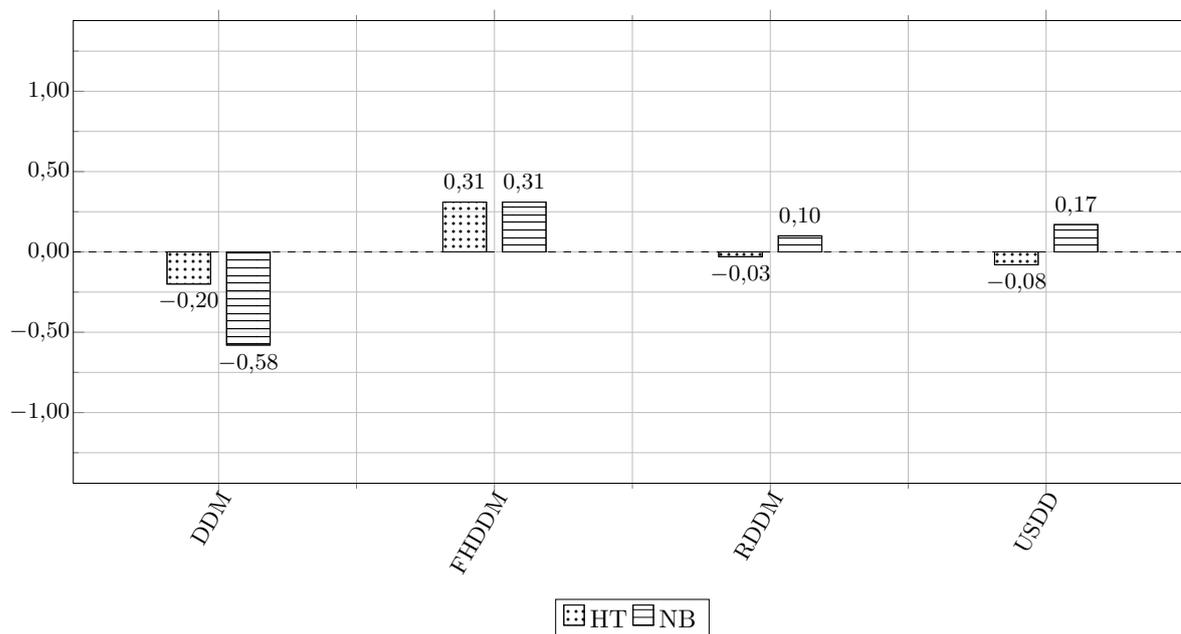
	Totais														
	Abruptas					Graduais					Geral				
	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
ADDMW0	9	72	9	63	7	34	27	29	-2	4	43	99	38	61	7
ADDMW008	8	65	17	48	6	29	36	25	11	6	37	101	42	59	6
ADDMW021	5	49	36	13	4	27	46	17	29	7	32	95	53	42	5
ADDMW055	6	30	54	-24	3	29	32	29	3	5	35	62	83	-21	3
ADDMWW008	18	48	24	24	5	48	17	25	-8	3	66	65	49	16	4
ADDMWW021	6	24	60	-36	2	48	14	28	-14	2	54	38	88	-50	2
ADDMWW055	2	0	88	-88	1	35	18	37	-19	1	37	18	125	-107	1

Fonte: a autora (2022).

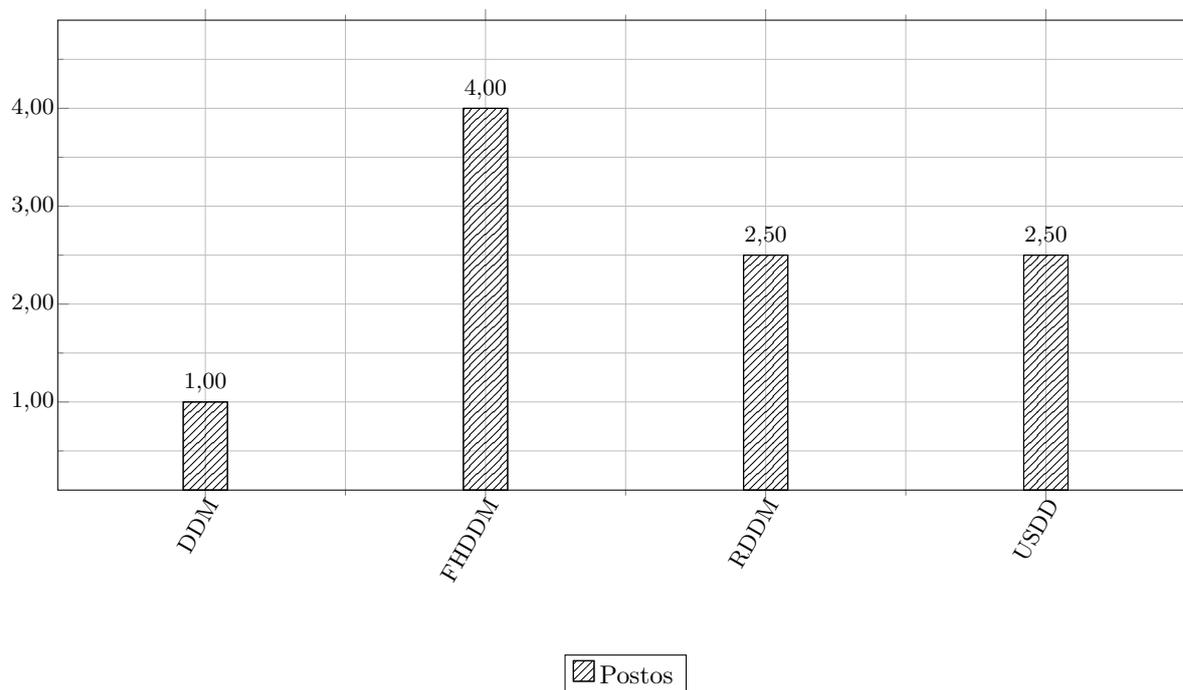
Nas Tabelas 24 e 25 são exibidas as combinações das comparações do método de detecção artificial ADDM, estudo de caso referentes a Seção 4. Neste caso, há uma variação acrescentada para que o resultado geral pudesse ser comparado ao *benchmark*, que é o caso ideal. Assim, pode-se observar que os resultados para HT e NB foram muito parecidos, somente alterando os dois melhores desempenhos em cada um dos classificadores. No NB o melhor foi a variação com instâncias em *Warning* para treinamento com $w = 8$, o somatório geral do $ADDM_{w=8} = 41$ e do $ADDM_{w=0} = 38$. E no HT o melhor foi a variação do ponto ideal, onde

Figura 16 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações dos métodos tradicionais sem sinais de Warning.

(a) Diferenças calculadas com HT e NB, individualmente.



(b) Rank das diferenças calculadas com HT e NB normalizadas.

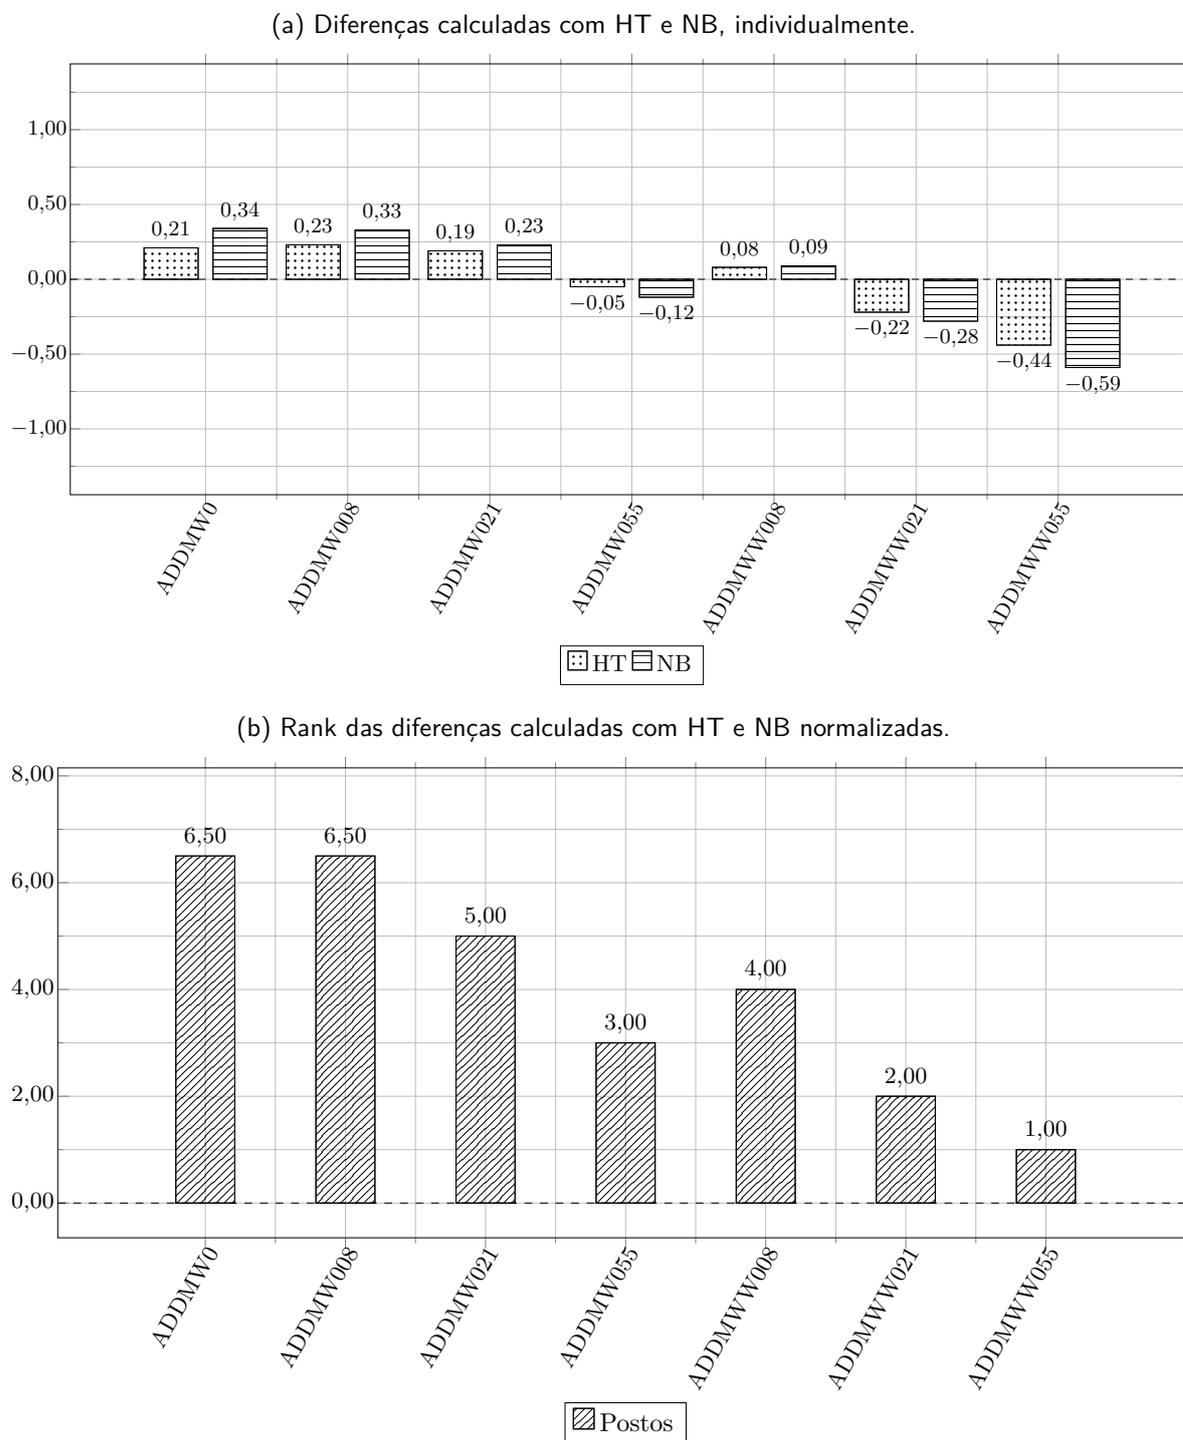


Fonte: a autora (2022).

o somatório geral foi $ADDMM_{w=8} = 59$ e do $ADDMM_{w=0} = 61$. Vale salientar que, os valores das diferenças de somatórios gerais para esses casos foi bem próximo, indicando que a variação com $w = 8$ proporciona resultados excelentes. Nas mudanças abruptas com HT e NB, como esperado, o $ADDMM_{w=0}$ ficou na melhor posição seguido do $ADDMM_{w=8}$. Nas graduais, para os

dois classificadores, a melhor variação foi o $ADDM_{w=21}$.

Figura 17 – Resumo dos ranks de acurácia Prequential com HT e NB. Considerando comparações com parametrizações do método ADDM.



Fonte: a autora (2022).

Para corroborar com esta informação, a Figura 17 exibe os dois gráficos referentes à análise do método ADDM, com o objetivo de apresentar o desempenho entre a variação ideal e as variações ($w = 8, 21$ e 55) com e sem sinais de *Warning*. Na Figura 17(a) são mostradas as

comparações de desempenho de cada uma das variações em um gráfico de barras entre HT e NB, individualmente analisadas.

Entretanto, nota-se que os valores dos resultados não são, de fato, os mesmos encontrados nas Tabelas 24 e 25, pois estes valores foram normalizados. Na imagem observa-se que a variação no ponto ideal ($w = 0$) e as variações com treinamento de tamanho $w = 8$ e 21 obtiveram os melhores resultados. Nela, também é possível visualizar que o NB teve o melhor desempenho para as variações obtendo os melhores resultados. No caso, o melhor desempenho para NB foi, especificamente, para $w = 0$, e para HT, $w = 8$.

Então, na Figura 17(b) é visto o *rank* geral (entre HT e NB) dos resultados da média do cálculo dos postos para esta avaliação entre o ponto ideal e das variações do ADDM. Assim, nota-se que no *rank* geral, o topo do *rank* ficou um empate entre o ADDM no ponto ideal (*benchmark*) e o ADDM com $w = 8$ instancias em *Warning* para treinamento do novo modelo.

Dando continuidade, a última análise desta seção apresenta os resultados das combinações das comparações entre todos os métodos reais e suas variações apresentadas na Seção 5 para os classificadores HT e NB, respectivamente, nas Tabelas 26 e 27, que apresentam somente a análise dos dados. Lembrando que estas tabelas têm somente uma replicação da análise, mas as tabelas completas estão no Apêndice A.

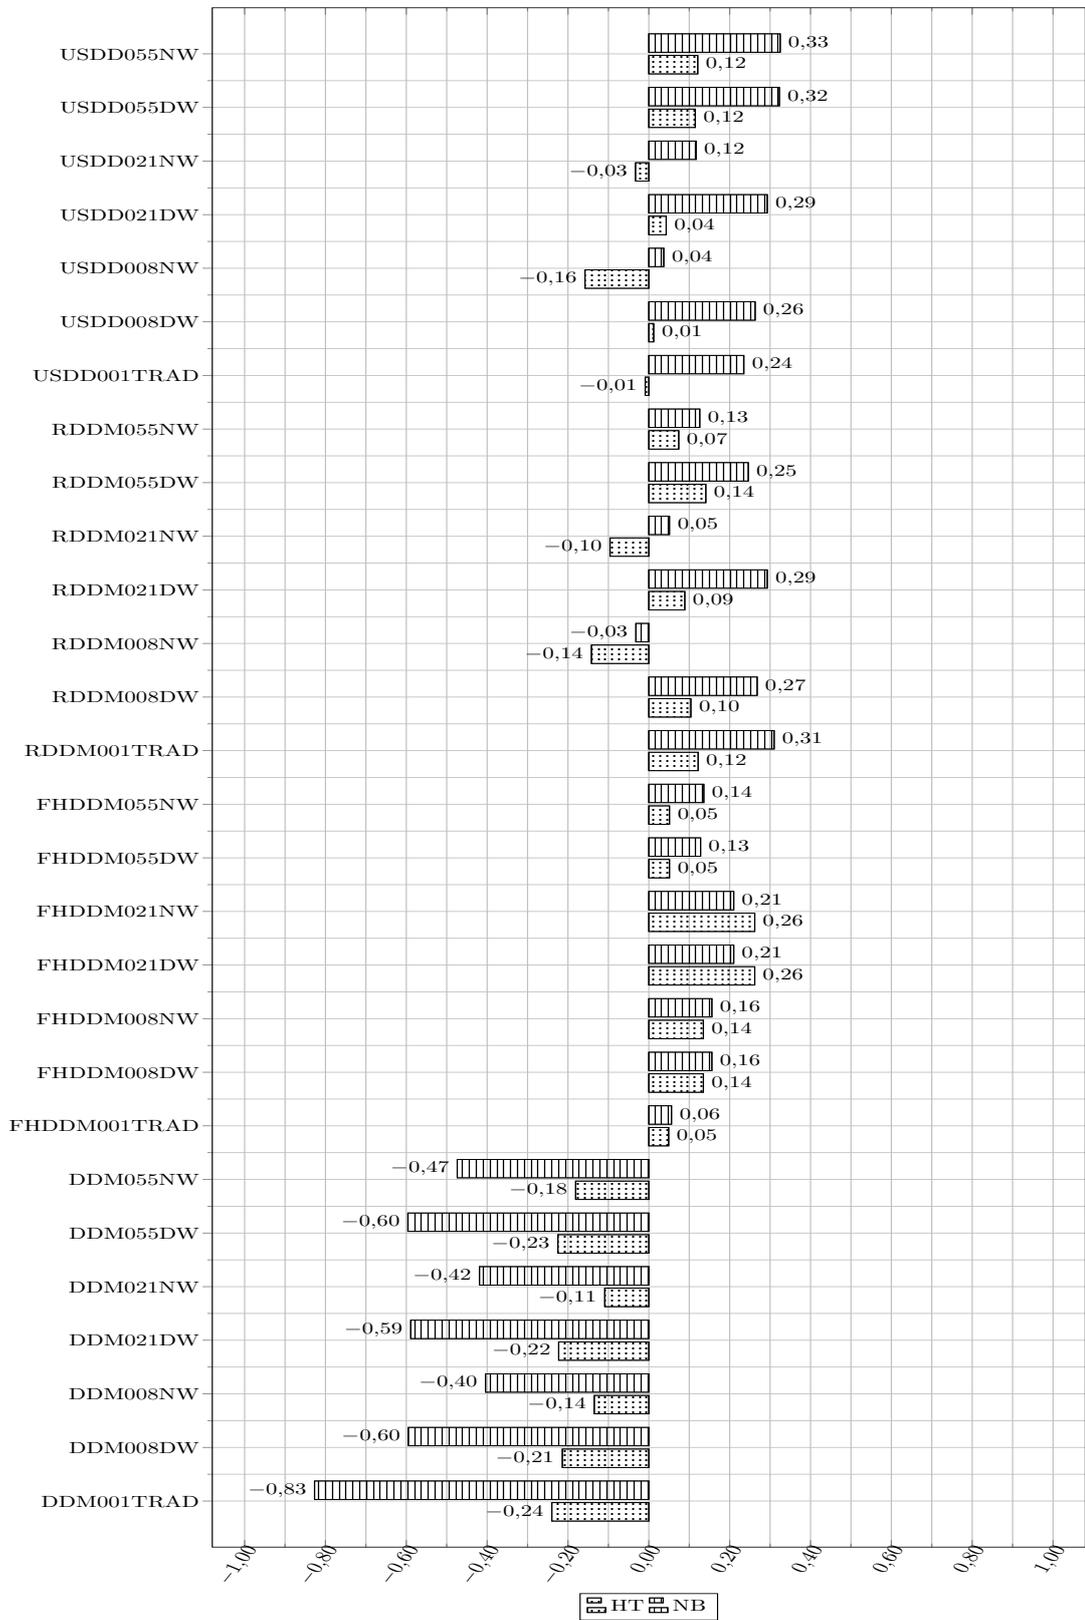
Na análise geral, tem-se a variação do FHDDM com NW e DW para o tamanho de $w = 21$ empatadas com melhor desempenho para HT. É interessante observar que, além do melhor colocado, as próximas quatro posições também são das variações do NW e DW, ficando o método tradicional RDDM nesta avaliação somente com a sexta posição. Nas mudanças abruptas e graduais, este resultado para o FHDDM se mantém.

Em relação ao NB, a variação com melhor desempenho foi o USDD com NW para o tamanho de $w = 55$. Neste caso, a segunda posição foi para a variação do DW aplicado ao USDD também com tamanho de $w = 55$, e em seguida o método tradicional RDDM. Nas mudanças abruptas o resultado para o USDD se mantém, porém nas graduais o melhor resultado é do RDDM tradicional.

Contrariamente, o DDM se manteve como o método tradicional pior colocado, seguido por suas variações do NW e DW.

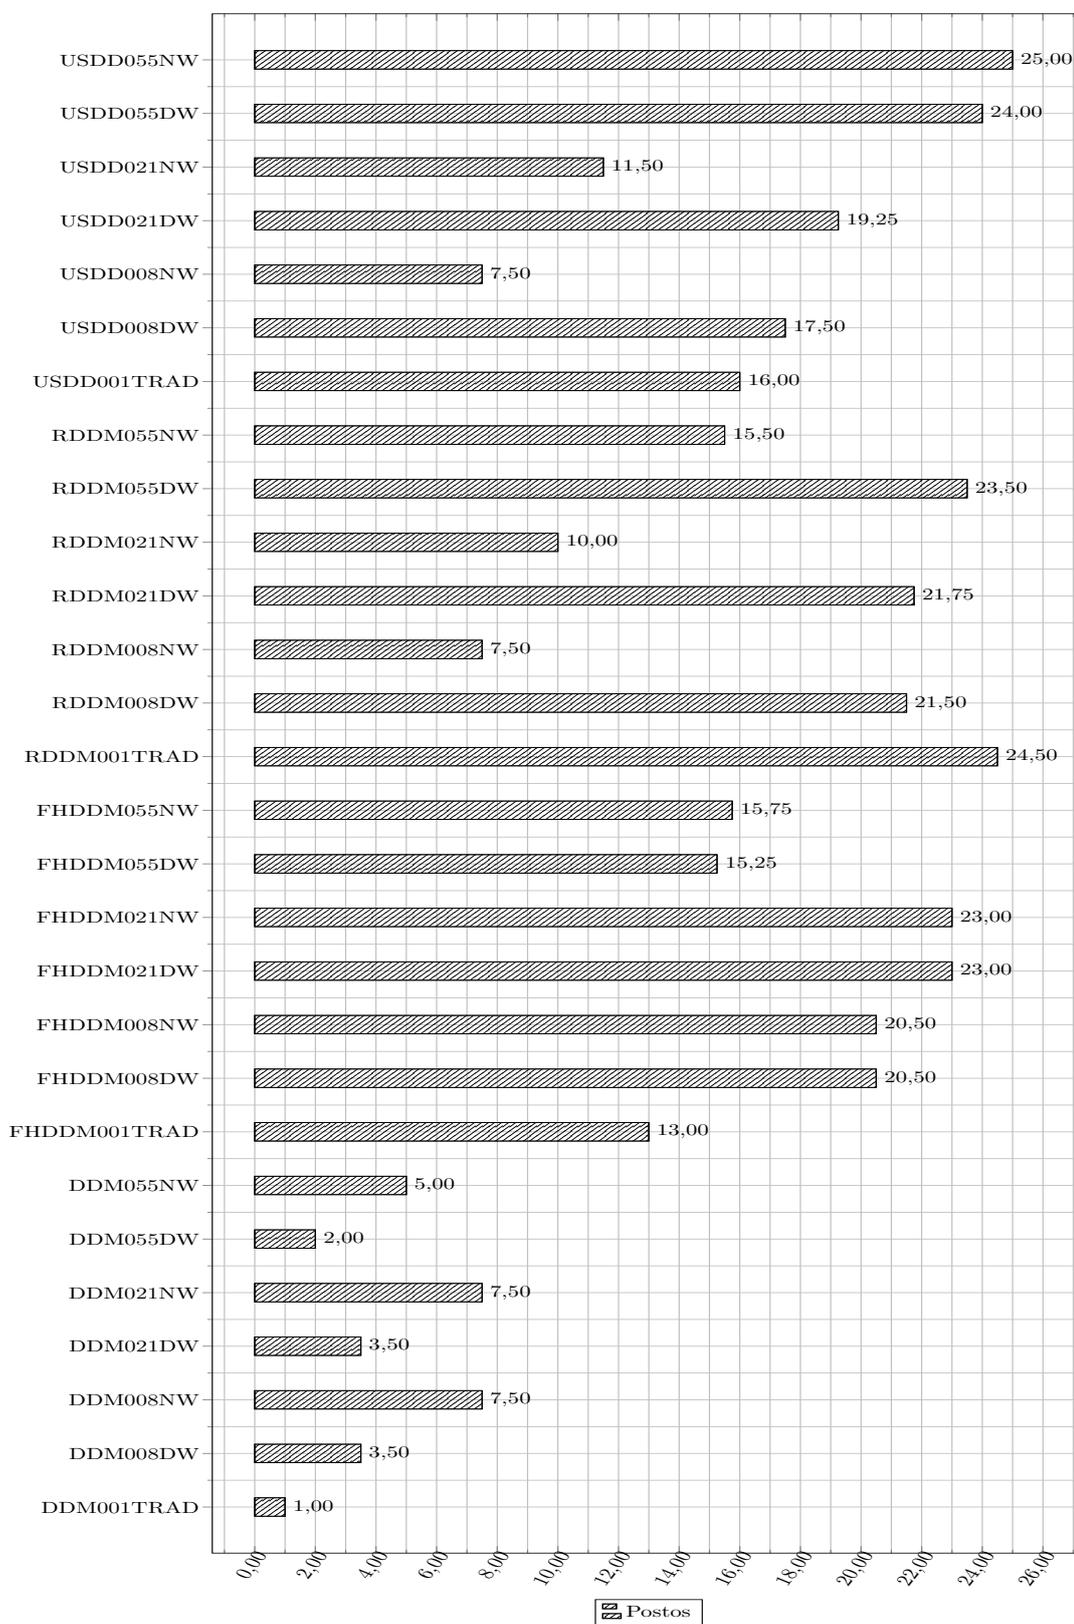
Esta última análise reuniu um grande número de comparações, portanto as figuras são exibidas de forma um pouco diferente, alongadas, para uma melhor visualização. A Figura 18 apresenta um gráfico em barras das comparações de desempenho de todos os métodos reais e suas variações de NW e DW avaliadas anteriormente, entre HT e NB, individualmente

Figura 18 – Diferenças calculadas de acurácia Prequential para a comparação geral dos métodos tradicionais e variações com NW e DW para HT e NB, individualmente.



Fonte: a autora (2022).

Figura 19 – Resumo dos ranks de acurácia Prequential para a comparação geral dos métodos tradicionais e variações com NW e DW HT e NB normalizadas



Fonte: a autora (2022).

Tabela 26 – Análise das somas dos valores das hipóteses estatísticas de Wilcoxon em relação a acurácia na comparação geral do DDM, FHDDM, RDDM e USDD nas versões tradicionais e variações do NW e DW para HT.

	Totais				Rank	Graduais				Rank	Geral				Rank
	Abruptas														
	\sum_{H_0}	\sum_{H_1}	\sum_{H_2}	$\sum_{H_1} - \sum_{H_2}$		\sum_{H_0}	\sum_{H_1}	\sum_{H_2}	$\sum_{H_1} - \sum_{H_2}$		\sum_{H_0}	\sum_{H_1}	\sum_{H_2}	$\sum_{H_1} - \sum_{H_2}$	
DDM001TRAD	142	80	183	-103	5	144	85	176	-91	1	286	165	359	-194	1
DDM008DW	137	77	191	-114	3,5	136	105	164	-59	4	273	182	355	-173	4
DDM008NW	138	86	181	-95	7	139	126	140	-14	9	277	212	321	-109	8
DDM021DW	133	73	199	-126	1	132	109	164	-55	5,5	265	182	363	-181	3
DDM021NW	134	97	174	-77	8	138	128	139	-11	10	272	225	313	-88	9
DDM055DW	141	75	189	-114	3,5	131	103	171	-68	3	272	178	360	-182	2
DDM055NW	165	62	178	-116	2	146	114	145	-31	7,5	311	176	323	-147	5
FHDDM001TRAD	105	174	126	48	20	155	121	129	-8	11	260	295	255	40	15
FHDDM008DW	116	193	96	97	25,5	165	126	114	12	17,5	281	319	210	109	24,5
FHDDM008NW	116	193	96	97	25,5	165	126	114	12	17,5	281	319	210	109	24,5
FHDDM021DW	127	211	67	144	27,5	151	161	93	68	27	278	372	160	212	27,5
FHDDM021NW	127	211	67	144	27,5	151	161	93	68	27	278	372	160	212	27,5
FHDDM055DW	130	156	119	37	18,5	141	134	130	4	12,5	271	290	249	41	16,5
FHDDM055NW	130	156	119	37	18,5	141	134	130	4	12,5	271	290	249	41	16,5
RDDM001TRAD	113	187	105	82	24	146	138	121	17	19	259	325	226	99	23
RDDM008DW	102	190	113	77	23	140	136	129	7	14,5	242	326	242	84	20
RDDM008NW	119	127	159	-32	10	154	84	167	-83	2	273	211	326	-115	7
RDDM021DW	107	181	117	64	22	145	134	126	8	16	252	315	243	72	19
RDDM021NW	142	120	143	-23	12,5	154	98	153	-55	5,5	296	218	296	-78	10
RDDM055DW	136	162	107	55	21	140	162	103	59	25	276	324	210	114	26
RDDM055NW	141	149	115	34	16	149	141	115	26	21	290	290	230	60	18
USDD001TRAD	131	124	150	-26	11	148	138	119	19	20	279	262	269	-7	12
USDD008DW	130	126	149	-23	12,5	146	146	113	33	22	276	272	262	10	13
USDD008NW	112	98	195	-97	6	144	115	146	-31	7,5	256	213	341	-128	6
USDD021DW	134	135	136	-1	14	143	149	113	36	23	277	284	249	35	14
USDD021NW	123	124	158	-34	9	138	137	130	7	14,5	261	261	288	-27	11
USDD055DW	136	152	117	35	17	145	159	101	58	24	281	311	218	93	21
USDD055NW	135	150	120	30	15	137	168	100	68	27	272	318	220	98	22

Fonte: a autora (2022).

analisadas, com o objetivo de mostrar o desempenho de cada um.

Assim como nas demais imagens semelhantes a esta, os valores dos resultados não são, de fato, os mesmos encontrados nas Tabelas 26 e 27, pois estes valores também foram normalizados. Então, nota-se na imagem que, fora o caso do DDM, que ficou bem abaixo do desempenho dos demais, a grande maioria dos métodos e variações teve um bom desempenho.

Em relação aos classificadores, é possível notar que o NB apresentou melhores resultados para os métodos RDDM e USDD. O melhor resultado para NB foi visto com o USDD aplicado

Tabela 27 – Análise das somas dos valores das hipóteses estatísticas de Wilcoxon em relação a acurácia na comparação geral do DDM, FHDDM, RDDM e USDD nas versões tradicionais e variações do NW e DW para NB.

	Totais														
	Abruptas					Graduais					Geral				
	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
DDM001TRAD	53	0	352	-352	1	71	8	326	-318	1	124	8	678	-670	1
DDM008DW	73	33	299	-266	2,5	93	48	264	-216	4	166	81	563	-482	3
DDM008NW	102	35	268	-233	6	121	95	189	-94	7	223	130	457	-327	7
DDM021DW	74	37	294	-257	4	93	46	266	-220	2	167	83	560	-477	4
DDM021NW	91	41	273	-232	7	138	80	187	-107	6	229	121	460	-339	6
DDM055DW	69	35	301	-266	2,5	96	46	263	-217	3	165	81	564	-483	2
DDM055NW	77	44	284	-240	5	135	63	207	-144	5	212	107	491	-384	5
FHDDM001TRAD	85	196	124	72	13	146	116	143	-27	8	231	312	267	45	11
FHDDM008DW	102	210	93	117	23,5	154	130	121	9	10,5	256	340	214	126	16,5
FHDDM008NW	102	210	93	117	23,5	154	130	121	9	10,5	256	340	214	126	16,5
FHDDM021DW	98	221	86	135	25,5	146	147	112	35	15,5	244	368	198	170	18,5
FHDDM021NW	98	221	86	135	25,5	146	147	112	35	15,5	244	368	198	170	18,5
FHDDM055DW	93	200	112	88	15	117	152	136	16	13,5	210	352	248	104	14
FHDDM055NW	93	203	109	94	17	117	152	136	16	13,5	210	355	245	110	15
RDDM001TRAD	81	219	105	114	22	112	215	78	137	28	193	434	183	251	26
RDDM008DW	69	216	120	96	18	104	211	90	121	23	173	427	210	217	23
RDDM008NW	57	168	180	-12	9	81	155	169	-14	9	138	323	349	-26	8
RDDM021DW	75	220	110	110	21	100	216	89	127	26	175	436	199	237	24,5
RDDM021NW	81	175	149	26	10	92	164	149	15	12	173	339	298	41	10
RDDM055DW	75	218	112	106	19	88	205	112	93	20	163	423	224	199	21
RDDM055NW	85	187	133	54	12	91	181	133	48	18	176	368	266	102	13
USDD001TRAD	130	180	95	85	14	142	184	79	105	21	272	364	174	190	20
USDD008DW	126	184	95	89	16	137	196	72	124	25	263	380	167	213	22
USDD008NW	90	151	164	-13	8	100	174	131	43	17	190	325	295	30	9
USDD021DW	114	200	91	109	20	131	201	73	128	27	245	401	164	237	24,5
USDD021NW	93	176	136	40	11	100	180	125	55	19	193	356	261	95	12
USDD055DW	119	215	71	144	28	135	194	76	118	22	254	409	147	262	27
USDD055NW	109	218	78	140	27	136	196	73	123	24	245	414	151	263	28

Fonte: a autora (2022).

ao NW com $w = 55$, seguido do mesmo com DW. Já para o HT, o melhor resultado foi alcançado com o FHDDM empatado nas variações do NW e DW para $w = 21$. Os piores casos, tanto para HT como NB foram para o DDM na versão tradicional, mostrando que as duas abordagens melhoraram os resultados do método, em todas as variações avaliadas.

Por fim, na Figura 19 é apresentado o *rank* geral (entre HT e NB) dos resultados da média dos cálculo dos postos para esta avaliação entre os métodos tradicionais e suas variações experimentais. Portanto, se observou que neste *rank* geral, a melhor variação ficou com o

USDD na variação do NW com $w = 55$ e a pior foi o DDM tradicional.

6.4 DISCUSSÃO

A Subseção 6.3.1 apresentou os resultados das comparações dos métodos de detecção de mudança de conceito tradicionais, assim como é visto nas publicações da área de detectores. A metodologia de análise aplicada para indicar o detector que teve melhor desempenho em acurácia *Prequential* foi diferente (com resultados compatíveis), porém, o objetivo em si, não era indicar qual, de fato, é o melhor método, mas sim, compara com os resultados da análise seguinte: os métodos em sua versão sem sinais de detecção *Warning*.

Por mais que a avaliação sem sinais de detecção *Warning* tenha sido gerenciada pelo NW, para ignorar os sinais de *Warning*, os métodos de detecção foram executados por meio de seu comportamento padrão, com suas próprias características para identificação de mudança de conceito.

Neste sentido, o quarto questionamentos apontados nos objetivos da Seção 4 foi se o sinal de detecção *Warning* poderia confundir a real eficiência de métodos detectores ao rastrear a mudança de conceito nas avaliações de desempenho. A comparação entre essas duas avaliações mostra que *o método pode ser eficiente em rastrear os sinais de detecção Warning obtendo bons valores de acurácia e sendo considerado um bom detector, mas na verdade não sendo bom em rastrear a mudança de conceito*. Isto deixa claro, também, a real importância que os sinais de detecção *Warning* têm para manter um bom desempenho para estes detectores, da mesma forma como foi observada na Seção 4.

A representação disto pode ser vista, como esperado, com os resultados do método FHDDM, que não tem os *Warnings* em sua implementação, assim, apresentando obviamente resultados semelhantes nas duas avaliações (tradicional e sem *Warning*). Diferentemente, os demais detectores tiveram seus desempenhos degradados. O FHDDM não foi o método melhor colocado do *rank* nas avaliações tradicionais, porém, nas avaliações sem *Warning* ficou no topo do *rank*. Como o método não conta com estes sinais, mas é um bom detector, sua técnica consegue obter bons resultados quando os demais não estão “completos”. No entanto, nota-se para os demais métodos de detecção a importância dos sinais de detecção *Warning* para manter bons resultados de acurácia *Prequential*.

Em relação a avaliação geral do estudo de caso, com o método de detecção artificial ADDM, considerando a representação de uma detecção no ponto exato de mudança, ponto

perfeito (mas irreal para detectores reativos), foi visto que métodos de detecção reativos, como são os detectores em geral, que garantem um conjunto mínimo de instâncias em *Warning* para treinamento do novo modelo, podem obter bons e até melhores resultados do que quando a detecção é dada no ponto ideal. De fato, para as mudanças abruptas a detecção no ponto exato de mudança de conceito seria perfeito, porém, aplicando um pequeno conjunto de treinamento esse resultado se aproxima bastante. Além disso, nas mudanças graduais o ponto exato de detecção não apresenta um bom desempenho, mostrando que ter um conjunto de treinamento é mais eficiente do que ser preciso. Essa análise complementa a discussão do questionamento levantado no segundo objetivo da Seção 4.

Em relação a relevância das estratégias propostas, na Seção 5 todos os métodos de detecção nas variações do DW e NW foram avaliados separadamente, com o objetivo de indicar qual abordagem e qual variação seria mais indicada. Foi observado, nestas análises, que as estratégias do NW e DW contribuíram para a melhoria da acurácia *Prequential* em diversos casos, para a maioria dos métodos experimentados. No entanto, notou-se a necessidade de realizar uma comparação que englobasse todas as variações das duas propostas, sem deixar de lado os métodos tradicionais. Uma avaliação envolvendo as três abordagens.

A análise desta avaliação evidenciou nas comparações gerais, para NB e HT, que as duas abordagens propostas contribuíram para a melhoria do desempenho dos métodos DDM, FHDDM e USDD. Para o DDM e FHDDM, as abordagens tradicionais ficaram atrás de todas as variações do NW e DW (ficando nos sétimos, últimos, lugares dos *ranks*). O USDD teve um desempenho semelhante, mas com o tradicional ficando atrás de quatro das seis variações (ficando no quinto lugar do *rank*). Nas comparações gerais do RDDM para HT, a melhor contribuição foi uma variação do DW, seguida pela tradicional. Somente para o RDDM com NB que a abordagem tradicional superou todas as variações propostas.

Portanto, estas análises mostraram que as estratégias NW e DW, de fato, melhoram a acurácia *Prequential* dos métodos de detecção de mudança de conceito. Contando que isto é feito de uma maneira mais justa e mais robusta, por possibilitar uma padronização do conjunto de treinamento, diminuir a quantidade de tarefas atribuídas aos detectores e possibilitar o enfoque dos métodos de detecção na função de detectar as mudanças de conceito.

6.5 CONSIDERAÇÕES FINAIS

Esta seção apresentou uma série de avaliações envolvendo os métodos de detecção de mudança de conceito e suas variações propostas, utilizadas nas seções anteriores, para obter algumas conclusões e debater sobre algumas discussões. Para entender a influência e a importância que os sinais de detecção *Warning* têm na qualificação dos detectores a Subseção 6.3.1 apresentou a realização de duas avaliações, a convencional e a que ignora os sinais de *Warning*. Nestas avaliações, o método tradicional com melhores resultados, no geral, foi o RDDM e ignorando os sinais de *Warning*, o melhor resultado foi com o FHDDM.

Em sequência, a Subseção 6.3.2 apresentou, primeiramente, uma comparação geral dos resultados do ADDM, que obteve no topo do *rank* um empate entre a variação que configura o ponto de mudança de conceito igual ao ponto de detecção da mudança de conceito e a com $w = 8$ instâncias em *Warning* para treinamento. Em relação as demais comparações, as variações com instâncias em *Warning* para treinar novos modelos se destacaram dos casos sem instâncias em *Warning* para treinamento. Em sequência, foram apresentados os resultados entre os detectores no geral. Neste caso, observou-se que a primeira posição do *rank* total (HT + NB) ficou com o método USDD na variação $w = 55$ com o NW. Vale ressaltar que as primeiras posições dos *ranks*, separadamente, HT e NB também foram ocupadas por variações do NW e DW.

Portanto, de acordo com os melhores colocados de cada *rank* avaliado nesta seção, tradicional, sem sinais de *Warning* e geral, sendo o RDDM, FHDDM e USDD, respectivamente os topos, nota-se que a relevância, aqui, não está vinculada a determinação do melhor método de detecção de mudança de conceito. Cada método tem seus méritos e vantagens competitivas, porém, os meios que os envolvem e as parametrizações selecionadas podem contribuir significativamente para melhoria de seus desempenhos de acurácia *Prequential*.

7 CONSIDERAÇÕES FINAIS

Nesta seção estão presentes as conclusões acerca desta tese. A Seção 1 apresentou a contextualização, definição do problema, os objetivos e demais pontos importantes para entendimento desta pesquisa. Em sequência, a Seção 2 introduziu os conceitos referentes a literatura da área, referencias para desenvolvimento desta pesquisa. Na Seção 3 foi descrita toda a metodologia e as ferramentas seguidas para a realização dos experimentos, além do processo de inferência dos resultados utilizado. E por fim, as apresentações dos resultados foram feitas, analisadas e discutidas nas Seções 4, 5 e 6. Nestas seções são mostradas a importância do treinamento em modelos reconstruídos após mudanças de conceito, a proposição de novas abordagem de aprendizado adaptativo, e algumas avaliações adicionais para reflexão geral da temática, respectivamente.

A seção está organizado em 4 subseções. Na Subseção 7.1 são argumentados as principais contribuições teóricas da pesquisa. Além disso, na Subseção 7.2 é destacada a publicação proveniente desta tese. Em seguida, na Subseção 7.3 são descritas algumas limitações encontradas na pesquisa. E por fim, são sugeridos alguns trabalhos futuros que podem contribuir para evolução das propostas deste trabalho na Subseção 7.4.

7.1 CONCLUSÕES

Este trabalho tem como propósito contribuir com os avanços no estado da arte da área de aprendizado em fluxo de dados. Para tanto, foi analisado a relevância da aplicação dos sinais de detecção *Warning* e foram propostas duas novas abordagem adaptativas de aprendizado para modelos de classificação com detecção inspiradas na tradicionalmente conhecida abordagem de AACD de [Gama et al. 2004].

Inicialmente, foi realizado um estudo de caso, na Seção 4, avaliando por meio de simulações com um método de detecção de mudança de conceito artificial, qual seria a importância dos sinais de *Warning* dado o comportamento da acurácia *Prequential* de modelos que receberam e não receberam instâncias para treinamento, após a detecção de mudanças de conceito.

Assim, os resultados analisados mostraram que a utilização do sinal de detecção *Warning* contribuiu significativamente para melhoria da taxa de acurácia *Prequential* destes modelos (aumentado sua generalização) quando as instâncias em *Warning* foram utilizadas para treiná-

los após uma detecção de mudança de conceito. Observou-se, também que o modo como a abordagem tradicional lida com os sinais de *Warning* é muito importante para resolver o problema da mudança de conceito. Assim, quando é preciso (quando há uma mudança de conceito) essa abordagem substitui o modelo principal e o seu treinamento. Logo, concluiu-se que os sinais de *Warning* são essenciais para a aceleração da adaptação do aprendizado na presença de mudanças de conceito.

Ainda, foi inferido no início da Subseção 6.3.2, que os sinais de detecção *Warning* influenciam, de tal forma, na reconstrução dos modelos de aprendizado, ao ponto de pequenos conjuntos de treinamentos terem resultados equivalentes ao de um detector perfeito (não reativo). Vale salientar que, foi utilizado o método artificial ADDM para este experimento, porém, neste caso, foi necessário modificar uma parte da implementação do algoritmo para que ele reconhecesse o intervalo de instâncias em *Warning*.

Além disto, na Subseção 6.3.1, foi ressaltado o quanto os métodos de detecção, que possuem instâncias em *Warning* em suas implementações, têm seu desempenho degradado quando os sinais de *Warning* lhe são retirados. O objetivo foi simular uma avaliação mais justa entre estes detectores, onde, todos se mantêm com a mesma quantidade de treinamento (padronizados) e mostram seu real desempenho como método de detecção de mudança de conceito, não por sua avaliação em relação a acurácia da classificação, como de costume é realizada na literatura da área, influenciada pelo treinamento dos modelos.

Para compreensão da influência dos sinais de *Warning* nos detectores, notou-se que por mais que as instâncias em *Warning* auxiliassem o detector na identificação da mudança de conceito, também foi observado que os detectores têm uma sobrecarga de responsabilidade. Isto porque, além de identificar as detecções de mudanças de conceito, eles identificam as instâncias que serão utilizadas como conjunto de treinamento para treinar novos modelos (tarefa de classificação), quando há mudanças de conceito. Assim, foi questionada a necessidade dos detectores serem avaliados não somente pela qualidade das detecções das mudanças de conceito, mas sim pelo grau de assertividade da classificação.

Baseado nos resultados, nas inferências sobre a importância das instâncias em *Warning*, no questionamento sobre as responsabilidades dos detectores e na identificação de outros pontos de melhorias em relação a abordagem tradicional de AACD, este trabalho foi motivado a criar as estratégias NW e DW, descritas na Seção 5.

As abordagens propostas contribuíram assumindo a responsabilidade de identificação e gerenciamento do conjunto de treinamento dos novos modelos de decisão, utilizando uma

técnica, na qual, o conjunto das últimas instâncias treinadas pelo modelo atual é previamente armazenado, para ser utilizado quando houver uma detecção de mudança de conceito, e serem re-utilizadas para treinar o novo modelo. De fato, a aplicação desta técnica, mostrou ser possível garantir e gerenciar o conjunto de treinamento de uma maneira diferente do que é tradicionalmente utilizada pela abordagem de AACD (somente pela detecção de sinais de *Warning*).

Além disso, outra contribuição alcançada tanto com o NW quanto com o DW foi o mecanismo que evita a criação e treinamento de mais um modelo de decisão, como acontece na metodologia de AACD. Isto foi identificado como um ponto de melhoria da abordagem tradicional a ser tratado nesta tese, porque, nem sempre os modelos de decisão auxiliares criados e treinados são utilizados para substituir o modelo principal. Logo, caso o estado do fluxo volte a estabilidade, esse outro modelo foi criado e treinado desnecessariamente e será descartado (aumentado o custo computacional).

Conseqüentemente, foi visto que o NW, mesmo sem utilizar as instâncias em *Warning*, mas sim, sua proposta técnica de gerenciamento do conjunto de treinamento, se mostrou bem competitivo ao DDMC. E ainda, considerando a relevância dos sinal de detecção *Warning* dos detectores, o DW superou ainda mais as expectativas com resultados significativos em relação ao DDMC, e sua possibilidade de escolha entre a técnica do NW e as próprias instâncias em *Warning* detectadas pelos métodos de detecção. Assim, as duas abordagens provaram ser úteis e inteligentes para prover a melhoraria da acurácia *Prequential*, caso haja uma mudança de conceito para o modelo de decisão depois de reiniciado seu aprendizado.

Portanto, de acordo com as condições detalhadas na Seção 5 e o resultado da avaliação geral apresentado na Subseção 6, as avaliações estatísticas realizadas do NW e DW contra as versões tradicionais dos métodos de detecção, mostraram que as duas estratégias obtiveram as maiores contribuições para a taxa de acurácia *Prequential*, para o DDM, FHDDM e USDD. Embora, menor, ainda existe contribuição do DW para o RDDM, também.

7.2 PUBLICAÇÃO

Até a presente data, a tese tem um trabalho publicado:

- Publicação do artigo intitulado "*An Optimized Training Dynamic for Data Streams*", no *IEEE Symposium Series on Computational Intelligence (SSCI)* em Orlando, Flórida,

EUA, Dezembro, 2021;

7.3 LIMITAÇÕES

- O foco de interesse desta tese não está na criação de novos classificadores ou detectores. Assim, esta tese limita-se a aplicar classificadores e detectores ao avaliar as novas estratégias de aprendizado adaptativo NW e DW.
- A análise da complexidade computacional das três estratégias: AACD, NW e DW. A análise assintótica para representar a complexidade de algoritmos para encontrar o pior caso, caso médio e melhor caso. Há muitas dependências dos algoritmos a abstrações nas implementações, tornando-se uma tarefa complexa.
- E por fim, a investigação da acurácia dos sinais de detecção *Warning* dos métodos detectores, considerando suas corretas identificações para utilizar as instâncias como conjunto de treinamento de novos modelos quando há detecções de mudanças de conceito.

7.4 TRABALHOS FUTUROS

Existem direções que podem ser investigadas como trabalhos futuros. A seguir, são listadas algumas destas, incluindo extensões e novas sugestões.

- Extensa análise comparativa dos principais ou últimos algoritmos de detecção publicados com as estratégias NW e DW. Como é vista nos artigos [Barros e Santos 2018] e [Gonçalves Jr. et al. 2014]. Avaliar o desempenho deste detectores em relação ao rastreamento da mudança de conceito de forma mais justa, controlando a quantidade de treinamento dos novos modelos, no caso do NW. E flexibilizando o uso das instâncias em *Warning* no caso do DW.
- Seleção do tamanho do conjunto de treinamento. Uma investigação mais profunda para indicar a melhor maneira de determinar o valor que representa o tamanho do conjunto de treinamento para os novos modelos. Logo, analisar se o ideal é generalizar ou especificar o valor, gerando-o dinamicamente para cada detector avaliado;
- Extensão do NW e DW. Inspirado no AACD, o desenvolvimento dessas estratégias foi uma interessante inovação para algoritmos de classificação com detecção proposta. A

ideia de melhorar a acurácia *Prequential* considerando a similaridade entre conceitos contraria a lógica utilizada na abordagem de AACD, na qual a dissimilaridade contribui para melhorar os resultados. Portanto, investigar a similaridade dos conceitos, pode ser uma opção de trabalho futuro;

- A investigação da aplicação das estratégias NW e DW a comitês de classificadores. A abordagem de AACD se mostrou competitiva quando aplicada a comitês de classificadores [Barros, Santos e Gonçalves Jr. 2016]. Assim, torna-se uma opção a análise da utilização das propostas a comitês de classificadores com detectores.

REFERÊNCIAS

- AGGARWAL, C. *Data Streams: Models and Algorithms*. [S.l.: s.n.], 2007. v. 31. ISBN 978-0-387-28759-1.
- AGRAWAL, R.; IMIELINSKI, T.; SWAMI, A. N. Database mining: a performance perspective. *IEEE Transactions on Knowledge and Data Engineering*, v. 5, n. 6, p. 914–925, 1993.
- BABCOCK, B.; DATAR, M.; MOTWANI, R. Sampling from a moving window over streaming data. In: *Proceedings of the Thirteenth Annual ACM-SIAM Symposium on Discrete Algorithms*. Philadelphia, PA, USA: Society for Industrial and Applied Mathematics, 2002. (SODA '02), p. 633–634. ISBN 0-89871-513-X. Disponível em: <<http://dl.acm.org/citation.cfm?id=545381.545465>>.
- BAENA-GARCIA, M.; CAMPO-ÁVILA, J. D.; FIDALGO, R.; BIFET, A.; GAVALDÀ, R.; MORALES-BUENO, R. Early drift detection method. In: *International Workshop on Knowledge Discovery from Data Streams*. [S.l.: s.n.], 2006. p. 77–86.
- BARROS, R. S. M.; CABRAL, D. R. de L.; GONÇALVES JR., P. M.; SANTOS, S. G. T. de C. RDDM: Reactive drift detection method. *Expert Systems with Applications*, v. 90, n. C, p. 344–355, dez. 2017. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417417305614>>.
- BARROS, R. S. M.; CABRAL, D. R. L.; Gonçalves Jr., P. M.; SANTOS, S. G. T. C. RDDM: Reactive drift detection method. *Expert Systems with Applications*, Elsevier, v. 90, n. C, p. 344–355, 2017.
- BARROS, R. S. M.; HIDALGO, J. I. G.; CABRAL, D. R. L. Wilcoxon rank sum test drift detector. *Neurocomputing*, Elsevier, v. 275, n. C, p. 1954–1963, 2018.
- BARROS, R. S. M.; SANTOS, S. G. T. de C. A large-scale comparison of concept drift detectors. *Information Sciences*, v. 451-452, p. 348 – 370, 2018. ISSN 0020-0255. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0020025518302743>>.
- BARROS, R. S. M.; SANTOS, S. G. T. de C.; GONÇALVES JR., P. M. A boosting-like online learning ensemble. In: *Proceedings of IEEE International Joint Conference on Neural Networks (IJCNN)*. Vancouver, Canada: [s.n.], 2016. p. 1871–1878.
- BENAVOLI, A.; CORANI, G.; MANGILI, F. Should we really use post-hoc tests based on mean-ranks? *Journal of Machine Learning Research*, v. 17, n. 5, p. 1–10, 2016. Disponível em: <<http://jmlr.org/papers/v17/benavoli16a.html>>.
- BIFET, A. *Adaptive Learning and Mining for Data Streams and Frequent Patterns*. Tese (Doutorado) — Universitat Politècnica de Catalunya, 2009.
- BIFET, A.; GAVALDÀ, R. Learning from time-changing data with adaptive windowing. In: _____. *Proceedings of the 2007 SIAM International Conference on Data Mining*. [s.n.], 2007. p. 443–448. Disponível em: <<https://epubs.siam.org/doi/abs/10.1137/1.9781611972771.42>>.
- BIFET, A.; GAVALDÀ, R. Learning from time-changing data with adaptive windowing. In: *Proc. of 7th SIAM International Conference on Data Mining (SDM'07)*. Minneapolis, MN, USA: [s.n.], 2007. p. 443–448.

- BIFET, A.; GAVALDÀ, R.; HOLMES, G.; PFAHRINGER, B. *Machine Learning for Data Streams with Practical Examples in MOA*. [S.l.]: MIT Press, 2018. <<https://moa.cms.waikato.ac.nz/book/>>.
- BIFET, A.; HOLMES, G.; KIRKBY, R.; PFAHRINGER, B. MOA: Massive online analysis. *Journal of Machine Learning Research*, MIT Press, v. 11, p. 1601–1604, 2010.
- BIFET, A.; HOLMES, G.; PFAHRINGER, B. Leveraging bagging for evolving data streams. In: *Machine Learning and Knowledge Discovery in Databases*. [S.l.]: Springer, 2010, (LNCS, v. 6321). p. 135–150.
- BIFET, A.; HOLMES, G.; PFAHRINGER, B.; KIRKBY, R.; GAVALDÀ, R. New ensemble methods for evolving data streams. In: *Proceedings of 15th ACM International Conference on Knowledge Discovery and Data Mining (KDD'09)*. Paris, France: [s.n.], 2009. p. 139–148.
- BOTTOU, L. On-line learning in neural networks. In: SAAD, D. (Ed.). New York, NY, USA: Cambridge University Press, 1998. cap. On-line Learning and Stochastic Approximations, p. 9–42. ISBN 0-521-65263-4. Disponível em: <<http://dl.acm.org/citation.cfm?id=304710.304720>>.
- CABRAL, D. R. L.; BARROS, R. S. M. Concept drift detection based on Fisher's Exact test. *Information Sciences*, Elsevier, v. 442-443, n. C, p. 220–234, 2018.
- Carpenter, G. A.; Grossberg, S.; Markuzon, N.; Reynolds, J. H.; Rosen, D. B. Fuzzy artmap: A neural network architecture for incremental supervised learning of analog multidimensional maps. *IEEE Transactions on Neural Networks*, v. 3, n. 5, p. 698–713, Sep. 1992. ISSN 1045-9227.
- COHEN, L.; AVRAHAMI, G.; LAST, M.; KANDEL, A.; KIPERSZTOK, O. Real-time data mining of non-stationary data streams from sensor networks. *Information Fusion*, v. 9, p. 344–353, 07 2008.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine Learning*, v. 20, n. 3, p. 273–297, Sep 1995. ISSN 1573-0565. Disponível em: <<https://doi.org/10.1023/A:1022627411411>>.
- DAWID, A. P. Present position and potential developments: Some personal views: Statistical theory: The prequential approach. *Journal of the Royal Statistical Society. Series A (General)*, JSTOR, p. 278–292, 1984.
- DAWID, A. P.; VOVK, V. G. Prequential probability: Principles and properties. *Bernoulli*, JSTOR, p. 125–162, 1999.
- DELANY, S.; CUNNINGHAM, P.; TSYMBAL, A.; COYLE, L. A case-based technique for tracking concept drift in spam filtering. *Knowledge-Based Systems*, v. 18, p. 187–195, 08 2005.
- DEMŠAR, J. Statistical comparisons of classifiers over multiple data sets. *Journal of Machine Learning Research*, JMLR.org, v. 7, p. 1–30, 2006.
- DOMINGOS, P.; HULTEN, G. Mining high-speed data streams. In: *Proceedings of the Sixth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York, NY, USA: ACM, 2000. (KDD '00), p. 71–80. ISBN 1-58113-233-6. Disponível em: <<http://doi.acm.org/10.1145/347090.347107>>.

- DU, L.; SONG, Q.; JIA, X. Detecting concept drift: an information entropy based method using an adaptive sliding window. *Intelligent Data Analysis*, IOS Press, v. 18, n. 3, p. 337–364, 2014.
- DUDA, R.; HART, P. *Pattern Classification and Scene Analysis*. [S.l.]: Wiley, 1973.
- FRÍAS-BLANCO, I.; CAMPO-ÁVILA, J. del; RAMOS-JIMÉNEZ, G.; MORALES-BUENO, R.; ORTIZ-DÍAZ, A.; CABALLERO-MOTA, Y. Online and non-parametric drift detection methods based on hoeffding's bounds. *IEEE Transactions on Knowledge and Data Engineering*, v. 27, n. 3, p. 810–823, 2015.
- GAMA, J.; MEDAS, P.; CASTILLO, G.; RODRIGUES, P. Learning with drift detection. In: *Advances in Artificial Intelligence: SBIA 2004*. [S.l.]: Springer, 2004, (LNCS, v. 3171). p. 286–295.
- GAMA, J.; SEBASTIÃO, R.; RODRIGUES, P. On evaluating stream learning algorithms. *Machine Learning*, Springer, v. 90, n. 3, p. 317–346, 2013.
- GAMA, J.; ŽLIOBAITĚ, I.; BIFET, A.; PECHENIZKIY, M.; BOUCHACHIA, A. A survey on concept drift adaptation. *ACM Computing Surveys*, v. 46, n. 4, p. 44:1–37, 2014.
- GONCALVES JR., P. M.; BARROS, R. S. M. RCD: A recurring concept drift framework. *Pattern Recognition Letters*, Elsevier, v. 34, n. 9, p. 1018–1025, 2013.
- GONÇALVES JR., P. M.; SANTOS, S. G. T. de C.; BARROS, R. S. M.; VIEIRA, D. C. L. A comparative study on concept drift detectors. *Expert Systems with Applications*, Elsevier, v. 41, n. 18, p. 8144–8156, 2014.
- HIDALGO, J. I. G.; MACIEL, B. I. F.; BARROS, R. S. M. Experimenting with prequential variations for data stream learning evaluation. *Computational Intelligence*, v. 35, n. 4, p. 670–692, 2019. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/coin.12208>>.
- HOEFFDING, W. Probability inequalities for sums of bounded random variables. *Journal of the American Statistical Association*, v. 58, p. 13–30, 1963.
- JOHN, G. H.; LANGLEY, P. Estimating continuous distributions in bayesian classifiers. In: MORGAN KAUFMANN PUBLISHERS INC. *Proceedings of the Eleventh conference on Uncertainty in artificial intelligence*. [S.l.], 1995. p. 338–345.
- LANE, T.; BRODLEY, C. E. Approaches to online learning and concept drift for user identification in computer security. In: *KDD*. [S.l.: s.n.], 1998.
- MACIEL, B. *Otimização de Falsos Alarmes em Detecção de Mudança de Conceito*. Tese (Doutorado) — Universidade Federal de Pernambuco, 2020.
- MACIEL, B. I. F. *MOAM: Massive Online Analysis Manager*. 2019. Disponível em: <<https://github.com/brunom4ciel/moamanager>>.
- MACIEL, B. I. F.; HIDALGO, J. I. G.; BARROS, R. S. M. An ultimately simple concept drift detector for data streams. In: *2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. [S.l.: s.n.], 2021. p. 1–6.
- MAIMON, O.; ROKACH, L. *Data Mining and Knowledge Discovery Handbook*. [S.l.]: Springer US, 2010. ISBN 978-0-387-09822-7.

- MANAPRAGADA, C.; WEBB, G. I.; SALEHI, M. Extremely fast decision tree. In: *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York, NY, USA: Association for Computing Machinery, 2018. (KDD '18), p. 1953–1962. ISBN 9781450355520. Disponível em: <<https://doi.org/10.1145/3219819.3220005>>.
- MARON, O.; MOORE, A. W. Hoeffding races: Accelerating model selection search for classification and function approximation. *Robotics Institute*, p. 263, 1993.
- MINKU, L.; YAO, X. DDD: A new ensemble approach for dealing with concept drift. *IEEE Transactions on Knowledge and Data Engineering*, v. 24, n. 4, p. 619–633, 2012.
- MITCHELL, T. *Machine Learning*. New York, NY, USA: McGraw-Hill, 1997.
- MITCHELL, T. M. *Machine Learning*. New York, NY, USA: McGraw-Hill, 1997.
- NISHIDA, K.; YAMAUCHI, K. Detecting concept drift using statistical testing. In: *Proceedings of 10th International Conference on Discovery Science (DS'07)*. [S.l.]: Springer, 2007. (LNCS, v. 4755), p. 264–269.
- PAGE, E. S. Controlling the standard deviation by cusums and warning lines. *Technometrics*, v. 5, n. 3, p. 307–315, 1963.
- PESARANGHADER, A.; VIKTOR, H. L. Fast hoeffding drift detection method for evolving data streams. In: FRASCONI, P.; LANDWEHR, N.; MANCO, G.; VREEKEN, J. (Ed.). *Machine Learning and Knowledge Discovery in Databases*. Cham: Springer International Publishing, 2016. p. 96–111. ISBN 978-3-319-46227-1.
- PFAHRINGER, B.; HOLMES, G.; KIRKBY, R. New options for hoeffding trees. In: SPRINGER. *Australasian Joint Conference on Artificial Intelligence*. [S.l.], 2007. p. 90–99.
- RISH, I. et al. An empirical study of the naive bayes classifier. In: *IJCAI 2001 workshop on empirical methods in artificial intelligence*. [S.l.: s.n.], 2001. v. 3, n. 22, p. 41–46.
- ROSS, G. J.; ADAMS, N. M.; TASOULIS, D. K.; HAND, D. J. Exponentially weighted moving average charts for detecting concept drift. *Pattern Recognition Letters*, v. 33, n. 2, p. 191 – 198, 2012. ISSN 0167-8655. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167865511002704>>.
- RUSSELL, S.; NORVIG, P. Inteligência artificial. In: _____. 3. ed. São Paulo, SP, Brasil: GEN LTC, 2013.
- SAMUEL, A. L. Some studies in machine learning using the game of checkers. *IBM J. Res. Dev.*, IBM Corp., Riverton, NJ, USA, v. 3, n. 3, p. 210–229, jul. 1959. ISSN 0018-8646. Disponível em: <<http://dx.doi.org/10.1147/rd.33.0210>>.
- SANTOS, S. G. T. C.; BARROS, R. S. M.; Gonçalves Jr., P. M. Optimizing the parameters of drift detection methods using a genetic algorithm. In: *Proceedings of 27th IEEE International Conference on Tools with Artificial Intelligence (ICTAI'15)*. Vietri sul Mare, Italy: [s.n.], 2015. p. 1077–1084.
- SANTOS, S. G. T. de C.; GONÇALVES JR., P. M.; SILVA, G.; BARROS, R. S. M. Speeding up recovery from concept drifts. In: *Machine Learning and Knowledge Discovery in Databases*. [S.l.]: Springer, 2014, (LNCS, v. 8726). p. 179–194.

SEBASTIÃO, R.; GAMA, J. A study on change detection methods. In: *Proc. of 14th Portuguese Conference on Artificial Intelligence EPIA*. Aveiro, Portugal: New Trends in Artificial Intelligence, 2009. p. 353–364.

VAPNIK, V. N. An overview of statistical learning theory. *IEEE transactions on neural networks*, Citeseer, v. 10, n. 5, p. 988–999, 1999.

VAPNIK, V. N.; CHERVONENKIS, A. Y. On the uniform convergence of relative frequencies of events to their probabilities. *Theory of Probability & Its Applications*, SIAM, v. 16, n. 2, p. 264–280, 1971.

VAPNIK, V. N.; CHERVONENKIS, A. Y. On the uniform convergence of relative frequencies of events to their probabilities. In: _____. *Measures of Complexity: Festschrift for Alexey Chervonenkis*. Cham: Springer International Publishing, 2015. p. 11–30. ISBN 978-3-319-21852-6. Disponível em: <https://doi.org/10.1007/978-3-319-21852-6_3>.

VICTOR, S. E. C. B. H.; MELO, S. B.; MACIEL, B. I. F. An optimized training dynamic for data streams. In: *2021 IEEE Symposium Series on Computational Intelligence (SSCI)*. [s.n.], 2021. p. 1–8. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/9660022>>.

WANG, H.; FAN, W.; YU, P.; HAN, J. Mining concept-drifting data streams using ensemble classifiers. 07 2003.

ŽLIOBAITĖ, I.; BIFET, A.; READ, J.; PFAHRINGER, B.; HOLMES, G. Evaluation methods and decision theory for classification of streaming data with temporal dependence. *Machine Learning*, Springer, v. 98, n. 3, p. 455–482, 2015.

APÊNDICE A – TABELAS DAS AVALIAÇÕES GERAIS

Na seção 6 é realizada uma análise comparando os quatro métodos de detecção: DDM, FHDDM, RDDM e USDD nas suas versões tradicionais (com a abordagem de AACD), juntamente, com estes mesmos métodos nas variações de $w = 8, 21$ e 55 aplicados as duas abordagens propostas: NW e DW.

As tabelas apresentadas neste apêndice contém a estrutura semelhante as demais tabelas da seção 6, porém, diferentemente das outras comparações da seção em questão, esta, tem uma quantidade de métodos e variações muito grande, portanto, suas combinações geraram uma tabela extensa.

Assim, são exibidos os resultados destas comparações entre os métodos referentes aos classificadores HT e NB, respectivamente nas Tabelas 28 e 29. Ao fim de cada tabela é apresentada a análise com a soma dos valores das tabelas, gerando o posicionamento de cada método para as mudanças abruptas, graduais e totais, assim como apresentado na seção 6 nas Tabelas 26 e 27.

Tabela 28 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia na comparação geral do DDM, FHDDM, RDDM e USDD nas versões tradicionais e variações do NW e DW para HT.

Pares		Geradores de fluxo de dados														
		Agrawal			LED			Mix			RRBF			Sine		
		Tamanhos das bases de dados vezes 10k														
μ_1	μ_2	2	8	13	2	8	13	2	8	13	2	8	13	2	8	13
		Abruptas														
DDM001TRAD	DDM008DW	H ₀	H ₁	H ₀	H ₂	H ₀	H ₀	H ₂	H ₂	H ₁	H ₀	H ₀	H ₂	H ₀	H ₀	H ₀
DDM001TRAD	DDM008NW	H ₂	H ₀	H ₀	H ₁	H ₀	H ₀	H ₂	H ₀	H ₀	H ₀	H ₁	H ₀	H ₂	H ₀	H ₀
DDM001TRAD	DDM021DW	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₂	H ₁	H ₁	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀
DDM001TRAD	DDM021NW	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₂	H ₀	H ₀
DDM001TRAD	DDM055DW	H ₀	H ₁	H ₀												
DDM001TRAD	DDM055NW	H ₀	H ₀	H ₀	H ₁	H ₀										
DDM001TRAD	FHDDM001TRAD	H ₀	H ₁	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM001TRAD	FHDDM008DW	H ₀	H ₁	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM001TRAD	FHDDM008NW	H ₀	H ₁	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM001TRAD	FHDDM021DW	H ₀	H ₀	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM001TRAD	FHDDM021NW	H ₀	H ₀	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM001TRAD	FHDDM055DW	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM001TRAD	FHDDM055NW	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM001TRAD	RDDM001TRAD	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₂	H ₀	H ₂
DDM001TRAD	RDDM008DW	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₂	H ₀	H ₂
DDM001TRAD	RDDM008NW	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂
DDM001TRAD	RDDM021DW	H ₀	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂					

DDM001TRAD	RDDM021NW	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₁	H ₁	H ₂	H ₂	H ₀
DDM001TRAD	RDDM055DW	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀
DDM001TRAD	RDDM055NW	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₂					
DDM001TRAD	USDD001TRAD	H ₀	H ₁	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM001TRAD	USDD008DW	H ₀	H ₁	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM001TRAD	USDD008NW	H ₀	H ₀	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM001TRAD	USDD021DW	H ₀	H ₀	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM001TRAD	USDD021NW	H ₀	H ₁	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM001TRAD	USDD055DW	H ₀	H ₀	H ₁	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM001TRAD	USDD055NW	H ₀	H ₀	H ₁	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008DW	DDM008NW	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₀	H ₀	H ₀	H ₁	H ₀	H ₂	H ₀	H ₀
DDM008DW	DDM021DW	H ₂	H ₂	H ₁	H ₂	H ₂	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₁	H ₀	H ₁	H ₁
DDM008DW	DDM021NW	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₀	H ₂	H ₀	H ₀				
DDM008DW	DDM055DW	H ₁	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀
DDM008DW	DDM055NW	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀									
DDM008DW	FHDDM001TRAD	H ₀	H ₁	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008DW	FHDDM008DW	H ₀	H ₁	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008DW	FHDDM008NW	H ₀	H ₁	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008DW	FHDDM021DW	H ₀	H ₀	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008DW	FHDDM021NW	H ₀	H ₀	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008DW	FHDDM055DW	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008DW	FHDDM055NW	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008DW	RDDM001TRAD	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂				
DDM008DW	RDDM008DW	H ₂	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂				
DDM008DW	RDDM008NW	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008DW	RDDM021DW	H ₂	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂				
DDM008DW	RDDM021NW	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₂	H ₂	H ₀
DDM008DW	RDDM055DW	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀
DDM008DW	RDDM055NW	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀
DDM008DW	USDD001TRAD	H ₀	H ₀	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008DW	USDD008DW	H ₀	H ₁	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008DW	USDD008NW	H ₀	H ₀	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008DW	USDD021DW	H ₀	H ₁	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008DW	USDD021NW	H ₀	H ₀	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008DW	USDD055DW	H ₀	H ₀	H ₁	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008DW	USDD055NW	H ₀	H ₀	H ₁	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008NW	DDM021DW	H ₁	H ₀	H ₀	H ₂	H ₂	H ₂	H ₁	H ₀	H ₀	H ₀	H ₂	H ₀	H ₁	H ₀	H ₀
DDM008NW	DDM021NW	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀
DDM008NW	DDM055DW	H ₁	H ₀	H ₀	H ₂	H ₂	H ₂	H ₁	H ₀	H ₀	H ₀	H ₂	H ₀	H ₁	H ₀	H ₀
DDM008NW	DDM055NW	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₁	H ₀	H ₀	H ₀	H ₂	H ₀	H ₁	H ₀	H ₀
DDM008NW	FHDDM001TRAD	H ₁	H ₁	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008NW	FHDDM008DW	H ₀	H ₁	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008NW	FHDDM008NW	H ₀	H ₁	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008NW	FHDDM021DW	H ₀	H ₁	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008NW	FHDDM021NW	H ₀	H ₁	H ₁	H ₂	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008NW	FHDDM055DW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀	H ₂	H ₂

RDDM001TRAD	USDD001TRAD	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM001TRAD	USDD008DW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM001TRAD	USDD008NW	H1	H1	H1	H0	H1	H1	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM001TRAD	USDD021DW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM001TRAD	USDD021NW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM001TRAD	USDD055DW	H0	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM001TRAD	USDD055NW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008DW	RDDM008NW	H1	H1	H0	H1	H1	H1	H0	H0	H0	H0	H0	H1	H0	H0	H0
RDDM008DW	RDDM021DW	H1	H1	H1	H0	H2	H2	H1	H0	H2	H1	H1	H1	H0	H0	H0
RDDM008DW	RDDM021NW	H1	H1	H0	H1	H1	H1	H1	H0	H0	H0	H0	H1	H0	H0	H0
RDDM008DW	RDDM055DW	H0	H0	H0	H2	H2	H2	H1	H0	H0	H0	H0	H1	H1	H0	H1
RDDM008DW	RDDM055NW	H0	H1	H0	H2	H2	H2	H1	H0	H0	H0	H0	H1	H1	H0	H0
RDDM008DW	USDD001TRAD	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008DW	USDD008DW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008DW	USDD008NW	H1	H1	H1	H0	H1	H1	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008DW	USDD021DW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008DW	USDD021NW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008DW	USDD055DW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008DW	USDD055NW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008NW	RDDM021DW	H2	H2	H0	H2	H2	H2	H0	H0	H0	H0	H0	H2	H2	H0	H0
RDDM008NW	RDDM021NW	H0	H0	H0	H2	H2	H2	H1	H0	H0	H0	H0	H0	H2	H0	H0
RDDM008NW	RDDM055DW	H2	H0	H0	H2	H2	H2	H1	H0	H0	H0	H0	H2	H1	H0	H0
RDDM008NW	RDDM055NW	H0	H0	H0	H2	H2	H2	H1	H0	H0	H0	H0	H0	H1	H0	H0
RDDM008NW	USDD001TRAD	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008NW	USDD008DW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008NW	USDD008NW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008NW	USDD021DW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008NW	USDD021NW	H0	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008NW	USDD055DW	H0	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM008NW	USDD055NW	H0	H1	H1	H2	H2	H2	H1	H2	H2	H0	H1	H1	H0	H2	H2
RDDM021DW	RDDM021NW	H1	H1	H0	H1	H1	H1	H0	H1	H0	H0	H0	H1	H1	H0	H0
RDDM021DW	RDDM055DW	H0	H0	H0	H2	H2	H2	H1	H0	H0	H0	H0	H0	H1	H0	H0
RDDM021DW	RDDM055NW	H0	H1	H0	H2	H2	H2	H1	H0	H0	H0	H0	H0	H1	H0	H0
RDDM021DW	USDD001TRAD	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H1	H2	H2
RDDM021DW	USDD008DW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H1	H2	H2
RDDM021DW	USDD008NW	H1	H1	H1	H0	H1	H1	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM021DW	USDD021DW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM021DW	USDD021NW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM021DW	USDD055DW	H0	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM021DW	USDD055NW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM021NW	RDDM055DW	H2	H0	H0	H2	H2	H2	H1	H0	H0	H0	H0	H2	H1	H0	H0
RDDM021NW	RDDM055NW	H0	H0	H0	H2	H2	H2	H1	H0	H0	H0	H0	H0	H1	H0	H0
RDDM021NW	USDD001TRAD	H0	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM021NW	USDD008DW	H0	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM021NW	USDD008NW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H1	H1	H1	H0	H2	H2
RDDM021NW	USDD021DW	H1	H1	H1	H2	H2	H2	H1	H2	H2	H0	H1	H1	H0	H2	H2

DDM008DW	USDD055NW	H ₀	H ₁	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM008NW	DDM021DW	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀
DDM008NW	DDM021NW	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀								
DDM008NW	DDM055DW	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀
DDM008NW	DDM055NW	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₀						
DDM008NW	FHDDM001TRAD	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008NW	FHDDM008DW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008NW	FHDDM008NW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008NW	FHDDM021DW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008NW	FHDDM021NW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008NW	FHDDM055DW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₂
DDM008NW	FHDDM055NW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₂
DDM008NW	RDDM001TRAD	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀					
DDM008NW	RDDM008DW	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀					
DDM008NW	RDDM008NW	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀
DDM008NW	RDDM021DW	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀					
DDM008NW	RDDM021NW	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀					
DDM008NW	RDDM055DW	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀					
DDM008NW	RDDM055NW	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀					
DDM008NW	USDD001TRAD	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₀	H ₂
DDM008NW	USDD008DW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008NW	USDD008NW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008NW	USDD021DW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008NW	USDD021NW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008NW	USDD055DW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM008NW	USDD055NW	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM021DW	DDM021NW	H ₂	H ₁	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀
DDM021DW	DDM055DW	H ₂	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₂	H ₀	H ₂	H ₁	H ₀	H ₀	H ₁	H ₁
DDM021DW	DDM055NW	H ₂	H ₁	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₂	H ₀					
DDM021DW	FHDDM001TRAD	H ₀	H ₁	H ₁	H ₀	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM021DW	FHDDM008DW	H ₀	H ₁	H ₁	H ₀	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂				
DDM021DW	FHDDM008NW	H ₀	H ₁	H ₁	H ₀	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂				
DDM021DW	FHDDM021DW	H ₀	H ₁	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM021DW	FHDDM021NW	H ₀	H ₁	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM021DW	FHDDM055DW	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM021DW	FHDDM055NW	H ₀	H ₁	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂
DDM021DW	RDDM001TRAD	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀					
DDM021DW	RDDM008DW	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀					
DDM021DW	RDDM008NW	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀
DDM021DW	RDDM021DW	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₁	H ₀					
DDM021DW	RDDM021NW	H ₀	H ₂	H ₀	H ₁	H ₀										
DDM021DW	RDDM055DW	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀
DDM021DW	RDDM055NW	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₀						
DDM021DW	USDD001TRAD	H ₀	H ₁	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM021DW	USDD008DW	H ₀	H ₁	H ₁	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂					
DDM021DW	USDD008NW	H ₀	H ₁	H ₁	H ₀	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂

USDD021DW	USDD055NW	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	H ₀	
USDD021NW	USDD055DW	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₁	H ₁	H ₀	H ₀	H ₂	H ₂	H ₁	H ₀	
USDD021NW	USDD055NW	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₁	H ₁	H ₀	H ₀	H ₂	H ₂	H ₀	H ₀	
USDD055DW	USDD055NW	H ₀	H ₀	H ₀	H ₁	H ₀	H ₁	H ₂	H ₀	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	
		Totais														
		Abruptas				Graduais				Geral						
		$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank
DDM001TRAD		142	80	183	-103	5	144	85	176	-91	1	286	165	359	-194	1
DDM008DW		137	77	191	-114	3,5	136	105	164	-59	4	273	182	355	-173	4
DDM008NW		138	86	181	-95	7	139	126	140	-14	9	277	212	321	-109	8
DDM021DW		133	73	199	-126	1	132	109	164	-55	5,5	265	182	363	-181	3
DDM021NW		134	97	174	-77	8	138	128	139	-11	10	272	225	313	-88	9
DDM055DW		141	75	189	-114	3,5	131	103	171	-68	3	272	178	360	-182	2
DDM055NW		165	62	178	-116	2	146	114	145	-31	7,5	311	176	323	-147	5
FHDDM001TRAD		105	174	126	48	20	155	121	129	-8	11	260	295	255	40	15
FHDDM008DW		116	193	96	97	25,5	165	126	114	12	17,5	281	319	210	109	24,5
FHDDM008NW		116	193	96	97	25,5	165	126	114	12	17,5	281	319	210	109	24,5
FHDDM021DW		127	211	67	144	27,5	151	161	93	68	27	278	372	160	212	27,5
FHDDM021NW		127	211	67	144	27,5	151	161	93	68	27	278	372	160	212	27,5
FHDDM055DW		130	156	119	37	18,5	141	134	130	4	12,5	271	290	249	41	16,5
FHDDM055NW		130	156	119	37	18,5	141	134	130	4	12,5	271	290	249	41	16,5
RDDM001TRAD		113	187	105	82	24	146	138	121	17	19	259	325	226	99	23
RDDM008DW		102	190	113	77	23	140	136	129	7	14,5	242	326	242	84	20
RDDM008NW		119	127	159	-32	10	154	84	167	-83	2	273	211	326	-115	7
RDDM021DW		107	181	117	64	22	145	134	126	8	16	252	315	243	72	19
RDDM021NW		142	120	143	-23	12,5	154	98	153	-55	5,5	296	218	296	-78	10
RDDM055DW		136	162	107	55	21	140	162	103	59	25	276	324	210	114	26
RDDM055NW		141	149	115	34	16	149	141	115	26	21	290	290	230	60	18
USDD001TRAD		131	124	150	-26	11	148	138	119	19	20	279	262	269	-7	12
USDD008DW		130	126	149	-23	12,5	146	146	113	33	22	276	272	262	10	13
USDD008NW		112	98	195	-97	6	144	115	146	-31	7,5	256	213	341	-128	6
USDD021DW		134	135	136	-1	14	143	149	113	36	23	277	284	249	35	14
USDD021NW		123	124	158	-34	9	138	137	130	7	14,5	261	261	288	-27	11
USDD055DW		136	152	117	35	17	145	159	101	58	24	281	311	218	93	21
USDD055NW		135	150	120	30	15	137	168	100	68	27	272	318	220	98	22

Fonte: a autora (2022).

Tabela 29 – Valores das hipóteses estatísticas de Wilcoxon em relação a acurácia na comparação geral do DDM, FHDDM, RDDM e USDD nas versões tradicionais e variações do NW e DW para NB.

FHDDM055DW	USDD055NW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₁	H ₁	H ₁						
FHDDM055NW	RDDM001TRAD	H ₀	H ₂	H ₀	H ₁										
FHDDM055NW	RDDM008DW	H ₀	H ₂	H ₀	H ₀	H ₁									
FHDDM055NW	RDDM008NW	H ₀	H ₂	H ₂	H ₁	H ₂	H ₂	H ₂	H ₀	H ₁					
FHDDM055NW	RDDM021DW	H ₀	H ₂	H ₀	H ₁										
FHDDM055NW	RDDM021NW	H ₀	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁					
FHDDM055NW	RDDM055DW	H ₂	H ₀	H ₁											
FHDDM055NW	RDDM055NW	H ₀	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁					
FHDDM055NW	USDD001TRAD	H ₀	H ₀	H ₀	H ₁	H ₂	H ₀	H ₂	H ₀	H ₁	H ₁				
FHDDM055NW	USDD008DW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₀	H ₀	H ₂	H ₁	H ₁				
FHDDM055NW	USDD008NW	H ₁	H ₁	H ₁	H ₁	H ₂	H ₀	H ₀	H ₁	H ₁					
FHDDM055NW	USDD021DW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₀	H ₂	H ₀	H ₁	H ₁				
FHDDM055NW	USDD021NW	H ₁	H ₁	H ₁	H ₁	H ₂	H ₀	H ₀	H ₁	H ₁					
FHDDM055NW	USDD055DW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₀	H ₁	H ₁						
FHDDM055NW	USDD055NW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₁	H ₁							
RDDM001TRAD	RDDM008DW	H ₂	H ₁	H ₀	H ₁	H ₁	H ₁	H ₁	H ₂	H ₁	H ₂	H ₀	H ₀	H ₂	H ₀
RDDM001TRAD	RDDM008NW	H ₁	H ₀	H ₁	H ₁	H ₀	H ₁	H ₀	H ₁	H ₀					
RDDM001TRAD	RDDM021DW	H ₂	H ₀	H ₀	H ₁	H ₀	H ₁	H ₀	H ₀	H ₁	H ₂	H ₀	H ₀	H ₂	H ₀
RDDM001TRAD	RDDM021NW	H ₁	H ₀												
RDDM001TRAD	RDDM055DW	H ₂	H ₀	H ₀	H ₂	H ₀	H ₀	H ₁	H ₀						
RDDM001TRAD	RDDM055NW	H ₀	H ₀	H ₁	H ₀										
RDDM001TRAD	USDD001TRAD	H ₁	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₀				
RDDM001TRAD	USDD008DW	H ₁	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₀				
RDDM001TRAD	USDD008NW	H ₁	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₀				
RDDM001TRAD	USDD021DW	H ₁	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₀				
RDDM001TRAD	USDD021NW	H ₁	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₀				
RDDM001TRAD	USDD055DW	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂
RDDM001TRAD	USDD055NW	H ₀	H ₁	H ₁	H ₁	H ₁	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂
RDDM008DW	RDDM008NW	H ₁	H ₀	H ₁	H ₁	H ₀	H ₁	H ₀	H ₁	H ₀					
RDDM008DW	RDDM021DW	H ₁	H ₂	H ₂	H ₂	H ₂	H ₁	H ₀	H ₀	H ₁	H ₂	H ₂	H ₀	H ₀	H ₀
RDDM008DW	RDDM021NW	H ₁	H ₀	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀					
RDDM008DW	RDDM055DW	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀	H ₂
RDDM008DW	RDDM055NW	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀	H ₂
RDDM008DW	USDD001TRAD	H ₁	H ₁	H ₁	H ₁	H ₀	H ₂	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₂
RDDM008DW	USDD008DW	H ₁	H ₁	H ₁	H ₁	H ₀	H ₂	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₂
RDDM008DW	USDD008NW	H ₁	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₀				
RDDM008DW	USDD021DW	H ₁	H ₁	H ₁	H ₁	H ₀	H ₂	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₂
RDDM008DW	USDD021NW	H ₁	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₁	H ₂				
RDDM008DW	USDD055DW	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂
RDDM008DW	USDD055NW	H ₁	H ₁	H ₁	H ₁	H ₀	H ₀	H ₁	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂
RDDM008NW	RDDM021DW	H ₂	H ₀	H ₂	H ₀	H ₂	H ₂	H ₀							
RDDM008NW	RDDM021NW	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀	H ₀	H ₂	H ₀					
RDDM008NW	RDDM055DW	H ₂	H ₁	H ₀	H ₂	H ₀	H ₂	H ₀	H ₂	H ₀					
RDDM008NW	RDDM055NW	H ₂	H ₁	H ₀	H ₂	H ₀	H ₀	H ₀	H ₂	H ₀					
RDDM008NW	USDD001TRAD	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₁	H ₂	H ₁	H ₂				
RDDM008NW	USDD008DW	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₁	H ₂	H ₁	H ₂				

USDD008DW	USDD021DW	H ₀	H ₀	H ₀	H ₂	H ₁	H ₂	H ₂	H ₀	H ₂	H ₀					
USDD008DW	USDD021NW	H ₀	H ₁	H ₂	H ₀	H ₂	H ₀	H ₀	H ₁	H ₀	H ₀	H ₀				
USDD008DW	USDD055DW	H ₀	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂								
USDD008DW	USDD055NW	H ₀	H ₁	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂				
USDD008NW	USDD021DW	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀						
USDD008NW	USDD021NW	H ₂	H ₀	H ₂	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀						
USDD008NW	USDD055DW	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂					
USDD008NW	USDD055NW	H ₂	H ₀	H ₀	H ₀	H ₂										
USDD021DW	USDD021NW	H ₀	H ₁	H ₀	H ₁	H ₁	H ₀	H ₁								
USDD021DW	USDD055DW	H ₀	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂								
USDD021DW	USDD055NW	H ₀	H ₁	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂				
USDD021NW	USDD055DW	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂								
USDD021NW	USDD055NW	H ₀	H ₂	H ₀	H ₀	H ₀	H ₀	H ₂								
USDD055DW	USDD055NW	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀								

		Graduais														
DDM001TRAD	DDM008DW	H ₀	H ₂	H ₀	H ₀	H ₂	H ₂	H ₁	H ₁	H ₁	H ₂	H ₀	H ₀	H ₂	H ₀	H ₀
DDM001TRAD	DDM008NW	H ₀	H ₂	H ₂	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀				
DDM001TRAD	DDM021DW	H ₀	H ₂	H ₀	H ₀	H ₂	H ₂	H ₁	H ₁	H ₀						
DDM001TRAD	DDM021NW	H ₀	H ₂	H ₀	H ₀	H ₂	H ₀	H ₀								
DDM001TRAD	DDM055DW	H ₀	H ₂	H ₀	H ₀	H ₂	H ₂	H ₁	H ₂	H ₁	H ₀					
DDM001TRAD	DDM055NW	H ₀	H ₂	H ₀	H ₀	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀				
DDM001TRAD	FHDDM001TRAD	H ₂	H ₂	H ₂	H ₀	H ₀	H ₂									
DDM001TRAD	FHDDM008DW	H ₀	H ₂	H ₂	H ₀	H ₀	H ₂									
DDM001TRAD	FHDDM008NW	H ₀	H ₂	H ₂	H ₀	H ₀	H ₂									
DDM001TRAD	FHDDM021DW	H ₀	H ₂	H ₂	H ₀	H ₀	H ₂									
DDM001TRAD	FHDDM021NW	H ₀	H ₂	H ₂	H ₀	H ₀	H ₂									
DDM001TRAD	FHDDM055DW	H ₂	H ₂	H ₂	H ₀	H ₀	H ₂									
DDM001TRAD	FHDDM055NW	H ₂	H ₂	H ₂	H ₀	H ₀	H ₂									
DDM001TRAD	RDDM001TRAD	H ₂														
DDM001TRAD	RDDM008DW	H ₂														
DDM001TRAD	RDDM008NW	H ₂	H ₂	H ₂	H ₀	H ₂										
DDM001TRAD	RDDM021DW	H ₂														
DDM001TRAD	RDDM021NW	H ₂	H ₂	H ₂	H ₀	H ₂										
DDM001TRAD	RDDM055DW	H ₂														
DDM001TRAD	RDDM055NW	H ₂	H ₂	H ₂	H ₀	H ₂										
DDM001TRAD	USDD001TRAD	H ₂	H ₂	H ₂	H ₀	H ₂										
DDM001TRAD	USDD008DW	H ₂	H ₂	H ₂	H ₀	H ₂										
DDM001TRAD	USDD008NW	H ₀	H ₂	H ₂	H ₁	H ₂										
DDM001TRAD	USDD021DW	H ₂	H ₂	H ₂	H ₀	H ₂										
DDM001TRAD	USDD021NW	H ₀	H ₂	H ₂	H ₀	H ₂										
DDM001TRAD	USDD055DW	H ₂	H ₂	H ₂	H ₀	H ₂										
DDM001TRAD	USDD055NW	H ₂	H ₂	H ₂	H ₀	H ₂										
DDM008DW	DDM008NW	H ₀	H ₀	H ₂	H ₁	H ₁	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀
DDM008DW	DDM021DW	H ₁	H ₂	H ₀	H ₂	H ₁	H ₁	H ₂	H ₁	H ₁	H ₁	H ₀				
DDM008DW	DDM021NW	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₂	H ₀	H ₀
DDM008DW	DDM055DW	H ₂	H ₁	H ₁	H ₂	H ₂	H ₂	H ₁	H ₂	H ₁	H ₀	H ₀				

FHDDM055DW	RDDM008NW	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₁	H ₁
FHDDM055DW	RDDM021DW	H ₂	H ₁	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀	H ₁	H ₀					
FHDDM055DW	RDDM021NW	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₁	H ₁
FHDDM055DW	RDDM055DW	H ₂	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₁	H ₁					
FHDDM055DW	RDDM055NW	H ₂	H ₁	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁					
FHDDM055DW	USDD001TRAD	H ₀	H ₀	H ₀	H ₁	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₀	H ₁
FHDDM055DW	USDD008DW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₂	H ₀	H ₂	H ₀	H ₁					
FHDDM055DW	USDD008NW	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₀	H ₀	H ₂	H ₁	H ₁				
FHDDM055DW	USDD021DW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₂	H ₀	H ₂	H ₀	H ₁					
FHDDM055DW	USDD021NW	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₀	H ₀	H ₂	H ₁	H ₁				
FHDDM055DW	USDD055DW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₂	H ₀	H ₂	H ₀	H ₁					
FHDDM055DW	USDD055NW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₁	H ₁								
FHDDM055NW	RDDM001TRAD	H ₂	H ₁	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀	H ₁	H ₀					
FHDDM055NW	RDDM008DW	H ₂	H ₁	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀	H ₁	H ₁					
FHDDM055NW	RDDM008NW	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₁	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₁	H ₁
FHDDM055NW	RDDM021DW	H ₂	H ₁	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀	H ₁	H ₀					
FHDDM055NW	RDDM021NW	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₁	H ₁
FHDDM055NW	RDDM055DW	H ₂	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁	H ₀	H ₁	H ₁					
FHDDM055NW	RDDM055NW	H ₂	H ₁	H ₀	H ₀	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁					
FHDDM055NW	USDD001TRAD	H ₀	H ₀	H ₀	H ₁	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₂	H ₀	H ₁
FHDDM055NW	USDD008DW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₂	H ₀	H ₂	H ₀	H ₁					
FHDDM055NW	USDD008NW	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₀	H ₀	H ₂	H ₁	H ₁				
FHDDM055NW	USDD021DW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₂	H ₀	H ₂	H ₀	H ₁					
FHDDM055NW	USDD021NW	H ₀	H ₁	H ₁	H ₁	H ₀	H ₂	H ₀	H ₀	H ₂	H ₁	H ₁				
FHDDM055NW	USDD055DW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₂	H ₀	H ₂	H ₀	H ₁					
FHDDM055NW	USDD055NW	H ₀	H ₀	H ₀	H ₁	H ₂	H ₁	H ₁								
RDDM001TRAD	RDDM008DW	H ₀	H ₀	H ₀	H ₁	H ₀	H ₁	H ₁	H ₁	H ₂	H ₀	H ₁				
RDDM001TRAD	RDDM008NW	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁				
RDDM001TRAD	RDDM021DW	H ₂	H ₀													
RDDM001TRAD	RDDM021NW	H ₀	H ₁	H ₀	H ₁	H ₀	H ₁	H ₁								
RDDM001TRAD	RDDM055DW	H ₀	H ₁	H ₁	H ₁	H ₀										
RDDM001TRAD	RDDM055NW	H ₀	H ₀	H ₀	H ₁	H ₀	H ₁									
RDDM001TRAD	USDD001TRAD	H ₁	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀					
RDDM001TRAD	USDD008DW	H ₁	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀					
RDDM001TRAD	USDD008NW	H ₁	H ₂	H ₀	H ₀	H ₀										
RDDM001TRAD	USDD021DW	H ₁	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀					
RDDM001TRAD	USDD021NW	H ₁	H ₂	H ₀	H ₀											
RDDM001TRAD	USDD055DW	H ₁	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀					
RDDM001TRAD	USDD055NW	H ₁	H ₂	H ₀	H ₂	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀					
RDDM008DW	RDDM008NW	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁	H ₀	H ₀	H ₀	H ₁	H ₁				
RDDM008DW	RDDM021DW	H ₂	H ₂	H ₀	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₂	H ₁	H ₁	H ₀	H ₀	H ₂
RDDM008DW	RDDM021NW	H ₀	H ₁	H ₀	H ₁	H ₁	H ₁	H ₀	H ₁	H ₀	H ₁	H ₁				
RDDM008DW	RDDM055DW	H ₀	H ₁	H ₂	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀					
RDDM008DW	RDDM055NW	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₀	H ₁	H ₁	H ₀					
RDDM008DW	USDD001TRAD	H ₁	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀					
RDDM008DW	USDD008DW	H ₁	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀					

RDDM055NW	USDD021DW	H ₁	H ₀	H ₂												
RDDM055NW	USDD021NW	H ₁	H ₂	H ₀	H ₀											
RDDM055NW	USDD055DW	H ₁	H ₀	H ₂												
RDDM055NW	USDD055NW	H ₁	H ₀	H ₂												
USDD001TRAD	USDD008DW	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₂	H ₀	H ₀					
USDD001TRAD	USDD008NW	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁					
USDD001TRAD	USDD021DW	H ₂	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₂	H ₀	H ₀	H ₂	H ₀	H ₀
USDD001TRAD	USDD021NW	H ₀	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₁	H ₀	H ₁	H ₁				
USDD001TRAD	USDD055DW	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀	H ₂					
USDD001TRAD	USDD055NW	H ₀	H ₂	H ₂	H ₀	H ₀	H ₀	H ₁	H ₀							
USDD008DW	USDD008NW	H ₁	H ₂	H ₂	H ₂	H ₀	H ₁	H ₀	H ₀	H ₁	H ₁					
USDD008DW	USDD021DW	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀					
USDD008DW	USDD021NW	H ₁	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀	H ₁	H ₁					
USDD008DW	USDD055DW	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₁	H ₁	H ₀	H ₂					
USDD008DW	USDD055NW	H ₀	H ₂	H ₂	H ₀	H ₀	H ₀	H ₁	H ₀							
USDD008NW	USDD021DW	H ₂	H ₁	H ₁	H ₁	H ₀	H ₂	H ₀	H ₀	H ₂	H ₂					
USDD008NW	USDD021NW	H ₀	H ₀	H ₀	H ₂	H ₂	H ₂	H ₀	H ₁	H ₀	H ₂	H ₂				
USDD008NW	USDD055DW	H ₂	H ₁	H ₁	H ₁	H ₀	H ₂	H ₀	H ₀	H ₂	H ₂					
USDD008NW	USDD055NW	H ₂	H ₁	H ₁	H ₁	H ₂	H ₂	H ₀	H ₀	H ₂	H ₂					
USDD021DW	USDD021NW	H ₁	H ₂	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀	H ₁	H ₁					
USDD021DW	USDD055DW	H ₀	H ₀	H ₀	H ₂	H ₂	H ₀	H ₁	H ₁	H ₀	H ₂					
USDD021DW	USDD055NW	H ₀	H ₂	H ₂	H ₀	H ₀	H ₀	H ₁	H ₀							
USDD021NW	USDD055DW	H ₂	H ₁	H ₁	H ₁	H ₀	H ₂	H ₂	H ₀	H ₂	H ₂					
USDD021NW	USDD055NW	H ₂	H ₁	H ₁	H ₀	H ₀	H ₂	H ₂	H ₀	H ₂	H ₂					
USDD055DW	USDD055NW	H ₀	H ₀	H ₀	H ₁	H ₁	H ₁	H ₂	H ₂	H ₂	H ₀	H ₀	H ₀	H ₀	H ₁	H ₁

	Totais															
	Abruptas					Graduais					Geral					
	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	$\sum H_0$	$\sum H_1$	$\sum H_2$	$\sum H_1 - \sum H_2$	Rank	
DDM001TRAD	53	0	352	-352	1	71	8	326	-318	1	124	8	678	-670	1	
DDM008DW	73	33	299	-266	2,5	93	48	264	-216	4	166	81	563	-482	3	
DDM008NW	102	35	268	-233	6	121	95	189	-94	7	223	130	457	-327	7	
DDM021DW	74	37	294	-257	4	93	46	266	-220	2	167	83	560	-477	4	
DDM021NW	91	41	273	-232	7	138	80	187	-107	6	229	121	460	-339	6	
DDM055DW	69	35	301	-266	2,5	96	46	263	-217	3	165	81	564	-483	2	
DDM055NW	77	44	284	-240	5	135	63	207	-144	5	212	107	491	-384	5	
FHDDM001TRAD	85	196	124	72	13	146	116	143	-27	8	231	312	267	45	11	
FHDDM008DW	102	210	93	117	23,5	154	130	121	9	10,5	256	340	214	126	16,5	
FHDDM008NW	102	210	93	117	23,5	154	130	121	9	10,5	256	340	214	126	16,5	
FHDDM021DW	98	221	86	135	25,5	146	147	112	35	15,5	244	368	198	170	18,5	
FHDDM021NW	98	221	86	135	25,5	146	147	112	35	15,5	244	368	198	170	18,5	
FHDDM055DW	93	200	112	88	15	117	152	136	16	13,5	210	352	248	104	14	
FHDDM055NW	93	203	109	94	17	117	152	136	16	13,5	210	355	245	110	15	

RDDM001TRAD	81	219	105	114	22	112	215	78	137	28	193	434	183	251	26
RDDM008DW	69	216	120	96	18	104	211	90	121	23	173	427	210	217	23
RDDM008NW	57	168	180	-12	9	81	155	169	-14	9	138	323	349	-26	8
RDDM021DW	75	220	110	110	21	100	216	89	127	26	175	436	199	237	24,5
RDDM021NW	81	175	149	26	10	92	164	149	15	12	173	339	298	41	10
RDDM055DW	75	218	112	106	19	88	205	112	93	20	163	423	224	199	21
RDDM055NW	85	187	133	54	12	91	181	133	48	18	176	368	266	102	13
USDD001TRAD	130	180	95	85	14	142	184	79	105	21	272	364	174	190	20
USDD008DW	126	184	95	89	16	137	196	72	124	25	263	380	167	213	22
USDD008NW	90	151	164	-13	8	100	174	131	43	17	190	325	295	30	9
USDD021DW	114	200	91	109	20	131	201	73	128	27	245	401	164	237	24,5
USDD021NW	93	176	136	40	11	100	180	125	55	19	193	356	261	95	12
USDD055DW	119	215	71	144	28	135	194	76	118	22	254	409	147	262	27
USDD055NW	109	218	78	140	27	136	196	73	123	24	245	414	151	263	28

Fonte: a autora (2022).