



**UNIVERSIDADE FEDERAL DO AMAZONAS  
INSTITUTO DE COMPUTAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA**



**ALBERT FRANÇA JOSUÁ COSTA**

**DETECÇÃO DE MUDANÇA DE CONCEITO BASEADA EM APRENDIZADO  
ATIVO**

**MANAUS  
DEZEMBRO DE 2017**

**ALBERT FRANÇA JOSUÁ COSTA**

**DETECÇÃO DE MUDANÇA DE CONCEITO BASEADA EM APRENDIZADO  
ATIVO**

Dissertação apresentada ao Programa de Pós-Graduação em Informática do Instituto de Computação da Universidade Federal do Amazonas como requisito para a obtenção do grau de Mestre em Informática.

**Orientadora:** PhD. Eulanda Miranda dos Santos

**MANAUS  
DEZEMBRO DE 2017**

## Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

C837d Costa, Albert França Josué  
Detecção de mudança de conceito baseada em aprendizado ativo  
/ Albert França Josué Costa. 2017  
107 f.: il. color; 31 cm.

Orientadora: Eulanda Miranda dos Santos  
Dissertação (Mestrado em Informática) - Universidade Federal do Amazonas.

1. Detecção de Mudança de Conceito. 2. Aprendizado Ativo. 3. Margens Virtuais. 4. Incerteza. I. Santos, Eulanda Miranda dos II. Universidade Federal do Amazonas III. Título



PODER EXECUTIVO  
MINISTÉRIO DA EDUCAÇÃO  
INSTITUTO DE COMPUTAÇÃO

PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA



# FOLHA DE APROVAÇÃO

"DETECÇÃO DE MUDANÇA DE CONCEITO BASEADA EM  
APRENDIZADO ATIVO "

**ALBERT FRANÇA JOSUÁ COSTA**

Dissertação de Mestrado defendida e aprovada pela banca examinadora constituída pelos Professores:

Profa. Eulanda Miranda dos Santos - PRESIDENTE

Prof. Eduardo James Pereira Souto - MEMBRO INTERNO

Prof. Marco Antonio Pinheiro de Cristo - MEMBRO INTERNO

Prof. José Luiz de Souza Pio - MEMBRO EXTERNO

Manaus, 11 de Dezembro de 2017

## **AGRADECIMENTOS**

Grato as lei universais e imutáveis.

Grato pela dedicação na orientação da professora Doutora Eulanda Miranda dos Santos.

Grato aos trabalhadores brasileiros que com o suor do seu labor diário financiaram meus estudos.

Grato a FAPEAM pelo apoio financeiro disponibilizado para a execução dessa pesquisa através do edital de Chamada Pública Número 002/2014 RH-TI Capacitação/Amazônia Turmas Fora de Sede.

## RESUMO

As atuais técnicas de aprendizado de máquina aplicadas na tarefa de predição são baseadas na premissa de que o ambiente em que os dados são gerados apresenta um comportamento estacionário e supervisionado. Porém, os ambientes, na maioria dos problemas do mundo real, são considerados dinâmicos e semi-supervisionados, fatos que invalidam as premissas normalmente utilizadas. Nesses ambientes há a possibilidade da ocorrência do fenômeno conhecido na literatura por mudança de conceito (do inglês *concept drift*), que caracteriza-se pela alteração na relação entre as características das instâncias e a sua verdadeira classe com a passagem do tempo. Como efeito primário da ocorrência desse fenômeno tem-se a degradação significativa na taxa de desempenho do classificador, tornando-o obsoleto para a tarefa. Encontram-se na literatura métodos que lidam implicitamente ou explicitamente com a mudança de conceito, sendo que os métodos cegos (implícitos) arcam com os custos de retreinar o classificador de forma constante, enquanto que os métodos informados (explícitos) atuam normalmente baseados no monitoramento da degradação do desempenho do classificador, ou na realização de suposições sobre a distribuição das instâncias. Para contornar essas dificuldades, esta dissertação propõe o uso da variação da densidade das instâncias mais significativas, calculada com base em Aprendizado Ativo, como sinalizador explícito da ocorrência de mudança de conceito. A densidade é mensurada a partir do conceito de margens virtuais projetadas no espaço de entrada, sendo que as margens virtuais são obtidas com base na incerteza do classificador. Objetivando-se demonstrar a validade do método proposto, denominado de Método de Detecção de Mudança de Conceito Baseada em Aprendizado Ativo (DMAA), experimentos foram realizados em duas etapas. A primeira consistiu na aplicação do DMAA em seis bases de dados, sendo quatro sintéticas e duas reais. Os resultados obtidos demonstram que o método proposto identificou em média 95,45% das mudanças existentes nas bases sintéticas, e alcançou uma média geral de erro de 16,5%. Na segunda etapa de experimentos, foi feita uma comparação entre o DMAA e três *baselines*, incluindo dois métodos supervisionados e um método baseado em aprendizado ativo. Os resultados indicam que o DMAA alcançou resultados estatisticamente superiores em mais da metade das bases de dados investigadas, além de reduzir significativamente a quantidade de instâncias rotuladas necessárias para manter o sistema atualizado.

**Palavras-chave:** Detecção de Mudança de Conceito, Aprendizado Ativo, Margens Virtuais, Incerteza

## ABSTRACT

Current machine learning techniques used for prediction tasks rely on the assumption that the environment where data is generated is static and supervised. However, most of the real-world problems present dynamic and semi-supervised environments, which invalidate this assumed assumption. In these environments, it is possible the occurrence of a phenomenon known in the literature as concept drift. The main characteristic of such a phenomenon is that the relationship between instances' features and their true classes changes over time. The primary effect of the concept drift occurrence is the decrease on classifier performance, which leads the classifier to be obsolete for the task. There are methods in the literature that deal with concept drift implicitly or explicitly. The main drawback to blind (implicit) methods is the cost on retraining the classifier constantly, even with no concept drift occurrence, while the informed (explicit) methods generally work based on classifier performance decrease, or based on assumptions about the samples distribution. In order to try to overcome these drawbacks, in this work we propose to use density variation of the most significant instances as an explicit trigger for concept drift detection. Density variation measurement is based on Active Learning, and is calculated from virtual margins projected onto the input space according to the classifier confidence. Focusing on demonstrating the validity of the proposed method, called Concept Drift **D**etection **M**ethod Based on **A**ctive **L**earning (DMAA), we have carried out experiments divided into two series. In the first series, DMAA was investigated on six databases, which represent four synthetic and two real problems. The obtained results show that the proposed method achieved 95.45% of drift detection rate on synthetic databases, and 16.5% as mean error rate in both synthetic and real databases. In the second series of experiments, DMAA was compared to three baselines, including two supervised drift detectors and one Active Learning-based method. The obtained results show that DMAA reached statistically significant better recognition rates in the majority of databases. Besides, it reduced the amount of labeled instances needed to keep the system updated.

**Keywords:** Concept Drift Detection, Active Learning, Virtual Margins, Uncertainty.

# LISTA DE FIGURAS

Figura 2-1: Estrutura do fenômeno da Mudança de Conceito.....	15
Figura 2-2: Demonstração da ocorrência de Mudança de Conceito..	17
Figura 2-3: Comportamento do erro de classificação na presença de Mudança de Conceito.....	18
Figura 2-4: Mudança de Conceito gerada por alterações na distribuição da probabilidade <i>a priori</i> .....	19
Figura 2-5: Mudança de Conceito gerada por mudança na distribuição da probabilidade condicional.....	20
Figura 2-6: Mudança de Conceito gerada por mudança na distribuição da probabilidade <i>a posteriori</i> .....	21
Figura 2-7: Mudança Repentina.....	23
Figura 2-8: Mudança Probabilística Gradual.....	23
Figura 2-9: Mudança Gradual (Incremental).....	24
Figura 2-10: Conceito Recorrente.....	25
Figura 4-1: Estrutura Geral do MDAA.....	42
Figura 4-2: Margens Virtuais.....	44
Figura 4-3: Comportamento da variação da densidade em ambiente dinâmico.....	48
Figura 4-4: Comportamento da variação da densidade em ambiente estático.....	49
Figura 5-1: Conceitos existentes na base <i>Line</i> .....	52
Figura 5-2: Conceitos existentes na base <i>Circle</i> .....	53
Figura 5-3: Quatro primeiros conceitos existentes na base <i>sine1</i> .....	53
Figura 5-4: Quatro primeiros conceitos existentes na base <i>Gauss</i> .....	54
Figura 5-5: Resultado da detecção de mudança na base <i>Line</i> .....	67
Figura 5-6: Resultado da detecção de mudança na base <i>Circle</i> .....	67
Figura 5-7: Resultado da detecção de mudança na base <i>Sine1</i> .....	68
Figura 5-8: Resultado da detecção de mudança na base <i>Gauss</i> .....	68
Figura 5-9: Resultado da detecção de mudança na base <i>SPAM</i> .....	69
Figura 5-10: Resultado da detecção de mudança na base <i>ELEC</i> .....	69

# LISTA DE TABELAS

Tabela 3-1: Tabela comparativa dos trabalhos relacionados. ....	39
Tabela 5-1: Percentual de detecções corretas de acordo com a variação do parâmetro $\eta$ . ....	57
Tabela 5-2: Resumo do comportamento do método proposto com KNN. ....	59
Tabela 5-3: Resumo do comportamento do método proposto com SVM. ....	60
Tabela 5-4: Resumo do comportamento do método proposto com Árvore de Decisão. ....	61
Tabela 5-5: Comparação entre o DDM e MDAA. ....	63
Tabela 5-6: Comparação entre EDDM e MDAA. ....	63
Tabela 5-7: Comparação entre MD3 e MDAA. ....	63
Tabela 5-8: Resumo do comportamento do método proposto com diferentes métricas de avaliação. ....	66

# SUMÁRIO

Capítulo 1 INTRODUÇÃO .....	11
1.1 MOTIVAÇÃO E HIPÓTESE .....	12
1.2 PROBLEMA DA PESQUISA .....	13
1.3 OBJETIVOS .....	13
1.4 CONTRIBUIÇÕES .....	13
1.5 ESTRUTURA DA DISSERTAÇÃO .....	14
Capítulo 2 CONCEITOS FUNDAMENTAIS.....	15
2.1 PROBLEMA DE CLASSIFICAÇÃO.....	16
2.2 MUDANÇA DE CONCEITO: DEFINIÇÃO E ESTRUTURA.....	16
2.2.1 MUDANÇA DE CONCEITO: FONTES.....	19
2.2.2 MUDANÇA DE CONCEITO: TIPOS.....	21
2.2.3 MUDANÇA DE CONCEITO: CARACTERÍSTICAS.....	22
2.3 APRENDIZADO ATIVO.....	25
2.4 CONSIDERAÇÕES FINAIS .....	26
Capítulo 3 TRABALHOS RELACIONADOS.....	28
3.1 MÉTODOS INFORMADOS .....	28
3.2 MÉTODOS BASEADOS EM APRENDIZADO ATIVO PARA MANIPULAR MUDANÇA DE CONCEITO .....	32
3.3 CONSIDERAÇÕES FINAIS .....	37
Capítulo 4 MÉTODO PROPOSTO E ANÁLISE EMPÍRICA DO CONCEITO .....	41
4.1 MÉTODO DE DETECÇÃO DE MUDANÇA DE CONCEITO BASEADA EM APRENDIZADO ATIVO (MDAA) .....	42
4.1.1 COMPONENTE DE GERAÇÃO DO CLASSIFICADOR.....	43
4.1.2 COMPONENTE DETECÇÃO.....	43
4.1.3 COMPONENTE CLASSIFICAÇÃO .....	47
4.2 ANÁLISE EMPÍRICA DA VARIAÇÃO DA DENSIDADE.....	48
4.3 CONSIDERAÇÕES FINAIS .....	50

Capítulo 5 EXPERIMENTOS E RESULTADOS .....	51
5.1 BASE DE DADOS .....	52
5.1.1 BASES SINTÉTICAS .....	52
5.1.2 BASES REAIS.....	54
5.2 EXPERIMENTOS.....	55
5.2.1 DEFINIÇÃO DO TAMANHO DO LOTE ( $\eta$ ).....	55
5.2.2 DEFINIÇÃO DO LIMITE DE INCERTEZA ( $\lambda$ ) E LIMITE DE MUDANÇA ( $\theta$ ) ....	57
5.2.3 EXPERIMENTOS COM KNN .....	58
5.2.4 EXPERIMENTOS COM SVM LINEAR .....	60
5.2.5 EXPERIMENTO COM ÁRVORE DE DECISÃO .....	61
5.3 ANALISE ESTATÍSTICA COMPARATIVA .....	62
5.4 CONSIDERAÇÕES FINAIS .....	65
Capítulo 6 CONCLUSÕES.....	72
6.1 TRABALHOS FUTUROS .....	73
REFERÊNCIAS.....	74
APÊNDICES.....	77

# CAPÍTULO 1

## INTRODUÇÃO

Diversos métodos de aprendizado de máquina abordam o problema de previsão partindo da permissa que o ambiente em que estão inseridos é supervisionado e estático. Ambientes são ditos supervisionados quando, para cada instância  $x_i^t$  representada por um vector de características  $x_i^t = \{x^1, x^2, \dots, x^d\}$ , conhece-se a sua verdadeira classe  $y_i^t$  no tempo  $t$ .

Por estático, pode-se considerar como sendo a não modificação da relação entre as características dos dados de entrada das instâncias e a sua verdadeira classe ao longo do tempo.

Contudo, em muitos ambientes do mundo real, tal permissa frequentemente é violada, pois é comum que haja um número muito limitado de instâncias rotuladas disponíveis, uma vez que o processo de rotulagem é realizado em geral por um especialista humano, acarretando a esse processo um custo. Por outro lado, há um número praticamente ilimitado de instâncias não rotuladas, especialmente quando grande volume de dados é coletado e apresentado ao classificador em fluxo (*data stream*).

Aplicações que são designadas para operar no contexto de *data stream* precisam, além de saber lidar com as características presentes nas instâncias, tais como: alta velocidade, potencialmente infinitas e necessidade de análise contínua, também lidar com evoluções no ambiente ao longo do tempo, que é uma característica presente em meios dinâmicos (YANXIA ET AL., 2016).

Nos ambientes dinâmicos, a relação entre as características dos dados de entrada e a sua classificação pode modificar-se pela dimensão do tempo. Este fenômeno é conhecido na literatura por Mudança de Conceito, do inglês *Concept Drift*, e gera um impacto negativo no desempenho dos sistemas de previsão. Diante disso, a comunidade científica de, mas não limitado a aprendizado de máquina e mineração de dados, tem focado suas atenções no desenvolvimento de métodos capazes de manipular a ocorrência da mudança de conceitos no ambiente.

## 1.1 MOTIVAÇÃO E HIPÓTESE

Os métodos que manipulam Mudança de Conceito são divididos em dois grandes grupos denominados de métodos cegos e métodos informados. O primeiro grupo não possui um mecanismo para detecção explícita da ocorrência de mudanças no ambiente e atua retreinando o classificador em intervalos de tempo definidos de maneira estática ou dinâmica. Por outro lado, os métodos ditos informados possuem um mecanismo que, de maneira explícita, detecta a ocorrência de mudança no ambiente e só então realiza o retreino do classificador. Essa divisão está detalhada no capítulo 3.

O primeiro grupo apresenta a desvantagem de aumentar o custo computacional ao retreinar o classificador continuamente, independentemente da ocorrência ou não de mudança. De forma análoga, as desvantagens do segundo grupo estão relacionadas à dependência do decaimento da precisão do classificador (ambiente supervisionado) ou de suposições realizadas sobre a distribuição das instâncias apresentadas ao classificador (ambiente não-supervisionado).

Neste cenário, esta pesquisa baseia-se na hipótese de que o uso de técnicas de Aprendizado Ativo, um tipo de aprendizado semi-supervisionado, pode fornecer um sinalizador explícito para a ocorrência de Mudança de Conceito com base na variação da densidade das instâncias mais significativas. Desta forma, as desvantagens expostas acima, tanto dos métodos supervisionados quanto dos não supervisionados podem ser contornadas.

Com base na análise da literatura e em resultados experimentais preliminares, optou-se por utilizar a estratégia de Incerteza Fixa como técnica de Aprendizado Ativo. O objetivo dessa estratégia é permitir selecionar as instâncias que ocasionam mais dúvidas ao classificador. Tal dúvida é medida com base no valor da máxima probabilidade *a posteriori* a respeito da classe a ser atribuída à instância. Nesta pesquisa, buscou-se então adaptar essa estratégia do contexto puro de seleção de instâncias para um contexto de detecção de mudança de conceito.

Nesse processo de adaptação, cunhou-se o termo Margens Virtuais, que são hiperplanos projetados no espaço de entrada a uma distância específica do hiperplano de separação, permitindo dessa forma, que subespaços sejam delimitados no espaço de entrada. A projeção das margens virtuais é baseada no parâmetro denominado de Limite de Incerteza, que baseia-se na confiança do classificador. Por fim, o Limite de Mudança é um segundo parâmetro definido pelo usuário, que indica a partir de qual ponto modificações nas probabilidades das classes podem ser consideradas mudança de conceito.

## 1.2 PROBLEMA DA PESQUISA

Conduziu-se esta pesquisa buscando responder a seguinte questão: Como detectar a ocorrência de Mudança de Conceito de forma não supervisionada com base em estratégias de Aprendizado Ativo no contexto de problemas de classificação?

## 1.3 OBJETIVOS

O objetivo principal deste trabalho consiste em demonstrar a viabilidade do uso de Aprendizado Ativo como indicador da ocorrência de Mudança de Conceito. Para isto, propõe-se um método para detecção explícita de Mudança de Conceito baseada em Aprendizado Ativo. O método proposto reduz a dependência de instâncias rotuladas e a perda de desempenho do classificador.

Os objetivos específicos são definidos como:

- Adaptar estratégia de aprendizado ativo, denominada de Incerteza Fixa, utilizada em contexto de seleção de instâncias, para o contexto de detecção de mudança.
- Analisar o conceito de margem virtual para lidar com o problema de detecção de mudança independentemente do algoritmo de aprendizado de máquina utilizado.
- Analisar o comportamento do Limite de Incerteza em relação à capacidade de detecção de mudanças.
- Analisar o comportamento do Limite de Mudança em relação à capacidade de detecção de mudanças.

## 1.4 CONTRIBUIÇÕES

A principal contribuição desta pesquisa consiste na demonstração da capacidade do Aprendizado Ativo ser utilizado como indicador da ocorrência de Mudança de Conceito. O indicador de mudança baseia-se na variação da densidade das instâncias que caem dentro das margens virtuais projetadas pelo Aprendizado Ativo. Essa abordagem apresenta a vantagem de ser totalmente não-supervisionada na detecção de mudança, ocasionando, dessa forma, a redução do custo de rotulagem e evitando a degradação do desempenho do classificador, pois, atua antes do processo de classificação.

A contribuição secundária desta pesquisa reside na proposta do conceito de Margem Virtual. A Margem Virtual é projetada no espaço de entradas com base na incerteza permitida ao classificador. Desta forma, é possível utilizar o método proposto de forma independente do classificador utilizado.

## 1.5 ESTRUTURA DA DISSERTAÇÃO

O primeiro capítulo deste documento apresentou uma introdução ao tema em estudo, como também apresentou a motivação, hipótese, o problema, o objetivo geral e os objetivos específicos definidos nesta pesquisa. A partir deste ponto esta dissertação está estruturada da seguinte maneira.

No capítulo 2 há a apresentação dos conceitos fundamentais necessários para o entendimento desta dissertação. Inicia-se com a formalização do problema de classificação, passando por um detalhamento sobre o conceito, as fontes e as características da Mudança de Conceito.

O capítulo 3 apresenta os trabalhos relacionados ao tema desta pesquisa, o qual inicia com uma breve apresentação da classificação encontrada na literatura. Em seguida, apresenta-se o grupo de trabalhos classificados como métodos informados. Na terceira seção têm-se os trabalhos que utilizam Aprendizado Ativo para manipular Mudança de Conceito.

No capítulo 4 inicia-se com a descrição do Método de Detecção de Mudança de Conceito Baseada em Aprendizado Ativo (DMAA) proposto nesta pesquisa. Em seguida discorre-se sobre a análise empírica do método proposto e do conceito de Margens Virtual.

O capítulo 5 inicia com uma breve descrição das bases de dados utilizadas nesta pesquisa, em seguida discorre-se sobre os experimentos realizados com o método proposto e os resultados alcançados. Uma comparação estatística com métodos *baselines* da literatura é apresentada em seguida.

Por fim, no capítulo 6 encerra-se esta dissertação expondo as conclusões finais e as sugestões de trabalhos futuros.

# CAPÍTULO 2

## CONCEITOS FUNDAMENTAIS

Neste capítulo apresentam-se os conceitos fundamentais para o entendimento desta dissertação. Inicialmente apresenta-se o problema de classificação na perspectiva de aprendizado de máquina. Em seguida, trabalha-se sobre o fenômeno de Mudança de Conceito, partindo de sua definição e explorando sua estrutura.

A estrutura de análise da Mudança de Conceito adotada nesta pesquisa considera as fontes, os tipos e as características do fenômeno em análise. A Figura 2-1 apresenta como esses itens são relacionados e estruturados.



Figura 2-1: Estrutura do fenômeno da Mudança de Conceito de acordo com suas características e suas fontes.

Fonte: Própria

Conforme se pode observar na Figura 2-1, as fontes da Mudança de Conceito são alterações nas distribuições de probabilidade a *priori*, condicional ou a *posteriori* das instâncias. Encontra-se destacado também que, quando ocorrem mudanças nas probabilidades a *priori* ou condicional, gera-se o tipo Mudança de

Conceito virtual. Por sua vez, alterações na distribuição de probabilidade a *posteriori* geram o tipo conhecido como Mudança de Conceito real (destacado em azul escuro à direita).

Considerando a característica da velocidade da mudança, pode-se classificar a Mudança de Conceito em repentina, gradual ou incremental. Quando considerada a característica de ressurgimento, por sua vez, a Mudança de Conceito pode ser classificada como recorrente.

A classificação e a estrutura do fenômeno denominado de Mudança de Conceito estão detalhadas na seção 2.2 deste documento.

## 2.1 PROBLEMA DE CLASSIFICAÇÃO

As definições apresentadas nesta seção estão fundamentadas no trabalho de Bartosz e Wozniak (2011).

O problema de classificação consiste em associar a um determinado objeto uma das classes predefinidas  $y_i \in Y = \{y_1, y_2, \dots, y_n\}$  de acordo com o vector de características  $x_i = \{x^1, x^2, \dots, x^d\} \in X$  do objeto, sendo  $X$  considerado o espaço de características. Em termos matemáticos, o problema de classificação pode ser definido como sendo uma função (Equação 2.1) que mapeia  $x_i$  para  $y_i$  com o menor custo associado.

$$\varphi : X \rightarrow Y, \quad (2.1)$$

o custo associado é definido através de uma função de perda que descreve a perda de associar erroneamente um objeto pertencente à classe  $y_1$  à classe  $y_2$ .

$$L(y_1, y_2) = \begin{cases} 0, & y_1 = y_2 \\ 1, & y_1 \neq y_2 \end{cases} \quad (2.2)$$

a função denotada na Equação 2.2 é conhecida na literatura como a função de perda zero-um, pois a classificação correta gera uma perda nula e uma classificação incorreta gera uma perda de valor 1. Em ambientes estáticos, a função  $\varphi$  não precisa se preocupar com mudanças na relação  $x_i \rightarrow y_i$ , por outro lado, em ambientes com Mudanças de Conceito essa relação pode ser modificada com o passar do tempo, sendo então rescrita como  $x_i^t \rightarrow y_i^t$ .

## 2.2 MUDANÇA DE CONCEITO: DEFINIÇÃO E ESTRUTURA

O termo Mudança de Conceito foi inicialmente proposto por Schlimmer e Granher (1986), que em seu trabalho lidaram com o problema de classificação de objetos que modificam sua classe com a passagem do tempo. Gama et al.(2014) relatam que especialmente em ambientes dinâmicos é esperado que os dados

evoluam durante o tempo. Esses autores fornecem uma definição formal para Mudança de Conceito entre dois pontos no tempo.

$$\exists X : \rho_{t_0}(X, y) \neq \rho_{t_1}(X, y). \quad (2.3)$$

Na Equação 2.3,  $\rho_{t_0}$  indica a distribuição de probabilidade conjunta do dado de entrada  $X$  ser classificado como pertencente à classe  $y$  no tempo  $t_0$ . De forma semelhante,  $\rho_{t_1}$  é a probabilidade de  $X$  ser classificado como pertencente à classe  $y$  no tempo  $t_1$ . Observa-se então que a Mudança de Conceito é caracterizada como a alteração da probabilidade de classificação com o passar do tempo.

A Figura 2-2 ilustra a ocorrência de Mudança de Conceito na base sintética gerada nesta pesquisa denominada de Demonstração. A base é composta por oito mil instâncias divididas em duas classes: verdadeira e falsa. Cada instância possui três atributos, sendo dois atributos numéricos ( $x$  e  $y$ ) normalmente distribuídos no intervalo  $[0,10]$  e um atributo de classe.

As classes são definidas de acordo com a Equação 2.4:

$$classe = \begin{cases} verdadeira, & x + y \leq \theta \\ falsa, & x + y > \theta \end{cases} \quad (2.4)$$

Na Equação 2.4,  $x$  e  $y$  representam os atributos das instâncias e  $\theta$  um valor numérico de limite. Respectivamente, nos conceitos 1, 2, 3 e 4,  $\theta$  recebe os valores de 4, 8, 10 e 12.

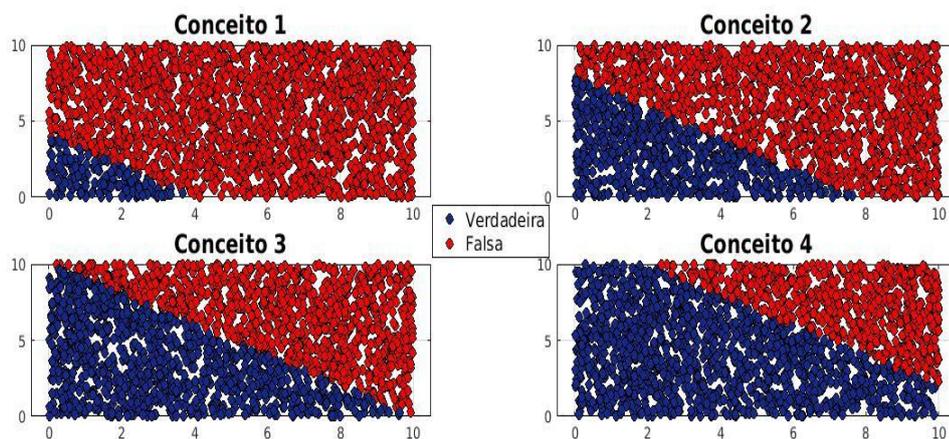


Figura 2-2: Demonstração da ocorrência de Mudança de Conceito. No conceito 1, as instâncias verdadeiras ocupam a região inferior esquerda do espaço de entradas. No conceito 2, as instâncias verdadeiras expandem-se em direção ao centro do espaço de entradas. Por sua vez, no conceito 3, as classes das instâncias ocupam regiões de tamanho equivalentes no espaço de entradas. Por fim, no conceito 4, as instâncias verdadeiras são maiorias no espaço de entradas.

Fonte: Própria

A Figura 2-3 ilustra o impacto da ocorrência de Mudança de Conceito no desempenho do classificador na base sintética Demonstração. Conforme já mencionado, esta base possui 8 mil instâncias e uma mudança de conceito a cada 2 mil instâncias. Neste exemplo, a base de treino do classificador possui apenas instâncias do primeiro conceito. Desta forma, a taxa do Erro Prequencial mantém-se baixa e estável até aproximadamente a instância 2 mil, onde pode-se notar um aumento significativo da taxa de erro de classificação, sendo essa perda catastrófica no desempenho do classificador consequência direta da ocorrência da mudança do conceito 1 ( $\theta = 4$ ) para o conceito 2 ( $\theta = 8$ ).

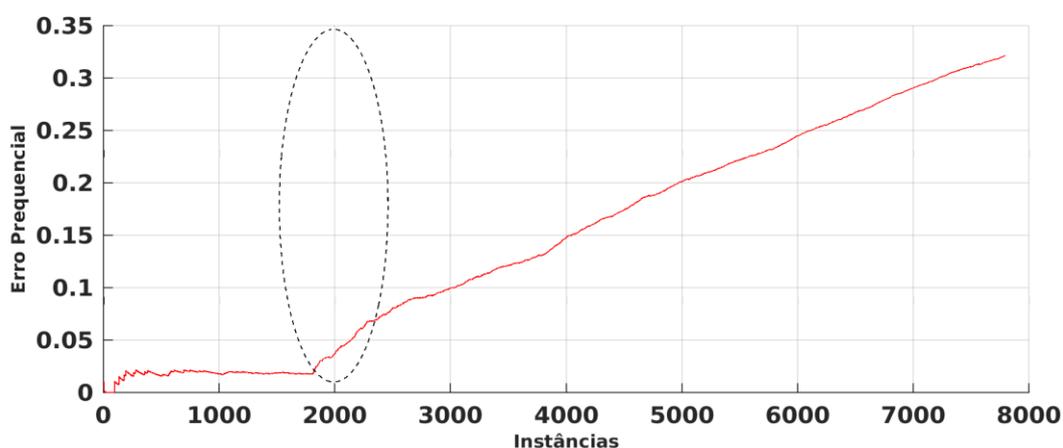


Figura 2-3: Comportamento do erro de classificação na presença de Mudança de Conceito. A linha em vermelho apresenta o comportamento do erro de classificação na base sintética Demonstração, gerada nesta pesquisa. O erro prequencial mantém-se estável até próximo à instância 2000, nesta instância ocorre a mudança do limite  $\theta$  definido na Equação 2.4 e uma Mudança de Conceito ocorre provocando uma perda catastrófica no desempenho do classificador.  
Fonte: Própria

O erro prequencial é definido por Dawid (1984) como sendo o valor acumulado da soma da função de perda entre os valores reais e os valores preditos pelo modelo, conforme a Equação 2.5.

$$S_i = \sum_1^n L(y_i, \hat{y}_i). \tag{2.5}$$

Na Equação 2.5,  $y_i$ ,  $\hat{y}_i$  e  $n$  significam, respectivamente, o valor real do instância, o valor predito pelo modelo e o total de instâncias computadas até o momento.

O problema da Mudança de Conceito é estruturado na literatura sob os mais diversos prismas, por exemplo: fontes, tipos e características. Essa estrutura é detalhada a seguir.

## 2.2.1 MUDANÇA DE CONCEITO: FONTES

Existem diversas fontes para ocorrência do fenômeno de Mudança de Conceito na tarefa de classificar objetos em ambientes dinâmicos. Sayed-Mouchaweh (2016), Henke, Souto e dos Santos (2015) e Lichtenwalter e Chawla (2010) listam três dessas fontes: probabilidade *a priori*, probabilidade condicional e probabilidade *a posteriori*.

### 2.2.1.1 PROBABILIDADE A PRIORI

A modificação da distribuição de probabilidade a priori das instâncias é uma das fontes do problema de Mudança de Conceito. A Figura 2-4 ilustra esta fonte, onde as classes são indicadas pela cor de preenchimento e as características pelo número associado à instância.

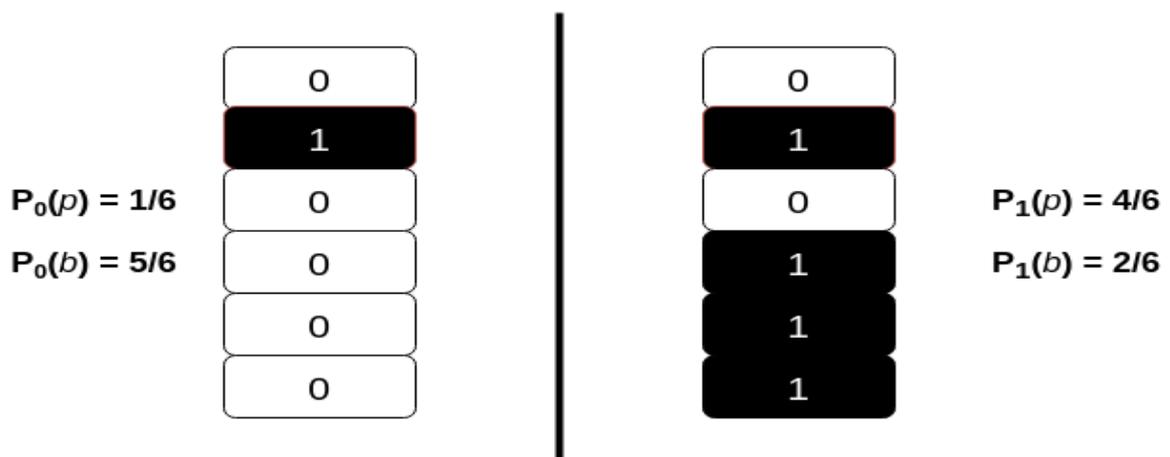


Figura 2-4: Mudança de Conceito gerada por alterações na distribuição da probabilidade *a priori*. No tempo 0 a probabilidade *a priori* de uma instância pertencer à classe branca é de 5/6, já no tempo 1, a probabilidade *a priori* é modificada para 2/6.

Fonte: Adaptado de Sayed-Mouchaweh (2016).

No tempo  $t_0$ , as instâncias que pertencem à classe preta (p) têm probabilidade *a priori* igual à  $P_0(p) = \frac{1}{6}$ , com a passagem de tempo para  $t_1$ , a probabilidade é modificada para  $P_1(p) = \frac{4}{6}$ . De forma semelhante, as instâncias da classe branca (b) também têm suas probabilidade *a priori* modificadas, passando de  $P_0(b) = \frac{5}{6}$  para  $P_1(b) = \frac{2}{6}$ . Essas modificações indicam uma possível ocorrência do problema de Mudança de Conceito.

### 2.2.1.2 PROBABILIDADE CONDICIONAL

A segunda fonte geradora de Mudança de Conceito está associada à mudança na distribuição da probabilidade condicional das instâncias conforme ilustrado na Figura 2-5.

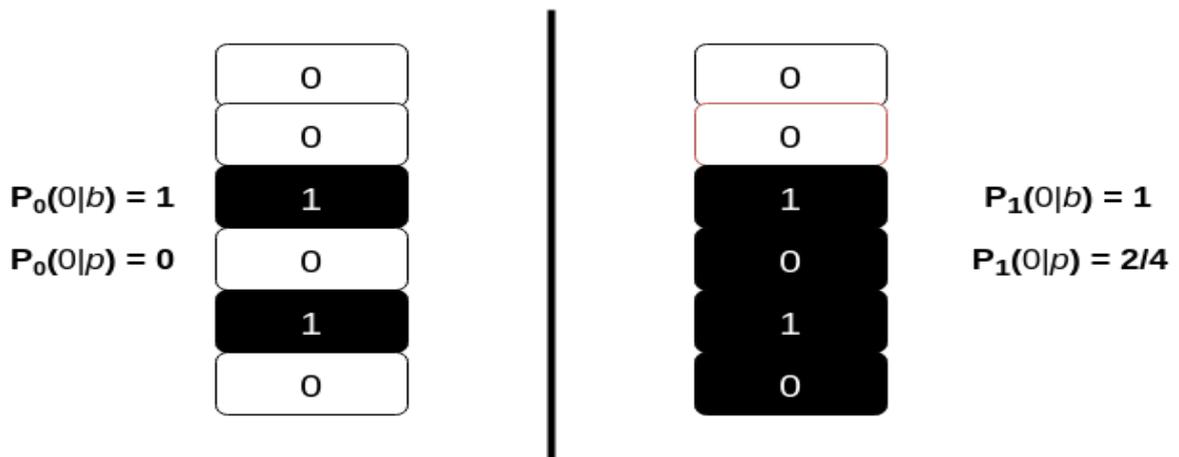


Figura 2-5: Mudança de Conceito gerada por mudança na distribuição da probabilidade condicional. No tempo 0, a probabilidade condicional das instâncias possuírem a característica 1, dado que pertencem à classe preta é 0. Por sua vez, no tempo 1, essa probabilidade condicional é modificada para 2/4.

Fonte: Adaptado de Sayed-Mouchaweh (2016)

No exemplo desta segunda fonte, a probabilidade condicional no tempo  $t_0$  que uma instância tenha a característica 0, dado que sua verdadeira classe é conhecida (branca), é calculada como sendo  $P_0(0|b) = 1$ . Enquanto a probabilidade condicional que uma instância da classe preta tenha a característica 0 é fornecida por  $P_0(0|p) = 0$ . Com a passagem de tempo para  $t_1$ , a mudança de conceito ocorre quando a probabilidade condicional da instância ter a característica 0, dado que a classe verdadeira é preta, passa a valer  $P_1(0|p) = \frac{2}{4}$ . Observa-se que não houve alteração em  $P(0|b)$ .

### 2.2.1.3 PROBABILIDADE A POSTERIORI

A Figura 2-6 ilustra a ocorrência da Mudança de Conceito causada pela mudança na distribuição da probabilidade a *posteriori* das instâncias. No tempo  $t_0$ , a probabilidade a *posteriori* da instância com característica 0 pertencer à classe branca é definida como  $P_0(b|0) = 1$ , e por sua vez  $P_0(p|0) = 0$ . Com o passar do tempo, têm-se as novas probabilidades a *posteriori*, as instâncias que possuem a característica 0 e pertencem à classe branca têm probabilidade igual a  $P_1(b|0) = \frac{2}{4}$ ,

enquanto as que pertencem à classe preta apresentam nesse segundo momento a probabilidade de  $P_1(p|0) = \frac{2}{4}$ .

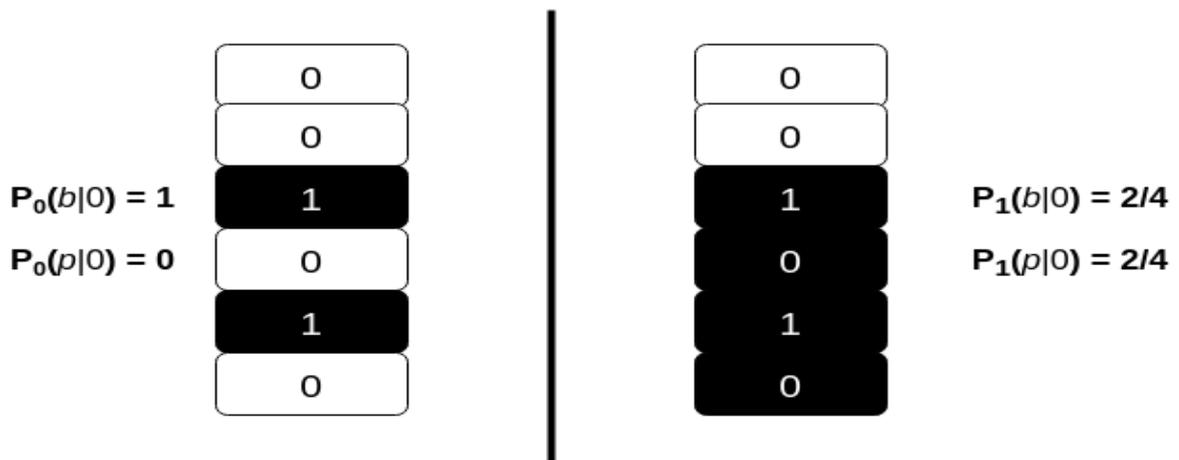


Figura 2-6: Mudança de Conceito gerada por mudança na distribuição da probabilidade a *posteriori*. No tempo 0, a probabilidade a *posteriori* das instâncias pertencerem à classe branca, dado que elas possuem a característica 1, é definida como 1. Por sua vez, no tempo 1, a probabilidade a *posteriori* é alterada para 2/4.

Fonte: Adaptado de Sayed-Mouchaweh (2016)

Sayed-Mouchaweh (2016) afirma que a Mudança de Conceito causada por esta fonte impacta na fronteira de decisão, levando à perda de desempenho do classificador.

### 2.2.2 MUDANÇA DE CONCEITO: TIPOS

O problema de Mudança de Conceito é também classificado na literatura pelo seu tipo. Nesse aspecto, pode-se classificá-lo em Mudança de Conceito real ou Mudança de Conceito virtual, sendo o tipo definido de acordo com a sua fonte geradora (BRZEZINSKI, 2010; GAMA et al., 2014; SAYED-MOUCHAWEH, 2016; WOZNIAK et al., 2016; ZLIOBAITE et al., 2011; ZLIOBAITE et al., 2014).

- Mudança de Conceito Virtual: Para Brzezinski (2010) e Sayed-Mouchaweh (2016), a Mudança de Conceito virtual está relacionada com a mudança na probabilidade condicional  $P(X|Y)$  sem afetar a probabilidade a posteriori  $P(Y|X)$ . Wozniak et al. (2016) afirmam que é discutível o fato de  $P(Y|X)$  ser afetada ou não. Gama et al. (2014) afirmam que a mudança da probabilidade a priori  $P(X)$  que não afeta a probabilidade a posteriori  $P(Y|X)$  também pode ser classificada como Mudança de Conceito Virtual.
- Mudança de Conceito Real: A mudança na probabilidade a posteriori  $P(Y|X)$  indica a ocorrência da Mudança de Conceito real, onde a classe  $Y$

irá se modificar para as mesmas características de entrada  $X$  quando a mudança do ambiente ocorrer (BRZEZINSKI, 2010; GAMA et al., 2014; SAYED-MOUCHAWEH, 2016; WOZNIAK et al., 2016; ZLIOBAITE et al., 2011; ZLIOBAITE et al., 2014). A Mudança de Conceito real ocorre independentemente de mudanças na probabilidade a priori  $P(X)$  (GAMA et al., 2014).

### 2.2.3 MUDANÇA DE CONCEITO: CARACTERÍSTICAS

As mudanças de conceitos ocorridas em ambientes dinâmicos possuem características que permitem o seu agrupamento em classes, essas características estão relacionadas, segundo Žliobaitė (2009), à velocidade de ocorrência da mudança e ao reaparecimento de conceitos antigos. Os grupos formados são denominados de repentino, gradual, incremental e recorrente e são discutidos nesta seção. Porém, antes se faz necessário a definição do conceito velocidade da mudança.

Minku, White e Yao (2010) definiram que a velocidade da mudança é o inverso do número de passos necessários para que um novo conceito substitua um conceito antigo.

$$V_d = \frac{1}{t_{de} - t_{ds}}, \quad (2.5)$$

Na Equação 2.5,  $V_d$  indica a velocidade da mudança,  $t_{de}$  e  $t_{ds}$  indicam o tempo em que a mudança terminou e o tempo em que a mudança iniciou, respectivamente. Sayed-Mouchaweh (2016) utiliza essa forma de mensuração para diferenciar entre a ocorrência de mudança repentina ou gradual.

Sayed-Mouchaweh (2016) denomina severidade, uma segunda característica presente na ocorrência de Mudança de Conceito, sendo essa, então, associada à quantidade de mudanças provocadas pela ocorrência do fenômeno. Alta severidade indica que a região ocupada pelo conceito antigo foi completamente modificada.

Em contraste, baixa severidade indica que somente parte da região ocupada pelo conceito antigo foi modificada pela mudança.

#### 2.2.3.1 MUDANÇA REPENTINA

De maneira formal, a mudança repentina é caracterizada pela substituição abrupta de um antigo conceito  $S_1$  no tempo  $t_0$  por um novo conceito  $S_2$  no tempo  $t_0$ . Em síntese, um valor próximo a 1 para a velocidade da mudança indica a ocorrência da mudança repentina.

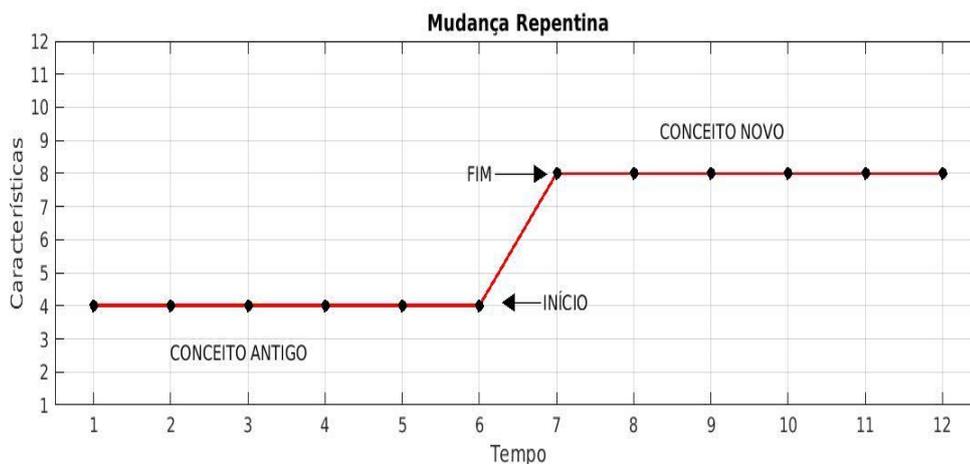


Figura 2-7: Mudança Repentina caracterizada pela substituição do conceito antigo pelo conceito novo entre os pontos de tempo 6 e 7.  
Fonte: Própria

A Figura 2-7 ilustra a substituição do conceito antigo no tempo 6 por um conceito novo no tempo 7. Esse tipo de mudança deteriora imediatamente o desempenho do classificador (SAYED-MOUCHAWEH, 2016).

### 2.2.3.2 MUDANÇA GRADUAL

Uma segunda classe relacionada com a velocidade da mudança encontrada na literatura recebe o nome de Mudança Gradual. Sob esse termo, Sayed-Mouchaweh (2016) e Žliobaitė (2009) destacam a existência dos subtipos: Mudança Probabilística Gradual ou somente Gradual, e Mudança Contínua Gradual (Incremental).

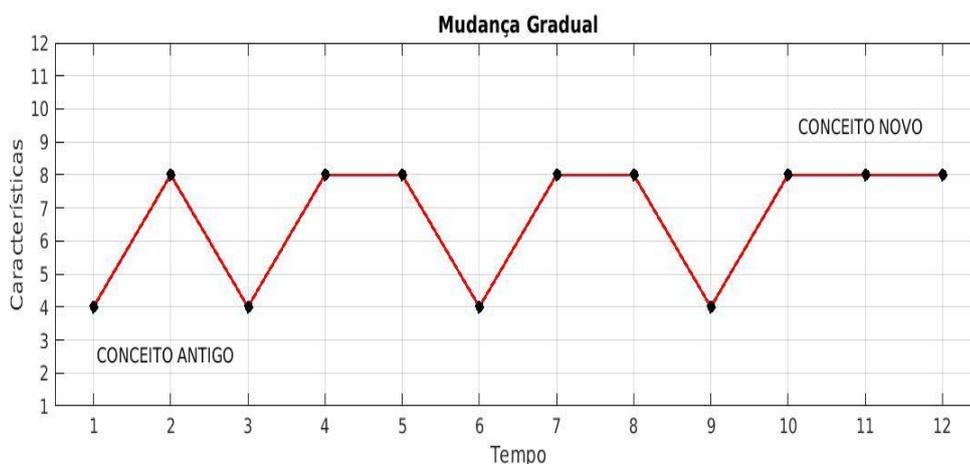


Figura 2-8: Mudança Probabilística Gradual caracterizada pela substituição suave do conceito antigo pelo conceito novo com coexistência de conceitos.  
Fonte: Própria

O primeiro está relacionado com a existência simultânea de dois conceitos  $S_1$  e  $S_2$ , mas com o passar do tempo a probabilidade do primeiro diminui até chegar a zero, enquanto a probabilidade do segundo aumenta. A Figura 2-8 ilustra a Mudança Probabilística Gradual.

Neste cenário, ambos os conceitos podem coexistir por um período de tempo, até que o novo conceito substitua integralmente o conceito anterior. Para Brzezinski (2010), a Mudança Probabilística Gradual envolve a mudança da probabilidade das classes.

### 2.2.3.3 MUDANÇA INCREMENTAL

A Mudança Contínua Gradual (Incremental) ou somente Mudança Incremental está associada com a lenta transformação de um conceito anterior  $S_1$  em um novo conceito  $S_2$ , porém, sem haver a coexistência de instâncias dos dois conceitos no mesmo ponto do tempo  $t_0$ .

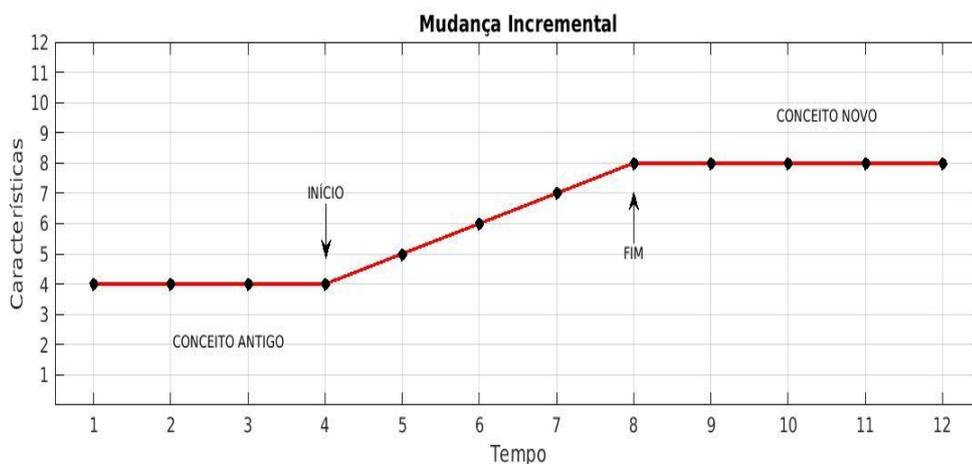


Figura 2-9: Mudança Gradual (Incremental) caracterizada pela substituição suave do conceito antigo pelo conceito novo sem coexistência de conceitos.

Fonte: Própria.

Conforme se pode observar na Figura 2-9, no cenário de uma Mudança Incremental ocorre uma transição suave entre os dois conceitos, não havendo coexistência entre  $S_1$  e  $S_2$ . Neste caso, os valores das características são lentamente modificados durante o tempo e a mudança só consegue ser detectada ao se considerar um longo período de tempo (BRZEZINSKI, 2010 e SAYED-MOUCHAWEH, 2016).

Em ambos os casos, Mudança Gradual está relacionada com um baixo valor para a velocidade da mudança. Brzezinski (2010), Huang et al. (2013) e Hoens et al. (2012) ressaltam que esses dois subtipos de mudanças são considerados sinônimos, não havendo, portanto, distinções práticas entre eles.

### 2.2.3.4 CONCEITOS RECORRENTES

Por fim, a última classe do problema de Mudança de Conceito considerando suas características é denominada de Conceitos Recorrentes. Žliobaitė (2009) e Sayed-Mouchaweh (2016) afirmam que, neste caso, um conceito  $S_1$  é substituído por um novo conceito  $S_2$  no tempo  $t_0$ . Contudo,  $S_1$  pode voltar a se tornar ativo com o passar do tempo, ocorrendo então a alternância de conceitos válidos no ambiente.

A Figura 2-10 apresenta exemplo da ocorrência de Conceitos Recorrentes. Nesse caso, o conceito  $S_1$  é substituído pelo conceito  $S_2$  no tempo  $t = 4$ . Contudo, o conceito  $S_1$  volta a torna-se válido após o tempo  $t = 9$ , com a observância de exemplos de  $S_1$ .

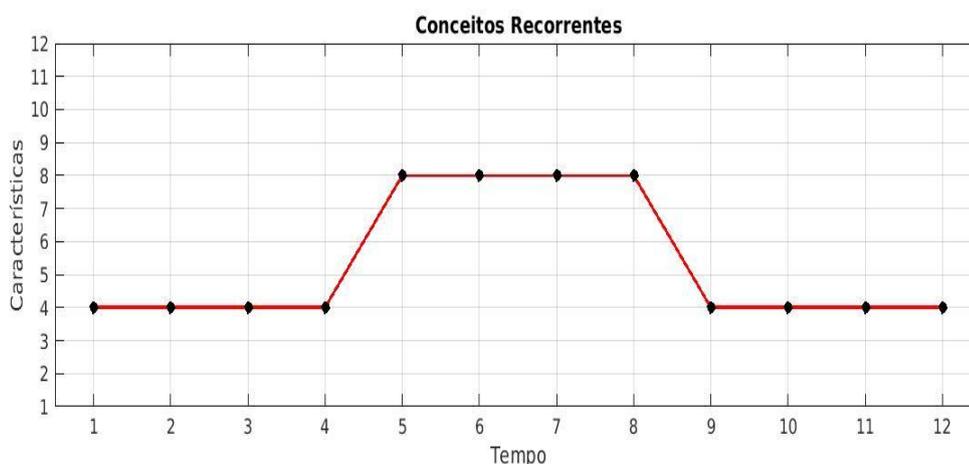


Figura 2-10: Conceito Recorrente caracterizado pelo ressurgimento de conceitos antigos. No tempo 4, o primeiro conceito é substituído por um novo conceito, porém, no tempo 9, o primeiro conceito retorna ao estado ativo.

Fonte: Própria

Conforme mencionado na introdução, este trabalho aplica uma técnica de aprendizagem ativo para detectar Mudança de Conceito. Para que o método proposto seja mais claramente descrito, na próxima seção discute-se sobre Aprendizado Ativo.

## 2.3 APRENDIZADO ATIVO

Aprendizado Ativo, conhecido na literatura pelo termo em inglês *Active Learning*, é uma espécie do gênero de aprendizado semi-supervisionado, e é considerado também uma subárea do aprendizado de máquina. A ideia base por trás do Aprendizado Ativo é permitir que o algoritmo possa de maneira ativa e autônoma selecionar as instâncias mais significativas que serão utilizadas no

processo de aprendizado. O objetivo disto é reduzir a necessidade de instâncias rotuladas sem perder a qualidade no processo de aprendizado (BURR, 2010).

Calma et al. (2015) e Kermer, Pedersen e Igel (2014) formalmente definem que o objetivo do Aprendizado Ativo é construir um classificador com a menor quantidade de instâncias rotuladas possíveis que minimize a função de risco do classificador. Em síntese, estratégias de Aprendizado Ativo buscam construir um classificador com poucas instâncias que tenham um desempenho equivalente a de um classificador treinado em um ambiente plenamente supervisionado.

Burr (2012) e Kermer, Pedersen e Igel (2014) listam algumas técnicas básicas de Aprendizado Ativo conhecidas na literatura, tais como Amostragem por Incerteza e Espaço de Versão. A primeira técnica consiste em selecionar as instâncias para as quais o classificador possui menor certeza sobre seu verdadeiro rótulo. Por exemplo, ao considerar um classificador SVM, as instâncias para as quais o SVM possui maior incerteza são as que estão mais próximas do hiperplano de separação.

A segunda técnica, Espaço de Versão, assume que uma hipótese é um modelo computacional que tenta explicar as instâncias de treinamento e consegue fazer a predição de novas instâncias corretamente. Então, o conjunto de todas as hipóteses forma o espaço de hipóteses. Considerando  $\nu$  um subconjunto do espaço de hipóteses contendo as hipóteses consistentes com o conjunto das instâncias de treinamento, a técnica Espaço de Versão atua selecionando a hipótese de  $\nu$  que mantém o melhor desempenho sobre as instâncias não rotuladas.

## 2.4 CONSIDERAÇÕES FINAIS

Neste capítulo foram discutidos os conceitos fundamentais necessários para o entendimento desta dissertação. Iniciando-se com a definição do conceito do problema de classificação e a exposição, a título de exemplo, da função de perda zero-um. Em seguida, o problema de Mudança de Conceito foi apresentado e sua estrutura discutida, considerando-se aspectos como fontes, tipos e características.

A Figura 2-1 possibilita uma visão geral de como o fenômeno em estudo está estruturado. Permitindo relacionar suas fontes e suas características com os seus respectivos tipos. Por mais que Mudança de Conceito ocorra tanto em problemas de regressão quanto de classificação, esta pesquisa está focada no segundo grupo de problemas. Desta forma, a seção 2.1 contextualiza a pesquisa em termos de tarefas de classificação.

A Figura 2-2 permite um entendimento visual da evolução do espaço de entradas das instâncias quando uma Mudança de Conceito ocorre. Por sua vez, a Figura 2-3 demonstra o impacto catastrófico da mudança no desempenho do classificador, o que justifica plenamente o desenvolvimento de pesquisas com o

objetivo de desenvolver métodos mais eficientes de detecção de Mudança de Conceito.

Por fim, foi apresentada uma definição formal de Aprendizado Ativo e definidas as técnicas de Amostragem por Incerteza e Espaço de Versão. No próximo capítulo será apresentada uma sumarização dos trabalhos relacionados, tratando dos métodos de detecção explícita e dos métodos que manipulam Mudança de Conceito utilizando Aprendizado Ativo independentemente da forma de detecção.

# CAPÍTULO 3

## TRABALHOS RELACIONADOS

Na literatura encontram-se diversos trabalhos que lidam com o problema de Mudança de Conceito. Esses trabalhos propõem métodos que podem ser classificados de acordo com a abordagem utilizada. Em uma perspectiva clássica, esses métodos são divididos com base na utilização ou não de mecanismos de detecção explícita da ocorrência de mudança. O primeiro grupo, denominado de métodos cegos, realiza a atualização regular do classificador independentemente da detecção de mudanças no ambiente, sendo essa característica sua principal desvantagem, devido ao elevado custo computacional envolvido no processo de retreino do classificador.

O segundo grupo recebe o nome de métodos informados. Esses métodos possuem mecanismos que explicitamente detectam a ocorrência da Mudança de Conceito e só então realizam a atualização do classificador. Alguns métodos pertencentes a esse grupo realizam a detecção monitorando a taxa de erro do classificador, cuja desvantagem é a necessidade de deterioração do desempenho do classificador para que mudanças sejam detectadas.

Esta pesquisa tem como foco a detecção explícita de mudanças de conceito no ambiente. Desta forma, neste capítulo apresentam-se trabalhos relacionados pertencentes a esse segundo grupo de métodos.

### 3.1 MÉTODOS INFORMADOS

Um dos métodos mais citados na literatura para detecção explícita de Mudança de Conceito foi proposto por Gama et al (2004) e nomeado de *Drift Detection Method* (DDM). O método utiliza aprendizado online para monitorar a ocorrência de mudanças através do decaimento do desempenho do classificador, sendo esse representado pelo aumento da taxa de erro no processo de classificação. Tal monitoramento baseia-se no modelo de aprendizado Provavelmente Aproximadamente Correto (PAC), o qual define que um aumento

significativo na taxa de erro sugere a ocorrência de mudanças na distribuição da classe (MITCHEL, 1997).

O DDM leva em consideração que, com número maior do que 30 instâncias, a Distribuição Binomial pode ser aproximada pela distribuição Normal com a mesma média e variância. Durante o processo de execução do classificador são definidos os valores das variáveis  $p_{min}$  e  $s_{min}$ , que indicam a probabilidade mínima do erro de classificação ( $p_i$ ) e seu desvio padrão ( $s_i$ ), este pode ser calculado pela Equação 3.8.

$$s_i = \sqrt{\frac{p_i(1-p_i)}{i}}, \quad (3.8)$$

$$p_i + s_i \geq p_{min} + \alpha * s_{min}, \quad (3.9)$$

$$p_i + s_i \geq p_{min} + \beta * s_{min}. \quad (3.10)$$

Para cada nova instância processada,  $p_{min}$  e  $s_{min}$  são atualizados se  $p_i + s_i \leq p_{min} + s_{min}$  for verdadeiro. Esses valores são então utilizados para indicar os níveis de alerta e de mudança, quando as Equações 3.9 e 3.10 são satisfeitas, respectivamente. Quando o nível de aviso é alcançado, o DDM passa a armazenar as instâncias. Se o nível de mudança for alcançado, então um novo classificador é treinado com as instâncias armazenadas a partir do nível de aviso. Caso contrário, as instâncias armazenadas são então descartadas. Os valores de  $\alpha$  e  $\beta$  são definidos experimentalmente. Os autores destacam que DDM apresenta melhores resultados ao detectar a mudança repentina.

Baena-Garcia et al.(2006) propuseram o método *Early Drift Detection Method* (EDDM) baseado no DDM com o objetivo de melhorar a capacidade de detecção de mudança gradual deste, porém, sem interferir negativamente na capacidade de detecção da mudança repentina. A ideia básica do EDDM consiste em considerar a distância entre dois erros de classificação ao invés de diretamente a probabilidade do erro. O aumento na distância entre dois erros indica um bom desempenho do classificador, por sua vez, uma redução na distância indicaria uma perda de desempenho.

O método calcula a distância média entre dois erros ( $p'_i$ ) e o seu respectivo desvio-padrão ( $s'_i$ ) e armazena seus valores máximos ( $p'_{max}, s'_{max}$ ). Desta forma, a Equação 3.11 indica o ponto onde a distribuição das distâncias entre os erros é máxima. Em síntese, isso representa o ponto onde o atual classificador melhor se aproxima do atual conceito das instâncias.

$$p'_{max} + 2 * s'_{max}. \quad (3.11)$$

De maneira semelhante ao DDM, Baena-Garcia et al.(2006) definem os níveis de aviso e de mudança para o EDDM. Respectivamente, o primeiro e o segundo nível são alcançados quando as Equações 3.12 e 3.13 são satisfeitas.

$$(p'_i + 2 * s'_i)/(p'_{max} + 2 * s'_{max}) < \alpha, \quad (3.12)$$

$$(p'_i + 2 * s'_i)/(p'_{max} + 2 * s'_{max}) < \beta, \quad (3.13)$$

Quando o nível de aviso é alcançado, o EDDM passa a armazenar as instâncias que chegam ao classificador, antecipando-se a uma possível mudança de conceito. Se o nível de mudança for alcançado, o atual classificador é substituído por um novo classificador treinado com as instâncias armazenadas pelo EDDM desde a entrada no nível de aviso até a indicação de mudança.

Baena-Garcia et al.(2006) destacam que a detecção de mudança somente é avaliada após a ocorrência de no mínimo 30 erros de classificação, o que pode representar um intervalo muito maior de instâncias processadas. Esse valor mínimo de erros é utilizado porque se deseja estimar a distribuição da distância entre erros e compará-la com distribuições futuras.

Pinage e dos Santos (2015) propuseram o método denominado de *Dissimilarity-based Drift Detection Method* que realiza a detecção de Mudança de Conceito baseada no monitoramento da dissimilaridade entre a distribuição das instâncias atuais e passadas, evitando desta forma realizar a detecção baseada no monitoramento do desempenho do classificador. O método é dividido nos módulos de Cálculo de Dissimilaridade e de Detecção de Mudança, este último baseado nos testes estatísticos do DDM ou EDDM.

O Módulo de Cálculo da Dissimilaridade inicialmente constrói  $n$  *clusters*, onde  $n$  representa a quantidade de classes existentes no problema. Para cada nova instância, o método a adiciona em cada um dos *clusters* e calcula a dissimilaridade entre os *clusters* originais e os *clusters* acrescidos da nova instância. A dissimilaridade é mensurada considerando o produto da distância euclidiana entre os centroides dos *clusters*, da rotação entre *clusters* e da entropia relativa simétrica. Com isto, a instância então é associada ao *cluster* que apresentar a menor dissimilaridade.

O Módulo de Detecção de Mudança é dividido na detecção baseada no teste estatístico do DDM ou no teste estatístico do EDDM. Em ambos os casos, o método recebe dois sinais sobre a predição da instância atual,  $pred1$  - que armazena a classe indicada como saída do classificador para a instância atual e  $pred2$  - que armazena a classe menos dissimilar da instância atual. Desta forma,  $pred2$  é considerada como valor de referência para  $pred1$ .

Na detecção de mudança baseada no DDM (DbDDM), os valores  $pred1$  e  $pred2$  são comparados para mensurar um erro-sintético ( $p_i$ ) e seu desvio-padrão ( $s_i = \sqrt{p_i(1-p_i)/i}$ ). Os autores afirmam que  $p_i$  é um erro-sintético, pois é calculado com base em  $pred2$  ao invés do rótulo real da instância. De forma similar ao DDM, os valores mínimos ( $p_{min}, s_{min}$ ) de  $p_i$  e  $s_i$  são armazenados e as seguintes situações são checadas: se  $p_i + s_i > p_{min} + \alpha * s_{min}$  é alcançada então o nível de aviso e o método passa a contar quantas vezes o nível de aviso é alcançado. Se a condição  $p_i + s_i > p_{min} + \beta * s_{min}$  é satisfeita, então o nível de mudança é alcançado e o método cria novos *clusters* de referência com base nas  $m$  próximas instâncias de cada classe e um novo classificador.

Por sua vez, na detecção baseada no EDDM (DbEDDM) calcula-se através da dissimilaridade a distância média entre dois erros-sintéticos ( $p'_i$ ) e seu desvio-padrão ( $s'_i$ ). Os valores máximos de  $p'_i$  e  $s'_i$  são armazenados em  $p'_{max}$  e  $s'_{max}$ . De forma análoga ao EDDM, os níveis de aviso e de mudança são definidos, respectivamente, de acordo com  $(p'_i + 2 * s'_i)/(p'_{max} + 2 * s'_{max}) < \alpha$  e  $(p'_i + 2 * s'_i)/(p'_{max} + 2 * s'_{max}) < \beta$ . No nível de aviso, o atual classificador é mantido e o método passa a contar a quantidade de vezes que esse nível foi alcançado. Quando o nível de mudança é alcançado, novos *clusters* de referência são criados, além de um novo classificador treinado com as  $m$  próximas instâncias de cada classe.

Por fim, o método *Error Distance Approach for Drift Detection and Monitoring* (EDIST2), proposto por Khamassi et al.(2015) é detalhado. O EDIST2 monitora o desempenho do classificador através de uma técnica de janela de dados auto adaptada por um teste de hipótese estatístico e é composto pelos passos de predição, monitoramento e atualização. No primeiro passo, o método faz uso do *feedback* da saída do processo de classificação para monitorar o desempenho do classificador. No passo de monitoramento, o EDIST2 analisa a distância entre dois erros consecutivos do classificador. É importante destacar que a distância é definida pelo número de instâncias classificadas corretamente entre dois erros de classificação, e que uma redução significativa nessa distância indica a ocorrência de mudança.

Ainda no passo de monitoramento, o EDIST2 faz uso de duas janelas de dados, a auto adaptada  $W_G$ , que representa as instâncias em um contexto global e é alargada de modo incremental quando não há a detecção de mudança, e estreitada, caso contrário. Contudo, em um contexto local,  $W_O$  armazena as instâncias coletadas entre a ocorrência de dois erros. O método então realiza um teste estatístico de hipótese com a distribuição da distância dos erros de  $W_G$  e  $W_O$ .

$$\mu_d = \mu_G - \mu_O. \quad (3.14)$$

Na Equação 3.14,  $\mu_G$  representa a média da distribuição dos erros em  $W_G$  e  $\mu_O$  representa a média da distribuição dos erros em  $W_O$ . A hipótese nula ( $H_0$ ), que

indica a não ocorrência de mudança, é definida como  $\mu_d = 0$ . Por outro lado, a hipótese alternativa ( $H_1$ ) que indica a ocorrência de mudança é definida como  $\mu_d > 0$ . Por fim,  $\mu_d$  é comparado com um limite  $\varepsilon$ , definido na Equação 3.16.

$$\sigma_d = \sqrt{\frac{\sigma_G^2}{N_G} + \frac{\sigma_0^2}{N_0}}, \quad (3.15)$$

$$\varepsilon = \sigma_d * 1,65. \quad (3.16)$$

Na equação 3.15,  $\sigma_G^2$ ,  $N_G$ , respectivamente, armazenam a variância e a quantidade de erros em  $W_G$ . De forma análoga,  $\sigma_0^2$ ,  $N_0$  são respectivamente a variância e a quantidade de erros em  $W_0$ . A hipótese  $H_0$  é aceita com 5% de probabilidade de estar errada, se  $\mu_d \leq \varepsilon$ , caso contrário,  $H_1$  é aceita.

O terceiro passo do método EDIST2 define os níveis em controle, de aviso e de mudança.

- Nível de controle:  $\mu_d \leq \varepsilon$ . Acima desse nível, considera-se que não há mudanças no ambiente. Com isso, as instâncias em  $W_0$  são adicionadas a  $W_G$ , parâmetro responsável por indicar se uma nova instância é apta a ser rotulada.
- Nível de aviso:  $\mu_d > \varepsilon$ . Acima desse nível, as instâncias são armazenadas em um  $W_{G'}$  temporário, aguardando a ocorrência da mudança. Caso não se confirme a mudança, então as instâncias armazenadas são descartadas.
- Nível em mudança:  $\mu_d > \varepsilon + \sigma_d$ . Acima desse nível, a mudança é confirmada e  $W_G$  é esvaziado para armazenar somente as instâncias armazenadas desde o nível de aviso.

O EDIST2 foi proposto para lidar com a ocorrência de Mudança de Conceito complexo (graduais contínuos).

### 3.2 MÉTODOS BASEADOS EM APRENDIZADO ATIVO PARA MANIPULAR MUDANÇA DE CONCEITO

Na literatura encontram-se poucos trabalhos que utilizam técnicas de Aprendizado Ativo para explicitamente detectar a ocorrência de Mudança de Conceito. Assim, nesta seção são apresentados trabalhos que manipulam mudanças no ambiente por Aprendizado Ativo independentemente se o contexto é de detecção ou de seleção de instâncias.

Sethi e Kantardzic (2015) propuseram a abordagem para detecção denominada de *Margin Density Drift Detection* (MD3). O MD3 é baseado na ideia de que um aumento ou diminuição da margem de um classificador indicaria a

ocorrência de mudança no conceito do ambiente. O método utiliza como classificador um SVM linear, tendo sua densidade de margem definida pela Equação 3.17.

$$\rho = \frac{\text{Quantidade de instâncias com } |w \cdot x + b| \leq 1}{\text{Quantidade total de instâncias}} \quad (3.17)$$

Na Equação 3.17,  $w$  e  $b$  representam os vetores de suporte e o bias do SVM, respectivamente, e a variável  $x$  representa a instância atual. A densidade é a razão entre a quantidade de instâncias que caem dentro da margem do classificador e a quantidade total de instâncias no lote. Conseqüentemente,  $\rho$  é comparado com um valor limite da densidade  $\theta$ . Caso  $\rho$  supere  $\theta$ , então uma mudança é sinalizada e o classificador é retreinado com as instâncias pertencentes ao lote atual. A principal desvantagem do MD3 relaciona-se a limitação imposta pelo método a escolha do classificador, sendo o MD3 desenvolvido para atuar exclusivamente com uma Máquina de Vetor de Suporte.

Tomando como base o conceito do MD3 e contornando a limitação da escolha do MD3, os autores Sethi e Kantardzic (2017) propuseram a utilização da variação do grau de discordância dos classificadores pertencentes a um conjunto de classificadores para realizar a detecção de mudança de conceito. Este método atual divide o espaço de entrada em  $K$  subespaços aleatórios, sendo então cada classificador do conjunto treinado em um desses subespaços. O método passa então a computar a quantidade de instâncias que possuem uma incerteza maior do que um limite estabelecido. Um aumento na discordância do valor predito pelo conjunto de classificadores indica um aumento da incerteza e, por sua vez, o aumento da incerteza acumulada sugere uma mudança de conceito.

A densidade da margem dessa abordagem é definida pela Equação 3.18.

$$MD_{RS} = \frac{\sum S_E(x)}{|X|}; \forall x \in X \quad (3.18)$$

$$S_E(x) = \begin{cases} 1, & |p_E(y = -1|x) - p_E(y = +1|x)| \leq \theta_{margem} \\ 0, & \text{caso contrário.} \end{cases}$$

Na Equação 3.18, o sinal da função  $S_E(x)$  verifica se a instância  $x$  tem certeza menor do que um limite estabelecido ( $\theta_{margem}$ ), geralmente 0,5. Por sua vez,  $p_E$  refere-se à probabilidade média da instância  $x$  pertencer a uma das classes de acordo com o voto majoritário do conjunto de classificadores.

Os autores destacam que essa abordagem gera um desconfortável número de falsos positivos e, por isso, fez-se necessária a inserção de um componente de confirmação da ocorrência de mudança de conceito. Esse componente rotula as últimas  $N$  instâncias e compara a acurácia do conjunto de classificadores com a acurácia obtida no conjunto de treinamento. Se ocorrer uma diminuição significativa da acurácia, a mudança é confirmada e o classificador retreinado com as  $N$  instâncias. A inclusão do componente de confirmação reduz os falsos positivos, entretanto, acarreta a desvantagem de aumentar a quantidade de instâncias rotuladas independentemente da ocorrência da mudança, tornando o método um detector supervisionado. Outras desvantagens dessa abordagem são o custo computacional de utilizar conjuntos de classificadores, quando comparado com a utilização de classificador único, e também a necessidade de realizar uma divisão não enviesada do espaço de entrada.

Lindstrom, Namee e Delany (2011) propuseram o método denominado *Confidence Distribution Batch Detection* (CDBD), que utiliza uma abordagem não supervisionada para detectar mudanças de conceito com base na comparação da distribuição da confiança do classificador no lote atual de instâncias em relação a um lote de instâncias de referência. O CDBD divide as instâncias em lotes, sendo o primeiro definido como lote de referência e utilizado para treinar o classificador. Então, a confiança do classificador nas instâncias pertencentes ao lote de treinamento é armazenada para formar a distribuição da confiança do classificador no referido lote ( $lote_{treino}$ ). Para cada novo lote de instâncias  $i$ , a confiança do classificador é armazenada, formando a distribuição da confiança do classificador no lote  $i$  ( $lote_i$ ). Por fim, a divergência entre as distribuições  $lote_{treino}$  e  $lote_i$  é mensurada pela divergência de Kullback-Leibler. Se a divergência for significativa, uma mudança é sinalizada e o classificador reconstruído.

Wozniak et al. (2016) propuseram um método híbrido para lidar com o problema de Mudança de Conceito baseado na combinação do paradigma de aprendizado *Online*, Aprendizado Ativo e do método de janelas deslizantes com mecanismo de esquecimento. Esse mecanismo assume que os dados mais recentes são mais relevantes para o problema de classificação, porque expressam as características dos conceitos atuais, enquanto que essa relevância diminui com o tempo. O método de Wozniak et al. (2016) armazena os *data streams* em lotes e para cada lote de instâncias aplica aprendizado *Online*. O método proposto utiliza dois parâmetros denominados *threshold* e *budget*.

- *threshold*: Parâmetro responsável por indicar se uma nova amostra é apta a ser rotulada.
- *budget*: Parâmetro responsável por indicar o percentual máximo de instâncias que poderão ser rotuladas. Esse valor é definido em uma porcentagem sobre o total de instâncias de cada lote.

Para cada instância  $x_i^j$  em cada lote  $i$ , aplica-se uma função de classificação, cujo resultado é comparado com o parâmetro *threshold*. Se o valor da função for menor e o percentual definido em *budget* for maior que zero, então o rótulo verdadeiro da instância é fornecido e essa passa a fazer parte do conjunto de treinamento do classificador, que então será retreinado. O método proposto por Wozniak et (2016) lida com Mudança de Conceito incremental, a desvantagem desse método consiste na possibilidade de uma saturação do parâmetro *budget* precocemente, não permitindo que novas instâncias sejam rotuladas.

Ienco, Pfahringer e Žliobaitė (2014) propuseram o método denominado *Density Based Active Learning for Data Streams* (DBALStream) que incorpora técnicas de Aprendizado Ativo ao método DDM (Gama et al. 2004) para lidar com o problema de Mudança de Conceito. O DBALStream seleciona como instâncias mais significativas as que possuem o maior Índice de Densidade Local (IDF) dentro do lote. O IDF é definido na Equação 3.18.

$$IDF(x_i) \sum_{x_j \in W} II(\text{MinDist}(x_j) > \text{dist}(x_i, x_j)), \quad (3.18)$$

sendo que na Equação 3.18, *II* indica uma função que retorna 1 se a desigualdade é verdadeira e 0 caso contrário. A função *dist* corresponde à distância entre os pontos  $x_i$  e  $x_j$  no lote e a função *MinDist*( $x_j$ ) é uma estrutura de dados que armazena a menor distância para cada instância. O DBALStream combina o valor do *IDF* ao valor da margem (Equação 3.19) de uma instância, definida como a diferença entre as duas maiores probabilidades a *posteriori*, para definir se uma instância será rotulada ou não.

$$\text{Margem}(x_i) = P_L(y_{cl_1}|x_i) - P_L(y_{cl_2}|x_i), \quad (3.19)$$

na equação 3.19,  $cl_1$  e  $cl_2$  representam as duas classes mais prováveis.

Definido o valor para a variável que representa o orçamento disponível para rotulagem ( $b$ ), o método então realiza dois testes. O primeiro verifica se a quantidade de instâncias já rotuladas é menor do que  $b$  e o segundo leva em consideração o índice da densidade local da instância. Se o teste duplo falha, então o algoritmo retorna falso e a instância não é rotulada, caso contrário, a margem da instância é calculada e comparada com um valor limite. Se o limite for superior à margem da instância, então a instância é selecionada para ser rotulada. Com a instância rotulada, o método utiliza o *framework* definido em Gama et al. (2004) para detectar a ocorrência de Mudança de Conceito.

Por último, Žliobaitė et al. (2014) realizaram um trabalho comparativo entre cinco estratégias de seleção ativa de instâncias: i) estratégia aleatória; ii) estratégia

de incerteza fixa; iii) estratégia de incerteza variável; iv) estratégia de incerteza variável aleatória e v) estratégia de divisão. As duas primeiras são *baselines* utilizados para comparação das três restantes.

A estratégia de incerteza variável tenta superar os problemas de o classificador esgotar o seu orçamento - quando o limite da incerteza é fixo; ou do classificador se manter a maior parte do tempo acima do limite de incerteza - problema esse presente na estratégia de incerteza fixa. Objetivando superar esses problemas, a estratégia de incerteza variável seleciona as instâncias de menor certeza dentro de um intervalo de tempo. Para isso, utiliza um limite variável de incerteza sobre o tempo, ajustando-o de acordo com a precisão do classificador. Se o classificador torna-se mais preciso, então o limite é aumentado, caso contrário, o limite é reduzido. Em seguida, define-se por rotular uma instância se a máxima probabilidade *a posteriori* for menor do que o limite de incerteza e, ao mesmo tempo, o limite de incerteza é reduzido. Caso contrário, a instância não é rotulada e o limite da incerteza é aumentado.

A estratégia de incerteza variável aleatória insere um componente de aleatoriedade à estratégia anterior para permitir que instâncias longe da fronteira de decisão também possam ser rotuladas, em razão de que mudanças de conceitos podem ocorrer em qualquer lugar do espaço de instâncias. À vista disso, para cada instância, o limite de incerteza é multiplicado por uma variável aleatória normalmente distribuída.

A última estratégia de Aprendizado Ativo proposta por Žliobaitė et al. (2014) assume que os detectores de mudanças são construídos com base no pressuposto de que a distribuição dos erros é uniformemente distribuída ao longo do tempo, a não ser que ocorra mudança. Considerando que a distribuição de instâncias rotuladas não é idêntica à distribuição das instâncias não rotuladas, os detectores poderiam encontrar dificuldades em identificar se uma mudança ocorre por causa de mudança do conceito ou pela ação de uma estratégia de seleção ativa de instâncias.

Para superar esse problema, a estratégia então divide as instâncias em dois grupos. No primeiro, as instâncias são rotuladas de acordo com uma estratégia de incerteza, já no segundo grupo, as instâncias são rotuladas de acordo com uma estratégia aleatória. Ambos os grupos são utilizados para treinar o classificador, porém, somente o último é utilizado para detectar mudanças.

Independentemente da estratégia de Aprendizado Ativo adotada, o método de Žliobaitė et al. (2014) utiliza o detector proposto por Gama et al. (2004) para monitorar a ocorrência de Mudança de Conceito com base nas instâncias selecionadas por Aprendizado Ativo.

Arabmakki, Kantardzic e Sethi (2014) propuseram o método denominado *Reduced Labeled Samples* (RLS), que é baseado em lote e de detecção não supervisionado. No RLS, os rótulos das instâncias só ficam plenamente disponíveis

para o lote de treinamento. Esse método também foi projetado para lidar com classes altamente desbalanceadas, e é dividido em duas fases. Na primeira, um classificador SVM é gerado com as instâncias pertencentes ao conjunto de treinamento. Considerando o alto desbalanceamento das classes e a sensibilidade do SVM a esse desbalanceamento, os autores propõem utilizar a técnica de amostragem denominada de *Synthetic Minority Over-sampling Technique* (SMOTE) para selecionar instâncias da classe minoritária (CHAWLA ET AL., 2002). Nesse momento, o método utiliza Aprendizado Ativo no contexto de seleção de instâncias.

As amostras selecionadas do lote inicial e todos os vetores de suporte passam a compor um subconjunto de instâncias denominado Amostras Emprestadas (*Borrow Samples*). A segunda fase do método consiste em aplicar o classificador nos próximos lotes de instâncias e verificar se o sinal de mudança foi disparado. Caso seja disparado, um novo classificador é gerado com o subconjunto de instâncias mais próximas das Amostras Emprestadas, denominadas Amostras Críticas (*Critical Samples*). Para detecção de Mudança de Conceito, o RLS utiliza como métrica a medida F. A medida F do lote atual é comparada com a medida F do lote anterior, se houver uma queda maior do que um limite  $\theta$ , uma ocorrência de Mudança de Conceito é sinalizada e o novo classificador é gerado.

Com base no método RLS (ARABMAKKI, KANTARDZIC E SETHI, 2014), os autores Arabmakki, Kantardzic e Sethi (2016) propuseram o método *Reduced Labeled Samples Extended* (RLS-E). Essa extensão distingue-se da primeira abordagem por utilizar um conjunto de classificadores no lugar de um único classificador.

### 3.3 CONSIDERAÇÕES FINAIS

Os trabalhos relacionados expostos neste capítulo abordam os eixos de trabalhos que realizam a detecção explícita e de trabalhos que utilizam Aprendizado Ativo para manipular a ocorrência de mudança. No primeiro eixo, tem-se os métodos consagrados na literatura DDM, EDDM e EDIST2 que, de forma direta ou indireta, utilizam o erro como indicador de mudança, desvantagem que esta pesquisa tenta contornar. O método baseado na dissimilaridade de Pinage e dos Santos (2015) apresenta a desvantagem de requisitar o rótulo verdadeiro de cada nova instância para atualizar os *clusters*, incorrendo no aumento do custo de rotulagem, sendo que o foco deste trabalho é descobrir mecanismos que minimizem a necessidade de rotular as instâncias.

O segundo eixo expõe os métodos que manipulam a ocorrência de Mudança de Conceito com Aprendizado Ativo, independentemente da detecção explícita. Os métodos de Wozniak et (2016), lenco, Pfahringer e Žliobaitė (2014) e Žliobaitė et al. (2014) são métodos ditos cegos, ou seja, não detectam explicitamente a ocorrência

de mudança. Desta forma, esta proposta busca por um detector explícito de mudanças.

Os métodos MD3 e CDBD tentam detectar mudanças de forma explícita por meio de abordagem baseada em lotes. A versão original do MD3 está fortemente ligado ao uso do classificador SVM, enquanto que sua versão mais recente usa conjuntos de classificadores. Neste trabalho busca-se propor um detector independente do classificador utilizado e baseado em classificador individual.

A Tabela 3-1 apresenta um resumo comparativo dos métodos elencados neste capítulo, incluindo o método proposto nesta pesquisa. Expressa-se a comparação em termos da abordagem realizada, se utiliza técnicas de aprendizado ativo, política de rotulagem das instâncias, sobre aspectos do classificador utilizado e a métrica utilizada para detectar mudanças de conceito. A última linha da tabela destaca o método proposto neste trabalho.

O método proposto diferencia-se dos métodos de 1 a 4 por não necessitar rotular todas as instâncias trabalhadas. Desta forma, o método proposto pode funcionar em ambientes não plenamente supervisionados. Outra diferença consiste na abordagem, pois, enquanto os métodos identificados acima utilizam uma abordagem *online*, o DMAA utiliza uma abordagem baseada em lotes. Tanto o método proposto quando os métodos de 1 a 4 utilizam classificador único, porém, os dois primeiros são restritos a classificadores que realizam aprendizado incremental.

Quando a comparação é feita com os métodos 5, 7, 11 e 12, observa-se que são métodos que realizam uma abordagem informada e baseada em lotes, com utilização de alguma forma de aprendizado ativo, bem como realizam a rotulagem somente após a ocorrência de mudança de conceito. Os métodos 4, 11 e 12 estão restritos ao classificador SVM.

Os métodos 8, 9 e 10 realizam uma abordagem cega, onde a detecção não é realizada de maneira explícita, o que os diferencia da abordagem proposta. Todos esses métodos aproximam-se do método proposto por utilizar aprendizado ativo. Destaca-se que o nono trabalho analisa técnicas de aprendizado ativo acopladas ao *framework* do DDM, não sendo diretamente um método para detecção de mudanças de conceito. Destaca-se também que nesse nono trabalho foi proposta a técnica de aprendizado ativo, Incerteza Fixa, utilizada nesta pesquisa.

Ao comparar o método proposto com o método 6, observa-se que ambos utilizam uma abordagem baseada em margens virtuais (pseudo-margens). Porém, o método 6 necessita que um determinado número de instâncias sejam rotuladas para confirmar a ocorrência da mudança de conceito. Portanto, a incerteza é utilizada somente como mera especulação sobre a ocorrência de mudança de conceito, tendo a métrica de erro o papel de confirmar a mudança. Desta forma, ainda há a necessidade de se rotular algumas instâncias antes da confirmação da mudança. Essa característica diferencia esse método do DMAA, pois o método proposto nesta

pesquisa detecta a mudança de forma plenamente não supervisionada, sendo os rótulos necessários unicamente para retreinar o classificador após a mudança de ter sido confirmada.

Na Tabela 3-1 a sigla A.A representa Aprendizado Ativo.

Tabela 3-1: Tabela comparativa dos trabalhos relacionados.

	Método	Abordagem	A. A	Rotulagem.	Classificador	Métrica
01	<i>Drift Detection Method</i> (GAMA et al , 2004)	Informada Online	Não	Todas instâncias	Único Aprendizado Incremental	Erro
02	<i>Early Drift Detection Method</i> (BAENA-GARCIA et al, 2006)	Informada Online	Não	Todas instâncias	Único Aprendizado Incremental	Erro
03	<i>Dissimilarity-Based Drift Detection Method</i> (PINAGE E DOS SANTOS, 2015)	Informada Online	Não	Todas instâncias	Único	Pseudo Erro
04	<i>Error Distance Approach for Drift Detection and Monitoring</i> (KHAMASSI ET AL ,2015)	Informada Online	Não	Todas instâncias	Único	Erro
05	<i>Margin Drift Detection Method</i> (SETHI E KANTARDZIC ,2015)	Informada Lote	Sim	Pós detecção	Único SVM	Margens do classificador
06	<i>On the Reliable Detection of Concept Drift from Streaming Unlabeled Data</i> (SETHI E KANTARDZIC ,2017)	Informada Online	Sim	Mais significativas	Conjunto	Erro
07	<i>Confidence Distribution Batch Detection</i> (LINDSTROM, NAMEE E DELANY, 2011)	Informada Lote	Sim	Pós detecção	Único	Confiança do classificador
08	<i>Active Learning Classifier for Streaming Data</i> (WORNIAZK et al, 2016)	Cega Online	Sim	Mais significativas	Único	-
09	<i>Density Based Active Learning for Data Streams</i> (IENCO,PFAHRINGER E ŽLIOBAITÉ ,2014)	Cega Online	Sim	Mais significativas	Único	-
10	<i>Active Learning With Drifting Streaming data</i> (ŽLIOBAITÉ ,2014)	Cega Online	Sim	Mais significativas	Único	-
11	<i>Reduced Labeled Samples</i> (ARABMAKKI,KANTARDZIC E SETHI, 2014)	Informada Lote	Sim	Pós detecção	Único SVM	Medida F
12	<i>Reduced Labeled Samples Extended</i> (ARABMAKKI,KANTARDZIC E SETHI, 2016)	Informada Lote	Sim	Pós detecção	Conjunto	Medida F
	<b>Método de Detecção de Mudança Baseada em Aprendizado Ativo.</b>	<b>Informada Lote</b>	<b>Sim</b>	<b>Pós detecção.</b>	<b>Único Qualquer</b>	<b>Margens virtuais</b>

Esta dissertação inova no uso de estratégias de Aprendizado Ativo como sinalizador para detectar explicitamente a ocorrência de Mudança de Conceito. O capítulo seguinte expõe o método e a análise experimental do conceito propostos neste trabalho.

## CAPÍTULO 4

# MÉTODO PROPOSTO E ANÁLISE EMPÍRICA DO CONCEITO

Este capítulo inicia com a descrição detalhada do método proposto neste trabalho para a detecção explícita de Mudança de Conceito em problemas de classificação. Conforme mencionado anteriormente, a detecção é baseada na hipótese de que a variação da densidade das instâncias mais significativas selecionadas por Aprendizado Ativo poderá indicar a ocorrência de Mudança de Conceito. O método proposto tem como objetivo contornar as seguintes desvantagens identificadas nos métodos atuais de detecção explícita: detecção baseada na degradação do desempenho do classificador ou em suposições realizadas sobre a distribuição das instâncias que devem ser classificadas. Esse método pode ser definido como de detecção explícita e não supervisionada.

Um dos diferenciais do nosso método é o uso de informações sobre a densidade das instâncias mais significativas, selecionadas por técnicas de Aprendizado Ativo, como sinalizador de mudança. O método proposto, que recebe o nome de Método de **Detecção de Mudança de Conceito Baseada em Aprendizado Ativo (DMAA)**, é composto por duas fases. Na primeira fase, há somente o componente de Geração do Classificador, responsável por gerar um modelo a partir das amostras do conjunto de treinamento. Na segunda fase, três componentes são considerados: Detecção, Reação e Classificação, respectivamente responsáveis por análise da ocorrência de mudança, geração de um novo classificador e classificação das instâncias do próximo lote.

Conforme exposto no capítulo 3, há pouquíssimos trabalhos na literatura que utilizam Aprendizado Ativo como sinalizador da ocorrência de Mudança de Conceito. Diante disto, a segunda parte deste capítulo expõe a análise experimental do conceito proposto. O objetivo desta análise consiste na demonstração do comportamento das densidades das margens e na definição dos valores de parâmetros utilizados no MDAA. Neste sentido, uma inovação desta dissertação reside na utilização do conceito de Margens Virtuais para a detecção de Mudança de Conceito, apresentados na subseção 4.1.3.1.

#### 4.1 MÉTODO DE DETECÇÃO DE MUDANÇA DE CONCEITO BASEADA EM APRENDIZADO ATIVO (MDAA)

O MDAA utiliza uma abordagem baseada em lotes. Por ser um método de detecção explícita de mudança de conceito, cada instância do lote é processada individualmente para calcular a densidade das instâncias mais significativas do lote atual. Portanto, não há necessidade de armazenar as instâncias já processadas, pois, somente os valores referentes às densidades calculadas precisam ser armazenados. Esse fato ocasiona, como consequência, uma redução do custo envolvido no uso de memória para execução do método.

A Figura 4-1 apresenta a estrutura geral do método proposto, dividido em suas duas fases. Na primeira fase o classificador é gerado com base nas instâncias do lote de treinamento. Na segunda fase, são realizadas etapas para detectar mudanças de conceito, reagir a mudanças detectadas e classificar as instâncias do lote atual. Essa estrutura está detalhada nesta seção. Destaca-se que a 1ª fase só ocorre no momento inicial da execução do método.

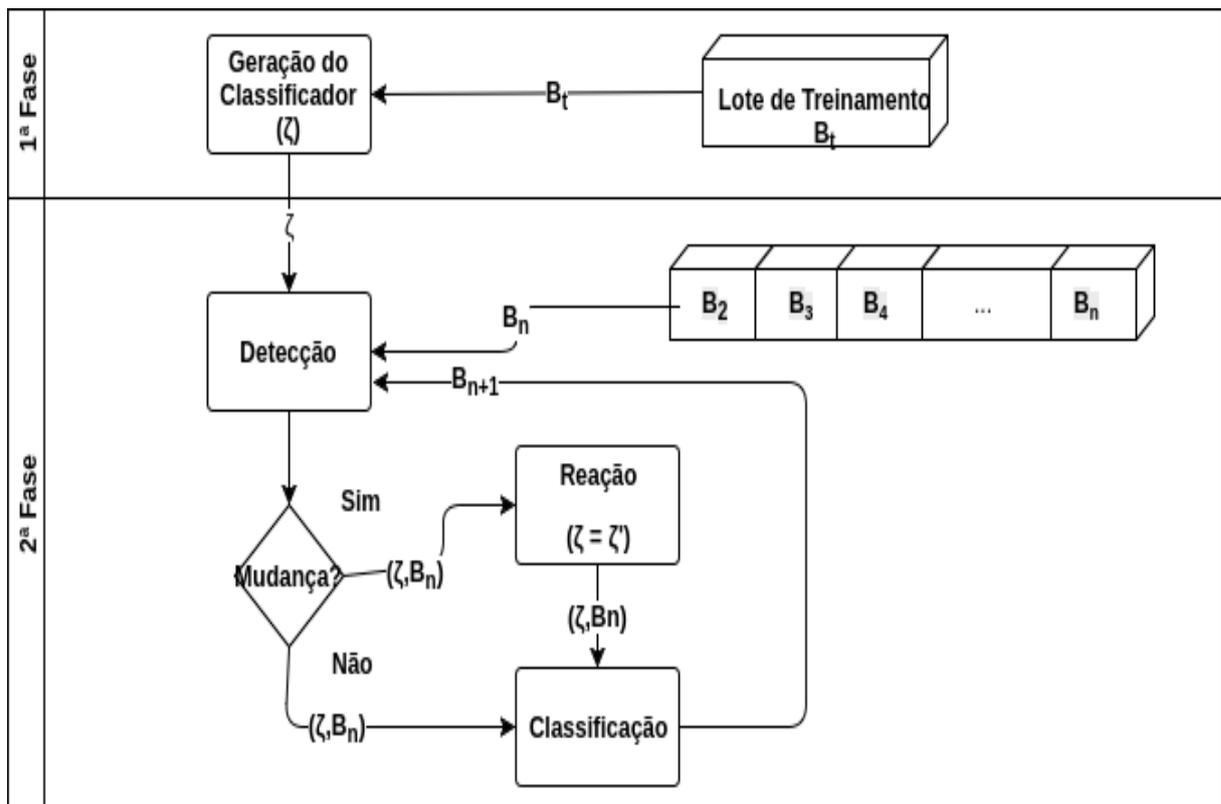


Figura 4-1: Estrutura Geral do MDAA. O método proposto é dividido em duas fases. A primeira fase consiste somente no componente de geração do classificador a partir das instâncias do lote de treinamento. Por sua vez, na segunda fase são executados os componentes de detecção, reação e classificação.

Fonte: Própria.

#### **4.1.1 COMPONENTE DE GERAÇÃO DO CLASSIFICADOR**

O objetivo da primeira fase do método proposto é unicamente gerar um classificador ( $\zeta$ ) com base nas instâncias pertencentes ao primeiro lote. Assume-se que neste lote, denominado de Lote de Treinamento, o acesso aos rótulos verdadeiros das instâncias é pleno. Ressalta-se que é somente na geração do classificador que o acesso aos rótulos verdadeiros é solicitado. Desta forma, a detecção é plenamente não supervisionada.

O tamanho de cada lote ( $\eta$ ) é um parâmetro definido pelo usuário. Na seção 4.2 realiza-se uma análise do impacto do valor deste parâmetro no desempenho do método. Um segundo parâmetro necessário para este componente diz respeito ao algoritmo de classificação utilizado no treinamento. Em princípio, qualquer método de aprendizado supervisionado pode ser utilizado nessa etapa, por exemplo KNN, Máquina de Vetores de Suporte ou Árvores de Decisão.

Na próxima subseção passa-se a discutir a segunda fase do método proposto.

#### **4.1.2 COMPONENTE DETECÇÃO**

Finalizada a primeira fase, o classificador ( $\zeta$ ) gerado é então utilizado pelo Componente de Detecção, conforme indicado na Figura 4-1. O objetivo desse componente é detectar a ocorrência de Mudança de Conceito. Antes de descrever por completo o Componente de Detecção, porém, faz-se rigorosamente necessária a apresentação do conceito de Margens Virtuais para o completo entendimento do método proposto.

##### **4.1.2.1 MARGENS VIRTUAIS**

O conceito de margens é natural a alguns tipos de classificadores, como por exemplo Máquinas de Vetores de Suporte (SVM). Conforme mencionado na seção 3.2, a análise da variação da densidade de margens foi utilizada satisfatoriamente por Sethi e Kantardzic (2015) na detecção de mudança de conceito. Nesse trabalho, os autores utilizaram uma abordagem em lote para analisar a densidades das instâncias que estavam dentro das margens de um SVM linear.

Porém, utilizar diretamente as margens de SVM linear limita totalmente o tipo de classificador utilizado, podendo acarretar em baixo desempenho no processo de classificação. Por exemplo, utilizar SVM linear limita a aplicação desse algoritmo de aprendizagem de máquina a somente problemas linearmente separáveis, que são minoria nos ambientes reais. Esses mesmos autores apresentaram em (SETHI E KANTARDZIC, 2017), conforme descrito na Subseção 3.2, um método de

detecção baseado na densidade das regiões de incerteza de conjunto de classificadores.

Para superar a limitação da estratégia apresentada por Sethi e Kantardzic (2015), neste trabalho propõe-se a utilização de margens virtuais projetadas no espaço de entrada baseadas no limite de incerteza permitido ao classificador, parâmetro  $\lambda$ , definido pelo usuário.

A Figura 4-2 apresenta visualmente o conceito de Margens Virtuais discutido nesta seção. A linha preta central representa a hipótese de decisão do classificador no espaço de entrada. As linhas pontilhadas projetadas em distâncias equidistantes da hipótese de decisão representam as margens virtuais.

A projeção das margens virtuais é baseada no Limite de Incerteza ( $\lambda$ ) permitido. Dessa forma, o subespaço formado entre as margens virtuais projetadas em  $-\lambda$  e  $+\lambda$  delimita o subespaço de interesse. A variação da densidade das instâncias que caem nesse subespaço selecionado é a métrica que é monitorada para a indicação da ocorrência ou não de mudança de conceito, bem como a necessidade de gerar um novo classificador.

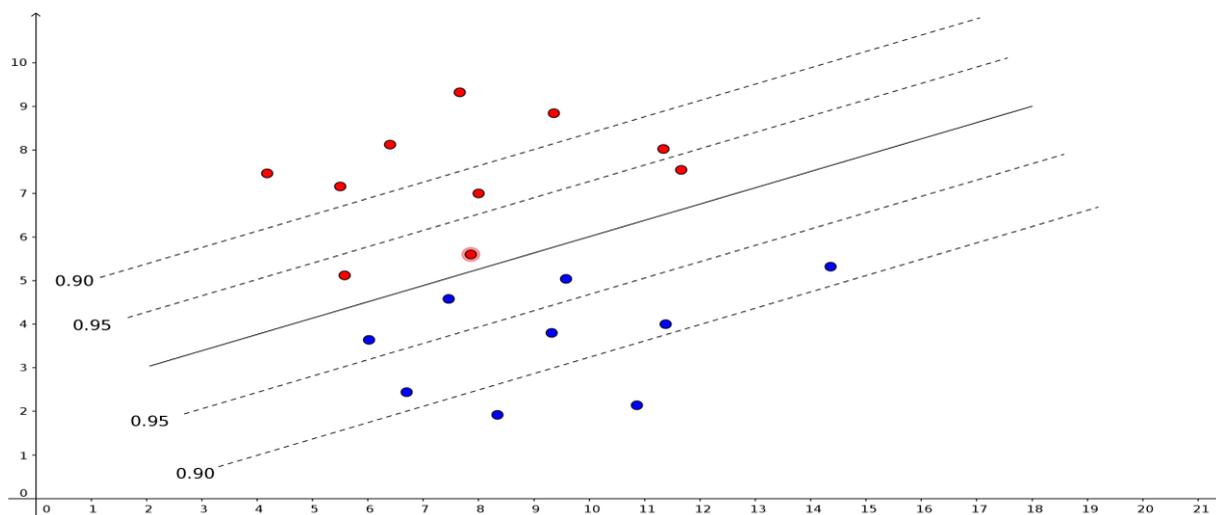


Figura 4-2: Margens Virtuais. A linha preta central representa a hipótese de decisão do classificador. As linhas pontilhadas equidistantes representam as margens virtuais projetadas de acordo com o limite de incerteza definido.  
Fonte: Própria.

Na Figura 4-2 há dois exemplos de margens virtuais. O primeiro, considerado o Limite de Incerteza ( $\lambda$ ) permitido em 0,95, forma um subespaço de interesse. De forma análoga, o segundo exemplo considera o Limite de Incerteza ( $\lambda$ ) em 0,90, o qual forma um subespaço de interesse maior que o anterior e permite assim que mais instâncias possam cair nesse subespaço de interesse.

Por fim, formalmente define-se Margens Virtuais como sendo dois hiperplanos projetados no espaço de entrada à distância  $\lambda$  equidistante do hiperplano da hipótese de decisão. O conceito de Margens Virtuais é uma das contribuições principais dessa pesquisa.

A análise contida nesta subseção atende ao segundo objetivo específico.

#### 4.1.2.2 PROCESSO DE DETECÇÃO

Definido o conceito de Margens Virtuais, passa-se a detalhar o processo de detecção de Mudança de Conceito. O Componente de Detecção recebe como entrada, além do classificador ( $\zeta$ ), um lote de instâncias não rotuladas ( $B_n$ ). Inicialmente calcula-se a densidade atual ( $\delta_{\text{atual}}$ ) das instâncias mais significativas do lote, as quais são selecionadas a partir do conceito de Margens Virtuais projetadas pela estratégia de Incerteza Fixa proposta por Žliobaitė et al. (2014).

Adotou-se a estratégia de Incerteza Fixa por esta ser considerada um *baseline* consolidado na literatura e por possuir somente um parâmetro a ser definido. É importante destacar, porém, que outras estratégias foram testadas neste trabalho, tais quais as estratégias de Limite de Incerteza Variável e o Limite de Incerteza Variável Aleatório, ambos propostos por Žliobaitė et al. (2014). Porém, o método de Incerteza Fixa apresentou melhores resultados.

O objetivo original dessa estratégia é selecionar as instâncias que levam o classificador ( $\zeta$ ) a apresentar menor certeza quanto às suas predições. A certeza da predição do classificador é medida com base na sua probabilidade *a posteriori*.

O Algoritmo 1 apresenta o pseudocódigo da Incerteza Fixa. Essa estratégia recebe três parâmetros, sendo o primeiro a instância atual não rotulada ( $x_i$ ), o segundo é o Limite de Incerteza ( $\lambda$ ) e, por fim, o terceiro é o classificador ( $\zeta$ ) gerado no primeiro componente. A saída da estratégia é um valor booleano que indica se a instância atual é significativa.

**Algoritmo 1: IncertezaFixa( $x_i, \lambda, \zeta$ )****Saída:** significativa  $\in \{\text{verdadeiro}, \text{falso}\}$ 

1. **significante**  $\leftarrow$  falso
2. **maxposteriori**  $\leftarrow$   $\zeta(x_i)$
3. **se**(maxposteriori  $<$   $\lambda$ )
4.   **significante**  $\leftarrow$  verdadeiro
5. **fimse**
6. **retorne** **significante**

A instância ( $x_i$ ) é apresentada ao classificador ( $\zeta$ ) com o objetivo de obter os valores das probabilidades *a posteriori* de cada classe. Seleciona-se, então, o máximo valor das probabilidades, o qual é comparado ao Limite de Incerteza ( $\lambda$ ). Se o valor da máxima *a posteriori* for menor do que o limite, isso significa que a instância atual está dentro do subespaço do espaço de entrada delimitado pelas margens virtuais projetadas. Portanto, a função retorna verdadeiro. Caso contrário, a instância estará fora das margens virtuais e a função retorna falso.

Após analisar todas as instâncias do lote atual, o Componente de Detecção passa a computar a densidade do lote atual ( $\delta_{\text{atual}}$ ) e compará-la aos valores de densidade máxima e densidade mínima ( $\delta_{\text{max}}$ ,  $\delta_{\text{min}}$ ) armazenados e que são recebidos como parâmetros. O Algoritmo 2 apresenta o pseudocódigo completo do método proposto.

**Algoritmo 2: MDAA( $B_n, \delta_{\text{min}}, \delta_{\text{max}}, \theta, \lambda, \zeta$ )**

**Saída:** mudança  $\in$  {verdadeiro,falso},

01. mudança  $\leftarrow$  falso
02. enquanto  $x_i$  em  $B_n$  faça
03. se(IncertezaFixa( $x_i, \lambda, \zeta$ )) entao
04.      $\delta_{\text{atual}} \leftarrow \delta_{\text{atual}} + 1$
05. fimse
06. fimenquanto
07.  $\delta_{\text{atual}} \leftarrow \delta_{\text{atual}} / \text{tamanho}(B_n)$
08. se( $\delta_{\text{atual}} < \delta_{\text{min}}$ ) entao
09.      $\delta_{\text{min}} \leftarrow \delta_{\text{atual}}$
10. fimse
11. se( $\delta_{\text{atual}} > \delta_{\text{max}}$ ) entao
12.      $\delta_{\text{max}} \leftarrow \delta_{\text{atual}}$
13. fimse
14. se( $(\delta_{\text{max}} - \delta_{\text{min}}) > \theta$ ) entao
15.     mudanca  $\leftarrow$  verdadeiro
16. fimse
17. retorne mudanca

Conforme já mencionado, inicialmente utiliza-se a estratégia de Incerteza Fixa para identificar as instâncias que estão dentro das margens virtuais. Esse processo está descrito entre as linhas 1 e 6 do Algoritmo 2. Na quarta linha, o total

de instâncias que estão dentro das margens virtuais é dividido pela quantidade total de instâncias do lote atual, permitindo, desta forma, que a densidade atual seja conhecida ( $\delta_{\text{atual}}$ ). Em seguida, a densidade atual ( $\delta_{\text{atual}}$ ) é comparada primeiramente ao valor da densidade mínima histórica ( $\delta_{\text{min}}$ ). Caso  $\delta_{\text{atual}}$  seja menor do que  $\delta_{\text{min}}$ , o valor atual passar a ser o novo valor mínimo (linhas 8 a 10). De forma análoga,  $\delta_{\text{atual}}$  é comparada à  $\delta_{\text{max}}$  e a substitui caso seu valor seja maior do que o máximo histórico (linhas 11 a 13).

O teste de detecção da ocorrência de Mudança de Conceito é realizado entre as linhas 14 e 16, quando a diferença entre os valores de  $\delta_{\text{max}}$  e  $\delta_{\text{min}}$  é comparada à variável definida pelo usuário, denominada Limite de Mudança ( $\theta$ ), proposto por Sethi e Kantardzic (2015). Neste ponto, duas opções são possíveis: 1) caso a diferença seja maior do que o Limite de Mudança ( $\theta$ ), uma Mudança de Conceito é sinalizada e o método inicia a execução do Componente de Reação; e 2) caso o Limite de Mudança ( $\theta$ ) não seja ultrapassado, o método sinaliza que o conceito atual do classificador ainda é válido. Nesse caso, o método inicializa a execução do Componente de Classificação.

Se a Mudança de Conceito for sinalizada (caso 1), o Componente de Reação envolve a geração de um novo classificador ( $\zeta'$ ), treinado com as instâncias pertencentes ao lote atual de instâncias ( $B_n$ ), em substituição ao classificador atual ( $\zeta$ ). Nesse ponto faz-se necessário que os rótulos verdadeiros das instâncias do lote atual estejam disponíveis. Na sequência, o método inicia a execução do Componente de Classificação para as instâncias do lote atual.

Caso o Componente de Detecção sinalize que não houve Mudança de Conceito, somente o Componente de Classificação é inicializado para classificar as instâncias atuais.

#### **4.1.3 COMPONENTE CLASSIFICAÇÃO**

O último componente do método proposto é executado sempre no final de um ciclo do método. Conforme já brevemente mencionado, o objetivo desse componente é realizar a classificação das instâncias não rotuladas do lote atual. Após, todas as instâncias do lote atual serem classificadas, o método retorna para o Componente de Detecção e recebe um novo lote de instâncias não rotuladas ( $B_{n+1}$ ).

O Componente de Classificação é executado independentemente da detecção, conforme exposto na estrutura geral do MDAA exposto na Figura 4-1. Na seção a seguir analisa-se empiricamente a variação da densidade como detector de Mudança de Conceito.

## 4.2 ANÁLISE EMPÍRICA DA VARIAÇÃO DA DENSIDADE

A hipótese de trabalho desta pesquisa é que a variação da densidade das instâncias mais significativas, selecionadas pela estratégia de Incerteza Fixa (Aprendizado Ativo), pode ser utilizada como um sinalizador da ocorrência de Mudança de Conceito.

Essa hipótese é uma expansão da hipótese trabalhada por Sethi e Kantardzic (2015). Esses autores construíram um detector com base na variação da densidade das margens de um classificador SVM Linear. Porém, como foi discutido no capítulo anterior, essa abordagem, apesar de promissora, limita a escolha do classificador. Por sua vez, neste trabalho propõe-se o uso do conceito de Margens Virtuais para a detecção de Mudança de Conceito, tornando a detecção baseada na variação da densidade das margens virtuais capaz de funcionar de forma independente ao classificador utilizado. Desta forma, nesta subseção realiza-se uma breve análise empírica do comportamento da densidade como indicador de Mudança de Conceito.

A Figura 4-3 apresenta o comportamento das densidades históricas máximas (linha tracejada com marcação X) e mínimas (linha tracejada com marcação  $\diamond$ ) na presença de Mudança de Conceito na base Demonstração, além do comportamento do erro (linha tracejada com marcação  $\bullet$ ). O método proposto sinaliza a mudança quando a diferença entre os valores máximo e mínimo da densidade ultrapassa um determinado limite de mudança permitido (linhas 13 a 15 do Algoritmo 2).

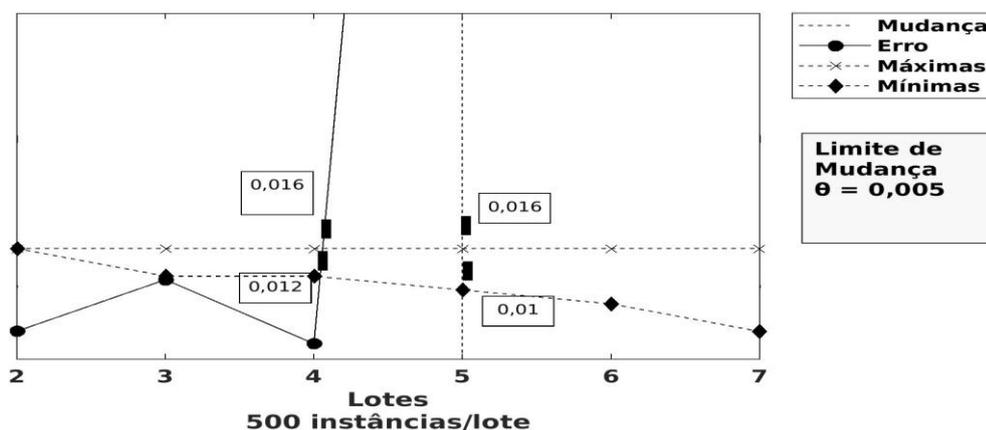


Figura 4-3: Comportamento da variação da densidade em ambiente dinâmico. As linhas tracejadas e com marcações em X e em  $\diamond$  representam, respectivamente, o valor histórico máximo e mínimo da densidade. A linha tracejada com marcação em  $\bullet$  representa o comportamento do erro.

Fonte: Própria

Nesse exemplo, há uma Mudança de Conceito conhecida no quinto lote (linha tracejada na vertical). Pode-se observar que a diferença entre os valores máximo e mínimo nos lotes anteriores à mudança tende a permanecer dentro do Limite de Mudança ( $\theta$ ) estabelecido. Destacando-se, o último (quarto) lote do primeiro conceito, onde se observa que a diferença entre o valor máximo e o valor mínimo históricos da densidade permanece abaixo do valor de mudança ( $0,016 - 0,012 < 0,005$ ).

Contudo, pode-se observar que a partir do quinto lote, há uma tendência de crescimento na diferença analisada, sugerindo uma substituição do conceito atual. Na Figura 4-3, a diferença entre os valores máximo (0,016) e mínimo (0,01) no quinto lote é superior ao limite  $\theta$  definido, fazendo com que o método proposto sinalize uma Mudança de Conceito. A plotagem do erro nesse exemplo objetiva corroborar com a indicação de mudança, já que de acordo com Gama et al (2004), um aumento significativo na taxa de erro sugere modificações no ambiente. Porém, ressalva-se que o método proposto utiliza como métrica de detecção de mudança somente a variação da densidade e, não a taxa de erro.

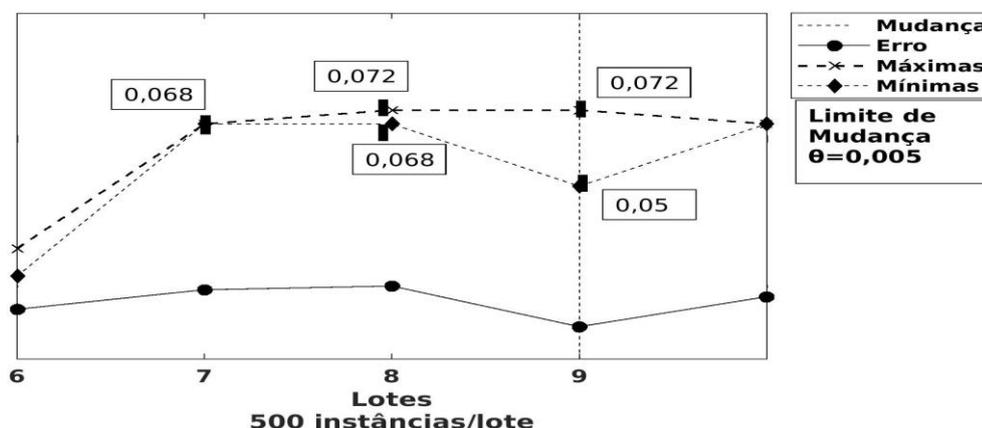


Figura 4-4: Comportamento da variação da densidade em ambiente estático. As linhas tracejadas e com marcações em X e em ♦ representam, respectivamente, o valor histórico máximo e mínimo da densidade. A linha tracejada com marcação em ● representa o comportamento do erro.

Fonte: Própria

O comportamento da densidade das instâncias mais significativas em ambientes sem a presença de Mudança de Conceito (inicia-se estático e apresenta uma mudança com a passagem do tempo) é apresentado na Figura 4-4. Neste exemplo, uma mudança é conhecida no lote 9 (linha tracejada na vertical). Pode-se observar que, no intervalo considerado estático, a variação da diferença de densidades máxima e mínima é muito pequena, em alguns pontos tornando-se nula. Porém, esse valor aumenta próximo ao lote em que ocorre uma mudança. No lote 7, por exemplo, a diferença é zero, enquanto que no lote seguinte, a diferença aumenta

em quatro unidades, porém, ainda abaixo do Limite de Mudança ( $\theta$ ) estabelecido. Por sua vez, no lote onde há uma mudança conhecida, a diferença da densidade aumenta para 0,022, sugerindo que o ambiente modificou-se.

### 4.3 CONSIDERAÇÕES FINAIS

Este capítulo apresentou o método proposto nesta dissertação para a detecção de Mudança de Conceito baseada na variação da densidade das instâncias mais significativas selecionadas por Aprendizado Ativo via Incerteza Fixa. Essa abordagem expande a hipótese de trabalho proposta por Sethi e Kantardzic (2015), excluindo a dependência de utilização de um SVM linear e, portanto, tornando-a independente do classificador utilizado, já que a densidade passa a ser calculada com base no conceito de Margens Virtuais e não mais nas margens reais de um classificador.

Em relação ao método proposto, o MDAA é composto por duas fases e quatro componentes. O componente mais importante é denominado de Componente de Detecção, o qual tem como objetivo analisar a ocorrência de mudanças no ambiente. Para isso, o método analisa a diferença entre as densidades máximas e mínimas históricas e compara essa diferença a um valor de limite estabelecido. Quando esse limite é superado, há a indicação do surgimento de um novo conceito e o atual classificador é substituído por um novo.

Ao analisar empiricamente o comportamento da densidade das instâncias mais significativas, observa-se que próximo à mudanças de conceito, a diferença entre as densidades máxima e mínima tem uma tendência positiva (Figura 4-3). Por outro lado, em ambientes estacionários a diferença tende a diminuir ou permanecer estável, conforme pode ser observado na Figura 4-4.

No aspecto geral o método proposto possui três parâmetros definidos pelo usuário, sendo esses o tamanho do lote ( $\eta$ ), o Limite de Incerteza ( $\lambda$ ) e o Limite de Mudança ( $\theta$ ). A definição desses valores, bem como os experimentos realizados e comparações com *baselines* são discutidos no próximo capítulo.

# CAPÍTULO 5

## EXPERIMENTOS E RESULTADOS

Neste capítulo são discutidos os experimentos realizados com o objetivo de aferir a capacidade do método de detecção de mudança conceito proposto nesta pesquisa em termos da capacidade de detecção, acurácia e percentual de instâncias rotuladas. Para isso, inicia-se fazendo uma breve apresentação das bases de dados utilizadas, em seguida, discute-se o ajuste dos parâmetros do método proposto, analisa-se o método nos termos supracitados e por fim, compara-se estatisticamente o método proposto com os métodos existentes na literatura.

Na primeira subseção as bases de dados são descritas com a finalidade de apresentar suas características e tipos de mudanças existentes. Esta pesquisa utilizou quatro bases sintéticas e duas bases reais. As bases sintéticas têm suas mudanças plenamente conhecidas, por sua vez, sobre as bases reais, pouco se sabe sobre o tipo, o local e até mesmo a existência concreta de mudanças. Por outro lado, bases reais são importantes, pois permitem observar o comportamento do método proposto em problemas existentes.

A subseção 5.2 apresenta uma análise da influência dos valores dos parâmetros selecionados, bem como apresenta os resultados obtidos pelo método proposto. Essa análise permite selecionar os valores dos parâmetros a fim de aperfeiçoar o desempenho do método proposto. Os parâmetros analisados correspondem ao tamanho de cada lote, Limite de Mudança e o Limite de Incerteza. Além disso, neste trabalho foram investigados os classificadores kNN, SVM linear e Árvore de Decisão.

Na subseção 5.3 realiza-se uma análise comparativa do método proposto com os métodos considerados *baselines* para detecção de Mudança de Conceito, precisamente DDM (GAMA ET AL., 2004), EDDM (BAENA-GARCIA ET AL., 2006) e o método MD3 (SETHI E KANTARDZIC, 2015), sendo este o método existente na literatura que mais se aproxima deste trabalho. É importante destacar que os métodos clássicos DDM e EDDM são métodos de detecção incremental, sendo que o método proposto é baseado em detecção em lote. Portanto, para tornar a comparação mais justa, os valores dos resultados do DDM e do EDDM são

expressos com base na média obtida a cada lote de 500 instâncias. Com exceção dessa mudança, os três métodos comparados são utilizados nas configurações propostas por seus autores.

## 5.1 BASE DE DADOS

Os experimentos desta pesquisa foram executados em quatro bases de dados sintéticas e duas bases reais. As bases sintéticas permitem avaliar o comportamento do método proposto em relação a taxa de detecção, atrasos de detecção, acurácia e quantidade de instâncias rotuladas. Por sua vez, as bases reais permitem somente avaliar o comportamento do método em relação à acurácia de classificação e à quantidade de instâncias rotuladas necessárias, dado que em bases reais não se conhece onde a Mudança de Conceito ocorre, sendo esta uma das principais características de aplicações reais (MINKU, WHITE E YAO, 2010).

### 5.1.1 BASES SINTÉTICAS

Todas as bases sintéticas expressas nesta subseção foram propostas por (MINKU, WHITE E YAO, 2010).

*Line*: Esta base de dados possui 2 mil instâncias divididas em duas classes de acordo com a equação da reta. Cada instância contém dois atributos numéricos e um atributo de classe (verdadeiro ou falso) que indica se a instância está acima ou abaixo da reta.

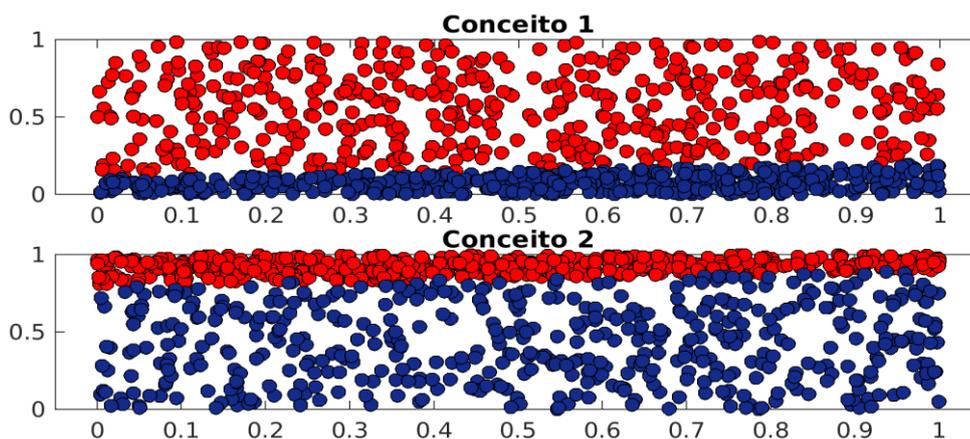


Figura 5-1: Conceitos existentes na base *Line*. Mudança de Conceito ocorre após mil instâncias. Fonte: Adaptada de Minku, White e Yao (2010).

A Figura 5-1 apresenta os dois conceitos existentes nesta base. A mudança ocorre de forma repentina após a milésima instância. Destaca-se que essa base possui classes plenamente balanceadas e sem reversão de conceitos após a mudança.

*Circle*: Esta base contém 4 mil instâncias divididas em duas classes (verdadeira ou falsa) de acordo com a equação do círculo. Cada instância é representada por dois atributos, além do atributo de classe.

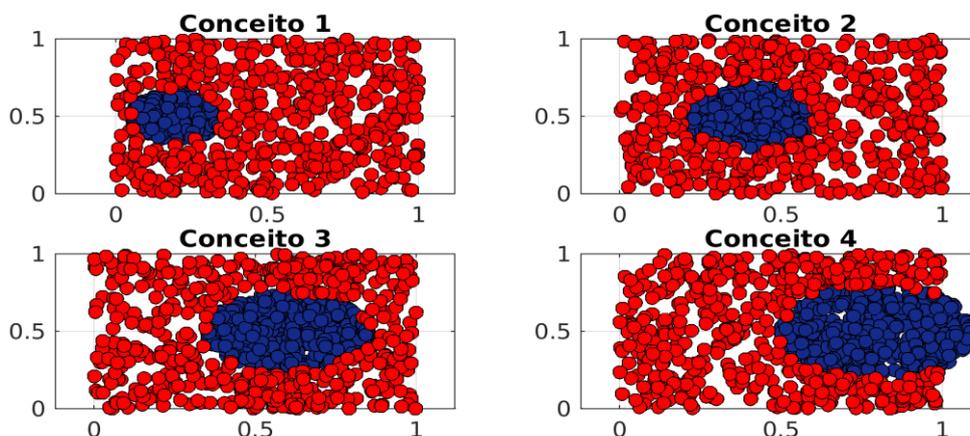


Figura 5-2: Conceitos existentes na base *Circle*. Mudança de Conceito ocorre após mil instâncias. Fonte: Adaptada de Minku, White e Yao (2010).

A Figura 5-2 apresenta os quatro conceitos existentes na base *Circle*. As mudanças ocorrem de forma gradual a cada mil instâncias e não há ruído nos dados. A mudança é caracterizada por um deslocamento do centro de um círculo pelo espaço de entradas. As classes nessa base são plenamente balanceadas.

*Sine1*: Esta base contém 10 mil instâncias divididas em duas classes (verdadeira ou falsa) de acordo com a equação do seno. Cada instância é representada por dois atributos, além do atributo de classe.

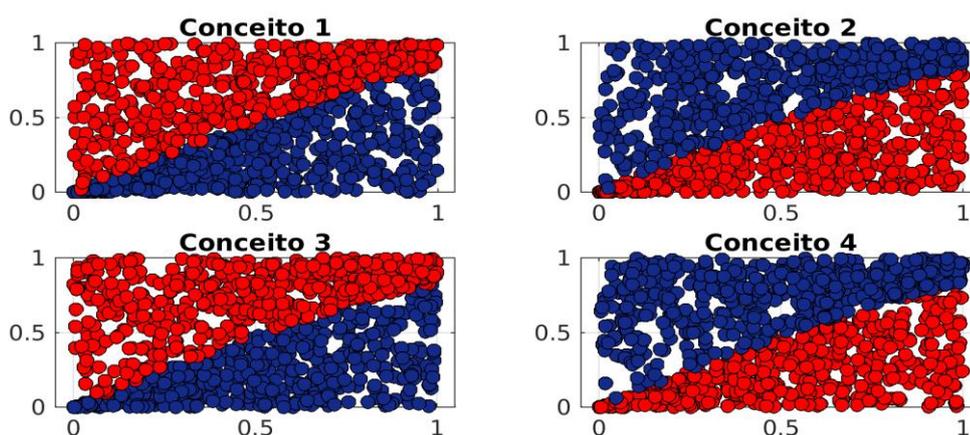


Figura 5-3: Quatro primeiros conceitos existentes na base *sine1*. Mudança de Conceito ocorre após mil instâncias. Fonte: Adaptada de Minku, White e Yao (2010).

Nesta base há nove mudanças de conceito conhecidas, cada mudança ocorre de forma gradual a cada mil instâncias. A Figura 5-3 ilustra os quatros

primeiros conceitos da base. Observa-se que essa base possui a seguinte característica particular: em cada mudança os conceitos são revertidos. Por exemplo, os conceitos 1 e 3 são semelhantes aos conceitos 2 e 4. Essa característica de reversão impõe mais dificuldade ao processo de detecção de mudança. As classes nessa base são plenamente balanceadas.

*Gauss*: A base Gauss contém 10 mil instâncias divididas em duas classes (verdadeira ou falsa) de acordo com duas distribuições gaussianas, as classes são plenamente balanceadas. Cada instância é representada por dois atributos, além do atributo de classe.

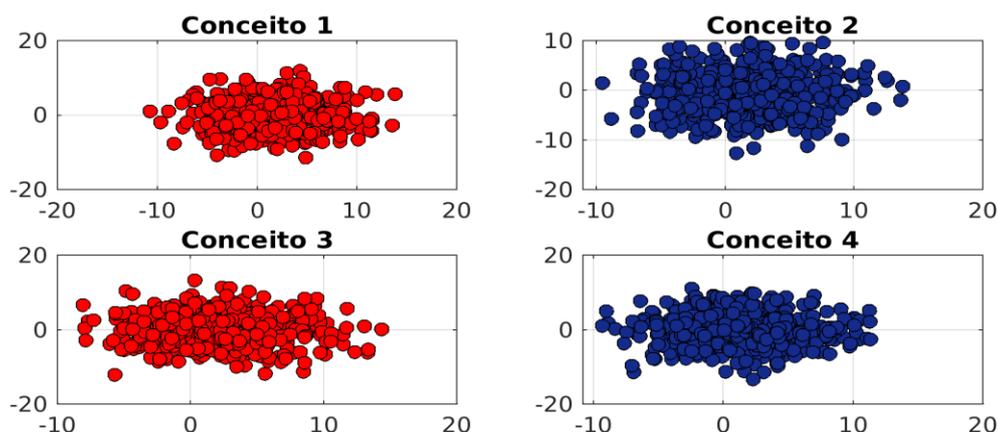


Figura 5-4: Quatro primeiros conceitos existentes na base *Gauss*. Mudança de Conceito ocorre após mil instâncias. Em cada conceito só aparece uma conceito porque eles se distribuem de maneira sobreposta.

Fonte: Adaptada de Minku, White e Yao (2010).

Na base *Gauss* há nove mudanças de conceito conhecidas, cada mudança ocorre de forma abrupta a cada mil instâncias. A Figura 5-4 apresenta os quatro primeiros conceitos da base. Pode-se observar que os conceitos são revertidos a cada mudança, imputando um desafio a mais no processo de detecção de mudança. Uma segunda característica dessa base consiste na existência de ruído nas instâncias

### 5.1.2 BASES REAIS

*Elec*: Essa base de dados cobre o período de dois anos do preço da eletricidade em New South Wales (Austrália) e contém 45.321 instâncias divididas em duas classes (*up* e *down*). A última classe tem uma probabilidade a priori de 58%. Cada instância é descrita por oito atributos, além do atributo de classe. A mudança de conceito é supostamente devida à modificações nos hábitos de consumo elétrico dos clientes.

SPAM: Essa base contém 9.324 instâncias divididas em duas classes (spam e legítima). Cada instância é representada por quatrocentos e noventa e nove atributos binários, além de um atributo de classe. A mudança de conceito nesta base é supostamente devida a modificações nos padrões das mensagens que são consideradas SPAM.

A diversidade das bases de dados utilizadas permite avaliar a robustez do método proposto à variação da dimensionalidade dos atributos e aos diferentes tipos de mudanças de conceito, bem como avaliar o desempenho na existência de ruído nos dados.

## 5.2 EXPERIMENTOS

Nesta subseção discorre-se sobre os experimentos realizados com o método proposto. Inicialmente, expõe-se o protocolo experimental utilizado nesta pesquisa. Em seguida, discute-se a influência da seleção do parâmetro do tamanho do lote processado, dos valores para os Limites de Mudança e de Incerteza e por fim, realiza-se uma comparação estatística com os métodos considerados *baselines* na detecção de mudança de conceito.

### 5.2.1 DEFINIÇÃO DO TAMANHO DO LOTE ( $\eta$ )

Um dos principais parâmetros que afetam diretamente o desempenho do método proposto está relacionado ao tamanho do lote ( $\eta$ ) de instâncias processadas por cada ciclo. Para a definição do parâmetro  $\eta$  utilizou-se nesta pesquisa as abordagens de revisão da literatura e a realização de testes com a variação do valor de  $\eta$ .

Os parâmetros Limite de Incerteza ( $\lambda$ ) e Limite de Mudança ( $\theta$ ) utilizados variaram, respectivamente, no intervalo [0,6; 0,95] com incremento de 0,05 e no intervalo de [0,005; 0,095] com incremento de 0,005. Esses parâmetros são mais discutidos na subseção a seguir.

Autores	Valores de $\eta$	Observação
Arabmakki, E., Kantardzic, M. e Sethi, T., S (2014)	600	Tamanho fixo
Arabmakki, E., Kantardzic, M. e Sethi, T., S (2016)	400,600,800,1000,1200	Teste com vários valores para $\eta$ .
Sethi, T., S e Kantardzic (2015)	300 ( $\leq 10.000$ ) 800 ( $> 10.000$ e $\leq 100.000$ ) 4000 ( $> 100.000$ )	Valor definido baseado no tamanho da base de dados disponível.

Quadro 5-1: Revisão da literatura sobre o parâmetro do tamanho do lote.

Fonte: Própria

O Quadro 5-1 apresenta em resumo as características dos trabalhos utilizados como base na definição do tamanho do lote nesta pesquisa. A primeira coluna indica a referência do trabalho, a segunda os valores testados e a terceira coluna apresenta observações sobre o trabalho referenciado.

O primeiro trabalho utilizou o valor fixo de 600 instâncias por lote. Por sua vez, o segundo trabalho testou valores para  $\eta$  variando de 400 a 1200, com passo de 200 instâncias. O valor de  $\eta$  igual a 1000 apresentou o melhor desempenho. O terceiro trabalho testou uma abordagem de definição do tamanho do lote com base no tamanho da base de dados. O tamanho do lote foi 300 instâncias, para bases de dados com tamanho até 10.000 instâncias; 800 instâncias para bases com número de instâncias entre 10.000 e 100.000; e, por fim, 4.000 instâncias para bases de dados maiores do que 100.000 instâncias.

A abordagem desse último trabalho destaca-se por ser pouco realista, porque em problemas reais, principalmente com dados em fluxo, o tamanho da base de dados não é conhecido antecipadamente.

Considerando que o tamanho das bases de dados investigadas, definidas na Seção 5.1, variam de 2.000 a 45.321 (2.000 (*Line*), 4.000 (*Circle*), 10.000 (*Sine1* e *Gauss*) 9.324 (*Spam*) e 45.321 (*Elec*)) e buscando-se um valor para  $\eta$  compatível para todas as bases analisadas, descartou-se valores de  $\eta$  encontrados na literatura maiores que 500 instâncias por serem superiores a 25% da base *Line*. Nessa mesma linha de pensamento, valores muito baixos para  $\eta$  são pouco representativos para as bases maiores, o que pode inviabilizar o aprendizado do classificador.

Nesse contexto, optou-se por realizar testes com valores de  $\eta$  iguais a 300, 400 e 500 instâncias. Os testes foram realizados em todas as bases sintéticas, onde se conhece o local da ocorrência das mudanças, com todos os valores do Limite de Incerteza e Limite de Mudança disponíveis. Utilizou-se como métrica de avaliação o percentual de mudanças de conceitos detectadas corretamente.

O percentual de mudanças de conceitos detectadas corretamente é definido como sendo a razão entre o total de detecções realizadas e o total de mudanças de conceitos existentes, conforme a Equação 5.1.

$$\text{Percentual} = \frac{\text{Total de detecções realizadas}}{\text{Total de mudanças existentes}} \quad (5.1)$$

A Tabela 5-1 apresenta em resumo o resultado dos testes realizados para definir-se o valor mais adequado para o parâmetro  $\eta$  nesta pesquisa. Pode-se observar que o percentual de detecções correta tem um aumento proporcional ao aumento do tamanho do lote das instâncias. Essa relação sugere que o classificador tenha disponíveis mais instâncias para extrair sua hipótese. Porém, como já

observado anteriormente, valores muito elevados para  $\eta$  são impraticáveis para algumas das bases de dados utilizadas nesta pesquisa.

Tabela 5-1: Percentual de detecções corretas de acordo com a variação do parâmetro  $\eta$ .

Bases	$\eta$		
	300	400	500
<i>Circle</i>	29,97%	36,35%	<b>74,78%</b>
<i>Line</i>	73,99%	50,00%	<b>94,44%</b>
<i>Sine1</i>	39,41%	54,65%	<b>60,31%</b>
<i>Gauss</i>	40,50%	48,83%	<b>51,02%</b>

Fonte: Própria

Por motivo de clareza do texto, o processo completo de realização dos testes para definir o valor de  $\eta$  está detalhado no Apêndice A deste documento. Observa-se que os valores destacados em negrito nas tabelas anexas indicam pontos em que não houve detecções de mudanças, desta forma, esses valores foram excluídos do cálculo da média. Por fim, destaca-se que o valor do parâmetro  $\eta$  é do tipo definido pelo usuário, podendo então ser alterado para melhorar o desempenho do detector em problemas reais específicos.

### 5.2.2 DEFINIÇÃO DO LIMITE DE INCERTEZA ( $\lambda$ ) E LIMITE DE MUDANÇA ( $\theta$ )

Dois outros parâmetros necessários para o melhor desempenho do método proposto são nomeados de Limite de Incerteza ( $\lambda$ ) e Limite de Mudança ( $\theta$ ). O primeiro consiste na quantidade de incerteza (mensurada pela probabilidade *a posteriori*) permitida ao classificador no processo de classificar as instâncias. Quando maior o valor de ( $\lambda$ ) maior será a incerteza do classificador em relação à instância atual.

O segundo parâmetro refere-se ao limite de modificação do espaço de entrada das instâncias permitido sem que essa mudança seja considerada significativa (conceito novo). Essa taxa de mudança é nomeada de Severidade da Mudança (do original em inglês, *Drift Severity*) por Sayed-Mouchaweh (2016)

A severidade refere-se à quantidade de mudanças causadas pela ocorrência de mudança de conceito. A severidade da mudança pode ser baixa (total) ou alta (parcial). Uma alta (total) severidade indica que o antigo conceito pode ser completamente modificado. Portanto, toda a região ocupada pelo antigo conceito será impactada pela mudança. Uma baixa (parcial) taxa de severidade impacta somente uma parte da região (SAYED-MOUCHAWEH, 2016)

Nesta pesquisa buscou-se definir os melhores valores para ( $\lambda$ ) e ( $\theta$ ) que aperfeiçoem o método proposto. Para isto, buscou-se na literatura valores de referências para ambos os parâmetros. Žliobaitė, I., et al. (2014) utilizaram o valor de  $\lambda = 1$ , porém esse valor gera uma saturação precoce na seleção de instâncias,

conforme os autores supracitados. Considerando esse resultado, nesta pesquisa foram testados valores para  $\lambda$  no intervalo de 0,60 a 0,95, com incrementos de 0,05.

Em relação ao parâmetro de Limite de Mudança ( $\theta$ ), os valores utilizados por Sethi e Kantardzic (2015) foram expandidos, esta expansão fez-se necessária para analisar de forma mais ampla a influência do Limite de Mudança no processo de detecção. Neste cenário, foram testados valores no intervalo de 0,005 a 0,095, com incrementos de 0,005. Conforme se pode observar no capítulo 4, o método proposto utiliza simultaneamente os valores de ( $\lambda$ ) e ( $\theta$ ), desta forma, foram realizados testes de 152 combinações de valores de ( $\lambda$ ) e ( $\theta$ ) por cada classificador investigado.

Em relação aos classificadores, esta pesquisa executou experimentos com KNN, SVM Linear e Árvore de Decisão. Os resultados e a análise desses experimentos estão expostos nas seções seguintes. Porém, por motivo de clareza do texto, o processo completo de realização dos testes para definir os Limites de Incerteza e de Mudança, com os respectivos classificadores bases, está detalhado no Apêndice B deste documento. Observa-se que nas tabelas do Apêndice B, a Taxa do Erro, Atraso de Detecções, Total de Detecções, Perdas de Detecções e Falsas Detecções são representados respectivamente por E, AD, D, PD e FD.

O Atraso de Detecções (AD) pode ser definido como o tempo transcorrido entre a ocorrência da mudança de conceito e a detecção realizada pelo classificador, observa-se que essa diferença pode ser negativa caso a detecção ocorra antes da mudança de conceito. Por sua vez, a métrica de Falsas Detecções (FD) é definida como sendo o disparo do detector em um local onde sabe-se que não existe a mudança de conceito.

### 5.2.3 EXPERIMENTOS COM KNN

As métricas de avaliação de desempenho do classificador analisadas são a quantidade de Perdas de Detecções (PD) concomitantemente com a taxa de erro (E). Os valores destacados em negrito representam no Apêndice B 1 os melhores resultados encontrados pelo método de detecção proposto na base de dados *Circle*, bem como também indicam os melhores parâmetros. Pode-se observar que os melhores resultados são encontrados quando o Limite de Mudança é menor ou igual a 0,035. Por sua vez, todos os valores de Limite de Incerteza apresentaram bons desempenhos.

É importante destacar também que os valores em negrito apresentaram desempenhos exatamente idênticos, sendo um Erro de 0,0305, sem atrasos, perdas ou falsas detecções.

No Apêndice B 2 estão expressos os resultados quando se aplica o método proposto juntamente com o classificador KNN na base *Line*. Os melhores resultados estão destacados em negrito. Pode-se observar que todos os valores do Limite de

Incerteza podem gerar bons resultados. Por outro lado, valores maiores que 0,50 para o Limite de Mudança causam uma perda de desempenho no processo de detecção. A melhor taxa de erro foi de 0,0225, sem atrasos, perdas ou falsas detecções. Destaca-se também que os resultados encontrados possuem valores idênticos.

O Apêndice B 3 reflete o desempenho do método proposto quando avaliado na base *Sine1* juntamente com o classificador KNN. Diferentemente dos demais resultados, somente quatro combinações de valores dos parâmetros apresentaram bom desempenho. Observa-se que somente o valor 0,005 para o Limite de Mudança apresentou bons resultados. Por sua vez, o Limite de Incerteza variou entre 0,80, 0,85, 0,90 e 0,95. Os melhores resultados apresentaram valor de 0,0267 para o erro e sem atrasos, perdas ou falsas detecções.

O desempenho do método proposto com o classificador KNN na base *Gauss* é ilustrado no Apêndice B 4. Pode-se observar (destacado em negrito) que os melhores resultados estão concentrados quando o Limite de Mudança é inferior a 0,010. Por sua vez o Limite de Incerteza apresenta melhores resultados quando superior a 0,80. Destaca-se também, ao contrário do que ocorre nas demais bases, o detector proposto não consegue alcançar 100% das mudanças de conceitos conhecidas. Desta forma, os melhores resultados apresentam uma taxa de erro de 0,1854, sem atrasos, mas uma mudança conhecida é perdida.

Analisado o comportamento do método proposto nas bases sintéticas, passa-se a discutir o comportamento do método juntamente com o classificador KNN nas bases reais. Nessas bases, ao contrário das bases sintéticas, análises mais precisas como atrasos, perdas e falsas detecções não são plausíveis de serem realizadas.

O melhor desempenho do método proposto na base SPAM (Apêndice B 5) foi alcançado com os valores de Limite de Mudança igual a 0,005 e no intervalo de 0,030 a 0,050, e o Limite de Incerteza variando entre 0,70 a 0,85, obtendo-se, desta forma, a taxa de erro de 0,1679 e com duas detecções (destacadas em negrito).

Tabela 5-2: Resumo do comportamento do método proposto com KNN.

Base	KNN			
	Perdas de Detecções	Taxa de Erro	Limite de Incerteza	Limite de Mudança
<i>Circle</i>	0	0,0305	Todos	< 0,035
<i>Line</i>	0	0,0225	Todos	< 0,50
<i>Sine1</i>	0	0,0267	> 0,80	0,005
<i>Gauss</i>	1	0,1854	> 0,80	< 0,010
SPAM	-	0,1679	[0,70;0,85]	0,005 e [0,030; 0,050]
Elec	-	0,1714	[0,70;0,75]	[0,005 a 0,010]

Fonte: Própria

Na última base analisada, a menor taxa de erro encontrada foi de 0,1714, com 44 detecções para os valores de 0,70 a 0,75 no Limite de Incerteza, e 0,005 a 0,010 para o Limite de Mudança, conforme destacado no Apêndice B 6.

A Tabela 5-2 apresenta em resumo o comportamento do método de detecção proposto com o classificador kNN.

#### 5.2.4 EXPERIMENTOS COM SVM LINEAR

O Apêndice B 7 expõe os resultados na base *Circle*. Pode-se observar que ao contrário dos resultados expostos até aqui, somente uma combinação de valores para o Limite de Incerteza e o Limite de Mudança produziu o melhor resultado. Neste cenário, o Limite de Incerteza ficou definido como 0,60 e o Limite de Mudança igual a 0,005, sem perdas ou falsas de detecções e uma taxa de erro de 0,3238.

O Apêndice B 8 apresenta o desempenho do método proposto na base *Line*. Observa-se que o Limite de Mudança apresentou melhor resultado quando fixado em 0,005 e, por sua vez, o Limite de Incerteza gerou o melhor resultado quando assumiu um dos dois seguintes valores: 0,90 e 0,95. Os melhores resultados estão destacados em negrito e apresentam uma taxa de erro de 0,014, com nenhuma perda, atrasos ou falsas detecções.

O resultado na base *Sine1* está expresso no Apêndice B 9. Pode-se observar que somente uma combinação de valores gerou o melhor resultado (em negrito). Quando o Limite de Mudança é definido em 0,005 e o Limite de Incerteza é fixado em 0,95, a taxa de erro é minimizada em 0,044, com nenhum atraso, perdas ou falsas detecções.

O Apêndice B 10 mostra os resultados do método de detecção proposto juntamente com o classificador SVM Linear na base *Gauss*. Os valores de 0,005 e 0,065 para, respectivamente, os Limites de Mudança e de Incerteza, geraram o melhor resultado (em negrito), com uma taxa de erro de 0,3275, 8 detecções corretas das 9 conhecidas, sem falsas ou perdas de detecções. Porém, pode-se observar que uma detecção ocorreu em atraso.

Tabela 5-3: Resumo do comportamento do método proposto com SVM.

Base	SVM			
	Perdas de Detecções	Taxa de Erro	Limite de Incerteza	Limite de Mudança
<i>Circle</i>	0	0,3238	0,60	0,005
<i>Line</i>	0	0,0140	[0,90;0,95]	0,005
<i>Sine1</i>	0	0,0440	0,95	0,005
<i>Gauss</i>	1	0,3275	0,65	0,005
SPAM	-	0,0700	0,70	0,035
Elec	-	0,2065	0,70	0,010

Fonte: Própria

Conforme já mencionado, nas bases reais não é possível mensurar a perda, atrasos ou falsas detecções. O Apêndice B 11 apresenta o desempenho na base *SPAM*. A combinação de valores do Limite de Mudança igual a 0,005 e o Limite de Incerteza igual a 0,65 gerou uma taxa de erro de 0,0700, com 8 detecções. Por sua vez, os valores de 0,035 e 0,70 para, respectivamente, o Limite de Mudança e o Limite de Incerteza gerou a mesma taxa de erro (0,0600), porém com somente 5 detecções. Ressalta-se que cada nova detecção e retreino do classificador aumenta o custo de rotulagem. No Apêndice B 12 apresenta-se o desempenho na base *ELEC*. A menor taxa de erro (0,2055) é alcançada quando o Limite de Mudança é igual a 0,010 e o Limite de Incerteza igual a 0,70.

A Tabela 5-3 apresenta em resumo o comportamento do método de detecção proposto com o classificador SVM. A próxima subseção discorre sobre os resultados encontrados com uma Árvore de Decisão.

### 5.2.5 EXPERIMENTO COM ÁRVORE DE DECISÃO

O método de detecção quando utilizado com o classificador de Árvore de Decisão apresenta um desempenho aquém do esperado. No Apêndice B 13 e no Apêndice B 14, respectivamente, estão os resultados para as bases *Circle* e *Line*. Nessas tabelas pode-se observar que nenhuma mudança é detectada pelo método proposto, tornando o resultado insatisfatório.

No Apêndice B 15 apresenta o resultado na base *Sine1*, o melhor resultado é alcançado quando o Limite de Mudança tem valor de 0,005 e o Limite de Incerteza igual a 0,95. O melhor resultado tem valor do erro igual a 0,2046, 8 detecções, uma perda e uma detecção em atraso (destacado em negrito).

Análoga à situação nas bases *Circle* e *Line*, o método proposto também não consegue realizar detecções de mudanças quando utiliza uma Árvore de Decisão como classificador na base *Gauss* (Apêndice B 16).

Tabela 5-4:Resumo do comportamento do método proposto com Árvore de Decisão.

Árvore de Decisão				
Base	Perdas de Detecções	Taxa de Erro	Limite de Incerteza	Limite de Mudança
<i>Circle</i>	3	0,3682	-	-
<i>Line</i>	1	0,2084	-	-
<i>Sine1</i>	1	0,2046	0,95	0,005
<i>Gauss</i>	9	0,3682	-	-
SPAM	-	0,1556	0,95	0,005
Elec	-	0,2421	0,90	[0,080;0,095]

Fonte: Própria

Em relação às bases reais, o Apêndice B 17 expõe os resultados na base *SPAM*. A menor taxa de erro (0,1556) é alcançada quando o Limite de Mudança é igual a 0,005 e o Limite de Incerteza 0,95 com 3 detecções. Já o Apêndice B 18

apresenta os resultados para a base ELEC, sendo que os melhores resultados estão destacados em negrito. Pode-se observar que a menor taxa de erro (0,2421) foi alcançada quando o Limite de Mudança está entre 0,080 e 0,095 e o Limite de Incerteza igual a 0,90.

A Tabela 5-4 apresenta em resumo o comportamento do método de detecção proposto com o classificador Árvore de Decisão.

### 5.3 ANALISE ESTATÍSTICA COMPARATIVA

Nesta subseção são expostos os resultados das comparações estatísticas entre o método proposto e os métodos considerados *baselines* na literatura. Os métodos DDM (GAMA ET AL., 2004), EDDM (BAENA-GARCIA ET AL., 2006) e MD3 (SETHI E KANTARDZIC, 2015) estão descritos no capítulo 3 desta dissertação. Os dois primeiros métodos utilizam uma abordagem de aprendizado incremental, portanto, com o objetivo de realizar uma comparação mais justa entre os métodos, mensurou-se o desempenho do DDM e EDDM como o valor médio calculado a cada 500 instâncias, conforme experimentos realizados na Seção 5.2.1. Finalmente, dado que o MD3 funciona unicamente com SVM Linear, e mantendo o objetivo de realizar uma comparação justa, a versão do método proposto utilizado para comparar com o MD3 utiliza também SVM Linear como classificador base.

Considerou-se como variável de interesse na análise a média do erro prequencial dos modelos. A significância estatística da diferença entre os desempenhos dos modelos é evidenciada pelo Teste Estatístico Não-Paramétrico de Wilcoxon. Optou-se por utilizar teste não-paramétrico pelos seguintes motivos: 1) Não haver garantias que os dados obedecem uma distribuição normal e 2) Pelo tamanho das amostras serem em geral menor do que 30.

O Teste de Wilcoxon analisa como hipótese nula ( $H_0$ ) se as medianas das duas amostras são oriundas da mesma distribuição, contra a hipótese alternativa ( $H_1$ ) que as medianas das amostras são oriundas de distribuições distintas. As hipóteses estão descritas na Equação 5.2, com nível de significância de 5% ( $\alpha=0,05$ ).

$$\begin{aligned} H_0: \textit{Mediana}_1 &= \textit{Mediana}_2 \\ H_1: \textit{Mediana}_1 &\neq \textit{Mediana}_2 \\ \alpha &= 0,05 \end{aligned} \tag{5.2}$$

Os resultados das comparações estatísticas estão expressos nas Tabelas 5-2 a 5-4. As nomenclaturas dos resultados estão padronizadas da seguinte maneira:  $\rho$ -valor, QD(DC) - Quantidade de Detecções (Detecções Conhecidas), ME(DP) – Média Erro (Desvio Padrão), %Rot – Percentual de instâncias rotuladas.

Considerando a média do erro, os métodos que tiveram menor ME estão destacados em negrito. Por sua vez, as comparações que apresentaram resultados com diferença estatística estão sublinhados.

Tabela 5-5: Comparação entre o DDM e MDAA

Base	p- valor	DDM			MDAA		
		QD(DC)	ME(DP)	%Rot	QD(DC)	ME(DP)	%Rot
<i>Line</i>	0,1429	2(1)	0,0678(0,0502)	100	1(1)	<b>0,0224(0,0082)</b>	33,33
<i>Circle</i>	0,0155	3(3)	0,0811(0,0507)	100	3(3)	<b>0,0305(0,0141)</b>	42,87
<i>Sine1</i>	<0,0005	10(9)	0,0769(0,0389)	100	9(9)	<b>0,0267(0,0097)</b>	47,36
<i>Gauss</i>	<0,0005	10(9)	<b>0,1751(0,0442)</b>	100	8(9)	0,1854(0,2373)	42,10
<i>SPAM</i>	0,5295	7	<b>0,1220(0,0516)</b>	100	2	0,1679(0,1539)	11,33
<i>Elec</i>	0,0130	26	0,1879(0,0349)	100	44	<b>0,1714(0,1219)</b>	49,09

Fonte: Própria

Tabela 5-6: Comparação entre EDDM e MDAA

Base	p- valor	EDDM			MDAA		
		QD(DC)	ME(DP)	%Rot	QD(DC)	ME(DP)	%Rot
<i>Line</i>	0,2286	1(1)	0,0542(0,0457)	100	1(1)	<b>0,0224(0,0082)</b>	33,33
<i>Circle</i>	0,0031	3(3)	0,1015(0,0630)	100	3(3)	<b>0,0305(0,0141)</b>	42,87
<i>Sine1</i>	<0,0005	10(9)	0,0721(0,0361)	100	9(9)	<b>0,0267(0,0097)</b>	47,36
<i>Gauss</i>	0,0094	10(9)	<b>0,1548(0,0451)</b>	100	8(9)	0,1854(0,2373)	42,10
<i>SPAM</i>	0,5200	5	<b>0,1177(0,0529)</b>	100	2	0,1679(0,1539)	11,33
<i>Elec</i>	0,0372	52	0,1835(0,0330)	100	44	<b>0,1714(0,1219)</b>	49,09

Fonte: Própria

Tabela 5-7: Comparação entre MD3 e MDAA

Base	p- valor	MD3			MDAA		
		QD(DC)	ME(DP)	%Rot	QD(DC)	ME(DP)	%Rot
<i>Line</i>	0,0040	1(1)	0,0781(0,0268)	17,64	1(1)	<b>0,0148(0,0170)</b>	33,33
<i>Circle</i>	<0,0005	2(3)	0,3322(0,1438)	16,21	3(3)	<b>0,0305(0,0141)</b>	42,87
<i>Sine1</i>	<0,0005	3(9)	0,4158(0,4154)	9,27	9(9)	<b>0,0443(0,0139)</b>	47,36
<i>Gauss</i>	0,0781	4(9)	0,4872(0,2206)	12,37	9(9)	<b>0,3261(0,0940)</b>	42,10
<i>SPAM</i>	0,0285	3	0,1389(0,1424)	9,97	8	<b>0,0741(0,1264)</b>	11,33
<i>Elec</i>	<0,0005	17	0,3444(0,0779)	30,55	42	<b>0,2113(0,1002)</b>	46,86

Fonte: Própria

A Tabela 5-5 apresenta a comparação entre o método proposto e o DDM. Para as bases sintéticas, ambos os métodos apresentaram resultados semelhantes em relação à média da taxa do erro frequencial. Contudo, ao observar os resultados em detalhes, pode-se observar que o método proposto alcança menores taxas de erro nas bases *Circle*, *Sine1* e *Line*. Se considerarmos a capacidade de detecção de mudança de conceito, pode-se observar que o método DDM gera uma falsa detecção nas bases *Line*, *Sine1* e *Gauss*. Por outro lado, o método proposto não gera falsas detecções nas bases sintéticas, porém, perde uma detecção conhecida na base *Gauss*. Considerando o percentual de instâncias rotuladas, o método

proposto necessitou de menos de 50% dos rótulos das instâncias, enquanto que o DDM requereu 100% dos rótulos devido à sua abordagem supervisionada.

Analisando o desempenho dos métodos especificamente nas bases reais, observa-se que na base *Elec*, o DDM detectou poucas mudanças, quando comparado ao MDAA, enquanto que a média do erro do DDM foi superior a do método proposto. Novamente, o MDAA utilizou menos de 50% dos rótulos verdadeiros. Na base *SPAM*, o DDM detectou mais mudanças do que o método proposto e alcançou uma média do erro menor do que a alcançada pelo MDAA. Contudo, é importante destacar que o método proposto utiliza menos rótulos verdadeiros das instâncias em todas as bases de dados.

Analisando os resultados do teste estatístico aplicado aos resultados encontrados, expressos na coluna  $p$ -valor, pode-se observar que as diferenças não foram consideradas significativas estatisticamente nas bases *Line* e *SPAM*, nas demais, o teste estatístico indicou diferenças significativas. Nos casos com diferenças significativas, o método proposto obteve menor taxa de erro nas bases *Circle*, *Sine1* e *Elec*. Por sua vez, na base *Gauss*, o DDM apresentou uma taxa de erro menor, porém com duas detecções a mais, o que pode justificar essa menor taxa de erro.

A Tabela 5-6 mostra a comparação entre o MDAA e o método EDDM. Para as bases sintéticas *Circle*, *Sine1* e *Line*, o MDAA apresentou menores taxas de erro frequencial. Por sua vez, o EDDM tem desempenho melhor somente na base *Gauss*. Em termos de taxa de detecção de mudança de conceito, o método não apresenta falsas detecções, enquanto o EDDM apresenta uma falsa detecção nas bases *Sine1* e *Gauss*. O percentual de instâncias rotuladas é similar aos resultados encontrados na comparação com o DDM. Para ambas as bases de dados reais, o EDDM detectou mais mudanças do que o método proposto, obtendo uma taxa de erro menor. Essa vantagem do EDDM pode ser justificada pelo maior número de detecções realizadas.

Analisando os resultados dos testes estatísticos, pode-se observar que as diferenças são significativas nas bases *Circle*, *Sine1*, *Gauss* e *Elec*. Nessas bases, o método proposto apresentou uma menor taxa de erro em 3 das 4 bases.

Por fim, analisa-se na Tabela 5-7 a comparação do método proposto com o método MD3. Conforme já mencionado anteriormente, nessa comparação utilizou-se como classificador base para o método proposto o SVM Linear. Nas bases sintéticas, o método proposto apresentou menor taxa de erro em todas as bases. Em relação à quantidade de detecções, pode-se observar que o MD3 apresentou baixo desempenho, tendo detectado todas as mudanças conhecidas unicamente na base *Line*.

Em relação às bases reais, pode-se observar que na base *SPAM* o método proposto realizou 8 detecções contra 3 do MD3, o que gerou uma taxa de erro

menor para o método proposto. Já na base *Elec*, o MDAA realizou 42 detecções contra somente 17 detecções do MD3, gerando novamente uma taxa de erro menor a favor do método proposto.

Considerando o percentual de instâncias rotuladas, o método proposto necessitou de menos de 50% dos rótulos das instâncias, porém, ficando ainda com desempenho inferior ao MD3. Este, por sua vez, requereu 17,64% dos rótulos na base *Line*, 16,1% na *Circle*, 9,27% na *Sine1*, 12,37% na *Gauss*, enquanto que, nas bases reais, 9,97% do rótulos na *Spam* e 30,55% na *Elec*. Esse baixo percentual de rótulos requisitados pelo MD3 pode ser ocasionado pela quantidade inferior de detecções realizadas, tal hipótese de causa é sustentada pela média do erro mais elevada obtida pelo MD3 em comparação com o método proposto.

O Teste de Wilcoxon indicou diferenças estatística nas bases *Line*, *Circle*, *Sine1*, *SPAM* e *Elec*, já na base *Gauss* não há diferenças significativas no resultado encontrado. É importante destacar que, embora o MD3 tenha utilizado menos instâncias rotuladas, pode-se observar que o MDAA apresentou melhor compromisso entre baixa taxa de erro e baixa taxa de dados rotulados, uma vez que o MDAA foi superior ao MD3 em termos de taxas de erro e superior ao DMM e ao EDDM em termos de redução de instâncias rotuladas utilizadas.

#### **5.4 CONSIDERAÇÕES FINAIS**

Neste capítulo avaliou-se o desempenho do método proposto em quatro bases sintéticas e duas bases reais com diferentes valores para os parâmetros de Limite de Mudança e Limite de Incerteza. Além da comparação com três classificadores distintos (kNN, SVM Linear e Árvore de Decisão).

Analisando os resultados obtidos, pode-se inicialmente concluir que o método proposto de detecção apresentou baixo desempenho quando combinado com uma Árvore de Decisão. Tal baixo rendimento pode ser ocasionado por configurações não precisas do classificador, sendo este classificador desconsiderado no restante deste trabalho.

Analisando o desempenho do método proposto com o classificador SVM Linear, observa-se que a capacidade de detecção de mudança é elevada. Por exemplo, todas as mudanças foram detectadas nas bases sintéticas, com exceção de uma mudança na base *Gauss* que foi detectada com atraso. Entretanto, pode-se observar também que a taxa de erro manteve-se acima de 10% na maioria das bases. Tal situação justifica-se pelo fato de que SVM Linear é limitado a problemas linearmente separáveis, sendo que esta característica não está necessariamente presente na maior parte das bases utilizadas nesta pesquisa. Dessa forma, pode-se aferir que o método proposto para detecção de mudança de conceito utilizando SVM Linear alcançou desempenho satisfatório, quando analisada a capacidade de detecção.

O terceiro classificador investigado foi o kNN. Em termos de capacidade de detecção, o método proposto utilizado com kNN tem desempenho similar ao alcançado com SVM Linear, porém, com a vantagem de ter taxas de erros menores, conforme pode-se observar neste capítulo.

Tabela 5-8: Resumo do comportamento do método proposto com diferentes métricas de avaliação.

Base	Detecções	%Rotulagem	Falsas	Perdidas	Média Erro	Atrasos
<i>Line</i>	1	33,33	0	0	0,0224	(0)
<i>Circle</i>	3	42,87	0	0	0,0305	(0)(0)(0)
<i>Sine1</i>	9	47,36	0	0	0,0267	(0)(0)(0)(0) (0)(0)(0)(0)(0)
<i>auss</i>	8	42,10	0	1	0,1854	(0)(0)(x)(0) (0)(0)(0)(0)(0)
<i>Elec</i>	42	49,09	-	-	0,1714	-
<i>SPAM</i>	2	11,33	-	-	0,1679	-

Fonte: Própria

A Tabela 5-8 sumariza todos os resultados obtidos neste capítulo, levando em consideração a quantidade de instâncias rotuladas utilizadas, o atraso e falsas detecções. E adicionalmente, apresenta a média da taxa de erro prequencial para cada base de dados. Atrasos na detecção são representados por parênteses, onde (0) indica que não houve atrasos, (x) indica que não houve detecção e (-) indica que a base de dados não contém qualquer mudança de conceito conhecida (base de dados reais).

Na base *Line*, analisada primeiramente (Figura 5-5), o método proposto detectou a única mudança de conceito conhecida sem atraso, falsas ou perdas de detecções, com uma taxa de erro menor que 3%. Na base *Circle* (Figura 5-6), onde 3 mudanças são conhecidas, o método proposto detectou todas as mudanças sem atrasos, falsas detecções ou perdas de detecção e com uma taxa de erro de 3,05% em média. Essas duas primeiras bases apresentam mudança de conceito abrupta e gradual, respectivamente.

A base *Sine1* (Figura 5-7) não contém ruído, mas as classes sofrem reversão a cada mudança de conceito. Essa característica representa uma dificuldade adicional ao método proposto, dado que o MDAA é baseado na confiança do classificador, que é uma medida não sensível à reversão de classes. Desta forma, o método proposto alcançou uma baixa taxa de erro (2,67%) e foi capaz de detectar as 9 mudanças de conceitos conhecidas sem falsas ou perdas de detecções.

A última base de dados sintética (*Gauss* - Figura 5-8) apresenta 9 mudanças conhecidas, com ruído e reversão de classes a cada mudança. Nessa base de dados o método proposto perdeu uma mudança e alcançou uma taxa de erro mais elevada (18,54%) entre todas as bases sintéticas. Esse comportamento pode ser devido à presença de ruídos nos dados.

Como mencionado anteriormente, para as bases reais só é possível analisar o comportamento do método proposto em termos de acurácia e de quantidade de instâncias rotuladas. Na base *Elect* (Figura 5-9) o método proposto detectou 44 mudanças de conceito com uma taxa de erro médio igual a 17,14%. Por sua vez, na base *SPAM* (Figura 5-10), o método proposto detectou somente duas mudanças de conceito e alcançou uma taxa de erro igual a 16,19%.

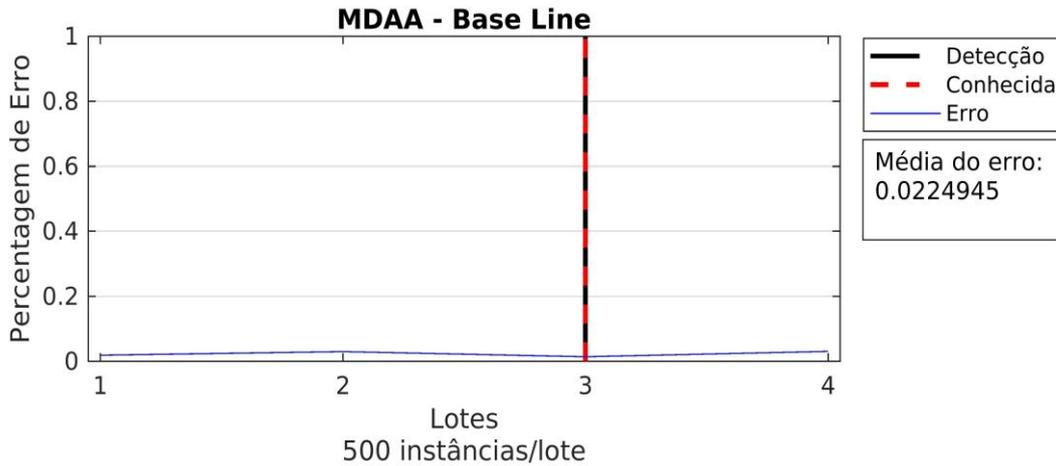


Figura 5-5: Resultado da detecção de mudança na base *Line*. Linha vermelha indica uma mudança conhecida, a linha preta indica uma detecção realizada e a linha em azul indica o comportamento do erro.

Fonte: Própria.

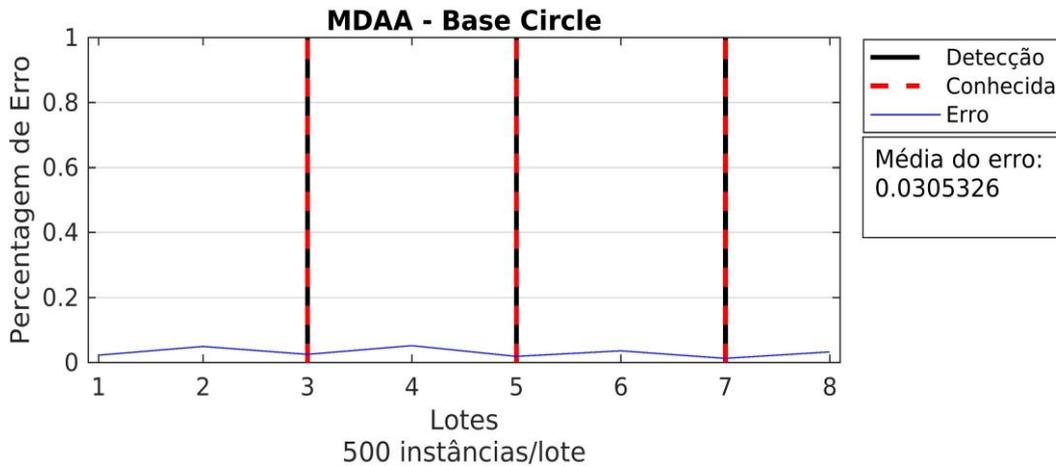


Figura 5-6: Resultado da detecção de mudança na base *Circle*. Linha preta indica uma mudança conhecida, a linha vermelha indica uma detecção realizada e a linha em azul indica o comportamento do erro.

Fonte: Própria.

O Quadro 5-2 apresenta de forma resumida os valores dos parâmetros que otimizam o desempenho do método proposto nas bases utilizadas nesta pesquisa. Pode-se observar que o Limite de Mudança em todos os casos não foi superior a 0,050. Isso indica que as bases utilizadas possuem baixa severidade e que valores maiores para o Limite de Mudança fazem com que o método de detecção não perceba pequenas modificações relevantes ao problema. Em contraponto, em

problemas onde as mudanças têm maior severidade, utilizar pequenos valores para o Limite de Mudança provocaria um aumento no número de falsos positivos. Essa análise do Limite de Mudança atende ao quarto objetivo específico.

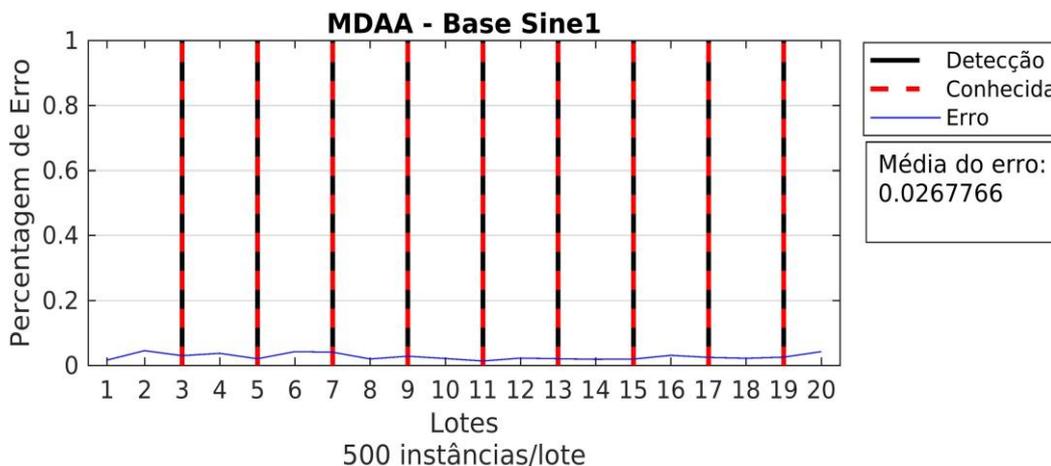


Figura 5-7: Resultado da detecção de mudança na base *Sine1*. Linha vermelha indica uma mudança conhecida, a linha preta indica uma detecção realizada e a linha em azul indica o comportamento do erro.

Fonte: Própria.

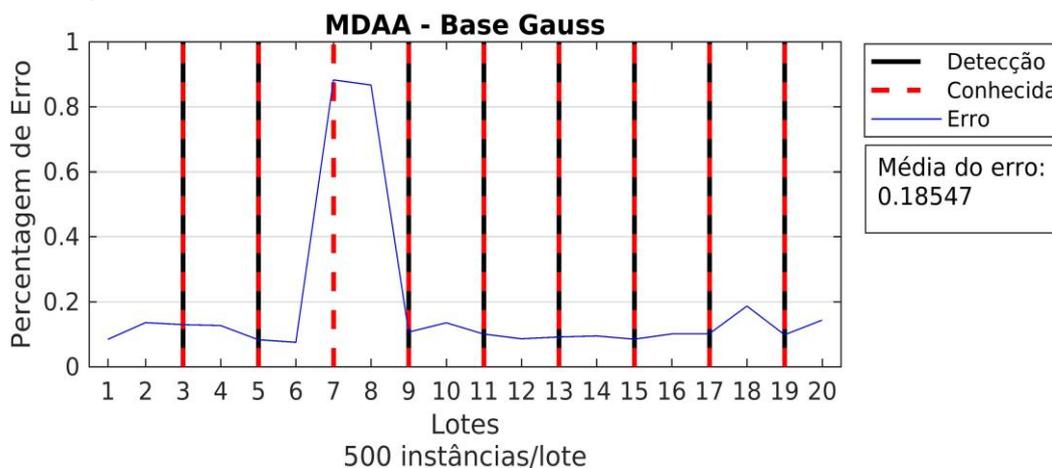


Figura 5-8: Resultado da detecção de mudança na base *Gauss*. Linha vermelha indica uma mudança conhecida, a linha preta indica uma detecção realizada e a linha em azul indica o comportamento do erro.

Fonte: Própria.

Em relação ao Limite de Incerteza, pode-se observar que praticamente todos os valores geraram resultados ótimos, desta forma, pode-se indicar que o Limite de Incerteza gera pouco impacto nos resultados. Porém, conforme já mencionado, valores para o Limite de Incerteza abaixo de 0,60 ou superiores a 0,95 geram uma perda catastrófica no processo de detecção. Essa análise do Limite de Incerteza atende ao terceiro objetivo específico desta pesquisa.

Por fim, sobre as comparações estatísticas, o método proposto apresentou resultados superiores, considerando a média do erro, estatisticamente significantes

contra o método DDM nas bases *Circle*, *Sine1* e *Elec*. Na base *Gauss* o método proposto tem desempenho estatisticamente inferior ao *baseline* analisado, já nas demais bases os resultados não foram estaticamente diferentes. Desta forma, o método proposto é estatisticamente superior em três bases, inferior em uma e em duas não há diferença estatística.

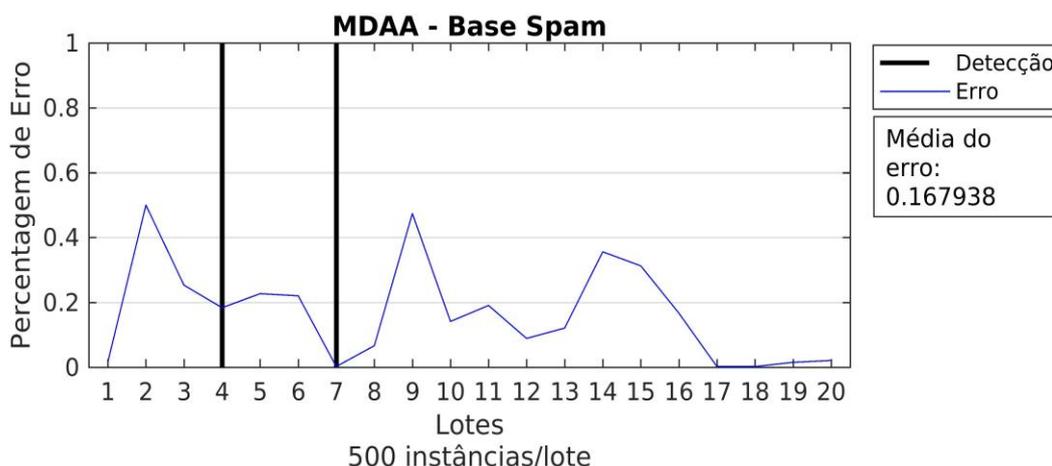


Figura 5-9: Resultado da detecção de mudança na base *SPAM*. A linha em preto representa uma detecção e a linha em azul representa o comportamento do erro.  
Fonte: Própria.

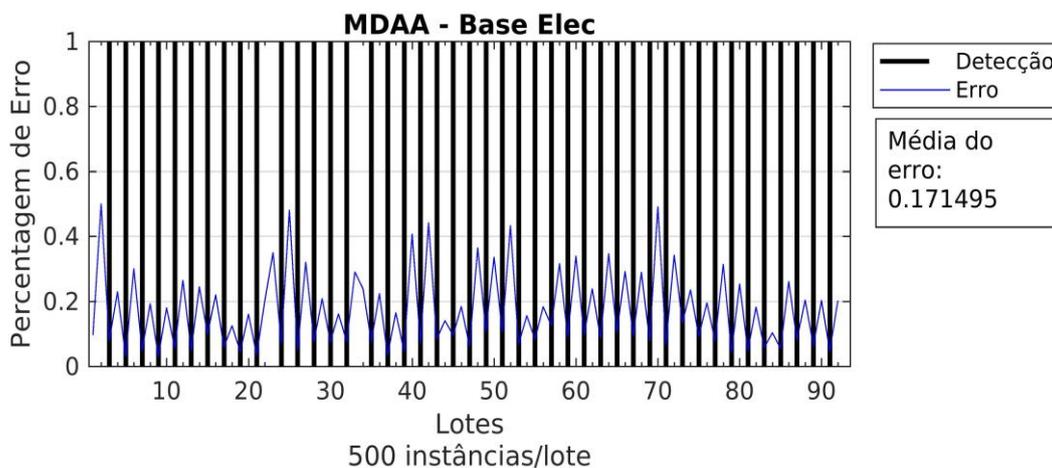


Figura 5-10: Resultado da detecção de mudança na base *ELEC*. A linha em preto representa uma detecção e a linha em azul representa o comportamento do erro.  
Fonte: Própria.

Quando comparado ao EDDM, o MDAA obteve desempenho superior estatisticamente nas bases *Circle*, *Sine1* e *Elec*. Sendo o desempenho do método proposto estaticamente inferior na base *Gauss*, enquanto nas demais bases os resultados não são estatisticamente diferentes. Conforme pode-se observar na comparação com o EDDM, o MDAA tem desempenho semelhante ao obtido quando comparado ao DDM, obtendo vantagem em três das seis bases analisadas,

desvantagem em uma, e nas duas bases restantes não há diferença estatística significativa.

Base	Parâmetros		
	$\zeta$	$\lambda$	$\theta$
Circle	kNN	0.60	0.005; 0.010; 0.015
		0.65	0.005; 0.010; 0.015
		0.70	0.005; 0.010; 0.015
		0.75	0.005; 0.010; 0.015
		0.80	0.005; 0.010; 0.015; 0.020; 0.025; 0.030; 0.035
		0.85	0.005; 0.010; 0.015; 0.020; 0.025; 0.030; 0.035
		0.90	0.005
Sine1	kNN	0.80	0.005
		0.85	0.005
		0.90	0.005
		0.95	0.005
Gauss	kKNN	0.80	0.005; 0.010
		0.85	0.005; 0.010
		0.90	0.005
		0.95	0.005
Line	kNN	0.60	0.005; 0.010
		0.65	0.005; 0.010
		0.70	0.005; 0.010; 0.015
		0.75	0.005; 0.010; 0.015
		0.80	0.005; 0.010; 0.015; 0.020; 0.025
		0.85	0.005; 0.010; 0.015; 0.020; 0.025
		0.90	0.005; 0.010; 0.015; 0.020; 0.025; 0.030; 0.035; 0.040; 0.045; 0.050
Elec	kNN	0.70	0.005; 0.010
		0.75	0.005; 0.010
Spam	kNN	0.70	0.005
		0.75	0.005
		0.80	0.030; 0.035; 0.040; 0.045; 0.050
		0.85	0.030; 0.035; 0.040; 0.045; 0.050

Quadro 5-2: Quadro resumo com os melhores parâmetros para o método proposto.  
Fonte: Própria.

Por sua vez, quando comparado ao MD3, pode-se observar que, em todas as bases com resultados estatisticamente significativos, o MDAA obteve desempenho superior ao método considerado *baseline*, isto é, nas bases *Line*, *Circle*, *Sine1*, *SPAM* e *Elec*. Não houve desempenho estatisticamente inferior, sendo o resultado na base *Gauss* não significativo. Portanto, neste cenário observa-se que o método proposto apresentou-se estatisticamente superior em termos da taxa do erro médio.

Destaca-se também, que quando considerado o percentual de instâncias rotuladas, o MDAA requer um número inferior de rótulos quando comparado ao DDM e ao EDDM, pois esses são método de detecção supervisionados, desta forma, requerem o rótulo de todas as instâncias processadas. Conforme, discutido na Subseção 5.4, o método MD3 requereu um percentual inferior de instâncias

rotuladas, provavelmente devido ao menor número de detecções realizadas. Porém, o erro obtido pelo MD3 foi superior ao erro produzido pelo MDAA em todas as bases investigadas.

No próximo capítulo as conclusões desta pesquisa são apresentadas e discutidas, bem como são feitas sugestões de trabalhos futuros.

# CAPÍTULO 6

## CONCLUSÕES

Neste trabalho estudou-se formas não supervisionadas para detectar a ocorrência do fenômeno nomeado na literatura como mudança de conceito. Conforme exposto no Capítulo 2, a ocorrência desse fenômeno acarreta em uma perda catastrófica no desempenho do classificador. A investigação realizada neste trabalho partiu da hipótese de que técnicas de Aprendizado Ativo podem fornecer indicadores explícitos da ocorrência de mudança de conceito e reduzir a quantidade de instâncias rotuladas necessárias ao processo de detecção.

Essa hipótese foi analisada nos capítulos 4 e 5. No primeiro, propõe-se o uso do conceito de Margens Virtuais projetadas no espaço de entradas baseadas na estratégia de Aprendizado Ativo conhecida como Incerteza Fixa (ZLIOBAITE ET AL., 2014). Conforme foi mostrado nesse capítulo, a utilização da densidade das margens virtuais permite que a detecção de mudança de conceito seja realizada de maneira não supervisionada, contornando o uso da degradação da taxa de erro ou de suposições sobre a distribuição dos dados. A análise do comportamento das Margens Virtuais contempla o segundo objetivo específico desta pesquisa.

No Capítulo 5 mostrou os experimentos realizados com o método proposto. Os experimentos sugerem que a hipótese de pesquisa é válida e que o objetivo geral foi cumprido. Nas bases sintéticas, o método proposto detectou sem atrasos a maioria das mudanças de conceito conhecidas e não apresentou perdas de detecção ou falsas detecções. Como consequência, baixas taxas de erro prequencial foram obtidas. Nas bases reais, conforme mencionado no decorrer do trabalho, somente é possível analisar o comportamento da taxa de erro. Em relação a esse critério, o método alcançou taxas médias de erro inferiores a 20% nas duas bases reais analisadas.

A adaptação da estratégia de Incerteza Fixa mostrou-se adequada ao desenvolvimento desta pesquisa por possuir um único parâmetro, o que simplifica a seleção do valor do parâmetro. A análise desse parâmetro, denominado de Limite de Incerteza ( $\lambda$ ), é apresentado na Subseção 5.2.2, onde constatou-se que todos os valores testados apresentaram resultados satisfatórios. Desta forma, a definição do

valor desse parâmetro é amplamente condicionado ao problema trabalhado, porém, conforme observado nos resultados dos experimentos, valores menores do que 0,60 ou maiores do que 0,99 provocam a saturação do detector.

É importante também mencionar que a adaptação da estratégia de Incerteza Fixa do contexto de seleção de instâncias para o contexto de detecção de mudança e a análise do comportamento do Limite de Incerteza ( $\lambda$ ), contemplam, respectivamente, o primeiro e o terceiro objetivos específicos.

Em relação ao Limite de Mudança ( $\theta$ ), pode-se observar que valores abaixo de 0,050 produziram os melhores resultados. Desta forma, esta pesquisa sugere utilizar valores entre 0,005 a 0,0050 para a detecção de mudanças. Essa análise contempla o quarto objetivo específico. Porém, em problemas onde as mudanças possuem elevados níveis de severidade, pode ser necessária a utilização de valores maiores para o Limite de Mudança.

Destaca-se que a necessidade de definição dos dois parâmetros de limites pode representar uma desvantagem na aplicação do método proposto, pois muitas vezes a definição dos valores é realizada através de um processo de tentativa e erro. Neste cenário, passa-se a discorrer sobre as sugestões de trabalhos futuros.

## **6.1 TRABALHOS FUTUROS**

No desenvolvimento desta pesquisa, observou-se que o comportamento da variação da densidade das instâncias mais significativas poderá ser utilizada unicamente como indicador de mudança de conceito, sem a necessidade de comparar com um limite pré-estabelecido. Desta forma, sugere-se conduzir pesquisas nesse sentido objetivando diminuir o número de parâmetros do método proposto.

Observou-se também que melhorias no desempenho do método podem ser alcançadas quando um Limite de Incerteza dinâmico for implementado, assim, problemas reais que possuem mudanças não equidistantes podem ser tratados com um melhor desempenho pelo método proposto, sem que ocorra a saturação do valor de limite.

Futuras pesquisas também podem ser desenvolvidas na adaptação do método proposto para uma abordagem incremental, o que permitirá maior precisão na detecção de mudança. Bem como realizar pesquisas para a incorporação de conjuntos de classificadores homogêneos e/ou heterogêneos, ao invés de classificador único.

# REFERÊNCIAS

- Arabmakki, E., Kantardzic, M. e Sethi, T., S. *RLS-A Reduced Labeled Samples Approach for Streaming Imbalanced Data with Concept Drift*. In: 15ª Conferência Internacional de Informação, Reuso e Integração (IEEE IRI), 13 a 15 de agosto de 2014, São Francisco, Califórnia, USA, 2014.
- Arabmakki, E., Kantardzic, M. e Sethi, T., S. *Ensemble Classifier for Imbalanced Streaming Data Using Partial Labeling*. In: 17ª Conferência Internacional de Informação, Reuso e Integração (IEEE IRI), 2016
- Baena-Garcia, M., Campo-Avila, J., Del, Fidalgo, R., Bifet, A., Gavalda, R., e Morales-Bueno, R. *Early drift detection method*. In ECML PKDD 2006 Workshop on Knowledge Discovery from Data Streams, 2006.
- Bartosz, K., e Wozniak, M. *Active Learning approach to Concept Drift problem*. In Logic Journal of the IGPL, volume: 25, pp: 550-559, 2011.
- Brzezinski, D. *Mining Data Streams with Concept Drift*. Dissertação de Mestrado, Universidade de Tecnologia de Poznan, Poznan, 2010.
- Burr, S. *Active learning literature survey*. In: Computer Sciences Technical Report 1648. University of Wisconsin – Madison, 2010.
- Burr., S. *Active learning – Synthesis lectures on artificial intelligence and machine learning*: Carnegie Mellon University, 114 páginas, 2012.
- Calma, A., Reitmaier, T., Sick, B., Lukowicz e Embrechts, M. *A new vision of collaborative active learning*. In: CoRR abs/1504.00285, 2015.
- Chawla, N.V., Bowyer, K. W., Hall, L. O. e Kegelmeyer, W.P. *SMOTE: Synthetic Minority Oversampling Technique*,”. In: Artificial Research, vol. 16, pp., 312-357, 2002.
- Dawid, A. P. *Statistical Theory. The prequential approach*. In: Journal of the Royal Statistical Society. 147, 278-292, 1984.

- Ditzler, G. e Polikar, R. *Hellinger distance based drift detection for nonstationary environments*. In: Computational Intelligence in Dynamic and Uncertain Environments (CIDUE), Symposium IEEE, 2011.
- Gama, J., Medas, P., Castillo, G. e Rodrigues, P. *Learning with drift detection*. In: SBIA Brazilian Symposium on Artificial Intelligence. pp:286-295, 2004.
- Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M. e Bouchachia, M. *A Survey on Concept Drift Adaptation*. ACM Comput. Surv, volume: 25, artigo 44, páginas 37, 2014.
- Henke, M., Souto, E. e dos Santos, E.M. *Analysis of the evolution of features in classification problems with concept drift: Application to spam detection*. In Proceedings of the 2015 IFIP/IEEE International Symposium on Integrated Network Management, pp: 874-877, 2015.
- Hoens, T.,R., Polikar, R., Chawla, N.,V. *Learning from streaming data with concept drift and imbalance:an overview*. In: Prog Artif Intell 1(1):89–101. doi:10.1007/s13748-011-0008-0, 2012.
- Huang, D.,T.,J., Koh, Y.S., Gillian, D., Pears, R. *Tracking drift types in changing data streams*. In: Hiroshi M, Wu Z, Cao L, Zaiane O, Min Y, Wei W (eds) Advanced data mining and applications. Lecture notes in computer science. Springer, Berlin, pp 72–83. doi:10.1007/978-3-642-53914-5\_7, 2013.
- Ienco, D., Pfahringer, B., Žliobaitė, I. *High density-focused uncertainty sampling for active learning over evolving stream data*. In: JMLR: Whorshop and Conferece Proceedings 36, pp:133-148, 2014.
- Khamassi, I., Mouchaweh-Sayed, M., Hammami, M. e Ghédira, K. *Self-adaptive windowing approach for handling complex concept drift*. In Cognitive Computation, volume: 7, issue:6, pp: 772-790, 2015.
- Kremer, J., Pederse, K., S., Igel, C. *Active Learning with support vector machines*. Wiley Interdisciplinary reviews. Data mining and knowledge discovery, pp: 133-326, 2014.
- Lichtenwalter, R., N. e Chawla, N., V. *Adaptive methods for classification in arbitrarily imbalanced and drifting data streams*. In Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), volume: 5669 LNAI, pp:53-75, 2010.
- Lindstrom, P., Namee, B.N., Delany, S. J. *Drift detection using uncertainty distribution divergence*. In: Evolving Systems. volume 4, issue 1, pp:13-25, 2013.

- Minku, L.,L., White, A., L. e Yao X. *The impact of diversity on online ensemble learning in the presence of concept drift*. In IEEE Transaction on Knowledge and Data Engineering, volume: 22, issue: 5, pp: 730-742, 2010.
- Mitchell, T. *Machine Learning*. McGraw Hill, 1997.
- Pinage, Felipe, A. e dos Santos, Eulanda, M. *A dissimilarity-based drift detection method*. In: Tools with Artificial Intelligence (ICTAI), 2015 IEEE 27<sup>th</sup> International Conference on, 2015.
- Sayed-Mouchaweh, M. *Learning from data streams in dynamic environments*. VIII, 75, Springer International Publishing, 2016.
- Schlimmer, J., Granger. R. *Incremental learning from noisy data*. Machine Learning, 1, 317-354, 1986.
- Sethi, T., S e Kantardzicm M. *Don't pay for validation: Detecting drifts from unlabeled data using margin density*, In Procedia Computer Science, vol. 53, pp.103-122, Elsevier, 2015.
- Sethi, T., S e Kantardzicm M. *On the reliable detection of concept drift from streaming unlabeled data*, In Expert Systems with Applications, vol. 82, pp.77-99, Elsevier, 2017.
- Wozniak, M., Cyganek, B., L., Kasprzak, A., Iksieniewicz, P. e Walkowiak, K. *Active learning classifier for streaming data*. In: Hybrid Artificial Intelligent Systems: 11th International Conference, HAIS 2016, Seville, Spain, April 18-20, 2016, Proceedings Springer International Publishing, pp:186-197, 2016.
- Yanxia, L., Cuirong, W., Cong. W., Bingyuy, L. *Uncertain Data Stream Classification with Concept Drift*. In: Conference International on Advanced Cloud and Big Data (CDB) 2016, 2016.
- Žliobaitė, I. Learning under concept drift: An overview. Relatório Técnico, Universidade Vilnius, 2009.
- Žliobaitė, I., Bifet, A., Pfahringer, B, e Holmes, G. *Active learning with evolving streaming data*. In: Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), volume: 6913 LNAI, pp:597-612, 2011.
- Žliobaitė, I., Bifet, A., Pfahringer, B, e Holmes, G. *Active learning with drifting streaming data*. In: IEEE Transactions on Neural Networks and Learning Systems, volume: 25, pp: 27-29, 2014.

# APÊNDICES

## APÊNDICE A

Apêndice A 1: Experimento com  $\eta = 300$  na base *Line*.

Base: <i>Line</i>	$\eta: 300$															
	L. Incerteza															
	0,60		0,65		0,70		0,75		0,80		0,85		0,90		0,95	
L. Mudança	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC
0,005	2	0	2	0	3	0	3	0	2	0	2	0	3	0	3	0
0,010	1	0	1	0	3	0	3	0	2	0	2	0	3	0	3	0
0,015	1	0	1	0	1	1	1	1	2	0	2	0	2	0	2	0
0,020	0	0	0	0	1	0	1	0	2	0	2	0	2	0	2	0
0,025	0	2	0	0	0	0	0	0	2	0	2	0	2	0	2	0
0,030	0	0	0	0	0	0	0	0	0	0	0	0	2	0	2	0
0,035	0	0	0	0	0	0	0	0	0	0	0	0	2	0	2	0
0,040	0	0	0	0	0	0	0	0	1	1	1	1	1	0	1	0
0,045	0	0	0	0	0	0	0	0	1	1	1	1	0	0	0	0
0,050	0	0	0	0	0	0	0	0	1	1	1	1	1	0	1	0
0,055	0	0	0	0	0	0	0	0	1	0	1	0	1	0	1	0
0,060	0	0	0	0	0	0	0	0	1	0	1	0	1	0	1	0
0,065	0	0	0	0	0	0	0	0	1	0	1	0	1	1	1	1
0,070	0	0	0	0	0	0	0	0	1	0	1	0	1	1	1	1
0,075	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
0,080	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1
0,085	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1
0,090	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1
0,095	0	0	0	0	0	0	0	0	0	0	0	1	1	1	0	0

Fonte: Própria

Apêndice A 2: Experimento com  $\eta = 300$  na base *Circle*.

Base: <i>Circle</i>	$\eta: 300$															
	L. Incerteza															
	0,60		0,65		0,70		0,75		0,80		0,85		0,90		0,95	
L. Mudança	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC
0,005	5	0	5	0	6	2	6	2	6	1	6	1	6	1	6	1
0,010	5	1	5	1	5	1	5	1	6	2	6	2	6	2	6	2
0,015	4	3	4	3	5	3	5	3	5	1	5	1	6	2	6	2
0,020	3	0	3	0	4	1	4	1	5	1	5	1	6	2	6	2
0,025	2	0	2	0	4	1	4	1	5	1	5	1	6	2	6	2
0,030	1	0	1	0	4	1	4	1	5	1	5	1	6	2	6	2
0,035	1	0	1	0	4	1	4	1	5	1	5	1	6	2	6	2
0,040	1	0	1	0	4	1	4	1	4	2	4	2	3	2	3	2
0,045	1	0	1	0	3	1	3	1	3	1	3	1	3	2	3	2
0,050	1	0	1	0	3	1	3	1	3	1	3	1	3	2	3	2
0,055	0	0	0	0	3	1	3	1	3	1	3	1	4	2	4	2
0,060	0	0	0	0	3	1	3	1	3	1	3	1	4	1	4	1
0,065	0	0	0	0	1	1	1	1	3	1	3	1	4	1	4	1
0,070	0	0	0	0	1	0	1	0	3	1	3	1	3	1	3	1
0,075	0	0	0	0	1	0	1	0	3	1	3	1	3	1	3	1
0,080	0	0	0	0	1	0	1	0	3	1	3	1	2	0	2	0
0,085	0	0	0	0	1	0	1	0	3	1	3	1	2	0	2	0
0,090	0	0	0	0	0	0	0	0	2	0	2	0	2	0	2	0
0,095	0	0	0	0	0	0	2	0	2	0	2	0	2	0	2	0

Fonte: Própria

Apêndice A 3: Experimento com  $\eta = 300$  na base Gauss.

Base: Gauss	$\eta: 300$															
	L. Incerteza															
	0,60		0,65		0,70		0,75		0,80		0,85		0,90		0,95	
L. Mudança	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC
0,005	14	3	14	3	14	3	14	3	16	5	16	5	16	5	16	5
0,010	14	4	14	14	14	3	14	3	15	5	15	5	15	6	15	6
0,015	9	1	9	1	12	3	12	3	13	5	13	5	12	7	12	7
0,020	7	3	7	3	9	1	9	1	13	5	13	5	11	5	11	5
0,025	5	1	5	2	9	6	8	6	8	3	8	3	7	1	7	1
0,030	2	2	2	2	6	4	6	4	8	3	8	3	6	3	6	3
0,035	2	2	2	2	3	1	3	1	8	3	8	3	4	1	4	1
0,040	2	2	2	2	0	0	0	0	6	2	6	2	5	0	5	0
0,045	2	1	2	1	0	0	0	0	3	1	3	1	3	1	3	1
0,050	0	0	0	0	0	0	0	0	2	1	2	1	2	0	2	0
0,055	0	0	0	0	0	0	0	0	2	1	2	1	2	0	2	0
0,060	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,065	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,070	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,075	0	0	0	0	0	0	0	0	0	0	0	0	3	2	3	2
0,080	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,085	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0
<b>0,090</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,095</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>

Fonte: Própria

Apêndice A 4: Experimento com  $\eta = 300$  na base *Sine1*.

Base: <i>Sine1</i>	$\eta: 300$															
	L. Incerteza															
	0,60		0,65		0,70		0,75		0,80		0,85		0,90		0,95	
L. Mudança	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC
0,005	12	4	12	4	13	2	13	2	16	5	16	5	15	4	15	4
0,010	12	4	12	4	13	2	13	2	15	5	15	5	14	4	14	4
0,015	11	3	11	3	10	1	10	1	13	4	13	4	13	4	13	4
0,020	8	4	8	4	7	1	7	1	12	2	12	2	11	5	11	5
0,025	3	1	3	1	8	3	8	3	10	2	10	2	6	3	6	3
0,030	2	1	2	1	5	1	5	1	8	3	8	3	5	2	5	2
0,035	1	0	1	0	5	3	5	3	8	3	8	3	3	2	3	2
0,040	1	0	1	0	0	0	0	0	7	3	7	3	4	1	4	1
0,045	1	0	1	0	0	0	0	0	3	0	3	0	2	1	2	1
0,050	0	0	0	0	0	0	0	0	3	1	3	1	2	1	2	1
0,055	0	0	0	0	0	0	0	0	5	1	5	1	2	1	2	1
0,060	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,065	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,070	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,075	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,080	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,085	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,090	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,095	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1

Fonte: Própria

Apêndice A 5: Experimento com  $\eta = 400$  na base *Line*.

Base: <i>Line</i>	$\eta: 400$															
	L. Incerteza															
	0,60		0,65		0,70		0,75		0,80		0,85		0,90		0,95	
L. Mudança	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC
0,005	1	0	1	0	0	0	0	0	1	1	1	1	2	1	2	1
0,010	1	0	1	0	0	0	0	0	1	0	1	0	1	0	1	0
0,015	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0
0,020	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0
0,025	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0
0,030	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0
<b>0,035</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,040</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,045</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,050</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,055</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,060</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,065</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,070</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,075</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,080</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,085</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,090</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,095</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>

Fonte: Própria

Apêndice A 6: Experimento com  $\eta = 400$  na base *Circle*.

Base: <i>Circle</i>	$\eta: 400$															
	L. Incerteza															
	0,60		0,65		0,70		0,75		0,80		0,85		0,90		0,95	
L. Mudança	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC
0,005	4	1	4	1	4	1	4	1	4	1	4	1	4	1	4	1
0,010	4	1	4	4	4	1	4	1	4	2	4	2	4	1	4	1
0,015	3	0	3	0	3	1	3	1	4	1	4	1	4	1	4	1
0,020	2	1	2	1	3	1	3	1	4	2	4	2	4	1	4	1
0,025	2	1	2	1	3	1	3	1	4	2	4	2	4	1	4	1
0,030	1	0	1	0	3	3	3	3	4	2	4	2	3	2	3	2
0,035	1	0	1	0	3	3	3	3	3	1	3	1	3	2	3	2
0,040	0	0	0	0	1	0	1	0	2	1	2	1	3	1	3	1
0,045	0	0	0	0	1	0	1	0	2	0	2	0	2	1	2	1
0,050	0	0	0	0	1	0	1	0	2	0	2	0	2	1	2	1
0,055	0	0	0	0	1	0	1	0	2	0	2	0	2	1	2	1
0,060	0	0	0	0	1	0	1	0	1	0	1	0	2	0	2	0
0,065	0	0	0	0	1	0	1	0	1	0	1	0	1	0	1	0
0,070	0	0	0	0	1	0	1	0	1	0	1	0	1	0	1	0
0,075	0	0	0	0	0	0	0	0	1	0	1	0	1	0	1	0
0,080	0	0	0	0	0	0	0	0	1	0	1	0	1	0	1	0
0,085	0	0	0	0	0	0	0	0	1	0	1	0	1	0	1	0
0,090	0	0	0	0	0	0	0	0	1	0	1	0	1	1	1	1
0,095	0	0	0	0	0	0	0	0	1	0	1	0	1	1	1	1

Fonte: Própria

Apêndice A 7: Experimento com  $\eta = 400$  na base Gauss.

Base: Gauss	$\eta: 400$															
	L. Incerteza															
	0,60		0,65		0,70		0,75		0,80		0,85		0,90		0,95	
L. Mudança	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC
0,005	10	4	10	4	11	3	11	3	12	4	12	4	7	4	7	4
0,010	9	3	9	3	9	6	9	6	11	4	11	4	4	1	4	1
0,015	7	2	7	2	7	4	7	4	10	3	10	3	1	1	1	1
0,020	4	2	4	2	7	5	7	5	8	3	8	3	1	1	1	1
0,025	2	1	2	1	7	4	7	4	8	4	8	4	9	1	9	1
0,030	2	0	2	0	5	4	5	4	1	1	1	1	1	1	1	1
0,035	1	1	1	1	5	4	5	4	1	1	1	1	1	1	1	1
0,040	1	0	1	0	5	2	5	2	1	1	1	1	1	1	1	1
0,045	1	0	1	0	3	2	3	2	3	2	3	2	1	1	1	1
0,050	1	0	1	0	1	0	1	0	3	2	3	2	1	1	1	1
0,055	0	0	0	0	0	0	0	0	3	2	3	2	1	1	1	1
0,060	0	0	0	0	0	0	0	0	2	1	2	1	1	1	1	1
0,065	0	0	0	0	0	0	0	0	1	1	1	1	2	0	2	0
0,070	0	0	0	0	0	0	0	0	1	1	1	1	1	0	1	0
0,075	0	0	0	0	0	0	0	0	1	1	1	1	2	1	2	1
0,080	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,085	0	0	0	0	0	0	0	0	1	0	1	0	1	1	1	1
<b>0,090</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,095</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>

Fonte: Própria

Apêndice A 8: Experimento com  $\eta = 400$  na base *Sine1*.

Base: <i>Sine1</i>	$\eta: 400$															
	L. Incerteza															
	0,60		0,65		0,70		0,75		0,80		0,85		0,90		0,95	
L. Mudança	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC
0,005	10	3	10	3	10	5	10	5	9	2	9	2	1	1	1	1
0,010	9	4	9	4	8	4	8	4	8	2	8	2	1	1	1	1
0,015	5	1	5	1	6	2	6	2	7	3	7	3	1	1	1	1
0,020	1	1	1	1	5	3	5	3	6	3	6	3	3	2	3	2
0,025	0	0	0	0	1	1	1	1	5	0	5	0	3	2	3	2
0,030	0	0	0	0	1	1	1	1	4	1	4	1	4	2	4	2
0,035	0	0	0	0	1	1	1	1	3	2	3	2	6	2	6	2
0,040	0	0	0	0	1	1	1	1	2	0	2	0	2	2	2	2
0,045	0	0	0	0	0	0	0	0	2	0	2	0	2	2	2	2
0,050	0	0	0	0	0	0	0	0	1	1	1	1	3	2	3	2
0,055	0	0	0	0	0	0	0	0	1	1	1	1	2	1	2	1
<b>0,060</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>1</b>	<b>1</b>
<b>0,065</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,070</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,075</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,080</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,085</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,090</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,095</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>

Fonte: Própria

Apêndice A 9: Experimento com  $\eta = 500$  na base *Line*.

Base: <i>Line</i>	$\eta: 500$															
	L. Incerteza															
	0,60		0,65		0,70		0,75		0,80		0,85		0,90		0,95	
L. Mudança	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC
0,005	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
0,010	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
0,015	1	0	1	0	1	1	1	1	1	1	1	1	1	1	1	1
0,020	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1
0,025	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1
0,030	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
0,035	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
0,040	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
0,045	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
0,050	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
<b>0,055</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,060</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,065</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,070</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,075</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,080</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,085</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,090</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,095</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>

Fonte: Própria

Apêndice A 10: Experimento com  $\eta = 500$  na base *Circle*.

Base: <i>Circle</i>	$\eta: 500$															
	L. Incerteza															
	0,60		0,65		0,70		0,75		0,80		0,85		0,90		0,95	
L. Mudança	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC
0,005	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
0,010	3	3	3	3	3	3	3	3	3	3	3	3	2	1	2	1
0,015	3	3	3	3	3	3	3	3	3	3	3	3	2	1	2	1
0,020	2	2	2	2	2	1	2	1	3	3	3	3	2	2	2	2
0,025	2	2	2	2	2	1	2	1	3	3	3	3	2	2	2	2
0,030	1	0	1	0	2	1	2	1	3	3	3	3	2	2	2	2
0,035	1	0	1	0	2	1	2	1	3	3	3	3	2	2	2	2
0,040	0	0	0	0	1	1	1	1	2	1	2	1	2	2	2	2
0,045	0	0	0	0	1	0	1	0	2	1	2	1	2	2	2	2
0,050	0	0	0	0	1	0	1	0	2	1	2	1	2	2	2	2
0,055	0	0	0	0	1	0	1	0	2	1	2	1	1	1	1	1
0,060	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1
0,065	0	0	0	0	1	1	1	1	1	0	1	0	1	1	1	1
0,070	0	0	0	0	0	0	0	0	1	0	1	0	1	0	1	0
0,075	0	0	0	0	0	0	0	0	1	0	1	0	1	0	1	0
0,080	0	0	0	0	0	0	0	0	1	0	1	0	1	0	1	0
0,085	0	0	0	0	0	0	0	0	1	0	1	0	1	0	1	0
0,090	0	0	0	0	0	0	0	0	1	1	1	1	1	0	1	0
0,095	0	0	0	0	0	0	0	0	1	1	1	1	1	0	1	0

Fonte: Própria

Apêndice A 11: Experimento com  $\eta = 500$  na base *Gauss*.

Base: <i>Gauss</i>	$\eta: 500$															
	L. Incerteza															
	0,60		0,65		0,70		0,75		0,80		0,85		0,90		0,95	
L. Mudança	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC
0,005	8	1	8	1	8	4	8	4	8	8	8	8	9	7	9	7
0,010	5	3	5	3	7	2	7	2	8	8	8	8	9	4	9	4
0,015	5	3	5	3	7	3	7	3	8	4	8	4	8	4	8	4
0,020	3	1	3	1	5	1	5	1	7	5	7	5	8	4	8	4
0,025	1	1	1	1	3	2	3	2	7	1	7	1	6	5	6	5
0,030	1	1	1	1	3	0	3	0	5	2	5	2	6	5	6	5
0,035	1	0	1	0	2	0	2	0	3	1	3	1	6	5	6	5
0,040	0	0	0	0	0	0	0	0	3	1	3	1	4	4	4	4
0,045	0	0	0	0	0	0	0	0	3	1	3	1	3	3	3	3
0,050	0	0	0	0	0	0	0	0	2	0	2	0	2	2	2	2
0,055	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,060	0	0	0	0	0	0	0	0	0	0	0	0	2	1	2	1
0,065	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0
0,070	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0
0,075	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0
0,080	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0
0,085	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0
<b>0,090</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,095</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>

Fonte: Própria

Apêndice A 12: Experimento com  $\eta = 500$  na base *Gauss*.

Base: <i>Sine1</i>	$\eta: 500$															
	L. Incerteza															
	0,60		0,65		0,70		0,75		0,80		0,85		0,90		0,95	
L. Mudança	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC	D	DC
0,005	7	5	7	5	7	5	7	5	9	9	9	9	9	9	9	9
0,010	4	3	4	3	5	3	5	3	6	3	6	3	8	6	8	6
0,015	4	4	4	4	5	3	5	3	4	4	6	4	6	2	6	2
0,020	2	2	2	2	5	3	5	3	5	3	5	3	6	2	6	2
0,025	1	0	1	0	2	1	2	1	5	3	5	3	5	4	5	4
0,030	0	0	0	0	1	1	1	1	5	3	5	3	5	4	5	4
0,035	0	0	0	0	1	1	1	1	2	2	2	2	4	2	4	2
0,040	0	0	0	0	0	0	0	0	0	0	0	0	4	2	4	2
0,045	0	0	0	0	0	0	0	0	0	0	0	0	3	2	3	2
<b>0,050</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,055</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,060</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,065</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,070</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,075</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,080</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,085</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,090</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>0,095</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>

Fonte: Própria

## APÊNDICE B

Apêndice B 1:Resultado do método proposto na base *Circle* com classificador KNN.

<i>Circle</i>		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	<b>0,0305</b>							
		AD	<b>0</b>							
		D PD FD	<b>3 0 0</b>							
	0,010	E	<b>0,0305</b>	<b>0,0305</b>	<b>0,0305</b>	<b>0,0305</b>	<b>0,0305</b>	<b>0,0305</b>	0,1297	0,1297
		AD	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	1	1
		D PD FD	<b>3 0 0</b>	2 2 1	2 2 1					
	0,015	E	<b>0,0305</b>	<b>0,0305</b>	<b>0,0305</b>	<b>0,0305</b>	<b>0,0305</b>	<b>0,0305</b>	0,1297	0,1297
		AD	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	1	1
		D PD FD	<b>3 0 0</b>	2 2 1	2 2 1					
	0,020	E	0,1054	0,1054	0,1297	0,1297	<b>0,0305</b>	<b>0,0305</b>	0,0916	0,0916
		AD	0	0	1	1	<b>0</b>	<b>0</b>	0	0
		D PD FD	2 1 0	2 1 0	2 2 1	2 2 1	<b>3 0 0</b>	<b>3 0 0</b>	2 1 0	2 1 0
	0,025	E	0,1054	0,1054	0,1297	0,1297	<b>0,0305</b>	<b>0,0305</b>	0,0916	0,0916
		AD	0	0	1	1	<b>0</b>	<b>0</b>	0	0
		D PD FD	2 1 0	2 1 0	2 2 1	2 2 1	<b>3 0 0</b>	<b>3 0 0</b>	2 1 0	2 1 0
	0,030	E	0,2173	0,2773	0,1297	0,1297	<b>0,0305</b>	<b>0,0305</b>	0,0916	0,0916
		AD	0	0	1	1	<b>0</b>	<b>0</b>	0	0
		D PD FD	1 2 0	1 2 0	2 2 1	2 2 1	<b>3 0 0</b>	<b>3 0 0</b>	2 1 0	2 1 0
	0,035	E	0,2773	0,2773	0,1297	0,1297	<b>0,0305</b>	<b>0,0305</b>	0,0916	0,0916
		AD	0	0	1	1	<b>0</b>	<b>0</b>	0	0
		D PD FD	1 2 0	1 2 0	2 2 1	2 2 1	<b>3 0 0</b>	<b>3 0 0</b>	2 1 0	2 1 0
	0,040	E	0,3551	0,3551	0,2133	0,2133	0,1297	0,1297	0,0916	0,0916
		AD	-	-	0	0	1	1	0	0
		D PD FD	0 3 0	0 3 0	1 2 0	1 2 0	2 2 1	2 2 1	2 1 0	2 1 0
	0,045	E	0,3551	0,3551	0,2485	0,2485	0,1297	0,1297	0,0916	0,0916
		AD	-	-	1	1	1	1	0	0
		D PD FD	0 3 0	0 3 0	1 1 1	1 1 1	2 2 1	2 2 1	2 1 0	2 1 0
0,050	E	0,3551	0,3551	0,2485	0,2485	0,1297	0,1297	0,0916	0,0916	
	AD	-	-	1	1	1	1	0	0	
	D PD FD	0 3 0	0 3 0	1 1 1	1 1 1	2 2 1	2 2 1	2 1 0	2 1 0	
0,055	E	0,3551	0,3551	0,2485	0,2485	0,2133	0,2133	0,2133	0,2133	
	AD	-	-	1	1	0	0	0	0	
	D PD FD	0 3 0	0 3 0	1 1 1	1 1 1	1 2 0	1 2 0	1 2 0	1 2 0	
0,060	E	0,3551	0,3551	0,2173	0,2173	0,2133	0,2133	0,2133	0,2133	
	AD	-	-	0	0	0	0	0	0	
	D PD FD	0 3 0	0 3 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	
0,065	E	0,3551	0,3551	0,2173	0,2173	0,2133	0,2133	0,2133	0,2133	
	AD	-	-	0	0	0	0	0	0	
	D PD FD	0 3 0	0 3 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	
0,070	E	0,3551	0,3551	0,3551	0,3551	0,2485	0,2485	0,2485	0,2485	
	AD	-	-	-	-	1	1	1	1	
	D PD FD	0 3 0	0 3 0	0 3 0	0 3 0	1 2 1	1 2 1	1 2 1	1 2 1	
0,075	E	0,3551	0,3551	0,3551	0,3551	0,2485	0,2485	0,2485	0,2485	
	AD	-	-	-	-	1	1	1	1	
	D PD FD	0 3 0	0 3 0	0 3 0	0 3 0	1 2 1	1 2 1	1 2 1	1 2 1	
0,080	E	0,3551	0,3551	0,3551	0,3551	0,2485	0,2485	0,2485	0,2485	
	AD	-	-	-	-	1	1	1	1	
	D PD FD	0 3 0	0 3 0	0 3 0	0 3 0	1 2 1	1 2 1	1 2 1	1 2 1	
0,085	E	0,3551	0,3551	0,3551	0,3551	0,2485	0,2485	0,2485	0,2485	
	AD	-	-	-	-	1	1	1	1	
	D PD FD	0 3 0	0 3 0	0 3 0	0 3 0	1 2 1	1 2 1	1 2 1	1 2 1	
0,090	E	0,3551	0,3551	0,3551	0,3551	0,2173	0,2173	0,2485	0,2485	
	AD	-	-	-	-	0	0	1	1	
	D PD FD	0 3 0	0 3 0	0 3 0	0 3 0	1 2 0	1 2 0	1 2 1	1 2 1	
0,095	E	0,3551	0,3551	0,3551	0,3551	0,2173	0,2173	0,2485	0,2485	
	AD	-	-	-	-	0	0	1	1	
	D PD FD	0 3 0	0 3 0	0 3 0	0 3 0	1 2 0	1 2 0	1 2 1	1 2 1	

Fonte: Própria

Apêndice B 2: Resultado do método proposto na base *Line* com classificador KNN.

<i>Line</i>		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	<b>0,0224</b>							
		AD	0	0	0	0	0	0	0	0
		D PD FD	1 0 0	1 0 0	1 0 0	1 0 0	1 0 0	1 0 0	1 0 0	1 0 0
	0,010	E	<b>0,0224</b>							
		AD	0	0	0	0	0	0	0	0
		D PD FD	1 0 0	1 0 0	1 0 0	1 0 0	1 0 0	1 0 0	1 0 0	1 0 0
	0,015	E	0,1183	0,1183	<b>0,0224</b>	<b>0,0224</b>	<b>0,0224</b>	<b>0,0224</b>	<b>0,0224</b>	<b>0,0224</b>
		AD	1	1	0	0	0	0	0	0
		D PD FD	1 1 1	1 1 1	1 0 0	1 0 0	1 0 0	1 0 0	1 0 0	1 0 0
	0,020	E	0,2045	0,2045	0,2045	0,2045	0,2045	<b>0,0224</b>	<b>0,0224</b>	<b>0,0224</b>
		AD	-	-	-	-	-	0	0	0
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	1 0 0	1 0 0	1 0 0
	0,025	E	0,2045	0,2045	0,2045	0,2045	0,2045	<b>0,0224</b>	<b>0,0224</b>	<b>0,0224</b>
		AD	-	-	-	-	-	0	0	0
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	1 0 0	1 0 0	1 0 0
	0,030	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	<b>0,0224</b>	<b>0,0224</b>
		AD	-	-	-	-	-	-	0	0
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	1 0 0	1 0 0
	0,035	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	<b>0,0224</b>	<b>0,0224</b>
		AD	-	-	-	-	-	-	0	0
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	1 0 0	1 0 0
	0,040	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	<b>0,0224</b>	<b>0,0224</b>
		AD	-	-	-	-	-	-	0	0
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	1 0 0	1 0 0
	0,045	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	<b>0,0224</b>	<b>0,0224</b>
		AD	-	-	-	-	-	-	0	0
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	1 0 0	1 0 0
	0,050	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	<b>0,0224</b>	<b>0,0224</b>
		AD	-	-	-	-	-	-	0	0
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	1 0 0	1 0 0
0,055	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,060	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,065	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,070	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,075	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,080	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,085	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,090	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,095	E	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	0,2045	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	

Fonte: Própria

Apêndice B 3: Resultado do método proposto na base *Sine1* com classificador KNN.

<i>Sine1</i>		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,2615	0,2615	0,2615	0,2615	<b>0,0267</b>	<b>0,0267</b>	<b>0,0267</b>	<b>0,0267</b>
		AD	2	2	2	2	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
		D PD FD	7 4 2	7 4 2	7 4 2	7 4 2	<b>9 0 0</b>	<b>9 0 0</b>	<b>9 0 0</b>	<b>9 0 0</b>
	0,010	E	0,3153	0,3153	0,3061	0,3061	0,4005	0,4005	0,2160	0,2160
		AD	1	1	2	2	3	3	2	2
		D PD FD	4 6 1	4 6 1	5 6 2	5 6 2	6 6 3	6 6 3	8 3 2	8 3 2
	0,015	E	0,3137	0,3137	0,3619	0,3619	0,3104	0,3104	0,4058	0,4058
		AD	-	-	2	2	2	2	4	4
		D PD FD	4 5 0	4 5 0	5 6 2	5 6 2	6 5 2	6 5 2	6 7 4	6 7 4
	0,020	E	0,4063	0,4063	0,3619	0,3619	0,3118	0,3118	0,4058	0,4058
		AD	-	-	2	2	2	2	4	4
		D PD FD	2 7 0	2 7 0	5 6 2	5 6 2	5 6 2	5 6 2	6 7 4	6 7 4
	0,025	E	0,4545	0,4545	0,4528	0,4528	0,3118	0,3118	0,3587	0,3587
		AD	1	1	1	1	2	2	1	1
		D PD FD	1 9 1	1 9 1	1 8 1	1 8 1	4 7 2	4 7 2	5 5 1	5 5 1
	0,030	E	0,4989	0,4989	0,4064	0,4064	0,3118	0,3118	0,3587	0,3587
		AD	-	-	0	0	2	2	1	1
		D PD FD	0 9 0	0 9 0	1 8 0	1 8 0	5 6 2	5 6 2	5 5 1	5 5 1
	0,035	E	0,4989	0,4989	0,4065	0,4065	0,4079	0,4079	0,4558	0,4558
		AD	-	-	0	0	0	0	2	2
		D PD FD	0 9 0	0 9 0	1 8 0	1 8 0	2 7 0	2 7 0	4 7 2	4 7 2
	0,040	E	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,3558	0,3558
		AD	-	-	-	-	-	-	2	2
		D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	4 7 2	4 7 2
	0,045	E	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,3592	0,3592
		AD	-	-	-	-	-	-	1	1
		D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	3 7 1	3 7 1
	0,050	E	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0
0,055	E	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,060	E	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,065	E	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,070	E	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,075	E	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,080	E	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,085	E	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,090	E	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,095	E	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	0,4989	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	

Fonte: Própria

Apêndice B 4: Resultado do método proposto na base Gauss com classificador KNN.

Gauss		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,4534	0,4534	0,3391	0,3391	<b>0,1854</b>	<b>0,1854</b>	0,1874	0,1874
		AD	7	7	4	4	-	-	-	-
		D PD FD	8 8 7	8 8 7	8 5 4	8 5 4	<b>8 1 0</b>	<b>8 1 0</b>	9 2 2	9 2 2
	0,010	E	0,4571	0,4571	0,4630	0,4630	<b>0,1854</b>	<b>0,1854</b>	0,3080	0,3080
		AD	2	2	5	5	-	-	5	5
		D PD FD	5 6 2	5 6 2	7 7 5	7 7 5	<b>8 1 0</b>	<b>8 1 0</b>	9 5 5	9 5 5
	0,015	E	0,3774	0,3774	0,4191	0,4191	0,3435	0,3435	0,3450	0,3450
		AD	2	2	4	4	4	4	4	4
		D PD FD	5 6 2	5 6 2	7 6 4	7 6 4	8 5 4	8 5 4	8 5 4	8 5 4
	0,020	E	0,4151	0,4151	0,4943	0,4943	0,3379	0,3379	0,3450	0,3450
		AD	2	2	4	4	2	2	4	4
		D PD FD	3 8 2	3 8 2	5 8 4	5 8 4	7 4 2	7 4 2	8 5 4	8 5 4
	0,025	E	0,4996	0,4996	0,4115	0,4115	0,4575	0,4575	0,2577	0,2577
		AD	0	0	0	0	6	6	1	1
		D PD FD	1 8 0	1 8 0	3 7 2	3 7 2	7 8 6	7 8 6	6 4 1	6 4 1
	0,030	E	0,4971	0,4971	0,4599	0,4599	0,4528	0,4528	0,2577	0,2577
		AD	0	0	2	2	2	2	1	1
		D PD FD	1 8 0	1 8 0	3 9 3	3 9 3	5 7 3	5 7 3	6 4 1	6 4 1
	0,035	E	0,4633	0,4633	0,4623	0,4623	0,4550	0,4550	0,2577	0,2577
		AD	1	1	3	3	2	2	1	1
		D PD FD	1 9 1	1 9 1	2 9 2	2 9 2	3 8 2	3 8 2	6 4 1	6 4 1
	0,040	E	0,4999	0,4999	0,4999	0,4999	0,4550	0,4550	0,2568	0,2568
		AD	-	-	-	-	2	2	1	1
		D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	3 8 2	3 8 2	6 4 1	6 4 1
	0,045	E	0,4999	0,4999	0,4999	0,4999	0,4550	0,4550	0,4089	0,4089
		AD	-	-	-	-	2	2	0	0
		D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	3 8 2	3 8 2	3 6 0	3 6 0
	0,050	E	0,4999	0,4999	0,4999	0,4999	0,4623	0,4623	0,4948	0,4948
		AD	-	-	-	-	2	2	0	0
		D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	2 9 2	2 9 2	2 7 0	2 7 0
0,055	E	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	0,4965	0,4965	
	AD	-	-	-	-	-	-	0	0	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	2 7 1	2 7 1	
0,060	E	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	0,4150	0,4150	
	AD	-	-	-	-	-	-	1	1	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	2 8 1	2 8 1	
0,065	E	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	0,4150	0,4150	
	AD	-	-	-	-	-	-	1	1	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	2 8 1	2 8 1	
0,070	E	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	0,4986	0,4986	
	AD	-	-	-	-	-	-	1	1	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	1 9 1	1 9 1	
0,075	E	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	0,4986	0,4986	
	AD	-	-	-	-	-	-	1	1	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	1 9 1	1 9 1	
0,080	E	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	0,4986	0,4986	
	AD	-	-	-	-	-	-	1	1	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	1 9 1	1 9 1	
0,085	E	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	0,4986	0,4986	
	AD	-	-	-	-	-	-	1	1	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	1 9 1	1 9 1	
0,090	E	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,095	E	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	0,4999	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	

Fonte: Própria

Apêndice B 5: Resultado do método proposto na base SPAM com classificador KNN.

SPAM		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,7313	0,7313	<b>0,1679</b>	<b>0,1679</b>	0,1681	0,1681	0,1681	0,1681
		D	0	0	<b>2</b>	<b>2</b>	3	3	3	3
	0,010	E	0,7313	0,7313	0,2470	0,2470	0,1681	0,1681	0,1681	0,1681
		D	0	0	5	5	3	3	3	3
	0,015	E	0,7313	0,7313	0,2510	0,2510	0,1681	0,1681	0,1681	0,1681
		D	0	0	4	4	3	3	3	3
	0,020	E	0,7313	0,7313	0,2693	0,2693	0,1681	0,1681	0,1681	0,1681
		D	0	0	3	3	3	3	3	3
	0,025	E	0,7313	0,7313	0,2490	0,2490	0,1681	0,1681	0,1681	0,1681
		D	0	0	4	4	3	3	3	3
	0,030	E	0,7313	0,7313	0,2490	0,2490	<b>0,1679</b>	<b>0,1679</b>	0,1681	0,1681
		D	0	0	4	4	<b>2</b>	<b>2</b>	3	3
	0,035	E	0,7313	0,7313	0,2462	0,2462	<b>0,1679</b>	<b>0,1679</b>	0,1681	0,1681
		D	0	0	4	4	<b>2</b>	<b>2</b>	3	3
	0,040	E	0,7313	0,7313	0,7313	0,7313	<b>0,1679</b>	<b>0,1679</b>	0,1385	0,1385
		D	0	0	0	0	<b>2</b>	<b>2</b>	7	7
	0,045	E	0,7313	0,7313	0,7313	0,7313	<b>0,1679</b>	<b>0,1679</b>	0,1446	0,1446
		D	0	0	0	0	<b>2</b>	<b>2</b>	7	7
	0,050	E	0,7313	0,7313	0,7313	0,7313	<b>0,1679</b>	<b>0,1679</b>	0,1365	0,1365
		D	0	0	0	0	<b>2</b>	<b>2</b>	7	7
	0,055	E	0,7313	0,7313	0,7313	0,7313	0,1716	0,1716	0,1366	0,1366
		D	0	0	0	0	5	5	6	6
	0,060	E	0,7313	0,7313	0,7313	0,7313	0,1716	0,1716	0,1793	0,1793
		D	0	0	0	0	5	5	2	2
	0,065	E	0,7313	0,7313	0,7313	0,7313	0,1716	0,1716	0,1793	0,1793
		D	0	0	0	0	5	5	2	2
	0,070	E	0,7313	0,7313	0,7313	0,7313	0,2462	0,2462	0,1793	0,1793
		D	0	0	0	0	4	4	2	2
	0,075	E	0,7313	0,7313	0,7313	0,7313	0,3678	0,3678	0,1793	0,1793
		D	0	0	0	0	3	3	2	2
0,080	E	0,7313	0,7313	0,7313	0,7313	0,7313	0,7313	0,1793	0,1793	
	D	0	0	0	0	0	0	2	2	
0,085	E	0,7313	0,7313	0,7313	0,7313	0,7313	0,7313	0,1793	0,1793	
	D	0	0	0	0	0	0	2	2	
0,090	E	0,7313	0,7313	0,7313	0,7313	0,7313	0,7313	0,1858	0,1858	
	D	0	0	0	0	0	0	4	4	
0,095	E	0,7313	0,7313	0,7313	0,7313	0,7313	0,7313	0,1858	0,1858	
	D	0	0	0	0	0	0	4	4	

Fonte: Própria

Apêndice B 6: Resultado do método proposto na base *Elec* com classificador KNN.

ELEC		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,1681	0,1681	<b>0,1714</b>	<b>0,1714</b>	0,1740	0,1740	0,1777	0,1777
		D	44	44	<b>44</b>	<b>44</b>	44	44	44	44
	0,010	E	0,1843	0,1843	<b>0,1714</b>	<b>0,1714</b>	0,1740	0,1740	0,1747	0,1747
		D	39	39	<b>44</b>	<b>44</b>	44	44	44	44
	0,015	E	0,2754	0,2754	0,2738	0,2738	0,1740	0,1740	0,1757	0,1757
		D	25	25	26	26	44	44	43	43
	0,020	E	0,1888	0,1888	0,2722	0,2722	0,1780	0,1780	0,1834	0,1834
		D	36	36	26	26	41	41	42	42
	0,025	E	0,1968	0,1968	0,2725	0,2725	0,2770	0,2770	0,1833	0,1833
		D	35	35	26	26	26	26	41	41
	0,030	E	0,2140	0,2140	0,2756	0,2756	0,2770	0,2770	0,1833	0,1833
		D	29	29	25	25	26	26	41	41
	0,035	E	0,2122	0,2122	0,2756	0,2756	0,2791	0,2791	0,1869	0,1869
		D	30	30	25	25	25	25	41	41
	0,040	E	0,3425	0,3425	0,2756	0,2756	0,2776	0,2776	0,1900	0,1900
		D	11	11	25	25	25	25	39	39
	0,045	E	0,2123	0,2123	0,1997	0,1997	0,2776	0,2776	0,2014	0,2014
		D	25	25	34	34	25	25	35	35
	0,050	E	0,2385	0,2385	0,2162	0,2162	0,2895	0,2895	0,2109	0,2109
		D	24	24	30	30	23	23	35	35
	0,055	E	0,2368	0,2368	0,2237	0,2237	0,2895	0,2895	0,2121	0,2121
		D	23	23	27	27	23	23	32	32
	0,060	E	0,2484	0,2484	0,2116	0,2116	0,2848	0,2848	0,2188	0,2188
		D	22	22	26	26	23	23	30	30
	0,065	E	0,2768	0,2768	0,2116	0,2116	0,2885	0,2885	0,2210	0,2210
		D	15	15	16	16	22	22	30	30
	0,070	E	0,4495	0,4495	0,2215	0,2215	0,2952	0,2952	0,2412	0,2412
		D	7	7	27	27	20	20	28	28
0,075	E	0,2635	0,2635	0,2130	0,2130	0,2952	0,2952	0,2412	0,2412	
	D	17	17	26	26	20	20	28	28	
0,080	E	0,3455	0,3455	0,2978	0,2978	0,3003	0,3003	0,2412	0,2412	
	D	7	7	16	16	19	19	28	28	
0,085	E	0,4952	0,4952	0,2978	0,2978	0,2985	0,2985	0,2381	0,2381	
	D	2	2	16	16	19	19	29	29	
0,090	E	0,4952	0,4952	0,3751	0,3751	0,2170	0,2170	0,2431	0,2431	
	D	2	2	9	9	31	31	26	26	
0,095	E	0,4952	0,4952	0,3703	0,3703	0,2175	0,2175	0,2344	0,2344	
	D	2	2	9	9	28	28	24	24	

Fonte: Própria

Apêndice B 7: Resultado do método proposto na base *Circle* com classificador SVM Linear.

<i>Circle</i>		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	<b>0,3228</b>	0,3242	0,3230	0,3439	0,3611	0,4812	0,4820	0,4827
		AD	<b>0</b>	0	0	1	0	0	0	-
		D PD FD	<b>3 0 0</b>	3 0 0	3 0 0	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0
	0,010	E	0,3243	0,3247	0,3255	0,3768	0,3597	0,4977	0,4980	0,4820
		AD	0	0	0	1	0	1	1	1
		D PD FD	3 0 0	3 0 0	3 0 0	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0
	0,015	E	0,3248	0,3792	0,3254	0,4980	0,4980	0,4975	0,4974	0,4823
		AD	0	1	1	1	1	1	1	0
		D PD FD	3 0 0	2 1 0	3 0 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0
	0,020	E	0,3244	0,3795	0,3239	0,3794	0,4982	0,3505	0,4979	0,3512
		AD	0	1	0	1	1	0	1	0
		D PD FD	3 0 0	2 1 0	3 0 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0
	0,025	E	0,3786	0,3568	0,3245	0,4973	0,4974	0,3512	0,4979	0,3498
		AD	1	0	0	1	1	0	1	0
		D PD FD	2 1 0	2 1 0	3 0 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0
	0,030	E	0,3787	0,3586	0,3781	0,3507	0,4974	0,3503	0,4980	0,3500
		AD	1	0	1	0	1	0	1	0
		D PD FD	2 1 0	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0
	0,035	E	0,3572	0,3572	0,3802	0,3790	0,3505	0,3507	0,3506	0,3500
		AD	0	0	1	1	0	0	0	0
		D PD FD	2 1 0	2 1 0	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0
	0,040	E	0,3581	0,3565	0,3781	0,3498	0,3500	0,3506	0,3495	0,3503
		AD	0	0	1	0	0	0	0	0
		D PD FD	2 1 0	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0
	0,045	E	0,3572	0,3585	0,3584	0,3496	0,3519	0,3509	0,3500	0,3492
		AD	0	0	1	0	0	0	0	0
		D PD FD	2 1 0	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0
	0,050	E	0,3565	0,3561	0,3580	0,3495	0,3504	0,3515	0,3505	0,3503
AD		0	0	1	0	0	0	0	0	
D PD FD		2 1 0	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	
0,055	E	0,3570	0,3572	0,3566	0,3508	0,3503	0,3501	0,3501	0,3497	
	AD	0	0	1	0	0	0	0	0	
	D PD FD	2 1 0	2 1 0	2 1 0	1 0 0	1 2 0	1 2 0	1 2 0	1 2 0	
0,060	E	0,3564	0,3557	0,3576	0,3509	0,3504	0,3499	0,3505	0,3501	
	AD	0	0	1	1	1	0	0	0	
	D PD FD	2 1 0	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	
0,065	E	0,3570	0,3564	0,3579	0,3510	0,3500	0,3505	0,3503	0,3508	
	AD	0	0	1	0	0	0	0	0	
	D PD FD	2 1 0	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	
0,070	E	0,3573	0,3562	0,3400	0,3516	0,3498	0,3504	0,3506	0,3505	
	AD	0	0	0	0	0	0	0	0	
	D PD FD	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	
0,075	E	0,3569	0,3570	0,3501	0,3509	0,3504	0,3515	0,3504	0,3499	
	AD	0	0	0	0	0	0	0	0	
	D PD FD	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	
0,080	E	0,3575	0,3567	0,3503	0,3509	0,3510	0,3504	0,3503	0,3500	
	AD	0	0	0	0	0	0	0	0	
	D PD FD	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	
0,085	E	0,3566	0,3574	0,3508	0,3500	0,3504	0,3496	0,3509	0,3501	
	AD	0	0	0	0	0	0	0	0	
	D PD FD	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	
0,090	E	0,3573	0,3564	0,3498	0,3497	0,3505	0,3505	0,3505	0,3498	
	AD	0	0	0	9	0	0	0	0	
	D PD FD	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 0	
0,095	E	0,3555	0,3577	0,3507	0,3508	0,3504	0,3503	0,3501	0,3501	
	AD	0	0	0	0	0	0	0	0	
	D PD FD	2 1 0	2 1 0	1 2 0	1 2 0	1 2 0	1 2 0	1 2 1	1 2 0	

Fonte: Própria

Apêndice B 8: Resultado do método proposto na base *Line* com classificador SVM Linear.

<i>Line</i>		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,2218	0,2217	0,2218	0,2218	0,2218	0,2217	<b>0,014</b>	<b>0,014</b>
		AD	-	-	-	-	-	-	<b>0</b>	<b>0</b>
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	<b>1 0 0</b>
	0,010	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0
	0,015	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0
	0,020	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0
	0,025	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0
	0,030	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0
	0,035	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0
	0,040	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0
	0,045	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0
	0,050	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218
AD		-	-	-	-	-	-	-	-	
D PD FD		0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,055	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,060	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,065	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,070	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,075	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,080	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,085	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,090	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	
0,095	E	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	0,2218	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	0 1 0	

Fonte: Própria

Apêndice B 9: Resultado do método proposto na base *Sine1* com classificador SVM Linear.

<i>Sine1</i>		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,3654	0,3619	0,4126	0,3229	0,2290	0,1355	0,1813	<b>0,044</b>
		AD	5	5	3	3	2	0	3	<b>0</b>
		D PD FD	8 0 1	8 1 0	6 3 0	7 2 0	8 1 0	8 1 0	9 0 0	<b>9 0 0</b>
	0,010	E	0,4177	0,3218	0,3246	0,3696	0,3210	0,2291	0,2273	0,1357
		AD	4	2	2	4	5	3	4	2
		D PD FD	5 3 0	6 3 0	5 4 0	7 2 0	8 1 0	8 1 0	9 0 0	9 0 0
	0,015	E	0,4099	0,4617	0,4140	0,3706	0,4193	0,4139	0,3189	0,2749
		AD	0	2	1	2	6	2	6	1
		D PD FD	1 8 0	3 6 0	3 6 0	6 3 0	7 2 0	5 3 0	9 0 0	6 3 0
	0,020	E	0,4099	0,5034	0,5001	0,3729	0,4131	0,3673	0,3205	0,2748
		AD	0	1	2	2	2	2	2	1
		D PD FD	1 8 0	1 8 0	2 7 0	4 5 0	4 5 0	4 5 0	6 3 0	6 3 0
	0,025	E	0,5015	0,5025	0,5025	0,4581	0,4570	0,3673	0,3673	0,3681
		AD	-	1	1	3	1	0	1	1
		D PD FD	0 0 0	1 8 0	1 8 0	3 6 0	3 6 0	4 5 0	4 5 0	5 4 0
	0,030	E	0,5015	0,5015	0,4099	0,5025	0,5020	0,4134	0,3673	0,3681
		AD	-	-	0	1	2	2	1	2
		D PD FD	0 9 0	0 9 0	1 8 0	1 8 0	2 7 0	3 6 0	4 5 0	5 4 0
	0,035	E	0,5019	0,5019	0,5010	0,5026	0,4586	0,5017	0,3674	0,3674
		AD	-	-	0	1	1	2	2	2
		D PD FD	0 9 0	0 9 0	0 9 0	1 8 0	2 7 0	2 7 0	3 5 0	4 6 0
	0,040	E	0,5016	0,5016	0,5016	0,5025	0,5025	0,5025	0,4134	0,4073
		AD	-	-	-	1	1	1	2	1
		D PD FD	0 9 0	0 9 0	0 9 0	1 8 0	1 8 0	1 8 0	3 6 0	3 7 0
	0,045	E	0,5016	0,5016	0,5016	0,5016	0,5027	0,5027	0,4106	0,4573
		AD	-	-	-	-	1	1	1	1
		D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	1 8 0	1 8 0	3 6 0	2 7 0
	0,050	E	0,5016	0,5016	0,5016	0,5016	0,5027	0,5027	0,4586	0,5026
AD		-	-	-	-	1	1	2	1	
D PD FD		0 9 0	0 9 0	0 9 0	0 9 0	1 8 0	1 8 0	2 7 0	1 8 0	
0,055	E	0,5016	0,5016	0,5016	0,5016	0,5016	0,5025	0,5016	0,5026	
	AD	-	-	-	-	-	1	-	1	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	1 8 0	0 9 0	1 8 0	
0,060	E	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,065	E	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,070	E	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,075	E	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,080	E	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,085	E	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,090	E	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,095	E	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	0,5016	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	

Fonte: Própria

Apêndice B 10: Resultado do método proposto na base Gauss com classificador SVM Linear.

Gauss		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,4099	<b>0,3275</b>	0,4185	0,4520	0,3905	0,3914	0,4867	0,4867
		AD	3	1	4	6	1	3	1	1
		D PD FD	8 1 0	<b>9 0 0</b>	8 1 0	8 1 0	6 3 0	8 1 0	2 7 0	1 8 0
	0,010	E	0,4096	0,3447	0,4184	0,4586	0,4286	0,4567	0,4736	0,4864
		AD	3	0	2	6	5	3	1	1
		D PD FD	8 1 0	8 1 0	7 2 0	8 1 0	8 1 0	5 4 0	1 8 0	1 8 0
	0,015	E	0,4264	0,4414	0,4531	0,4341	0,4493	0,4897	0,4873	0,4664
		AD	3	3	4	3	3	3	1	1
		D PD FD	7 2 0	7 2 0	7 2 0	7 2 0	6 3 0	3 6 0	1 8 0	1 8 0
	0,020	E	0,4900	0,4497	0,4524	0,4504	0,4866	0,4125	0,4873	0,4855
		AD	3	4	5	4	1	0	1	-
		D PD FD	6 3 0	6 3 0	7 2 0	6 3 0	2 8 0	4 5 0	1 0 0	0 0 0
	0,025	E	0,4671	0,4478	0,4302	0,4504	0,4498	0,4720	0,4866	0,4866
		AD	2	3	0	0	3	1	-	-
		D PD FD	3 6 0	6 3 0	6 6 0	3 6 0	5 4 0	2 7 0	0 0 0	0 0 0
	0,030	E	0,4279	0,4303	0,4842	0,4488	0,4717	0,4872	0,4868	0,4868
		AD	1	2	2	0	1	1	-	-
		D PD FD	4 5 0	5 4 0	2 7 0	2 7 0	2 7 0	1 8 0	0 0 0	0 0 0
	0,035	E	0,4282	0,4092	0,4851	0,4705	0,4863	0,4870	0,4865	0,4865
		AD	1	1	2	1	0	1	-	-
		D PD FD	4 5 0	4 5 0	2 7 0	3 6 0	1 8 0	1 8 0	0 9 0	0 9 0
	0,040	E	0,4656	0,4832	0,4561	0,4561	0,4561	0,4561	0,4868	0,4868
		AD	1	1	0	0	0	0	-	-
		D PD FD	2 7 0	4 5 0	1 8 0	1 8 0	1 8 0	1 8 0	0 0 0	0 0 0
	0,045	E	0,4655	0,4873	0,4626	0,4873	0,4479	0,4864	0,4864	0,4864
		AD	1	1	0	0	0	0	0	0
		D PD FD	2 7 0	2 7 0	1 8 0	1 8 0	1 8 0	0 9 0	0 9 0	0 9 0
	0,050	E	0,4656	0,4848	0,4869	0,4870	0,4869	0,4869	0,4869	0,4869
AD		1	2	-	0	-	-	-	-	
D PD FD		2 7 0	2 7 0	0 9 0	1 8 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,055	E	0,4658	0,4850	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	
	AD	0	2	-	-	-	-	-	-	
	D PD FD	1 8 0	2 7 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,060	E	0,4739	0,4739	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	
	AD	1	1	-	-	-	-	-	-	
	D PD FD	1 8 0	1 8 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,065	E	0,4739	0,4739	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	
	AD	1	1	-	-	-	-	-	-	
	D PD FD	1 8 0	1 8 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,070	E	0,4739	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	
	AD	1	-	-	-	-	-	-	-	
	D PD FD	1 8 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,075	E	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,080	E	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,085	E	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,090	E	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	
0,095	E	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	0,4869	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	0 9 0	

Fonte: Própria

Apêndice B 11: Resultado do método proposto na base SPAM com classificador SVM Linear.

SPAM		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,0741	<b>0,0700</b>	0,1441	0,1441	0,1441	0,1441	0,1441	0,1441
		D	6	<b>8</b>	3	3	3	3	3	3
	0,010	E	0,0744	0,0721	0,1441	0,1441	0,1441	0,1441	0,1441	0,1441
		D	6	7	3	3	3	3	3	3
	0,015	E	0,091	0,1440	0,1441	0,1441	0,1441	0,1441	0,1441	0,1441
		D	5	3	3	3	3	3	3	3
	0,020	E	0,091	0,1441	0,1441	0,1441	0,1441	0,1441	0,1441	0,1441
		D	5	3	3	3	3	3	3	3
	0,025	E	0,2234	0,2234	0,0834	0,2131	0,0914	0,091	0,1441	0,1441
		D	3	3	5	1	7	8	3	3
	0,030	E	0,2239	0,6833	0,2124	0,095	0,091	0,099	0,0935	0,0946
		D	2	0	1	6	7	6	6	8
	0,035	E	0,6743	0,2230	<b>0,070</b>	0,2125	0,0938	0,0985	0,0979	0,0970
		D	0	3	<b>5</b>	1	7	6	5	6
	0,040	E	0,4628	0,2929	0,2901	0,1220	0,2129	0,0979	0,1007	0,096
		D	1	2	2	3	1	5	5	6
	0,045	E	0,6876	0,2216	0,2920	0,2125	0,1001	0,2133	0,0982	0,0928
		D	0	2	1	1	4	1	5	7
	0,050	E	0,6876	0,6876	0,6876	0,2123	0,2123	0,0972	0,1105	0,1050
		D	0	0	0	1	1	5	5	5
	0,055	E	0,6876	0,6876	0,2254	0,2254	0,2123	0,2123	0,0932	0,096
		D	0	0	2	2	1	1	7	6
	0,060	E	0,6876	0,6876	0,6876	0,2122	0,2122	0,1012	0,1019	0,099
		D	0	0	0	1	1	4	5	5
	0,065	E	0,6876	0,6876	0,6876	0,6876	0,2230	0,2125	0,0993	0,1064
		D	0	0	0	0	3	1	5	5
	0,070	E	0,6876	0,6876	0,6876	0,2114	0,2122	0,0981	0,1073	0,1022
		D	0	0	0	1	1	3	5	5
	0,075	E	0,6876	0,6876	0,6876	0,2208	0,6876	0,2498	0,073	0,1044
		D	0	0	0	2	0	2	4	5
0,080	E	0,6876	0,6876	0,6876	0,6876	0,2110	0,2843	0,2131	0,1077	
	D	0	0	0	0	1	3	1	5	
0,085	E	0,6876	0,6876	0,6876	0,6876	0,2110	0,0748	0,2131	0,1075	
	D	0	0	0	0	1	4	1	5	
0,090	E	0,6876	0,6876	0,6876	0,6876	0,6876	0,2116	0,079	0,1047	
	D	0	0	0	0	0	1	2	3	
0,095	E	0,6876	0,6876	0,6876	0,6876	0,6876	0,2121	0,0797	0,1922	
	D	0	0	0	0	0	1	3	2	

Fonte: Própria

Apêndice B 12: Resultado do método proposto na base *Elec* com classificador SVM Linear.

ELEC		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,2113	0,2096	0,2105	0,2088	0,2109	0,2131	0,2139	0,2192
		D	42	45	45	44	44	44	43	43
	0,010	E	0,2206	0,2145	<b>0,2055</b>	0,2070	0,2145	0,2156	0,211	0,2209
		D	41	43	<b>43</b>	44	42	42	42	42
	0,015	E	0,2212	0,2119	0,2095	0,2232	0,2152	0,2122	0,2154	0,2231
		D	36	39	43	43	41	42	40	42
	0,020	E	0,2180	0,2136	0,2104	0,2119	0,2185	0,2235	0,2192	0,2205
		D	34	39	38	41	41	40	39	42
	0,025	E	0,2296	0,2187	0,2214	0,2205	0,2199	0,2184	0,2273	0,2170
		D	32	36	39	38	40	40	36	41
	0,030	E	0,2287	0,2228	0,2164	0,2137	0,2181	0,2194	0,2194	0,2181
		D	27	32	36	37	40	37	37	41
	0,035	E	0,235	0,2243	0,2155	0,2156	0,2201	0,2128	0,2328	0,2163
		D	28	32	37	37	40	39	35	41
	0,040	E	0,2427	0,2318	0,2279	0,2159	0,2204	0,2158	0,2264	0,2201
		D	25	29	33	35	39	39	35	38
	0,045	E	0,2391	0,2292	0,2248	0,2218	0,2189	0,2150	0,2243	0,2236
		D	24	31	32	33	38	37	35	36
	0,050	E	0,2425	0,2350	0,2244	0,2243	0,2172	0,2176	0,2238	0,2206
		D	21	27	31	34	35	37	35	36
	0,055	E	0,2568	0,2403	0,2300	0,2196	0,2244	0,2242	0,2210	0,2261
		D	21	23	28	31	34	34	36	34
	0,060	E	0,2489	0,2411	0,2243	0,2244	0,2169	0,2248	0,2273	0,2197
		D	15	23	29	32	35	33	31	33
	0,065	E	0,2559	0,2428	0,2376	0,2238	0,2141	0,2208	0,2294	0,2788
		D	16	23	27	29	32	32	31	16
	0,070	E	0,2631	0,2492	0,2382	0,2320	0,2202	0,2189	0,2347	0,2786
		D	11	20	25	26	31	33	31	18
0,075	E	0,2633	0,2509	0,2456	0,2232	0,2225	0,2246	0,2313	0,2956	
	D	11	18	24	27	31	32	28	14	
0,080	E	0,3079	0,2504	0,2376	0,2299	0,2185	0,2289	0,2289	0,2707	
	D	14	16	26	24	32	31	28	18	
0,085	E	0,3813	0,2627	0,2451	0,2297	0,2208	0,2187	0,2372	0,2965	
	D	7	15	19	26	30	32	27	12	
0,090	E	0,2662	0,2581	0,2398	0,2305	0,2337	0,2281	0,2395	0,2762	
	D	14	14	26	24	25	28	26	15	
0,095	E	0,2595	0,3050	0,2420	0,2318	0,2336	0,2238	0,2454	0,2776	
	D	3	14	20	24	25	28	26	16	

Fonte: Própria

Apêndice B 13: Resultado do método proposto na base *Circle* com o classificador Árvore de Decisão.

<i>Circle</i>		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,010	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,015	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,020	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,025	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,030	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,035	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,040	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,045	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,050	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
AD		-	-	-	-	-	-	-	-	
D PD FD		0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,055	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,060	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,065	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,070	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,075	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,080	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,085	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,090	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,095	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	

Fonte: Própria

Apêndice B 14: Resultado do método proposto na base *Line* com o classificador Árvore de Decisão.

<i>Line</i>		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,010	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,015	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,020	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,025	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,030	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,035	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,040	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,045	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,050	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084
AD		-	-	-	-	-	-	-	-	
D PD FD		0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,055	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,060	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,065	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,070	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,075	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,080	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,085	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,090	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,095	E	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	0,2084	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	

Fonte: Própria

Apêndice B 15: Resultado do método proposto na base *Sine1* com o classificador Árvore de Decisão.

<i>Sine1</i>		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,4244	<b>0,2046</b>
		AD	-	-	-	-	-	-	0	<b>1</b>
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	2 7 0	<b>8 1 0</b>
	0,010	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,4515	0,4860
		AD	-	-	-	-	-	-	3	5
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	4 5 0	6 4 0
	0,015	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5025	0,4515
		AD	-	-	-	-	-	-	0	4
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	1 8 0	5 4 0
	0,020	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5025	0,4515
		AD	-	-	-	-	-	-	0	4
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	1 8 0	5 4 0
	0,025	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5025	0,4515
		AD	-	-	-	-	-	-	0	4
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	1 8 0	5 4 0
	0,030	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5025	0,4554
		AD	-	-	-	-	-	-	0	3
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	1 8 0	4 5 0
	0,035	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5025	0,5025
		AD	-	-	-	-	-	-	0	0
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	1 8 0	1 8 0
	0,040	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5025	0,5025
		AD	-	-	-	-	-	-	0	0
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	1 8 0	1 8 0
	0,045	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5010	0,4962
		AD	-	-	-	-	-	-	1	2
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	1 8 0	2 7 0
	0,050	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5010	0,5010
		AD	-	-	-	-	-	-	1	1
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	1 8 0	1 8 0
0,055	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5010	0,5010	
	AD	-	-	-	-	-	-	1	1	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	1 8 0	1 8 0	
0,060	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5000	
	AD	-	-	-	-	-	-	-	1	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	1 8 0	
0,065	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,070	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,075	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,080	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,085	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,090	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,095	E	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	0,5040	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	

Fonte: Própria

Apêndice B 16: Resultado do método proposto na base Gauss com o classificador Árvore de Decisão.

Gauss		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,010	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,015	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,020	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,025	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,030	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,035	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,040	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,045	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
	0,050	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682
		AD	-	-	-	-	-	-	-	-
		D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0
0,055	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,060	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,065	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,070	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,075	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,080	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,085	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,090	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	
0,095	E	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	0,3682	
	AD	-	-	-	-	-	-	-	-	
	D PD FD	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	0 0 0	

Fonte: Própria

Apêndice B 17: Resultado do método proposto na base SPAM com o classificador Árvore de Decisão.

SPAM		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,6063	0,6686	0,6686	0,6686	0,3689	0,3689	0,3624	<b>0,1556</b>
		D	0	1	1	1	2	2	4	<b>3</b>
	0,010	E	0,6063	0,6686	0,6686	0,6686	0,6218	0,6218	0,6218	0,6218
		D	0	1	1	1	2	2	2	2
	0,015	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	<b>0,1556</b>
		D	0	1	1	1	1	1	1	<b>3</b>
	0,020	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	<b>0,1556</b>
		D	0	1	1	1	1	1	1	<b>3</b>
	0,025	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	<b>0,1556</b>
		D	0	1	1	1	1	1	1	<b>3</b>
	0,030	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	<b>0,1556</b>
		D	0	1	1	1	1	1	1	<b>3</b>
	0,035	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	<b>0,1556</b>
		D	0	1	1	1	1	1	1	<b>3</b>
	0,040	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	<b>0,1556</b>
		D	0	1	1	1	1	1	1	<b>3</b>
	0,045	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	<b>0,1556</b>
		D	0	1	1	1	1	1	1	<b>3</b>
	0,050	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	0,3923
		D	0	1	1	1	1	1	1	2
	0,055	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	0,3923
		D	0	1	1	1	1	1	1	2
	0,060	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	0,3923
		D	0	1	1	1	1	1	1	2
	0,065	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	0,2027
		D	0	1	1	1	1	1	1	2
	0,070	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	0,2027
		D	0	1	1	1	1	1	1	2
	0,075	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	0,2027
		D	0	1	1	1	1	1	1	2
0,080	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	0,2027	
	D	0	1	1	1	1	1	1	2	
0,085	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	0,2027	
	D	0	1	1	1	1	1	1	2	
0,090	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	0,2027	
	D	0	1	1	1	1	1	1	2	
0,095	E	0,6063	0,6686	0,6686	0,6686	0,6686	0,6686	0,6686	0,2027	
	D	0	1	1	1	1	1	1	2	

Fonte: Própria

Apêndice B 18: Resultado do método proposto na base *Elec* com o classificador Árvore de Decisão.

ELEC		Limite de Incerteza								
		0,60	0,65	0,70	0,75	0,80	0,85	0,90	0,95	
Limite de Mudança	0,005	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,010	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,015	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,020	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,025	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,030	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,035	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,040	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,045	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,050	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,055	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,060	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,065	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,070	E	0,4128	0,4128	0,4128	0,4128	0,2838	0,2838	0,2838	0,2838
		D	0	0	0	0	2	2	2	2
	0,075	E	0,4128	0,4128	0,4128	0,4128	0,3015	0,2750	0,2750	0,2982
		D	0	0	0	0	3	5	8	3
0,080	E	0,4128	0,4128	0,4128	0,4128	0,3015	0,2750	<b>0,2421</b>	0,2982	
	D	0	0	0	0	3	5	<b>11</b>	3	
0,085	E	0,4128	0,4128	0,4128	0,4128	0,3015	0,2750	<b>0,2421</b>	0,2982	
	D	0	0	0	0	3	5	<b>11</b>	3	
0,090	E	0,4128	0,4128	0,4128	0,4128	0,3015	0,2750	<b>0,2421</b>	0,2982	
	D	0	0	0	0	3	5	<b>11</b>	3	
0,095	E	0,4128	0,4128	0,4128	0,4128	0,3015	0,2750	<b>0,2421</b>	0,2982	
	D	0	0	0	0	3	5	<b>11</b>	3	

Fonte: Própria