



DETECCÃO DE ANOMALIAS EM IMAGENS DE DUTOS SUBMARINOS COM MÉTODOS NÃO-SUPERVISIONADOS

Fernando Venceslau Isensee

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Orientadores: Mariane Rembold Petraglia
José Gabriel Rodriguez
Carneiro Gomes

Rio de Janeiro
Março de 2019

DETECÇÃO DE ANOMALIAS EM IMAGENS DE DUTOS SUBMARINOS
COM MÉTODOS NÃO-SUPERVISIONADOS

Fernando Venceslau Isensee

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

Profa. Mariane Rembold Petraglia, Ph.D.

Prof. José Gabriel Rodriguez Carneiro Gomes, Ph.D.

Prof. Felipe Maia Galvão França, Ph.D.

Prof. Diego Barreto Haddad, D.Sc.

RIO DE JANEIRO, RJ – BRASIL
MARÇO DE 2019

Isensee, Fernando Venceslau

Detecção de Anomalias em Imagens de Dutos Submarinos com Métodos Não-Supervisionados/Fernando Venceslau Isensee. – Rio de Janeiro: UFRJ/COPPE, 2019.

XVI, 78 p.: il.; 29, 7cm.

Orientadores: Mariane Rembold Petraglia

José Gabriel Rodriguez Carneiro Gomes

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2019.

Referências Bibliográficas: p. 62 – 65.

1. Dutos Submarinos Rígidos. 2. Visão Computacional. 3. Processamento de Imagem. 4. Análise de Textura de Imagem. 5. Aprendizado de Máquina. 6. Detecção de Anomalia. I. Petraglia, Mariane Rembold *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

Agradecimentos

Aos meus pais, Paulo Roberto e Jaine pela paciência que tiveram e pelo suporte que me deram na minha decisão de deixar a Marinha do Brasil para me dedicar exclusivamente à conclusão do Mestrado.

À minha namorada, Nicole, que me ajudou a encarar minhas dificuldades com serenidade em momentos de estresse.

Ao meu amigo Paulo, que me ajuda a manter vivo o espírito de engenharia dentro de mim através de discussões sobre projetos e formas de executá-los.

A todos os meus colegas do antigo trabalho na Marinha do Brasil, que, direta, ou indiretamente, me ajudaram e me motivaram e a continuar meus estudos na UFRJ.

Por último, gostaria de agradecer a meus orientadores, Mariane e José Gabriel, que sempre estiveram disponíveis e dispostos a me ajudar no desenvolvimento deste trabalho.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

DETECÇÃO DE ANOMALIAS EM IMAGENS DE DUTOS SUBMARINOS COM MÉTODOS NÃO-SUPERVISIONADOS

Fernando Venceslau Isensee

Março/2019

Orientadores: Mariane Rembold Petraglia

José Gabriel Rodriguez Carneiro Gomes

Programa: Engenharia Elétrica

O enfoque deste trabalho é a utilização de visão computacional e aprendizado de máquina na detecção automatizada de defeitos em dutos submarinos rígidos através das imagens de vídeo de inspeções feitas com uso de veículos submarinos operados remotamente. Para isso, foram utilizadas técnicas de processamento de imagem para extrair atributos de textura de regiões das imagens. Essas regiões foram classificadas como normais ou intrusas através de algoritmos de detecção de anomalias em ambientes de aprendizado de máquina.

Através de anotações manuais das anomalias presentes nos dados de treinamento, foi possível a criação de gráficos que possuem métricas de comparação de desempenho que puderam ser usadas em diferentes estratégias de detecção de anomalias. A métrica de desempenho utilizada foi a área abaixo da curva da característica de operação do receptor, e o melhor algoritmo obteve pontuação de 0,953 para um valor máximo igual a 1.

Esse algoritmo apresentou taxa de verdadeiro positivo de 85,81% para uma taxa de falso positivo de 5%, que obtida através da seleção manual de um limiar de classificação. Adicionalmente, com a escolha automática do limiar de classificação, obteve resultado de 89,54% para uma taxa de falso positivo de apenas 7,90%. Esses resultados, aliados às imagens do vídeo de teste apresentadas no Capítulo 4, demonstram que é possível a utilização desse algoritmo sem a intervenção inicial do usuário na escolha de um limiar de classificação de anomalias.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

ANOMALY DETECTION IN UNDERWATER PIPELINES WITH UNSUPERVISED METHODS

Fernando Venceslau Isensee

March/2019

Advisors: Mariane Rembold Petraglia

José Gabriel Rodriguez Carneiro Gomes

Department: Electrical Engineering

The focus of this work is the use of computational vision and machine learning in the automated fault detection in rigid underwater pipelines through video images from inspections done using remotely operated submarine vehicles. For this purpose, image processing techniques were used to extract texture features from regions of images. Those regions were classified as normal or outlier through anomaly detection algorithms in machine learning environments.

Through manual annotations of the anomalies present in the training data, it was possible to create graphics that have performance comparison metrics that could be used in various anomaly detection strategies. The performance metric used was the area under the curve of the receiver operating characteristic, and the best algorithm scored 0.953 out of a maximum of 1.

This algorithm showed a true positive rate of 85.81% for a false positive rate of 5%, which was obtained by manual selection of a classification threshold. In addition, with the automatic choice of classification threshold, it obtained a result of 89.54% for a false positive rate of only 7.90%. These results, coupled with the test video images presented in Chapter 4, demonstrate it is possible to use this algorithm without the initial user intervention on the choice of an anomaly classification threshold.

Sumário

Lista de Figuras	ix
Lista de Tabelas	xiv
Lista de Abreviaturas	xv
1 Introdução	1
1.1 Motivação	1
1.2 Objetivos	3
1.3 Metodologia	3
1.4 Estrutura da Dissertação	6
2 Representação de Texturas	7
2.1 Atributos Estatísticos de Primeira Ordem	7
2.2 Matriz de Coocorrência de Níveis de Cinza	9
2.3 Padrões Binários Locais	12
2.4 Filtros de Gabor	16
2.5 Análise de Componentes Principais	17
3 Detecção de Anomalias	20
3.1 Configurações de Detectores de Anomalia	20
3.2 Tipos de Anomalia	22
3.3 Algoritmos Não-Supervisionados	23
3.3.1 <i>k-Nearest Neighbors</i>	23
3.3.2 <i>Local Outlier Factor</i>	24
3.3.3 <i>Histogram-Based Outlier Score</i>	25
3.3.4 <i>One-Class Support Vector Machine</i>	26
3.4 Característica de Operação do Receptor	26
3.4.1 Construção da ROC	27
3.4.2 Performance da ROC	28
3.4.3 Escolha de Limiar	29

4	Aplicação Experimental e Resultados	31
4.1	Aplicação Experimental	31
4.1.1	Preparação dos Dados	31
4.1.2	Extração de Atributos	33
4.1.3	Detecção de Anomalia	34
4.2	Resultados	36
5	Conclusões	60
	Referências Bibliográficas	62
A	Imagens de Treinamento e Teste da Aplicação Experimental	66
B	Imagens Resultantes da Aplicação Experimental	70

Lista de Figuras

1.1	Diagrama exemplificando um esquema de inspeção de dutos submarinos por meio de ROV.	2
1.2	Exemplo de seções de dutos submarinos com superfície em boas condições.	3
1.3	Exemplo de possíveis anomalias em seções dos dutos submarinos: (a) armadura externa danificada; (b) cruzamento entre dutos; (c) anodo de sacrifício; e (d) presença de peixe sobre o duto.	3
1.4	Contraste entre padrões de texturas de fragmentos de imagem.	4
1.5	Diferentes tipos de textura de dutos submarinos: (a) e (b) ao longo do próprio vídeo; e (a), (c) e (d) entre vídeos diferentes.	5
1.6	Preparação das imagens sequenciais de trechos de vídeos de inspeção: anotação manual das bordas dos dutos; remoção da distorção perspectiva; e anotação manual das anomalias (apenas nos dados de treinamento).	5
1.7	Resumo da metodologia: fragmentação das imagens, extração de atributos de textura e detecção de anomalias.	6
2.1	Comparação entre histogramas: (a) exemplo de assimetria; e (b) exemplo de curtose.	9
2.2	Comparação entre histogramas: (a) imagem estruturada; (b) histograma da imagem (a); (c) imagem embaralhada de (a); e (d) histograma da imagem (c).	9
2.3	Exemplo de deslocamentos usados no cálculo da GLCM.	10
2.4	Exemplo de cálculo de GLCM com deslocamento de um pixel na orientação de 0° para imagem com quatro níveis de cinza.	11
2.5	Exemplo de construção de padrão LBP: (a) região inicial usada no cálculo do padrão do pixel central; (b) resultado da limiarização dos píxeis da região; (c) máscara usada na etapa de modulação; e (d) padrão LBP indicado na posição do pixel central.	13
2.6	Vizinhança circular simétrica para diferentes (P, R)	14

2.7	Padrões binários únicos invariantes à rotação, com $P = 8$: (a) padrões uniformes; e (b) exemplo de alguns padrões não uniformes. Os círculos preenchidos e vazios são, respectivamente, equivalentes ao valor lógico 0 e 1.	15
2.8	Exemplo de um filtro de gabor: (a) parte real do filtro; (b) parte imaginária do filtro; e (c) resposta do filtro no domínio da frequência.	16
2.9	Exemplo de banco de filtros no domínio da frequência: (a) resultado da resposta completa para oito orientações e quatro escalas; e (b) exibição dos pontos tangentes entre os filtros.	17
2.10	Problema de separação de dados para a classificação com redução de dimensionalidade por PCA: (a) dados originais em espaço bidimensional, cujos eixos em vermelho e em azul representam, respectivamente, a componente principal e a componente de menor autovalor do PCA; (b) histograma da projeção na direção da componente principal; e (c) histograma da projeção na direção da componente de menor autovalor.	19
3.1	Diferentes configurações para detectores de anomalia de acordo com a presença de anotações.	21
3.2	Exemplos de anomalias globais, locais e micro agrupamentos.	22
3.3	Construção da pontuação de anomalia por HBOS com <i>bin</i> fixo, $K = 2$ e dimensão dos atributos $d = 2$	25
3.4	Característica de operação do receptor: (a) construção da curva característica de operação do receptor; e (b) exemplo de resultados de ROC para três algoritmos diferentes, com performance $I > II > III$	28
3.5	Performance de algoritmos de detecção de anomalias com uso da característica de operação do receptor: (a) comparação por TVP com TFP fixa; (b) comparação por AUC da ROC; e (c) comparação por p-AUC da ROC.	29
3.6	Critérios de escolha de limiar do detector baseados na curva ROC.	30
4.1	Fases da preparação dos dados: (a) recorte da área útil da imagem; e (b) segmentação da imagem em fragmentos com tamanhos e sobreposições diferentes.	32
4.2	Preparação das anotações: (a) suavização com operação morfológica; e (b) classificação das anotações de fragmentos de imagem sem sobreposição de tamanho $L = 100$	33
4.3	Melhores resultados de detectores de anomalias para diferentes tipos de atributos e parâmetros de detecção do algoritmo OCSVM-M, com $M = 1$	38

4.4	Melhores dois resultados de AUC e P-AUC para determinadas configurações de detectores OCSVM-M, com atributos PCA e STAT. . . .	39
4.5	Primeira amostra positiva de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.	42
4.6	Segunda amostra positiva de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.	42
4.7	Terceira amostra positiva de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.	43
4.8	Quarta amostra positiva de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.	43
4.9	Quinta amostra positiva de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.	44
4.10	Primeira amostra negativa de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.	44
4.11	Segunda amostra negativa de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.	45
4.12	Terceira amostra negativa de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.	45
4.13	Quarta amostra negativa de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.	46
4.14	Quinta amostra negativa de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.	46
4.15	Sexta amostra negativa de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.	47
4.16	Primeira amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	48
4.17	Segunda amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	49
4.18	Terceira amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	49
4.19	Quarta amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	50
4.20	Quinta amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	50
4.21	Sexta amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	51
4.22	Sétima amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	51

4.23	Oitava amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	52
4.24	Primeira amostra negativa de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	52
4.25	Segunda amostra negativa de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	53
4.26	Terceira amostra negativa de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	53
4.27	Quarta amostra negativa de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	54
4.28	Quinta amostra negativa de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	54
4.29	Sexta amostra negativa de detecção de anomalias aplicada aos dados de teste para TFP de 5%.	55
4.30	Primeira amostra de detecção de anomalias aplicada aos dados de treinamento para TFP automática.	56
4.31	Segunda amostra de detecção de anomalias aplicada aos dados de treinamento para TFP automática.	57
4.32	Primeira amostra de detecção de anomalias aplicada aos dados de teste para TFP automática.	57
4.33	Segunda amostra de detecção de anomalias aplicada aos dados de teste para TFP automática.	58
4.34	Terceira amostra de detecção de anomalias aplicada aos dados de teste para TFP automática.	58
4.35	Quarta amostra de detecção de anomalias aplicada aos dados de teste para TFP automática.	59
A.1	Amostra das sequências de imagens usadas na fase de treinamento.	67
A.2	Amostra das sequências de anotações de anomalias da sequência de treinamento.	68
A.3	Amostra das sequências de imagens usadas na fase de teste.	69
B.1	Amostra das sequências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 1 às imagens de treinamento.	71
B.2	Amostra das sequências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 2 às imagens de treinamento.	72
B.3	Amostra das sequências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 3 às imagens de treinamento.	73
B.4	Amostra das sequências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 4 às imagens de treinamento.	74

B.5	Amostra das sequências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 1 às imagens de teste.	75
B.6	Amostra das sequências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 2 às imagens de teste.	76
B.7	Amostra das sequências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 3 às imagens de teste.	77
B.8	Amostra das sequências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 4 às imagens de teste.	78

Lista de Tabelas

2.1	Atributos de primeira ordem descritores de textura	8
2.2	Cinco atributos de textura obtidos de GLCM mais utilizados.	12
4.1	Configurações dos parâmetros dos atributos das Tabela 4.2 e 4.3	37
4.2	Melhores resultados médios de AUC da ROC para diferentes configurações de detectores de anomalia.	37
4.3	Melhores resultados médios de p-AUC da ROC, com $p = 0,1$ da TFP, para diferentes configurações de detectores de anomalia.	37
4.4	Algoritmos com melhores resultados médios de AUC e p-AUC.	39
4.5	Taxas de falsos positivos e verdadeiros positivos para os pontos de operação dos melhores algoritmos.	40
B.1	Algoritmos com melhores resultados médios de AUC e p-AUC.	70

Lista de Abreviaturas

ANP	<i>Agência Nacional do Petróleo, Gás Natural e Biocombustíveis</i> , p. 1
AUC	<i>Area Under Curve</i> . Área Sob a Curva, p. 28
AUV	<i>Autonomous Underwater Vehicle</i> . Veículo Submarinos Autônomo, p. 2
GLCM	<i>Gray Level Cooccurrence Matrix</i> . Matriz de Coocorrência de Níveis de Cinza, p. 10
HBOS	<i>Histogram-Based Outlier Score</i> , p. 25
K-NN	<i>k-Nearest Neighbors</i> , p. 23
LBP	<i>Local Binary Patterns</i> . Padrões Binários Locais, p. 12
LOF	<i>Local Outlier Factor</i> , p. 24
LRD	<i>Local Reachability Distance</i> , p. 24
MB-LBP	<i>Multi-scale Block Local Binary Patterns</i> , p. 15
OCSVM	<i>One-Class Support Vector Machine</i> , p. 26
OLED	<i>Organic Light-Emitting Diode</i> . Diodo Emissor de Luz Orgânico, p. 15
PCA	<i>Principal Component Analysis</i> . Análise de Componentes Principais, p. 17
ROC	<i>Receiver Operating Characteristic</i> . Característica de Operação do Receptor, p. 27
ROV	<i>Remotely Operated Vehicle</i> . Veículo Operado Remotamente, p. 2

SGSS	Sistema de Gerenciamento da Segurança Operacional de Sistemas Submarinos, p. 1
TFP	Taxa de Falso Positivo, p. 27
TVP	Taxa de Verdadeiro Positivo, p. 27
VLBP	<i>Volume Local Binary Patterns</i> , p. 15
p-AUC	<i>Partial Area Under Curve</i> . Área Parcial Sob a Curva, p. 29

Capítulo 1

Introdução

1.1 Motivação

Sistemas Submarinos precisam ser submetidos a regulamentações técnicas no que diz respeito ao gerenciamento de segurança operacional, principalmente, devido a duas razões: a primeira decorre da prevenção de eventuais acidentes que possam causar danos às pessoas envolvidas ou não com a sua operação, ao patrimônio das instalações ou do público em geral e ao meio ambiente. A segunda tem como origem a manutenção do suprimento nacional de petróleo, derivados e gás natural.

A Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) é o órgão responsável pela fiscalização das atividades de exploração e produção de petróleo e gás natural, de acordo com o previsto na Lei nº 9.478/1997. O objetivo dessa fiscalização é prevenir falhas na segurança operacional das instalações e evitar eventuais prejuízos à vida, ao meio ambiente e ao patrimônio. Com base nesse objetivo, a ANP elaborou vários regulamentos técnicos para normatizar os procedimentos a serem adotados relativos à segurança operacional, como, por exemplo, o Regulamento Técnico do Sistema de Gerenciamento da Segurança Operacional de Sistemas Submarinos (SGSS).

Esse documento estabelece que a empresa detentora de direitos de exploração e produção de petróleo e gás natural ou autorizada pela ANP a construir e/ou operar um Sistema Submarino deve fazê-lo de forma segura e responsável, conscientizando seu corpo gerencial e funcional para o objetivo de uma operação isenta de incidentes. Desta forma, a empresa responsável pelo Sistema Submarino deve garantir que seu sistema seja propriamente projetado (seleção de rotas, projeto do controle de corrosão externa, etc.) e fiscalizado (avaliação da integridade através de inspeções visuais periódicas, etc.).

Tradicionalmente, inspeções e manutenções de Sistemas Submarinos são realizadas por meio de Veículos Submarinos Operados Remotamente (*Remotely Operated*

Vehicles – ROVs), que são veículos submarinos guiados por operadores humanos através de cabos ligados a uma embarcação de suporte na superfície marítima (Figura 1.1). Esses veículos são equipados com sensores que auxiliam sua navegação e inspeção do fundo do mar, como, por exemplo, sonares, sensores de pressão e câmeras de vídeo.

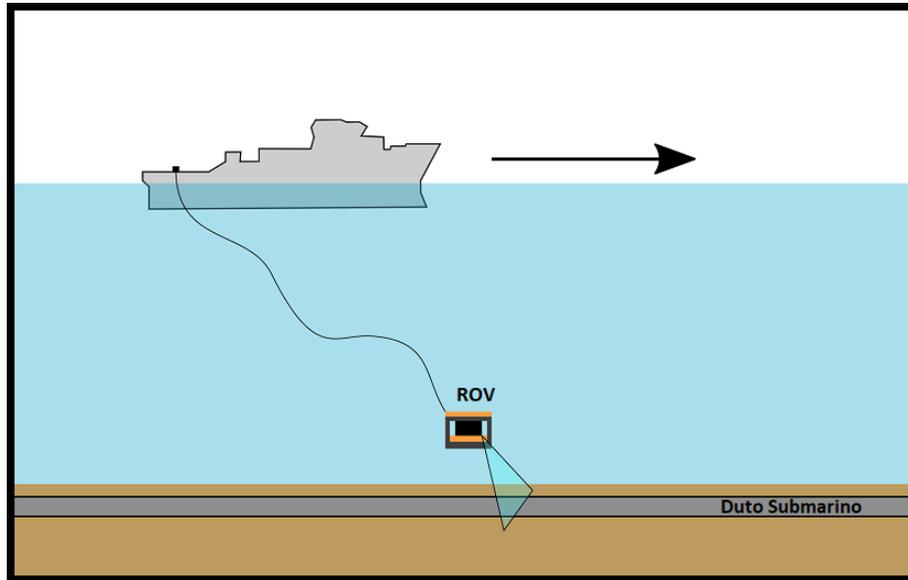


Figura 1.1: Diagrama exemplificando um esquema de inspeção de dutos submarinos por meio de ROV.

As imagens adquiridas pelas câmeras instaladas nos ROVs são monitoradas por um operador dedicado exclusivamente à tarefa de detecção de anomalias nos dutos submarinos. Essa tarefa de monitoramento em tempo real exige grande concentração por parte do operador humano, devido à qualidade variável das imagens submarinas, à necessidade de atenção por períodos extensos e à relativa monotonia das características da cena. Por causa dessa exigência, a probabilidade de falhas em detecção de anomalias associadas à perda de concentração do operador aumenta. Uma forma de reduzir esse risco seria apoiar as atividades humanas através de Veículos Submarinos Autônomos (*Autonomous Underwater Vehicles* – AUVs), capazes de guiagem e inspeções visuais autônomas.

A indústria de exploração de petróleo e gases naturais possui caráter conservador em relação à adoção de veículos submarinos totalmente autônomos, em parte devido à necessidade de certificações e atendimento a regulamentações. Desta forma, veículos submarinos semiautônomos, adaptados de ROVs, são passos iniciais que ajudariam na adoção dessas novas tecnologias autônomas [1]. Essa adaptação pode ser feita de maneira mais econômica que a construção de um novo AUV, como é o caso, por exemplo, da utilização das imagens da câmera do ROV para executar inspeção autonomamente.

1.2 Objetivos

Para que inspeções visuais autônomas em dutos submarinos possam ser realizadas satisfatoriamente, duas condições devem ser satisfeitas: a localização da região ocupada pelos dutos na imagem; e a posterior detecção de anomalias na região do duto demarcada anteriormente.

O objetivo deste trabalho é realizar a detecção de anomalias na superfície dos dutos levando em consideração que as bordas do duto já foram previamente localizadas. A melhor estratégia para essa tarefa será aquela que consiga realizar o processamento em tempo real da sequência de imagens, para garantir que a solução possa ser embarcada em AUVs.

Nas Figuras 1.2 e 1.3 são apresentadas, respectivamente, imagens obtidas de inspeções de dutos submarinos normais e com anomalia.



Figura 1.2: Exemplo de seções de dutos submarinos com superfície em boas condições.



Figura 1.3: Exemplo de possíveis anomalias em seções dos dutos submarinos: (a) armadura externa danificada; (b) cruzamento entre dutos; (c) anodo de sacrifício; e (d) presença de peixe sobre o duto.

1.3 Metodologia

A partir das Figuras 1.2 e 1.3, pode-se observar que dutos com superfície em boas condições apresentam padrões de textura visual homogêneos, enquanto que dutos com possíveis anomalias se destacam por apresentarem padrões diferentes desses. Essa condição é melhor exibida nos fragmentos de imagens da Figura 1.4 e demonstra que há a possibilidade de detecção de anomalias com base na diferenciação entre fragmentos de imagens com texturas similares e diferentes. Dessa forma, um passo crucial desta dissertação é a obtenção de representações de texturas de fragmentos

de imagens que melhor representem a superfície padrão do duto. Com essa representação padrão, pode-se classificar texturas raramente observadas como anomalias. Essa classificação pode ser realizada de maneira não-supervisionada, que é uma configuração de aprendizado de máquina que não precisa que as anomalias sejam previamente rotuladas na fase de treinamento do classificador. Maiores detalhes sobre detectores de anomalia serão abordados no Capítulo 3.

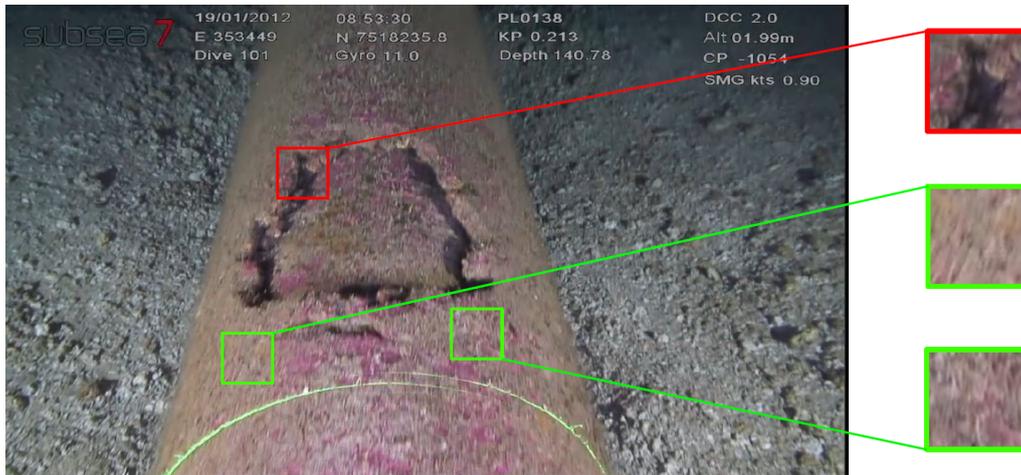


Figura 1.4: Contraste entre padrões de texturas de fragmentos de imagem.

A detecção de defeitos com base em texturas é uma área de pesquisa que foi vastamente estudada e aplicada em diversos ramos, como o de metalurgia [2] e [3], o da indústria madeireira [4], o da indústria têxtil [5], [6] e [7], o de construção civil [8], [9], [10] e [11], entre outros [12], [13], [14], [15] e [16]. Todos esses trabalhos possuem em comum ambientes bem iluminados, com o objeto a ser analisado posicionado perpendicularmente em relação à câmera e com baixa variabilidade contextual da textura observada. Diferentemente disso, no contexto de dutos submarinos, pode-se observar que a textura dos dutos sofrem alteração gradual de acordo com as condições marítimas do local de inspeção, conforme apresentado na Figura 1.5. Além disso, o duto é geralmente vistoriado obliquamente em relação à câmera, gerando problemas de luminosidade no eixo vertical da imagem. Essas dificuldades serão tratadas por meio análise local de fragmentos de imagens em um contexto temporal limitado, que permite adaptação gradual de mudança de textura, além de permitir a localização espacial das anomalias.

Ao conhecimento deste autor, não há muitas referências bibliográficas [17] que lidam com o problema de detecção autônoma visual de anomalias em dutos submarinos. Em [18] é apresentada uma forma de inspeção por meio de ultrassom. Mais recentemente, em [19] o autor utilizou redes neurais profundas (*deep learning*) para classificar eventos de interesse em inspeções visuais de dutos submarinos. Dessa forma, os estudos que melhor se assemelham a esse problema são os de detecção de

rachaduras em imagens de pavimento ou de dados estruturais em obras civis [8], [9], [10] e [11].

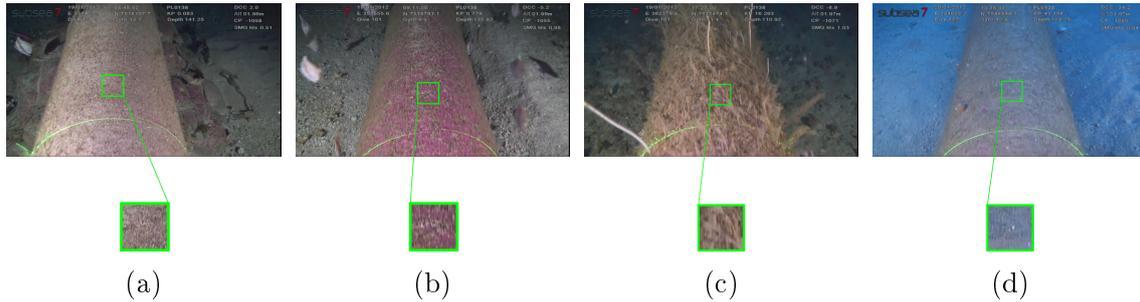


Figura 1.5: Diferentes tipos de textura de dutos submarinos: (a) e (b) ao longo do próprio vídeo; e (a), (c) e (d) entre vídeos diferentes.

A metodologia deste trabalho pode ser resumida nos seguintes passos: preparação das imagens sequenciais de trechos de vídeos de inspeção; fragmentação da imagem em sub-imagens de tamanho e sobreposição variável; extração de atributos dos fragmentos de imagens que representem texturas dos fragmentos; classificação não-supervisionada dos atributos para detecção de anomalias; e comparação dos métodos utilizados por meio de métricas objetivas.

A etapa de preparação (Figura 1.6) é feita pela anotação manual das bordas dos dutos, seguida da remoção da distorção perspectiva da imagem, seguida da anotação das possíveis anomalias, que serão utilizadas para gerar uma métrica de comparação objetiva entre os métodos de extração de atributos e classificação dos dados. A remoção da perspectiva foi feita para facilitar na fragmentação da imagem em sub-imagens, mesmo que introduza distorções nos píxeis da parte superior do duto. Contudo, os dados da anotação das bordas dos dutos são mantidos para futuras análises.



Figura 1.6: Preparação das imagens sequenciais de trechos de vídeos de inspeção: anotação manual das bordas dos dutos; remoção da distorção perspectiva; e anotação manual das anomalias (apenas nos dados de treinamento).

As etapas de fragmentação, extração de atributos e detecção de anomalias são representadas na Figura 1.7. Maiores detalhes sobre a implementação dessa etapa serão apresentados no Capítulo 4.

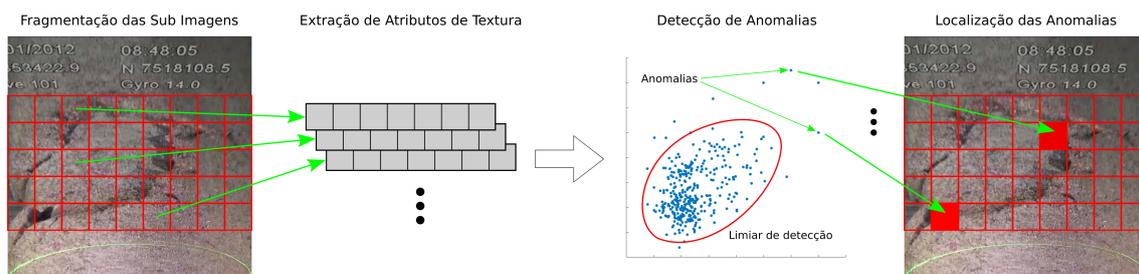


Figura 1.7: Resumo da metodologia: fragmentação das imagens, extração de atributos de textura e detecção de anomalias.

1.4 Estrutura da Dissertação

Esta dissertação está estruturada de maneira a apresentar inicialmente uma revisão sobre o conteúdo teórico que será utilizado para que, nos próximos capítulos, os experimentos, resultados e conclusões possam relatar melhor como o conteúdo teórico foi aplicado na prática.

O Capítulo 2 apresenta as técnicas de processamento de imagem usadas na fase de extração de atributos que representam texturas de imagem.

O Capítulo 3 continua a revisão teórica abordando os métodos de aprendizado de máquina usados na detecção de anomalias e os métodos de comparação de desempenho entre esses algoritmos.

O Capítulo 4 versa sobre o experimento prático de detecção de anomalias nos dutos submarinos através de filmagens de inspeções com ROVs e detalha como as técnicas dos capítulos anteriores foram utilizadas especificamente nesse ambiente.

Por fim, o Capítulo 5 apresenta as conclusões sobre este trabalho e sugestões sobre trabalhos futuros.

Capítulo 2

Representação de Texturas

Textura é um conceito subjetivo, que não possui uma definição estritamente matemática, usualmente atribuído à sensação visual causada pelo arranjo espacial e de variações tonais existentes entre os píxeis de uma imagem. Contudo, há um consenso de que as texturas, em geral, apresentam elementos básicos com repetição aleatória, ou periódica, que representam aspectos ásperos, finos, suaves, granulares, ondulados, etc. Esses aspectos são representados por atributos de textura, que são um conjunto de medidas feitas através de técnicas de processamento de imagem.

O processo de extração de atributos é um dos componentes mais importantes na maioria dos sistemas de reconhecimento de padrões. A *performance* do classificador depende diretamente da escolha do método de extração de atributos utilizados nos dados. Desta forma, esse método deve ser projetado com a intenção de obter uma representação compacta e significativa de atributos, a fim de garantir que o classificador receba dados não redundantes e separáveis para produzir melhores resultados na etapa de classificação. Portanto, há a necessidade de se investigar qual técnica de extração de atributos de textura produz os melhores resultados no processo de classificação.

O objetivo deste capítulo é introduzir as técnicas de processamento de imagem mais comumente utilizadas na literatura para a classificação ou segmentação de texturas de imagens. Essas técnicas são baseadas em métodos estatísticos, estruturais, de filtragem espaço-temporal e de redução de dimensionalidade, e foram usadas neste trabalho para extrair atributos de texturas de regiões de imagens para formar a base de dados usada na tarefa de detecção de anomalias.

2.1 Atributos Estatísticos de Primeira Ordem

Em análise estatística de texturas, atributos de textura são computados através da distribuição de combinações de intensidade de píxeis em diferentes posições relativas. De acordo com a quantidade de píxeis em cada combinação, a estatística é

classificada em primeira ordem, segunda ordem e ordens superiores.

Atributos estatísticos de primeira ordem consideram apenas as intensidades de cada pixel individualmente e são obtidos através do histograma de uma região da imagem. Considerando o caso em que uma imagem $I(x, y)$, de dimensão $(N \times M)$, é descrita por píxeis com N_g níveis de intensidade em escala de cinza, seu histograma de primeira ordem é definido por $P(i)$:

$$P(i) = \frac{h(i)}{NM}, \quad (2.1)$$

onde $h(i)$ representa a contagem de píxeis com intensidade i , definido por:

$$h(i) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} \delta(I(x, y) - i), \quad (2.2)$$

onde $\delta(x) = 1$ se $x = 0$, e $\delta(x) = 0$ se $x \neq 0$.

Com base no histograma, pode-se extrair inúmeros atributos que representem a textura da região, como por exemplo os momentos, momentos centrais e entropia, conforme apresentado na Tabela 2.1.

Tabela 2.1: Atributos de primeira ordem descritores de textura

Tipo de Atributo	Equação
Momentos	$m_n = E[I^n] = \sum_{i=0}^{N_g-1} i^n P(i) \quad (2.3)$
Momentos Centrais	$\mu_n = E[(I - E[I])^n] = \sum_{i=0}^{N_g-1} (i - m_1)^n P(i) \quad (2.4)$
Entropia	$H = -E[\log_2(P(I))] = - \sum_{i=0}^{N_g-1} P(i) \log_2 P(i) \quad (2.5)$

Os atributos mais utilizados são a média (m_1), variância ($\mu_2 = \sigma^2$), assimetria (μ_3/σ^3), curtose (μ_4/σ^4) e entropia. Elas representam, respectivamente, a média da iluminação da imagem, a variação de intensidade em torno dessa média, a inclinação da distribuição referente à média (Figura 2.1a), o grau de achatamento da distribuição (Figura 2.1b) e uma medida de uniformidade do histograma.

Neste trabalho, foram utilizadas combinações dos atributos descritos acima, adicionados ao valor mínimo e máximo entre os níveis de cinza dos píxeis da imagem, conforme sugerido em [9] para classificar rachaduras em imagens de pavimentos. Outros atributos que poderiam ser utilizados são a moda, a mediana e os quartis da distribuição.

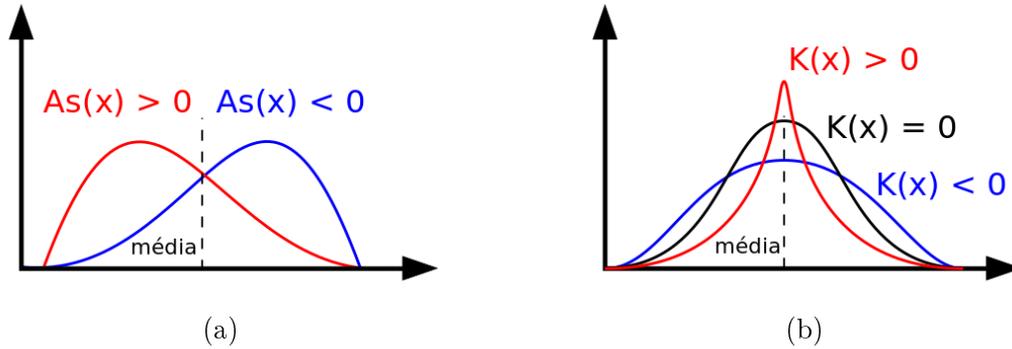


Figura 2.1: Comparação entre histogramas: (a) exemplo de assimetria; e (b) exemplo de curtose.

Cabe ressaltar que o presente método de extração de atributos falha em captar dependências estruturais entre píxeis. Na Figura 2.2 são apresentadas duas imagens com seus respectivos histogramas de intensidades de nível de cinza. Embora essas imagens possuam o mesmo histograma, e, portanto, os mesmos atributos de textura de estatísticas de primeira ordem, a primeira imagem é uma versão mais estruturada, que pode ser reconhecida pelo ser humano, enquanto que a segunda é a sua versão embaralhada, que é irreconhecível.

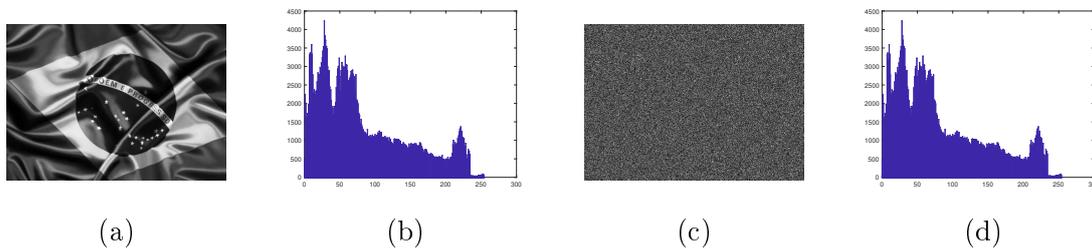


Figura 2.2: Comparação entre histogramas: (a) imagem estruturada; (b) histograma da imagem (a); (c) imagem embaralhada de (a); e (d) histograma da imagem (c).

2.2 Matriz de Coocorrência de Níveis de Cinza

Estatísticas de primeira ordem fornecem informação relacionada à distribuição dos níveis de cinza dos píxeis da imagem, mas não adicionam dados sobre as posições relativas desses píxeis. Dessa forma, os atributos desse tipo de estatística não serão capazes de medir com detalhes se agrupamentos de píxeis de nível baixo ou alto estão intercalados ou agrupados separadamente. Para vencer essa deficiência, pode-se calcular estatísticas de ordens mais elevadas e extrair atributos delas.

A Matriz de Coocorrência de Níveis de Cinza (*Gray Level Cooccurrence Matrix* – GLCM) se trata de um histograma de segunda ordem que mede a proporção de ocorrência de pares de píxeis para uma dada distância e orientação entre eles.

Dessa forma, atributos de texturas calculados a partir dessa matriz são considerados atributos estatísticos de segunda ordem. Essa matriz foi inicialmente concebida em [20] com a intenção de descrever atributos de textura na aplicação de classificação de imagens.

Para uma imagem I de dimensões $M \times N$, quantizada em N_g níveis de cinza, a GLCM é uma matriz quadrada C_{d_x, d_y} de dimensão $N_g \times N_g$, definida por um parâmetro de deslocamento (d_x, d_y) , onde cada elemento dessa matriz é dado por:

$$c_{d_x, d_y}(i, j) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} \delta(I(x, y) - i) \delta(I(x + d_x, y + d_y) - j) , \quad (2.6)$$

onde $\delta(x) = 1$ se $x = 0$, e $\delta(x) = 0$ se $x \neq 0$.

Os cálculos das matrizes GLCM são feitos comumente com os deslocamentos (d_x, d_y) parametrizados por vetores de deslocamento, com seu módulo (d) e direção angular (θ) normalmente discretizados nos valores de 0° , 45° , 90° e de 135° , conforme representado na Figura 2.3. Dessa forma, as matrizes passam a assumir a notação de $C_{d, \theta}$ no lugar de C_{d_x, d_y} .

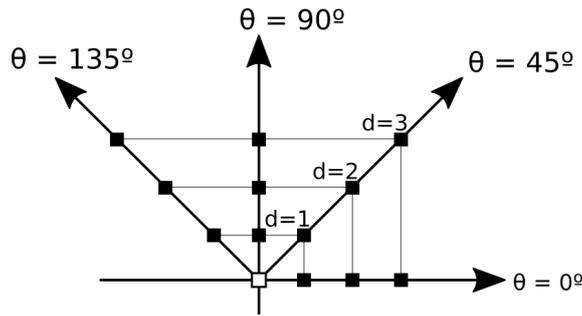


Figura 2.3: Exemplo de deslocamentos usados no cálculo da GLCM.

Para uma melhor discriminação e, conseqüentemente, classificação de texturas diferentes, as GLCMs utilizadas são simétricas, isto é, representam as variações dos píxeis em sentidos opostos ao longo de uma mesma direção. Para isso, não é necessário o cálculo das GLCMs dos ângulos de 180° , 225° , 270° e 315° , pois apresentam resultados iguais às transpostas dos ângulos de 0° , 45° , 90° e 135° .

A transformação das GLCMs em matrizes simétricas é feita conforme apresentado na Equação (2.7) e exemplificado na Figura 2.4. Nesse exemplo, a figura da esquerda representa uma imagem de tamanho 4×4 quantizada em 4 níveis de cinza e as figuras da direita são, respectivamente, as matrizes GLCM básica e sua versão simétrica, calculadas considerando o deslocamento de 1 unidade na direção de 0° . A imagem possui 3 ocorrências do par de píxeis $(0, 1)$ (vermelho), que são mapeadas na posição $(0, 1)$ da matriz GLCM e 1 ocorrência do par $(3, 3)$ (azul) que é mapeada na posição $(3, 3)$ da matriz.

Para se adicionar a propriedade de invariância à rotação, basta calcular uma única matriz para todas as direções, dada pela média entre seus elementos. Essa propriedade de invariância à rotação pode ser estendida para o deslocamento realizando operação similar com diferentes deslocamentos.

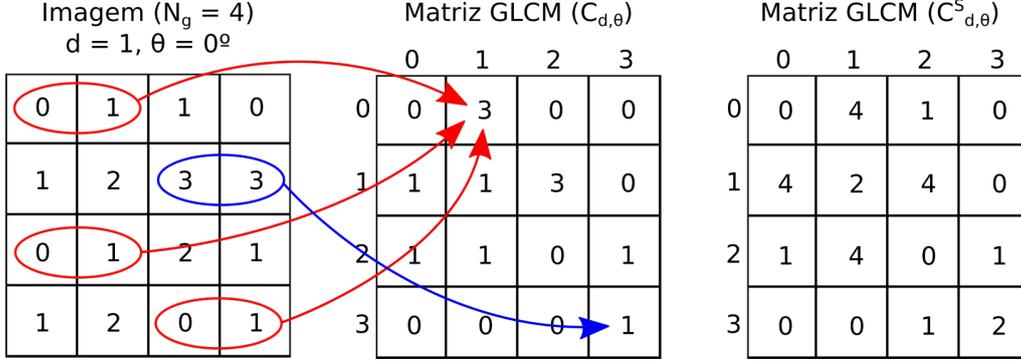


Figura 2.4: Exemplo de cálculo de GLCM com deslocamento de um pixel na orientação de 0° para imagem com quatro níveis de cinza.

$$C_{d,\theta}^S = C_{d,\theta} + C_{d,\theta}^T, \quad (2.7)$$

onde $C_{d,\theta}^S$ é a matriz simétrica de $C_{d,\theta}$, que torna invariante as observações em uma mesma direção.

De forma a obter densidades de probabilidade conjunta discretas factíveis e possibilitar o cálculo de atributos que representem texturas, as matrizes simétricas são normalizadas de acordo com:

$$P = \frac{C_{d,\theta}^S}{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} c_{d,\theta}^S(i, j)}, \quad (2.8)$$

onde $c_{d,\theta}^S(i, j)$ é o elemento (i, j) da matriz $C_{d,\theta}^S$.

Na Tabela 2.2 são apresentados alguns dos atributos definidos em [20] e [21], os quais foram utilizados neste trabalho para representar texturas de imagens de matrizes GLCM simétricas e invariantes à rotação.

Tabela 2.2: Cinco atributos de textura obtidos de GLCM mais utilizados.

Tipo de Atributo	Equação
Contraste	$f = \sum_{i,j} i - j ^2 P(i, j) \quad (2.9)$
Correlação	$f = \sum_{i,j} \frac{(i - \mu)(j - \mu)P(i, j)}{\sigma^2} \quad (2.10)$ $\mu = \sum_{i,j} iP(i, j), \quad \sigma^2 = \sum_{i,j} (i - \mu)^2 P(i, j)$
Energia	$f = \sum_{i,j} P(i, j)^2 \quad (2.11)$
Entropia	$f = - \sum_{i,j} P(i, j) \log_2(P(i, j)) \quad (2.12)$
Homogeneidade	$f = \sum_{i,j} \frac{P(i, j)}{1 + i - j } \quad (2.13)$

2.3 Padrões Binários Locais

Os Padrões Binários Locais (*Local Binary Patterns* – LBP) combinam abordagens estatística e estrutural na intenção de obter melhor poder discriminatório na classificação de texturas. Trata-se de operadores que incorporam estatística de ocorrência de estruturas locais obtidas da vizinhança dos píxeis. Foram inicialmente aplicados em [22] e depois refinados em uma nova formulação em [23] para incorporar invariância à rotação. Em ambos os casos os padrões são invariantes ao deslocamento linear de iluminação em níveis de cinza, pois são obtidos da comparação entre o pixel central de uma região com seus vizinhos. Além disso, podem ser aplicados com mais parâmetros para se obter invariância à escala da textura.

Padrões Básicos

No LBP básico, cada pixel de uma imagem define um padrão através da comparação do pixel central (g_c) com seus píxeis vizinhos (g_p). Esse processo pode ser resumido em uma etapa de limiarização seguida de uma etapa de modulação por um fator binomial 2^p único para cada um de seus P vizinhos. Na etapa de limiarização, os valores dos píxeis vizinhos são limiarizados em relação ao valor do pixel central, através da função descrita na Equação (2.14), com $x = (g_p - g_c)$. Esse processo é exemplificado na Figura 2.5b.

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} . \quad (2.14)$$

Os valores limiarizados dos vizinhos $s(g_p - g_c)$ são modularizados pelos códigos referentes à cada vizinho (2^p), conforme indicado na Equação (2.15) e ilustrado na Figura 2.5c. O resultado desse processo (Figura 2.5d) é um padrão que define uma microestrutura local para o pixel analisado, ou seja:

$$\text{LBP} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p . \quad (2.15)$$

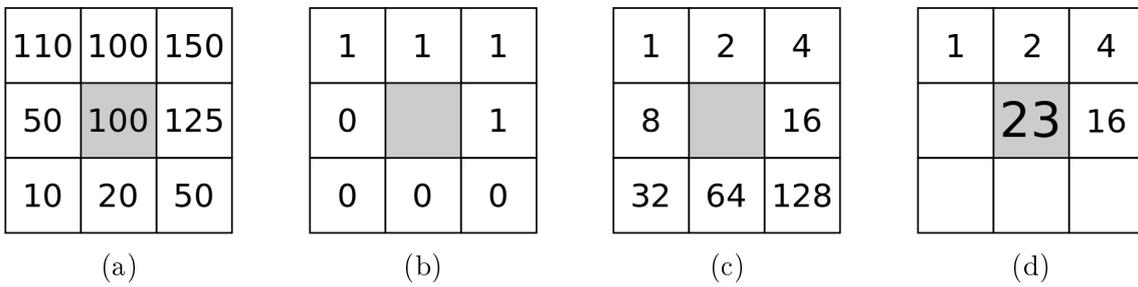


Figura 2.5: Exemplo de construção de padrão LBP: (a) região inicial usada no cálculo do padrão do pixel central; (b) resultado da limiarização dos píxeis da região; (c) máscara usada na etapa de modulação; e (d) padrão LBP indicado na posição do pixel central.

Com posse do padrão de cada pixel, constrói-se um histograma de padrões que definem a estatística de microestruturas de textura da imagem, que pode ser comparado com o histograma de outra imagem para se obter uma medida de similaridade. Originalmente a métrica escolhida foi a divergência de Kullback-Leibler, dada por:

$$D_{KL}(P||Q) = - \sum_i P(i) \log \frac{Q(i)}{P(i)} = \sum_i P(i) \log \frac{P(i)}{Q(i)} , \quad (2.16)$$

onde P e Q são os histogramas de duas imagens e i é o *bin* referente às microestruturas.

Padrões Uniformes

A definição original de região em torno do pixel central tomava como base uma janela de tamanho 3×3 e foi logo expandida para qualquer quantidade de píxeis vizinhos P dispostos simetricamente em um círculo de distância radial R em relação ao pixel central. Os valores de nível de cinza de vizinhos que não estiverem perfeitamente dentro dos centros dos píxeis da imagem são estimados com interpolação. A Figura 2.6 apresenta três configurações possíveis para R e P . Nela, os pontos vizinhos g_p

são dados pelas coordenadas $(R\sin(2\pi p/P), R\cos(2\pi p/P))$ em relação à coordenada do pixel central $(0, 0)$.

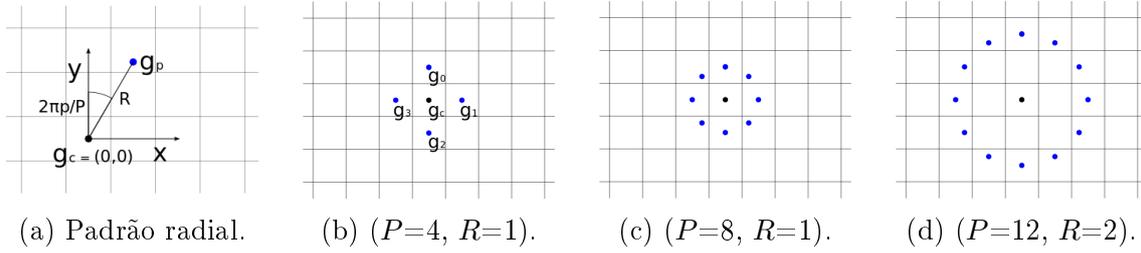


Figura 2.6: Vizinhança circular simétrica para diferentes (P, R) .

Uma das formas encontradas para garantir a invariância à rotação dos padrões locais foi a realização do deslocamento circular da palavra binária obtida após a limiarização, de maneira que o resultado final fosse o menor valor possível. Essa metodologia garante que a imagem rotacionada possua o mesmo resultado que a versão original. Contudo, além dessa metodologia não ter resultado em grande poder discriminatório, foram observados que certos padrões fundamentais para a definição de textura apresentavam ocorrências elevadas. Esses padrões apresentavam estruturas circulares contendo poucas transições espaciais e foram nomeados de Padrões Uniformes.

A definição do Padrões Binários Locais Uniformes é feita com a formulação da medida de uniformidade dos padrões, que tem como objetivo contar o número de transições binárias ao longo da estrutura circular após a limiarização, e é dada pela seguinte equação:

$$U(LBP_{P,R}) = \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)| + |s(g_{P-1} - g_c) - s(g_0 - g_c)|. \quad (2.17)$$

Essa medida de uniformidade estabelece P padrões básicos que possuem uniformidade menor ou igual a 2, que servem de modelo para microestruturas invariantes à rotação de pontos de luminosidade alta (0), pontos de luminosidade baixa (P), e bordas de diferentes curvaturas (1 a $P - 1$), conforme apresentado na Figura 2.7. Conforme disposto na equação a seguir, o valor do padrão do pixel analisado será entre 0 e P , indicando que é um dos modelos padrões mencionados anteriormente, ou $P + 1$, indicando que não é um padrão uniforme.

$$LBP_{P,R}^U = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c) & \text{se } U(LBP_{P,R}) \leq 2 \\ P + 1 & \text{caso contrário} \end{cases}. \quad (2.18)$$

O atributo final utilizado para esse operador é o histograma dos padrões para uma amostra de textura. Esse atributo possui melhor capacidade de discriminação

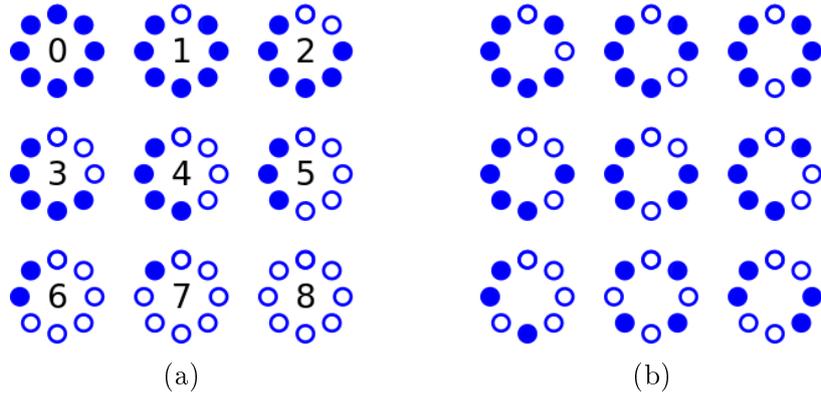


Figura 2.7: Padrões binários únicos invariantes à rotação, com $P = 8$: (a) padrões uniformes; e (b) exemplo de alguns padrões não uniformes. Os círculos preenchidos e vazios são, respectivamente, equivalentes ao valor lógico 0 e 1.

que os anteriores, pois os padrões uniformes são separados dos não uniformes, que apresentam baixa estatística e não conseguem ser estimados corretamente.

Outros Padrões

Além dos padrões mencionados anteriormente, existe uma quantidade extensa de variações para a representação de texturas por meio de padrões binários.

Em [24] os autores apresentam uma variante do LBP básico chamada *Multi-Scale Block Local Binary Pattern* (MB-LBP) que foi utilizada para reconhecimento facial. Essa versão utiliza a média dos níveis de cinza de blocos de píxeis para calcular os padrões binários, ao invés de considerar os píxeis individualmente, como é feito na versão básica.

Em [25] os padrões binários são estendidos para incorporar características temporais de texturas dinâmicas através do *Volume Local Binary Patterns* (VLBP). Essa técnica se baseia em analisar os padrões binários em planos ortogonais espaço-temporais para detectar variações em expressões faciais ao longo do tempo.

Em [15] é introduzido o conceito de razão *inlier-outlier* para auxiliar o LBP uniforme na detecção de micro defeitos em painéis compostos por Diodos Emissores de Luz Orgânicos (*Organic Light-Emitting Diodes* – OLEDs). São considerados *inliers* os píxeis que são similares ao pixel central da região analisada. Essa similaridade é feita através da comparação do pixel analisado e do pixel central por um limiar. São incorporadas varias razões de *inlier-outlier* para diferentes limiares nos dados de treinamento para garantir que micro defeitos sejam localizados mesmo em ambientes onde a diferença de iluminação é pequena.

2.4 Filtros de Gabor

Inspirados em sistemas biológicos, os Filtros de Gabor foram propostos com intuito de incorporar propriedades dos campos receptivos de células simples no córtex visual [26]. Formam um banco de filtros lineares usados em uma análise multiresolução de imagens, que possui a capacidade de descrição espacial e frequencial, simultaneamente, de atributos de textura. Foram inicialmente aplicados em [27] em segmentação de texturas.

Os filtros são compostos pela modulação de gaussianas, em qualquer rotação e escala, por uma exponencial complexa representando um plano de onda senoidal. Servem para localizar espacialmente determinadas componentes de frequências na imagem, em uma determinada direção. São matematicamente representados pela equação a seguir e ilustrados na Figura 2.8.

$$G(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(-\frac{x'^2}{2\sigma_x^2} - \frac{y'^2}{2\sigma_y^2}\right) \exp\left(j\omega_0 x'\right), \quad (2.19)$$

$$x' = x\cos(\theta) + y\sen(\theta),$$

$$y' = -x\sen(\theta) + y\cos(\theta),$$

onde ω_0 é a frequência do filtro, θ é o ângulo de rotação da gaussiana em relação ao plano de onda e σ_x e σ_y são os desvios padrões dos eixos principais da gaussiana. Sua Transformada de Fourier é dada por:

$$H(u, v) = \exp\left(-\frac{u^2}{2\sigma_u^2} - \frac{v^2}{2\sigma_v^2}\right), \quad (2.20)$$

$$u' = u\cos(\theta) + v\sen(\theta), \quad \sigma_u = 1/2\pi\sigma_x,$$

$$v' = -u\sen(\theta) + v\cos(\theta), \quad \sigma_v = 1/2\pi\sigma_y.$$

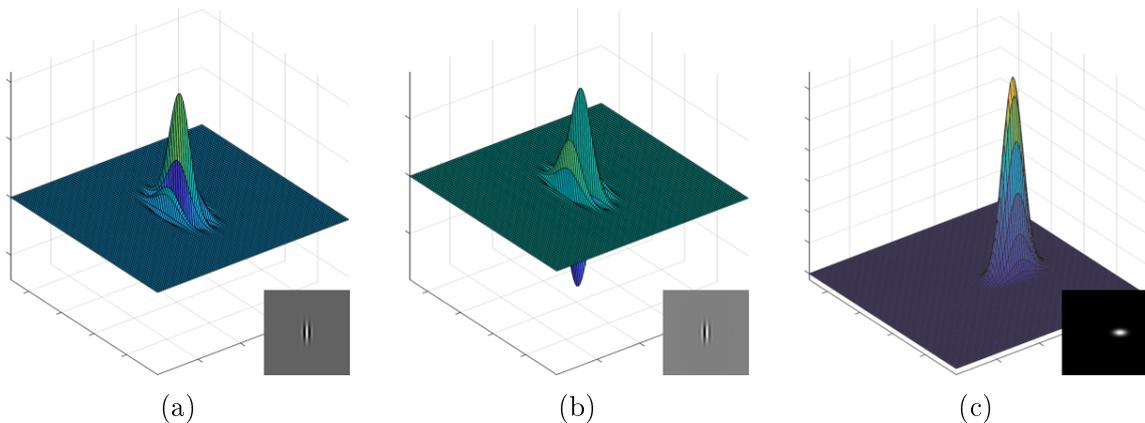


Figura 2.8: Exemplo de um filtro de gabor: (a) parte real do filtro; (b) parte imaginária do filtro; e (c) resposta do filtro no domínio da frequência.

Em [28] e [29] são detalhadas a construção do banco de filtros e a extração de atributos. Os parâmetros do banco de filtros são as frequências mínima e máxima

da onda senoidal e a quantidade de orientações a serem analisadas. Com esses parâmetros, é possível obter filtros no domínio da frequência que se tangenciam entre si na metade de suas amplitudes, conforme exemplificado na Figura 2.9. Essa figura representa o campo receptivo da visão biológica mencionado no começo desta seção. Cabe ressaltar que Filtros de Gabor não são usados na frequência $(0, 0)$, portanto a média da imagem deve ser removida antes da aplicação do banco de filtros.

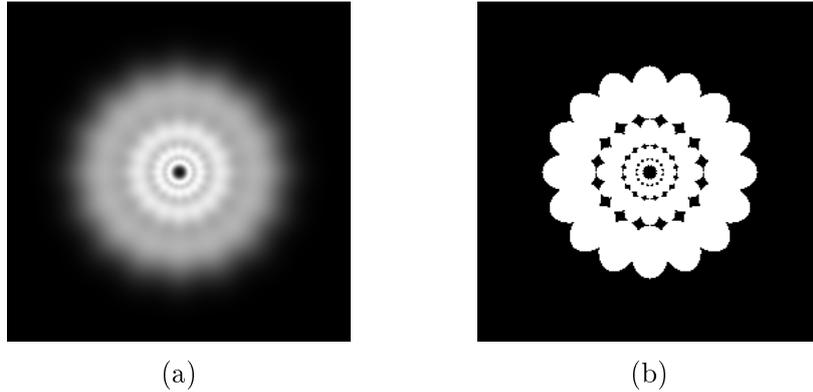


Figura 2.9: Exemplo de banco de filtros no domínio da frequência: (a) resultado da resposta completa para oito orientações e quatro escalas; e (b) exibição dos pontos tangentes entre os filtros.

Ainda, seguindo o artigo [28], os atributos de textura são obtidos aplicando-se o banco de filtros na imagem de maneira global e obtendo resultados de atributos em janelas de fragmentos de imagens. O módulo da filtragem é dado por:

$$I_{pq} = \sqrt{(I * Re(f_{pq}))^2 + (I * Im(f_{pq}))^2}. \quad (2.21)$$

Onde I_{pq} é a imagem resultante da filtragem de I por f_{pq} , os índices p e q representam escalas e orientações dos filtros, $*$ representa o operador da convolução bidimensional, e $Re(\cdot)$ e $Im(\cdot)$ são, respectivamente, as componentes reais e imaginárias dos filtros.

Considerando que as imagens serão fragmentadas em K janelas de tamanho $L \times L$, o vetor de atributos, para cada janela, é dado pela média de I_{pq} nessa janela, conforme descrito por:

$$D_k(p, q) = \frac{1}{L^2} \sum_{x,y \in k} I_{p,q}(x, y). \quad (2.22)$$

2.5 Análise de Componentes Principais

A Análise de Componentes Principais (*Principal Component Analysis* – PCA) é uma operação matemática linear que tem como objetivo a fatoração de uma ma-

triz de observações, possivelmente correlacionadas, em componentes ortogonais não correlacionadas chamadas Componentes Principais. Essa técnica é comumente utilizada em aprendizado de máquina na tarefa de redução de dimensionalidade, com o objetivo de se manter o mínimo de dados com grande capacidade descritiva.

Considere X uma matriz $M \times P$, onde M é o número de observações de dados e P é a dimensão original dos dados. A ideia é reordenar o sistema de coordenadas dos dados a fim de obter uma representação ortogonal com eixos (autovetores) ordenados de maneira decrescente por autovalores. Isso é feito através da matriz de Covariância C , de acordo com as equações:

$$Cv = \lambda v, \quad \text{com} \quad C = \frac{(X - \bar{X})^T(X - \bar{X})}{N - 1} \quad \text{e} \quad \bar{X} = \frac{\sum_{i=0}^{N-1} X(i)}{N}. \quad (2.23)$$

No caso das imagens usadas neste trabalho, a construção da matriz X consiste em incorporar, linha a linha, o resultado da vetorização das imagens, de tamanho $N \times N$, em observações de dimensões $1 \times N^2$. Dessa forma a dimensão P é equivalente a N^2 .

Em [30] essa técnica foi usada em imagens de rostos para redução de dimensionalidade e posterior reconhecimento facial de indivíduos. Os autovetores extraídos no processo foram denominados *eigenfaces* e são as bases usadas para a reconstrução da face de um determinado indivíduo. O reconhecimento facial é feito com uso da distância entre a reconstrução da face de um indivíduo desconhecido com as faces dos indivíduos usados no treinamento. Cabe ressaltar que, conforme apresentado em [30], essa técnica é válida para qualquer dimensão M da matriz X , contanto que a quantidade de observações seja superior à quantidade de componentes finais da redução.

Neste trabalho essa técnica será usada nos fragmentos de imagens de duto para obtermos uma representação desses fragmentos em bases de menor dimensão, com o máximo de variação possível entre esses dados. Dessa forma, além de se obter uma representação para os fragmentos de imagem em um espaço de dimensão inferior, texturas comuns formarão grupos mais densos de pontos, enquanto que anomalias estarão mais distantes desses agrupamentos.

Essa técnica apresenta um problema bem conhecido que pode impactar na separação dos dados para a classificação. A Figura 2.10 apresenta um exemplo desse problema. Nela, um conjunto de pontos em um espaço bidimensional será reduzido para apenas uma dimensão. Representando os dados pela sua componente principal, obtém-se o gráfico da Figura 2.10b, enquanto que representando os mesmos dados pela componente com menor autovalor, obtém-se o gráfico da Figura 2.10c. Pode-se verificar que, nesse exemplo, a representação pela componente de maior autovalor

resulta em observações não separáveis. Uma das formas de se resolver esse problema é utilizar a técnica de Análise de Componentes Independentes (*Independent Component Analysis* – ICA), que não será abordada nesse trabalho. Outra maneira de resolver o problema, que será utilizada neste trabalho, é manter algumas das componentes de menor autovalor na fase de redução de dimensionalidade com PCA.

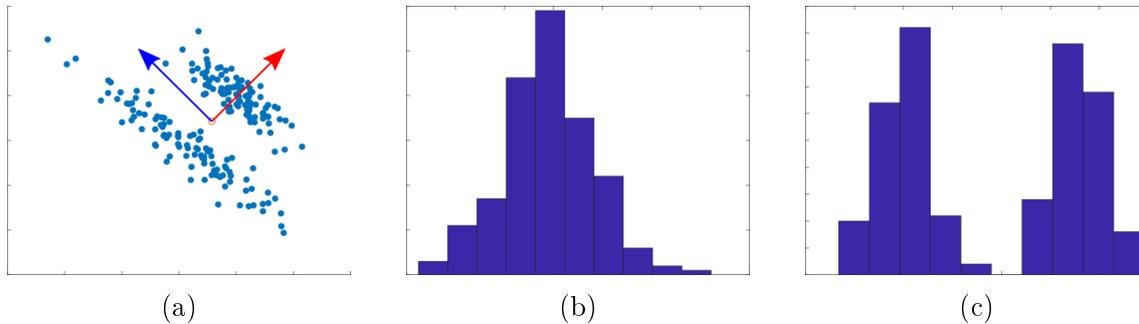


Figura 2.10: Problema de separação de dados para a classificação com redução de dimensionalidade por PCA: (a) dados originais em espaço bidimensional, cujos eixos em vermelho e em azul representam, respectivamente, a componente principal e a componente de menor autovalor do PCA; (b) histograma da projeção na direção da componente principal; e (c) histograma da projeção na direção da componente de menor autovalor.

Além do problema apresentado anteriormente, a presença de intrusos (anomalias) no conjunto de dados influenciam a resposta final dos autovetores. Para resolver esse problema, há versões mais recentes de algoritmos de cálculo de PCA robustos a esse problema [31] e [32] que faz uma decomposição da matriz de observações em outras duas, uma de baixo posto e outra esparsa, que representam, respectivamente, os dados robustos e o ruído introduzido pelos intrusos.

A análise por PCA é uma operação matemática linear, portanto pode não conseguir obter uma representação adequada para os dados em um espaço de dimensão reduzida. Para isso, há a possibilidade da utilização de aprendizado de máquina para se obter representações não lineares para os dados. Isso pode ser feito com uso de *Autoencoder*, ou *Convolutional Autoencoder*, que não serão apresentados neste trabalho por serem computacionalmente custosos, violando a premissa de análise em tempo real estabelecida nos objetivos do Capítulo 1.

Capítulo 3

Detecção de Anomalias

Este capítulo tem o propósito de introduzir o ferramental necessário para o aprendizado de máquina utilizado na detecção de anomalias em sequências de imagens de dutos submarinos.

Inicialmente é apresentado um resumo sobre técnicas de aprendizado de máquina utilizadas em detecção de anomalias, e, em seguida, são descritos os algoritmos não-supervisionados que foram utilizados nesta dissertação. Por último, são apresentados detalhes sobre a metodologia utilizada na comparação entre os algoritmos de detecção de anomalias.

3.1 Configurações de Detectores de Anomalia

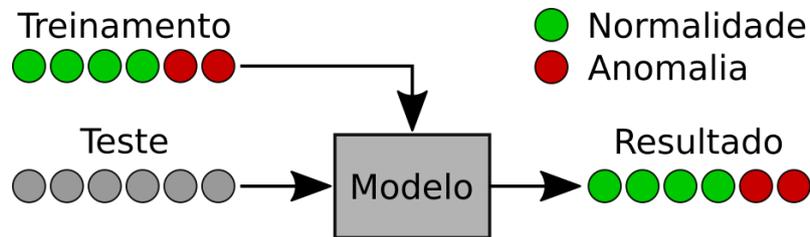
Detecção de anomalia, também conhecida como detecção de intrusos ou detecção de novidade, tem como objetivo o reconhecimento de padrões incomuns ou raramente encontrados em um conjunto de dados.

No aprendizado de máquina convencional, todos os dados possuem rótulos de suas classes, sendo divididos em grupos de treinamento, de validação e de teste, que servem para treinar e avaliar o desempenho do classificador. Contudo, no aprendizado de máquina voltado para detecção de anomalias, existem três abordagens ilustradas na Figura 3.1, que dependem da disponibilidade de anotações das anomalias no conjunto de treinamento: aprendizado supervisionado; semi-supervisionado; e não-supervisionado.

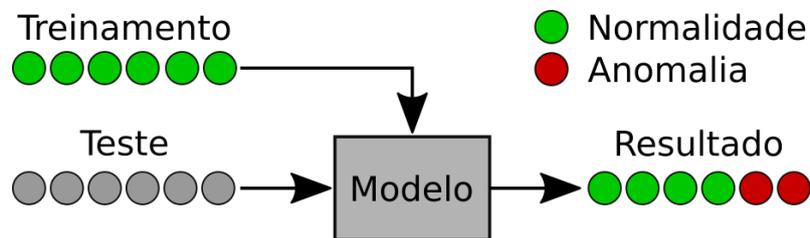
No aprendizado supervisionado, o classificador é treinado e validado similarmente a um classificador convencional de duas classes com a utilização dos rótulos das anomalias e observações comuns. Esse tipo de aprendizado é o menos utilizado no contexto de detecção de anomalias por haver a necessidade do conhecimento prévio das características que definem uma anomalia, bem como uma vasta base de dados de anomalias anotadas.

No aprendizado semi-supervisionado, não se sabe quais são as características das anomalias, ou não há a possibilidade de observação de anomalias no experimento, mas as condições normais de funcionamento de um sistema são conhecidas e podem ser mapeadas. Com as anotações das observações comuns e esperadas para um experimento, pode-se construir um classificador de uma única classe que detecte as observações comuns, classificando como anomalia o que se desvia do modelo obtido.

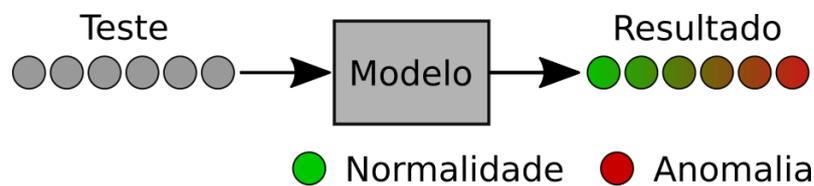
No aprendizado não-supervisionado, não há anotações durante a fase de treinamento. Nessa configuração, o detector atribui notas às observações de acordo com características intrínsecas dos dados, utilizando métricas de distância ou densidade para distanciar observações normais de anômalas. Essa pontuação é denominada pontuação de anomalia, que dá origem à classificação das observações anômalas através de sua limiarização.



(a) Detecção de anomalia supervisionada.



(b) Detecção de anomalia semi-supervisionada.



(c) Detecção de anomalia não-supervisionada.

Figura 3.1: Diferentes configurações para detectores de anomalia de acordo com a presença de anotações.

O tipo de aprendizado utilizado neste trabalho é o não-supervisionado, pois não há a possibilidade de mapeamento de todas as anomalias existentes nos dutos submarinos, uma vez que elas podem aparecer na forma de uma observação nunca vista. Além disso, conforme discutido no Capítulo 1 (Figura 1.5), não há a possibilidade

da construção de um modelo padrão para as imagens normais dos dutos devido à grande variação das imagens. Dessa forma, o aprendizado deverá ser local em poucos quadros de imagens do vídeo.

3.2 Tipos de Anomalia

As anomalias podem ser classificadas quanto ao escopo dos dados em anomalias globais, locais ou micro agrupamentos (*clusters*) e, referente ao tipo de detecção, em anomalia pontual, coletiva ou contextual [33].

Anomalias globais, locais e micro agrupamentos são, respectivamente: pontos que se distanciam da totalidade dos dados; pontos que se distanciam de um grupo local de dados; e conjunto de pontos que podem ou não ser classificados como anomalias, dependendo da aplicação e algoritmo usado. Essas anomalias são exemplificadas na Figura 3.2.

Anomalias pontuais são aquelas que partem da definição de que anomalias são observações que raramente ocorrem, portanto aparecem na forma de pontos singulares. Como essa suposição nem sempre é válida, foi concebida a ideia de anomalias coletivas, que são grupos de pontos que são diferentes de observações comuns.

Anomalias contextuais são classificadas de acordo com o contexto analisado, podendo ser classificadas em anomalia ou não em momentos diferentes. Um exemplo de contexto e anomalia contextual pode ser, respectivamente, a estação do ano e a venda de sorvete durante o inverno. Nessa situação, é esperada a venda de sorvete durante verão (padrão comum) e pouco observada no inverno (anomalia).

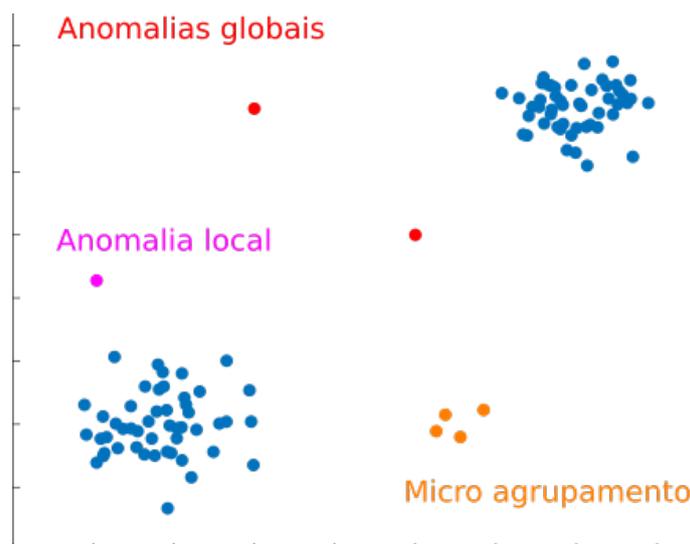


Figura 3.2: Exemplos de anomalias globais, locais e micro agrupamentos.

3.3 Algoritmos Não-Supervisionados

Existem inúmeros algoritmos de detecção de anomalias não-supervisionados que são baseados em métricas de distância, métricas de densidade, métodos de agrupamento, métodos estatísticos, classificadores, etc.

Em [33] e [34] são descritos algoritmos de detecção de anomalias não-supervisionadas, e em [35] são apresentados os métodos mais recentemente desenvolvidos baseados em aprendizagem profunda (*deep learning*) para detecção de anomalias em vídeos.

Essa dissertação se baseia em alguns dos métodos encontrados em [33] e [34]. As técnicas de aprendizagem profunda não foram investigadas, pois demandam um extenso conjunto de dados para treinamento, além de precisarem de dados com baixa variação contextual para aprendizado de um modelo padrão, que não é possível devido à variação contextual dos vídeos dos dutos submarinos.

Métodos baseados em distância, densidade ou na criação de um modelo para cada classe são preferidos, pois espera-se que as observações criem uma nuvem de pontos concentrada, com anomalias, em sua grande maioria, do tipo global. Portanto, os algoritmos selecionados para comparação da detecção de anomalias foram: *k-Nearest Neighbors*; *Local Outlier Factor*; *Histogram-Based Outlier Score*; e *One-Class Support Vector Machine*.

3.3.1 *k-Nearest Neighbors*

k-Nearest Neighbors (K-NN) é um algoritmo de classificação que possui duas vertentes: uma para classificação supervisionada convencional; e outra para geração de pontuação de anomalia usada em classificação não-supervisionada.

No contexto de detecção de anomalia, é um algoritmo de detecção global, baseado em distâncias entre observações. Nesse algoritmo, as distâncias entre todos os pontos são calculadas e a pontuação de anomalia que é atribuída às observações é dada pela média das distâncias dos K vizinhos mais próximos, de acordo com:

$$\text{K-NN}_k(x) = \frac{\sum_{y \in N_k(x)} d(x, y)}{|N_k(x)|}, \quad (3.1)$$

onde $\text{K-NN}_k(x)$ é a pontuação de anomalia do registro x , $d(x, y)$ é, geralmente, a distância euclidiana entre os registros x e y , $N_k(x)$ é o conjunto dos k -vizinhos mais próximos de x e $|\cdot|$ é o operador cardinalidade de conjuntos.

Esse algoritmo sofre de duas deficiências: a escolha do parâmetro K e a escolha do limiar usado na classificação das anomalias.

A escolha do parâmetro K não pode ser efetuada de antemão, pois, sendo esse algoritmo do tipo não-supervisionado, não há regras para garantir a escolha adequada

desse parâmetro através de validação cruzada. O que é feito é executar o algoritmo para diferentes parâmetros e verificar o comportamento médio na comparação com outros algoritmos.

A escolha do limiar da classificação é deficiente, pois as pontuações de anomalia dependem do conjunto de dados usados, número de dimensões e normalização. Mais detalhes sobre a escolha do limiar serão apresentados na seção de comparação entre os algoritmos de detecção de anomalias.

Esse algoritmo é o mais simples e servirá como base para comparação entre detectores mais avançados. Além disso, a pontuação de anomalias também poderia ser calculada pela mediana entre as distâncias dos k -vizinhos mais próximos.

3.3.2 *Local Outlier Factor*

Em [36] foi apresentado o conceito de anomalia local e, para resolver esse problema, foi proposto o algoritmo *Local Outlier Factor* (LOF). Esse algoritmo é baseado na análise da densidade das amostras e é capaz de detectar anomalias locais em agrupamentos com densidades diferentes.

O algoritmo é baseado em uma grandeza denominada *Local Reachability Distance* (LRD) que é o inverso da distância média entre os K -vizinhos mais próximos. Utilizando a Equação (3.1), a LRD é dada por:

$$\text{LRD}_k(x) = 1/\text{K-NN}_k(x) . \quad (3.2)$$

A pontuação do LOF é calculada a partir da razão entre densidades locais entre o registro e seus K -vizinhos mais próximos:

$$\text{LOF}_k(x) = \frac{\sum_{y \in N_k(x)} \frac{\text{LRD}_k(y)}{\text{LRD}_k(x)}}{|N_k(x)|} . \quad (3.3)$$

A vantagem desse algoritmo sobre o algoritmo de K -NN é que instâncias normais irão possuir densidade similar a de seus vizinhos, resultando em uma pontuação de 1. Anomalias possuirão densidade inferior a de seus vizinhos, resultando em pontuações superiores a 1. Dessa forma, há a possibilidade da escolha padronizada de limiares para a classificação de anomalias para diferentes tipos de dados.

Uma possível desvantagem dessa estratégia, notada em [33], é que há a tendência de muitos falsos alarmes serem obtidos em problemas nos quais não há o interesse em detectar anomalias locais.

3.3.3 Histogram-Based Outlier Score

Histogram-Based Outlier Score (HBOS) é um algoritmo de detecção global, baseado em densidade de observações locais, que se assemelha ao algoritmo de *Naive Bayes* em classificadores convencionais [37].

O algoritmo considera que as dimensões dos atributos são independentes entre si e obtém a pontuação de anomalia através da contribuição de medidas de densidade de cada histograma unidimensional. Esses histogramas podem ser construídos com número de observações por *bin* fixo, distribuindo os pontos em K regiões de tamanho fixo, ou dinâmico, distribuindo N/K pontos em regiões de tamanhos variáveis. A escolha do parâmetro K define o algoritmo e geralmente é escolhido como \sqrt{N} , mas serão testados alguns valores diferentes para verificar a performance do algoritmo.

O cálculo da pontuação é feito através da Equação (3.4), onde i e d são, respectivamente, o índice de iteração e a dimensão dos atributos, x é uma observação e $hist_i(x)$ é uma medida normalizada extraída do histograma da dimensão i dos atributos. Para cada histograma da dimensão i , verifica-se qual *bin* representa a dimensão i da observação x para a extração dessa medida. No caso de *bins* fixos, essa medida é o valor das contagens do histograma, enquanto que no caso de *bins* dinâmicos, essa medida é o número de contagens dividido pela largura do respectivo *bin*. A normalização é feita de tal maneira que o histograma final possua valor máximo unitário.

$$HBOS(x) = \sum_{i=1}^d \log \left(\frac{1}{hist_i(x)} \right). \quad (3.4)$$

O procedimento de cálculo da pontuação de anomalia com HBOS é ilustrado na Figura 3.3 para *bin* fixo, com $K = 2$ e atributos de dimensão $d = 2$.

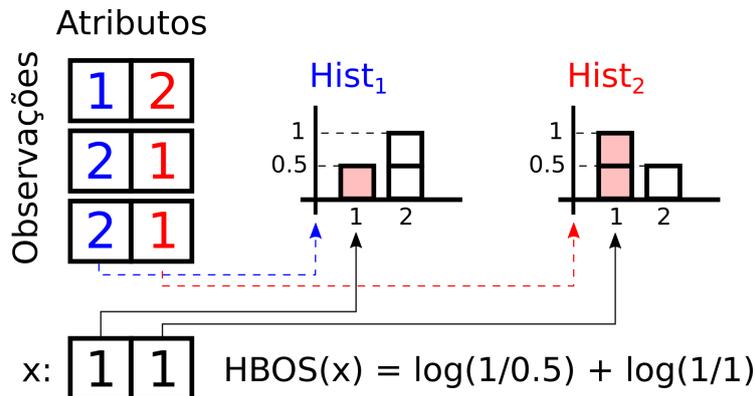


Figura 3.3: Construção da pontuação de anomalia por HBOS com *bin* fixo, $K = 2$ e dimensão dos atributos $d = 2$.

A consideração de independência entre os atributos pode comprometer a qualidade da detecção de anomalias, porém esse algoritmo traz a vantagem de ser com-

putacionalmente mais eficiente comparado com algoritmos baseados em distância.

3.3.4 *One-Class Support Vector Machine*

One-Class Support Vector Machine (OCSVM) é um algoritmo que aprende uma borda de decisão através de uma função de transformação $\phi(\cdot)$, definida por um *kernel*, que projeta os dados em um espaço de maior dimensão. Essa borda de decisão, no espaço de dimensão elevada, é representada por um hiperplano cuja função, quando aplicada às observações comuns do conjunto de dados, resultam em valores positivos, enquanto que, para o caso de anomalias, resultam valores em negativos.

Existe uma variedade de *kernels* que podem ser usados em OCSVM, como por exemplo o linear, o polinomial, o gaussiano, etc. O *kernel* utilizado neste trabalho é o gaussiano, pois pode ser utilizado em qualquer conjunto de dados, uma vez que garante a existência de uma borda de decisão [38].

A equação que garante a separação entre os dados é apresentada a seguir. Nela $g(x)$ representa a pontuação de anomalia das observações x , w é o vetor perpendicular à borda de decisão, ρ é um termo de polarização e ϕ é a função de transformação mencionada anteriormente. Quanto mais próximo de zero estiver essa função, mais provável que o dado seja uma anomalia. Nos classificadores semi-supervisionados convencionais, essa função é limiarizada, gerando apenas rótulos com dois valores.

$$g(x) = w^T \phi(x) - \rho . \quad (3.5)$$

O problema do OCSVM consiste em otimizar a função custo a seguir, cujo parâmetro ν , limitado entre 0 e 1, representa um limite superior no número de erros de classificação esperados (anomalias) e um limite inferior na quantidade de vetores de suporte referente ao total de dados usados no treinamento.

$$\min_{w, \xi, \rho} \frac{\|w\|^2}{2} - \rho + \frac{1}{\nu n} \sum_{i=1}^n \xi_i , \quad (3.6)$$

com restrições $w^T \phi(x_i) \geq \rho - \xi_i$ e $\xi_i \geq 0$.

A solução para esse problema é apresentada em [38], junto com outros algoritmos que apresentam robustez no treinamento na presença de anomalias.

3.4 Característica de Operação do Receptor

Em aprendizado não-supervisionado, detectores de anomalias não são treinados com rótulos que separem as observação padrões das anômalas. Essa característica dificulta a fase de validação dos resultados obtidos com o classificador, pois há a neces-

sidade de medidas externas ao problema para efetuar a comparação de algoritmos diferentes. Normalmente essas medidas são obtidas através de rótulos das anomalias de dados sinteticamente gerados ou através de anotações das anomalias em dados reais. Neste trabalho, os rótulos que compõem a base de anomalias são obtidos através das anotações manuais feitas nos dados experimentais, conforme exemplificado na Figura 1.6, no Capítulo 1.

Com posse das pontuações obtidas do detector de anomalias e dos respectivos rótulos base, é possível construir um gráfico chamado de Característica de Operação do Receptor (*Receiver Operating Characteristic* – ROC), que representa o quão bem o algoritmo é capaz de detectar, em média, as anomalias. Esse gráfico é construído ponto a ponto através da comparação dos rótulos base com rótulos obtidos através da limiarização das pontuações do detector [39] e [40]. Nesse gráfico, o eixo das abscissas representa a Taxa de Falso Positivo (TFP) e o das ordenadas a Taxa de Verdadeiro Positivo (TVP).

3.4.1 Construção da ROC

Considere B o conjunto dos rótulos base, $P(l)$ o conjunto dos rótulos obtidos da limiarização da pontuação de anomalias com o limiar l , U o conjunto universo de dados, e $|\cdot|$ o operador de cardinalidade de conjuntos. A taxa TVP(l) é definida como a taxa de anomalias base que foram corretamente detectadas pela rotulação das pontuações de anomalia, com o limiar l , sobre a quantidade de casos verdadeiros dos rótulos base, e é calculada de acordo com a seguinte equação:

$$\text{TVP}(l) = \frac{|P(l) \cap B|}{|B|}. \quad (3.7)$$

Em contrapartida, a taxa TFP(l) é definida como a taxa de anomalias erradamente detectadas pela rotulação das pontuações de anomalia, com o limiar l , sobre a quantidade de casos falsos dos rótulos base, e é calculada de acordo com a seguinte equação:

$$\text{TFP}(l) = \frac{|P(l) - B|}{|U - B|}. \quad (3.8)$$

A ROC é gerada através da obtenção de todos os conjuntos de coordenadas (TFP(l), TVP(l)) variando o valor de l de maneira que o gráfico se inicie no ponto (0, 0) e termine no ponto (1, 1), conforme apresentado na Figura 3.4a. Esses pontos indicam, respectivamente, que o limiar da rotulação da pontuação de anomalias definiu como anomalia nenhum e todos os dados presentes. A linha diagonal que liga esses pontos representa a performance de um detector aleatório, que possui 50% de chance de classificar corretamente uma amostra, e indica um limite inferior

de performance para os detectores. Curvas que estiverem mais próximas do ponto $(0, 1)$ possuem, em geral, melhor performance de detecção de anomalias (Figura 3.4b). Mais detalhes sobre avaliação de performance serão apresentados na subseção a seguir e a descrição da construção da ROC com os dados experimentais serão apresentados no Capítulo 4.

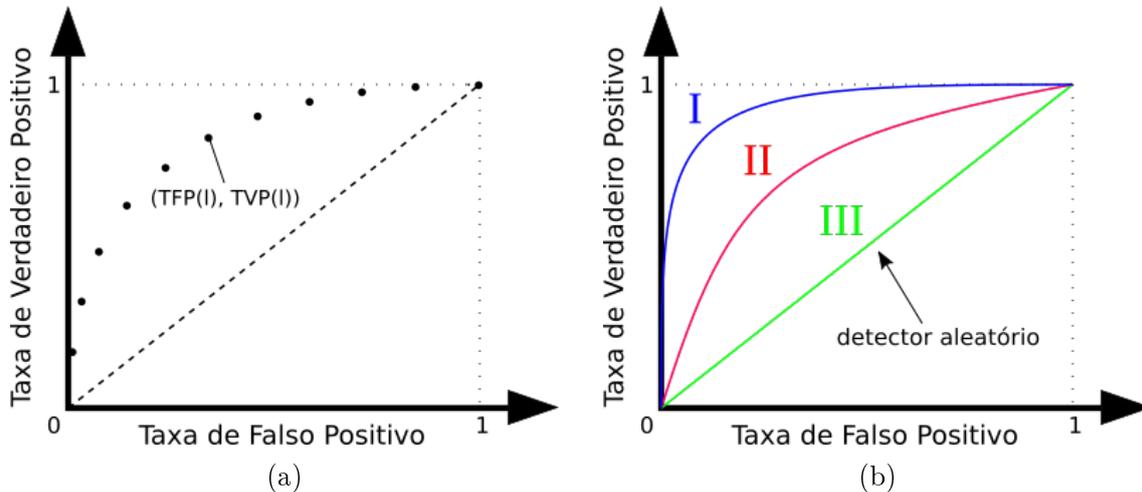


Figura 3.4: Característica de operação do receptor: (a) construção da curva característica de operação do receptor; e (b) exemplo de resultados de ROC para três algoritmos diferentes, com performance $I > II > III$.

3.4.2 Performance da ROC

Conforme apresentado anteriormente na Figura 3.4b, curvas mais próximas do ponto $(0, 1)$ são melhores que curvas mais próximas da linha diagonal. Essa dominância entre curvas, que indica melhoria de performance, pode ser comparada de diversas formas. A maneira mais básica é a de fixar um valor específico para a taxa TFP e comparar os valores resultantes das TVPs entre os algoritmos. Essa taxa representa um limite máximo de aceitação de falso alarme para os detectores e é diferente para cada problema.

A escolha da taxa TFP errada pode prejudicar a comparação entre algoritmos quando não se compreende a natureza do problema a ser analisado, conforme indicado na Figura 3.5a, onde a curva I é dominante sobre a curva II em um ponto distinto de TFP. Para isso, recomenda-se comparar os algoritmos através da métrica de Área Sob a Curva (*Area Under Curve* – AUC) da ROC. Essa área representa a probabilidade do algoritmo atribuir uma nota menor para um dado normal sorteado aleatoriamente que a nota que atribuiria para uma anomalia sorteada aleatoriamente.

Porém, como o método da AUC da ROC mapeia uma curva em apenas um ponto indicativo de performance, ela pode gerar ambiguidades entre duas curvas

distintas, conforme indicado na Figura 3.5b, onde a AUC da curva I é igual a da curva II. Para resolver esse problema, pode-se aliar os dois métodos de comparação de performance apresentados anteriormente e calcular a Área Parcial Sob a Curva (*Partial Area Under Curve* – p-AUC) da ROC. Esse método reúne o melhor entre os dois outros, pois é robusto a variações das curvas através do cálculo da área enquanto que prioriza a detecção até uma determinada taxa de falso alarme (Figura 3.5c).

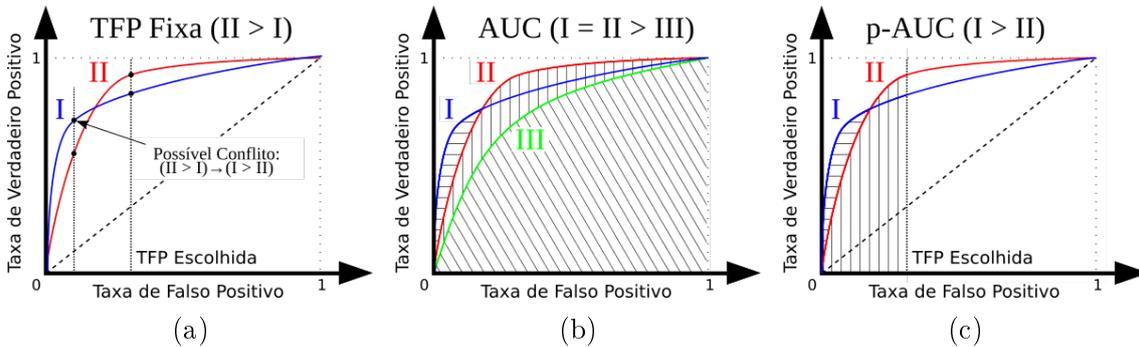


Figura 3.5: Performance de algoritmos de detecção de anomalias com uso da característica de operação do receptor: (a) comparação por TVP com TFP fixa; (b) comparação por AUC da ROC; e (c) comparação por p-AUC da ROC.

Os métodos de comparação de performance usados neste trabalho são os da AUC e da p-AUC.

3.4.3 Escolha de Limiar

Os métodos mais conhecidos de seleção automática de um limiar para o detector de anomalias com base na ROC dos dados de treinamento são o ponto da curva mais próximo do ponto (0, 1) e o Índice de Youden [41]. Esses critérios atribuem pesos iguais às taxas de verdadeiros positivos e falsos positivos.

O ponto da curva ROC mais próximo do ponto (0, 1) é o ponto que garante melhor relação entre as taxas de verdadeiros positivos e falsos positivos, por estar mais próximo do ponto do detector ideal, isto é, acerto de 100% com falso alarme de 0%. Em contrapartida, o Índice de Youden obtém o ponto da curva ROC que possui maior distância até a curva que representa o detector aleatório, atribuindo pesos iguais à taxa de detecção e à taxa de falso alarme. Esses dois critérios estão representados na Figura 3.6.

Além desses métodos, há a possibilidade de se definir uma função custo que relacione as taxas de detecção de anomalias e de falso alarme através de pesos diferentes para esses fatores. Contudo, é difícil de se estabelecer essa função em aplicações práticas pois a atribuição de pesos entre esses fatores pode se tornar um problema subjetivo.

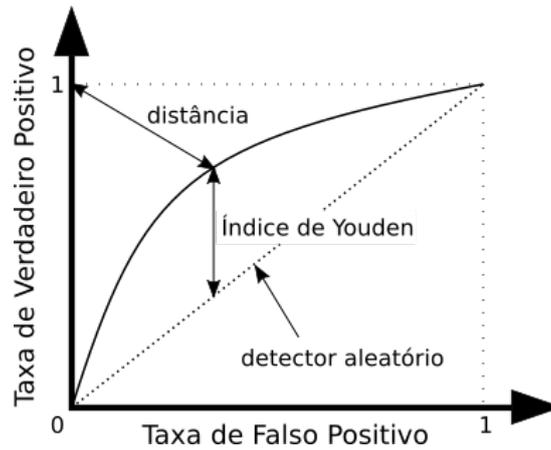


Figura 3.6: Critérios de escolha de limiar do detector baseados na curva ROC.

Por último, cabe ressaltar que a escolha automática de um limiar para a classificação de anomalias transforma os algoritmos não-supervisionados em semi-supervisionados, uma vez que a seleção é feita com base nos resultados obtidos dos dados de treinamento. Dessa forma, esses dados precisam possuir as mesmas características dos dados do ambiente em que o detector será aplicado para evitar falhas nas detecções.

Capítulo 4

Aplicação Experimental e Resultados

Este capítulo tem o propósito de apresentar os detalhes sobre a aplicação experimental de detecção de anomalias utilizada e os resultados obtidos para ela. A Seção 4.1 define os como os dados experimentais foram obtidos, apresentando detalhes sobre a escolha de parâmetros e implementação, enquanto que a Seção 4.2 apresenta as medidas de performance da detecção de anomalias, além de apresentar as detecções em vídeos de inspeção de dutos submarinos.

4.1 Aplicação Experimental

Nos experimentos deste trabalho, apenas três filmagens diferentes foram utilizadas para a formação de um grupo de treinamento e outros dois de teste devido a restrições de tempo na preparação dos dados. O grupo de treinamento serviu como base para a elaboração de estratégias de detecção de anomalias enquanto que os grupos de teste serviram para a verificação do funcionamento dessas estratégias. Nesses vídeos, foram selecionadas sequências de imagens nas quais há anomalias ao longo da filmagem. Essas sequências possuem duração de dez segundos e foram amostradas a seis quadros por segundo, resultando em um total de sessenta quadros por sequência. Essa taxa foi escolhida para garantir maior fluidez da movimentação das anomalias entre quadros adjacentes. O grupo de treinamento é composto por dez sequências enquanto que cada grupo de teste é composto por cinco. Amostras das imagens usadas na fase de treinamento e de teste são apresentadas no Apêndice A.

4.1.1 Preparação dos Dados

Conforme explicado no Capítulo 1, os dutos submarinos das imagens das filmagens foram delimitados manualmente para remoção da perspectiva da imagem do duto. Como não há dados sobre orientação do ROV, nem das dimensões do duto, essa transformação foi feita de maneira que as imagens resultantes tivessem um tamanho

padrão de 720×720 píxeis. Nos dados de treinamento, essas imagens resultantes foram usadas para anotação manual das anomalias (Figura 1.6).

A etapa de preparação consiste em segmentar a parte útil da imagem em fragmentos de imagens de tamanhos variados, podendo haver sobreposição entre os fragmentos. Para isso, a região útil usada na extração de atributos foi definida com base nas imagens de treinamento nas quais não há a presença do laser verde nem do texto do vídeo no canto superior. Esse recorte (Figura 4.1a) foi feito apenas no eixo vertical e foi limitado ao valor de 191 a 590. Depois disso, a região útil foi segmentada em fragmentos quadrados de tamanho de 100, 80, 60 ou 40, com sobreposição de 0%, 50% e 75% (Figura 4.1b). Inicialmente, esses fragmentos foram convertidos em escala de cinza para a etapa de extração de atributos.

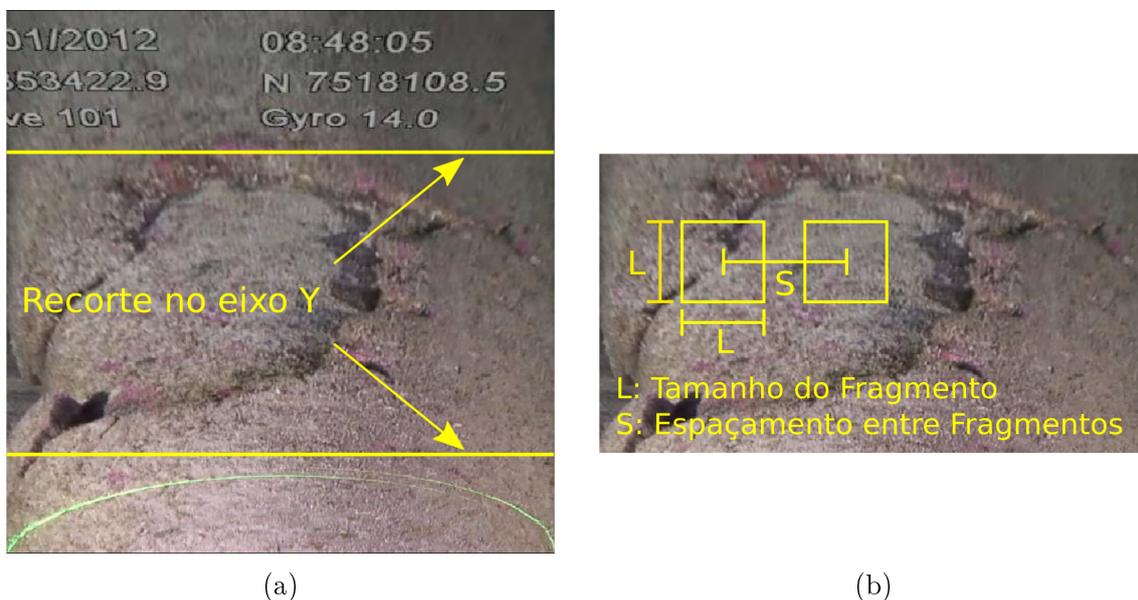


Figura 4.1: Fases da preparação dos dados: (a) recorte da área útil da imagem; e (b) segmentação da imagem em fragmentos com tamanhos e sobreposições diferentes.

De maneira semelhante, as imagens das anotações das anomalias foram recortadas e fragmentos foram obtidos da região útil desse recorte. A diferença é que a imagem original foi inicialmente tratada com o operador morfológico de erosão com elemento circular de tamanho seis para suavizar as marcações (Figura 4.2a).

Em seguida, os fragmentos de imagem resultantes após a erosão deram origem a uma imagem binária (Figura 4.2b) na qual cada pixel representa se seu respectivo fragmento de imagem é uma anomalia (1) ou não (0). Essa binarização foi realizada através da limiarização do percentual de píxeis indicativos de anomalia nos fragmentos de imagem e o limiar foi definido como $0.3/(L/50)^2$, onde L é o tamanho do fragmento. Essa imagem binária será referenciada como anotações automáticas ao longo do texto.

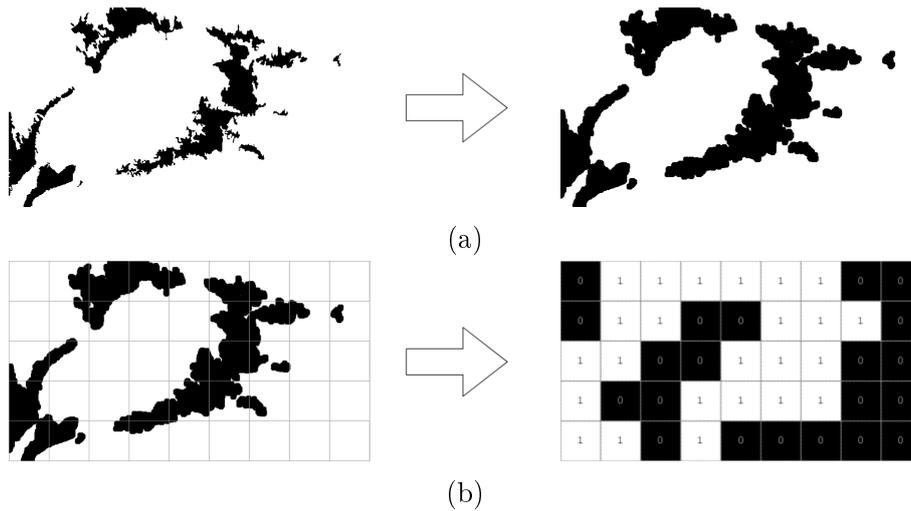


Figura 4.2: Preparação das anotações: (a) suavização com operação morfológica; e (b) classificação das anotações de fragmentos de imagem sem sobreposição de tamanho $L = 100$.

4.1.2 Extração de Atributos

Todos os atributos foram obtidos, inicialmente, de imagens em escala de cinza e foram separados em atributos não normalizados e normalizados com média zero e variância unitária.

A seguir são apresentados os parâmetros e peculiaridades de cada método de extração de atributos e como foram aplicados nos dados experimentais.

Atributos Estatísticos de Primeira Ordem

Esse tipo de atributo foi utilizado de maneira trivial, realizando-se as combinações possíveis de sete atributos dos fragmentos de imagens: média, variância, assimetria, curtose, valor mínimo, valor máximo e entropia.

Matriz de Coocorrência de Níveis de Cinza

As matrizes foram construídas para serem invariantes à orientação, conforme mencionado no Capítulo 2. Os parâmetros desse método de extração de atributos são: o módulo da distância entre pares de píxeis, valor lógico que indica se a matriz deve ser invariante à escala ou não e combinações dos atributos listados na Tabela 2.2. O parâmetro de distância é uma combinação de, no máximo, três valores que são 25%, 50% e 75% do tamanho dos fragmentos. O parâmetro de invariância à escala faz com que as matrizes em diferentes escalas sejam analisadas separadamente ou incorporadas em uma única, similar ao que é feito para a invariância à rotação.

Padrões Binários Locais

Padrões Binários Locais possuem apenas dois parâmetros: o módulo da distância entre píxeis e um valor lógico que indica se a matriz deve ser invariante à escala ou não. Os valores para esses parâmetros são similares aos apresentados anteriormente para o algoritmo da GLCM.

Filtros de Gabor

Na extração de atributos por Filtros de Gabor, a etapa de preparação dos dados é alterada, pois a filtragem não pode ser feita diretamente nos fragmentos de imagens devido às diferentes escalas dos filtros. Nesse caso, a filtragem deve ser feita na imagem em escala de cinza original antes da etapa de fragmentação, que será seguida da etapa de extração dos atributos de energia média.

Os parâmetros usados para a criação dos filtros desse algoritmo são o número de orientações (2 e 4) e número de escalas (3 e 5). As escalas definem as frequências dos Filtros de Gabor, que estão espaçadas em distâncias de oitavas entre si. O centroide do filtro de menor frequência é dado por $\omega = (3/2)(\pi/2^K)$, onde K é o número de escalas.

Análise de Componentes Principais

A Análise de Componentes Principais é feita com dois parâmetros: a quantidade de componentes principais e a quantidade de componentes de menor variância. Inicialmente foi feita a análise apenas com componentes principais, variando de duas unidades até vinte unidades, e em seguida são apresentadas as comparações com a inclusão de componentes de menor variância.

4.1.3 Detecção de Anomalia

Cada algoritmo de detecção de anomalia possui um conjunto de parâmetros que deverão ser variados para se calcular a média e desvio-padrão da desempenho do detector. Esses parâmetros e peculiaridades de cada método serão apresentados a seguir.

K-Nearest Neighbors

Esse classificador é o mais simples de todos e serve como base para a fixação do limite inferior na performance dos detectores. O parâmetro desse algoritmo é o número de vizinhos usados no cálculo, que foi definido como o intervalo de cinco a quarenta e cinco em passos de cinco.

Local Outlier Factor

O detector LOF é baseado em distância igual ao K-NN e possui apenas um parâmetro, que é o número de vizinhos usados no cálculo e foi definido como o mesmo intervalo do algoritmo de K-NN.

Histogram-Based Outlier Score

Esse algoritmo possui apenas um parâmetro, que é o número de observações por *bin* do histograma. Nesse trabalho, a construção dos histogramas é feita com quantidade de observações por *bins* dinâmica e o número de observações foi definido como o mesmo intervalo do algoritmo de K-NN.

One-Class Support Vector Machine

No caso do OCSVM, foram implementadas duas variantes: uma sem e outra com memória. A versão sem memória é treinada e testada com os atributos do próprio quadro atual, enquanto que a versão com memória utiliza atributos de quadros passados como base para o treinamento e realiza o teste no quadro atual. A atualização da memória é feita pela substituição de um percentual dos dados da memória com melhor pontuação por dados do quadro atual com melhor pontuação.

O parâmetro do algoritmo sem memória é apenas a relação entre vetores de suporte e número de anomalias. Para este parâmetro, os valores são selecionados do intervalo de 0,025 até 0,1 em passos de 0,025.

No caso do algoritmo com memória, os parâmetros são ν , o número de quadros de vídeo usados na memória, e o percentual de dados substituídos a cada iteração. O parâmetro ν foi fixado em 0,1, o número de quadros da memória em apenas 1 e o percentual de dados substituídos foi definido como 1%, 2%, 4% e 6%.

Devido ao alto custo computacional, o parâmetro de memória foi definido como 1 para permitir a simulação com inúmeras configurações de atributos. Futuramente, seria interessante a verificação dos resultados com diferentes valores para esse parâmetro para as melhores configurações de atributos.

Em ambos os casos os parâmetros do *kernel* do OCSVM são otimizados com métodos heurísticos de um pacote de aprendizado de máquina que implementa o projeto de SVMs.

Característica de Operação do Receptor

Cada ponto da curva ROC é gerado através da comparação das anotações automáticas das anomalias com as anomalias obtidas da limiarização dos dados de pontuação de anomalia com um determinado limiar. A construção da ROC total é feita para vários valores de limiares.

Neste trabalho, os limiares para geração das curvas ROC foram aplicados de maneira global, isto é, todas as pontuações de anomalia de todos os quadros das sequências de imagens dos dados de treinamento sofreram limiarização por um mesmo limiar global.

4.2 Resultados

Seguindo as diretrizes mencionadas na seção anterior, curvas ROC foram geradas para cada configuração conjunta dos parâmetros de extração dos fragmentos de imagens, dos parâmetros dos atributos e dos parâmetros dos classificadores. Os indicadores de desempenho dessas curvas são a área total abaixo da curva (AUC) e a área parcial abaixo da curva (p-AUC, integrada e normalizada até 0,1 da TFP).

Conforme mencionado nos capítulos anteriores, a técnica de extração de atributos é o principal fator que define a qualidade da detecção de anomalias. Além disso, o tamanho e passo das janelas de imagem obtidas na fase de extração de fragmentos de imagens também são fatores que influenciam a capacidade dos atributos de segregar as anomalias. Dessa forma, para comparar os inúmeros resultados e definir as melhores configurações que segregam melhor as anomalias, os resultados foram compilados em média e desvio padrão ao longo da dimensão dos parâmetros dos classificadores.

Na Tabela 4.1 são apresentadas as configurações dos atributos que originaram os melhores resultados médios de AUC e de p-AUC. Essas configurações serão utilizadas como referência na apresentação dos resultados ao longo deste capítulo e serão referenciadas de acordo com a primeira coluna da tabela, junto com a indicação de qual atributo está referenciado. Neste trabalho, os atributos nomeados STAT servem para para indicar atributos estatísticos de primeira ordem.

Nas Tabelas 4.2 e 4.3 são apresentados os resultados para os critérios de AUC e p-AUC respectivamente. Essas tabelas apresentam os melhores valores médios, com seus desvios-padrão, obtidos pelo processo mencionado anteriormente. Abaixo de cada valor estão as configurações dos atributos da Tabela 4.1, junto com os parâmetros da extração de fragmentos de imagem. O detector OCSVM indica que o modelo foi treinado e aplicado nos dados do mesmo quadro do vídeo enquanto que o detector OCSVM-M, utilizado com parâmetro de memória $M = 1$, indica que o modelo foi treinado com os dados de quadros anteriores e aplicado nos dados do quadro atual.

Os resultados dos atributos normalizados, com média zero e desvio-padrão unitário, se mostraram piores que os resultados baseados em atributos sem normalização. Além disso, a construção de atributos de PCA substituindo-se a última componente principal pela componente de menor autovalor também não proporcionou melhorias

na classificação de anomalias.

Tabela 4.1: Configurações dos parâmetros dos atributos das Tabela 4.2 e 4.3

	STAT	GLCM	LBP	GABOR	PCA
Config. 1	variância	D = (25, 50, 75)% contraste e entropia distâncias independentes	R = (12,5, 25, 37,5)% distâncias independentes	4 direções 3 escalas	10 componentes principais
Config. 2	média, variância e curtose	D = (25, 50, 75)% contraste e homogeneidade distâncias independentes	R = (12,5, 25)% distâncias independentes	4 direções 5 escalas	20 componentes principais
Config. 3	média, variância e valor mínimo	D = (25, 50, 75)% contraste, entropia e homogeneidade distâncias independentes	R = (12,5, 37,5)% distâncias independentes		
Config. 4	média, variância e valor máximo	D = (25, 50)% contraste, entropia e homogeneidade distâncias independentes	R = (12,5)%		
Config. 5			R = (25)%		
Config. 6			R = (37,5)%		

Tabela 4.2: Melhores resultados médios de AUC da ROC para diferentes configurações de detectores de anomalia.

	STAT	GLCM	LBP	GABOR	PCA
K-NN	0,8804 ± 0,0067 (60, 30) (Config. 3)	0,8694 ± 0,0018 (80, 20) (Config. 1)	0,8436 ± 0,0022 (60, 15) (Config. 2)	0,8750 ± 0,0041 (60, 60) (Config. 1)	0,9023 ± 0,0023 (80, 20) (Config. 1)
LOF	0,7378 ± 0,0539 (40, 40) (Config. 4)	0,7184 ± 0,0343 (40, 40) (Config. 2)	0,6628 ± 0,0198 (80, 40) (Config. 5)	0,7652 ± 0,0414 (40, 40) (Config. 2)	0,8467 ± 0,0333 (60, 30) (Config. 2)
HBOS	0,8463 ± 0,0032 (40, 10) (Config. 3)	0,8283 ± 0,0013 (60, 15) (Config. 2)	0,8284 ± 0,0058 (60, 15) (Config. 2)	0,7175 ± 0,0055 (60, 60) (Config. 1)	0,9016 ± 0,0009 (80, 20) (Config. 1)
OCSVM	0,7407 ± 0,0133 (40, 40) (Config. 2)	0,7543 ± 0,0138 (40, 10) (Config. 1)	0,6877 ± 0,0419 (60, 15) (Config. 6)	0,7001 ± 0,0141 (40, 20) (Config. 2)	0,8456 ± 0,0071 (40, 20) (Config. 1)
OCSVM-M	0,9476 ± 0,0039 (40, 20) (Config. 4)	0,8554 ± 0,0004 (40, 20) (Config. 3)	0,8109 ± 0,0011 (40, 40) (Config. 3)	0,8999 ± 0,0063 (40, 40) (Config. 2)	0,9194 ± 0,0043 (80, 40) (Config. 1)

Tabela 4.3: Melhores resultados médios de p-AUC da ROC, com p = 0,1 da TFP, para diferentes configurações de detectores de anomalia.

	STAT	GLCM	LBP	GABOR	PCA
K-NN	0,5510 ± 0,0105 (60, 60) (Config. 3)	0,5727 ± 0,0041 (80, 20) (Config. 1)	0,3571 ± 0,0019 (100, 25) (Config. 3)	0,5912 ± 0,0079 (60, 30) (Config. 1)	0,6396 ± 0,0064 (60, 15) (Config. 1)
LOF	0,3093 ± 0,0495 (60, 60) (Config. 3)	0,2685 ± 0,0538 (40, 40) (Config. 1)	0,1313 ± 0,0125 (100, 50) (Config. 4)	0,3058 ± 0,0431 (60, 60) (Config. 1)	0,4855 ± 0,0597 (60, 30) (Config. 2)
HBOS	0,4967 ± 0,0041 (60, 30) (Config. 1)	0,4277 ± 0,0339 (60, 30) (Config. 2)	0,2856 ± 0,0124 (60, 15) (Config. 3)	0,2417 ± 0,0033 (40, 40) (Config. 1)	0,5983 ± 0,0036 (60, 30) (Config. 1)
OCSVM	0,2688 ± 0,0087 (40, 10) (Config. 1)	0,2883 ± 0,0004 (40, 10) (Config. 2)	0,1481 ± 0,0041 (60, 15) (Config. 6)	0,2356 ± 0,0063 (40, 10) (Config. 1)	0,3933 ± 0,0016 (40, 20) (Config. 1)
OCSVM-M	0,7794 ± 0,0039 (60, 60) (Config. 4)	0,5689 ± 0,0025 (60, 60) (Config. 4)	0,4212 ± 0,0011 (40, 10) (Config. 1)	0,5880 ± 0,0064 (60, 60) (Config. 1)	0,6707 ± 0,0043 (60, 30) (Config. 1)

Conforme disposto nas Tabelas 4.2 e 4.3, os atributos que geram os melhores resultados na tarefa de detecção de anomalias para os dados de treinamento são o STAT e PCA, utilizando o detector OCSVM-M.

Na Figura 4.3 estão apresentados os gráficos de valores de AUC e p-AUC por parâmetros do detector OCSVM-M para essas configurações. Nota-se que a tendência é ter resultados melhores para baixos valores do parâmetro do detector, com exceção do caso do PCA com medida de desempenho p-AUC.

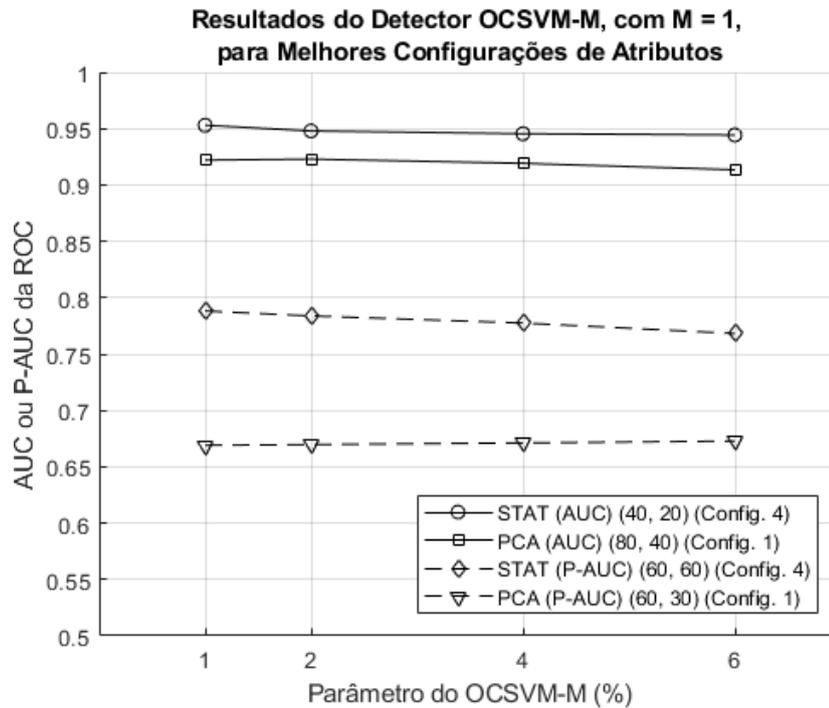


Figura 4.3: Melhores resultados de detectores de anomalias para diferentes tipos de atributos e parâmetros de detecção do algoritmo OCSVM-M, com $M = 1$.

Em seguida, foram selecionados os dois melhores atributos e classificadores para cada uma tabelas de AUC e p-AUC para comparação dos resultados. Os parâmetros dos classificadores foram escolhidos de acordo com a Figura 4.3. Esses algoritmos, junto com os respectivos resultados de AUC e p-AUC, estão resumidos na Tabela 4.4. O algoritmo que obteve melhor resultado na métrica de AUC foi o algoritmo 1 e apresentou resultado de 0,953 para um valor máximo de 1.

Os resultados da pontuação de anomalias dos melhores quatro algoritmos aplicados às imagens de treinamento e de teste do Apêndice A estão dispostos por meio de imagens de mapa de calor no Apêndice B.

Na Figura 4.4 estão dispostas as curvas ROC para os melhores algoritmos selecionados anteriormente. Pode-se observar que a curva de melhor resultado de AUC (linha sólida) apresenta resultados de TVP melhores que as curvas dos outros algoritmos apenas para TVP superior a 3% e que tem resultados de TVP piores que todas as outras curvas para TPF abaixo de aproximadamente 0,75%.

Tabela 4.4: Algoritmos com melhores resultados médios de AUC e p-AUC.

	Critério (Classificação)	Parâmetro dos Fragmentos de Imagem	Atributo	Detector	AUC / p-AUC
Algoritmo 1	AUC médio (1º lugar)	(40, 20)	STAT, média, variância e valor máximo	OCSVM-M, 1%	0,9530 / 0,7805
Algoritmo 2	AUC médio (2º lugar)	(80, 40)	PCA, 10 componentes principais	OCSVM-M, 2%	0,9230 / 0,6584
Algoritmo 3	p-AUC médio (1º lugar)	(60, 60)	STAT, média, variância e valor máximo	OCSVM-M, 1%	0,9457 / 0,7882
Algoritmo 4	p-AUC médio (2º lugar)	(60, 30)	PCA, 10 componentes principais	OCSVM-M, 6%	0,9067 / 0,6728

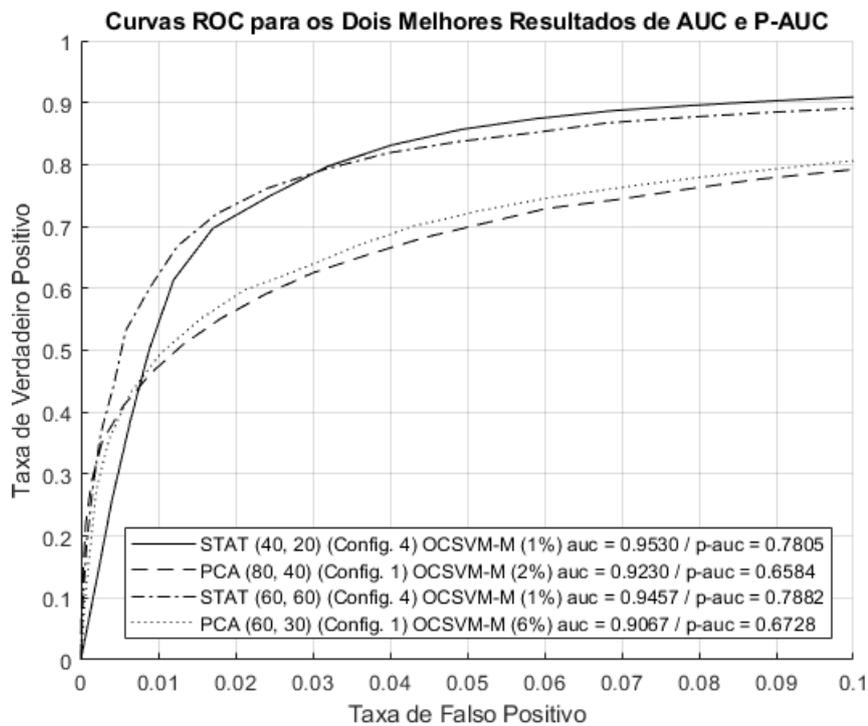


Figura 4.4: Melhores dois resultados de AUC e P-AUC para determinadas configurações de detectores OCSVM-M, com atributos PCA e STAT.

Com essas curvas, o ponto de operação dos algoritmos em relação à TFP e à TVP define um limiar para a classificação das anomalias. Os resultados a seguir consideram apenas dois pontos de operação para os algoritmos: limiar cuja TFP seja fixada em 5% para todos os algoritmos; e limiar automático, definido no Capítulo 3. A Tabela 4.5 lista os valores de TFP e TVP para esses dois pontos de operação.

Tabela 4.5: Taxas de falsos positivos e verdadeiros positivos para os pontos de operação dos melhores algoritmos.

	Algoritmo 1	Algoritmo 2	Algoritmo 3	Algoritmo 4
Ponto de Operação 1 (TFP de 5%)	(5%, 85,81%)	(5%, 69,85%)	(5%, 83,87%)	(5%, 72,07%)
Ponto de Operação 2 (Automático)	(7,90%, 89,54%)	(14,77%, 84,25%)	(8,86%, 88,39%)	(12,95%, 83,03%)

Serão apresentadas a seguir figuras com os resultados das detecções utilizando os dois pontos de operação nos dados de treinamento e de teste. As figuras são compostas por doze imagens dispostas em uma grade de três linhas por quatro colunas. As colunas dessas figuras representam os quatro algoritmos ordenados da esquerda para a direita conforme disposto nas linhas da Tabela 4.4, cujas taxas TVP e TFP estão dispostas nas colunas da Tabela 4.5. As linhas das figuras representam, em ordem, as imagens originais, com anotação no caso de dados de treinamento, seguidas do resultado da detecção da anomalia para o ponto de operação escolhido e por último as pontuações de anomalias em formato de mapa de calor.

Ponto de Operação 1 - Treinamento

As Figuras 4.5 a 4.9 apresentam exemplos de casos em que as detecções funcionaram de acordo com o esperado, classificando corretamente a grande maioria das anotações. Em todos os casos os quatro algoritmos apresentaram resultados semelhantes.

Nas Figuras 4.10 a 4.15 são apresentados alguns dos casos em que ocorreram falhas nas detecções.

Na Figura 4.10, todos os detectores marcaram a sombra causada por areia sobreposta ao duto como uma anomalia. Esse resultado era esperado, mesmo que não seja relevante para o inspetor, uma vez que se trata de uma anomalia na cena apresentada. Uma maneira de contornar esse problema seria a introdução de pós-processamento das detecções para eliminar esses casos, como por exemplo a utilização de um classificador posterior para separar esse tipo de caso. Outro possível pós-processamento seria a remoção de detecções que não formem grupos próximos de um determinado tamanho.

Na Figura 4.11 o detector com atributo tipo STAT marcou incorretamente inúmeros pontos que são casos comuns. Isso ocorreu devido ao limiar de 5% de TFP

estar muito alto a ponto de classificar alguns ruídos como anomalia. Além disso, foi notado pelo mapa de calor da pontuação de anomalias que há a variação do nível médio de pontuação de anomalias entre quadros adjacentes, que faz com que detecções com um limiar global sejam tendenciosas. Uma possível forma de reduzir esse problema seria a utilização de limiares locais a cada quadro. Outra forma seria a de se comparar quadros adjacentes igualando-se suas médias durante a fase de limiarização.

Na Figura 4.12 os quatro algoritmos detectaram as mesmas anomalias, que são pontos de pequenas pedras sobre o duto. Esse tipo de anomalia não é relevante e pode ser removido por meio de pós-processamento das detecções de maneira similar ao que foi descrito previamente para o caso de sombras causadas por areias.

Nas Figuras 4.13 e 4.14 são apresentados erros de detecção causados por sombras nos dutos. Na primeira figura o algoritmo com atributo PCA falha ao detectar sombras que ocupem muita área da imagem, pois acaba incorporando essa característica em seu modelo de atributo. Na segunda figura, o algoritmo com atributo STAT sofre problemas de detecção de sombras na parte superior do duto devido à baixa iluminação nessa posição. Foi feita a normalização da energia dos valores dos píxeis dos fragmentos de imagens para tentar contornar esse problema de iluminação, mas essa metodologia não produziu melhores resultados. A correção de efeitos de iluminação ao longo do eixo vertical da imagem pode ser a solução para esse problema.

Por último, a Figura 4.15 ilustra um problema que algoritmos que utilizam PCA como atributo sofrem, que é o de aprender modelos-padrão que não se encaixam perfeitamente na imagem fornecida. Nesse caso em particular, o modelo-padrão aprendido é semelhante às laterais dos dutos, que são mais homogêneas e escuras que a parte central. Dessa forma, o detector pode classificar incorretamente a parte discrepante como uma anomalia. Mais uma vez, isso pode ser corrigido através de pós-processamento dos resultados.

De uma maneira geral, os algoritmos apresentaram resultados bons nos dados de treinamento, conforme era esperado dos algoritmos não-supervisionados aplicados localmente a cada quadro de imagem. O objetivo dos algoritmos é reduzir a quantidade de informação que seria enviada a um especialista para análise da integridade dos dutos. Dessa forma, a ideia é detectar todas as anomalias, mesmo que isso produza falsos negativos no processo. Além disso, posteriormente pode-se reduzir os quadros classificados incorretamente através de pós-processamento, que pode ser implementado utilizando desde operadores morfológicos até aprendizado de máquina para rejeitar automaticamente casos desinteressantes.

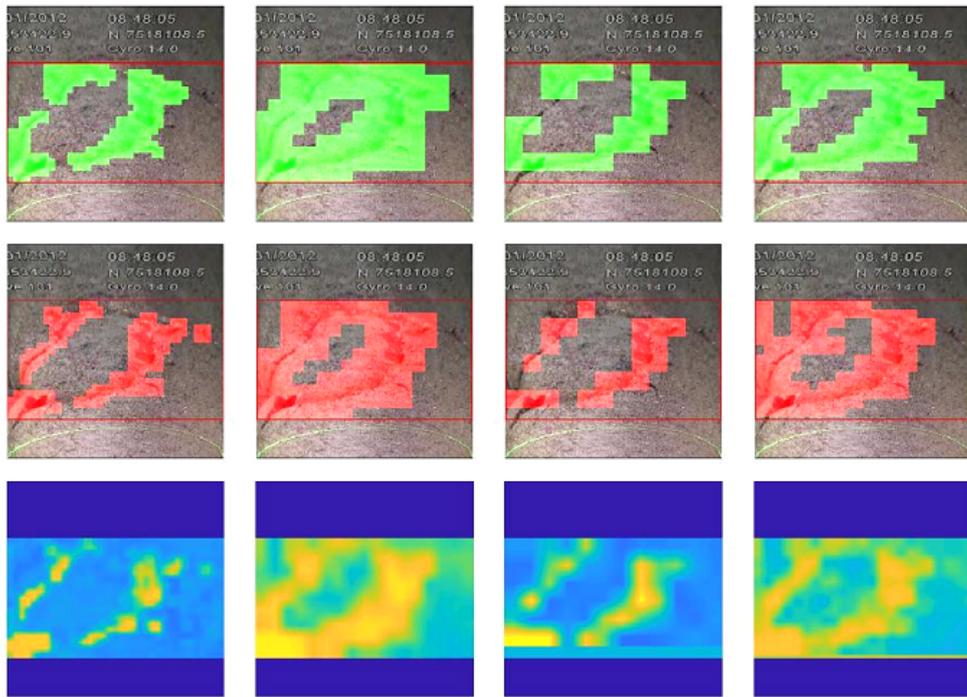


Figura 4.5: Primeira amostra positiva de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.

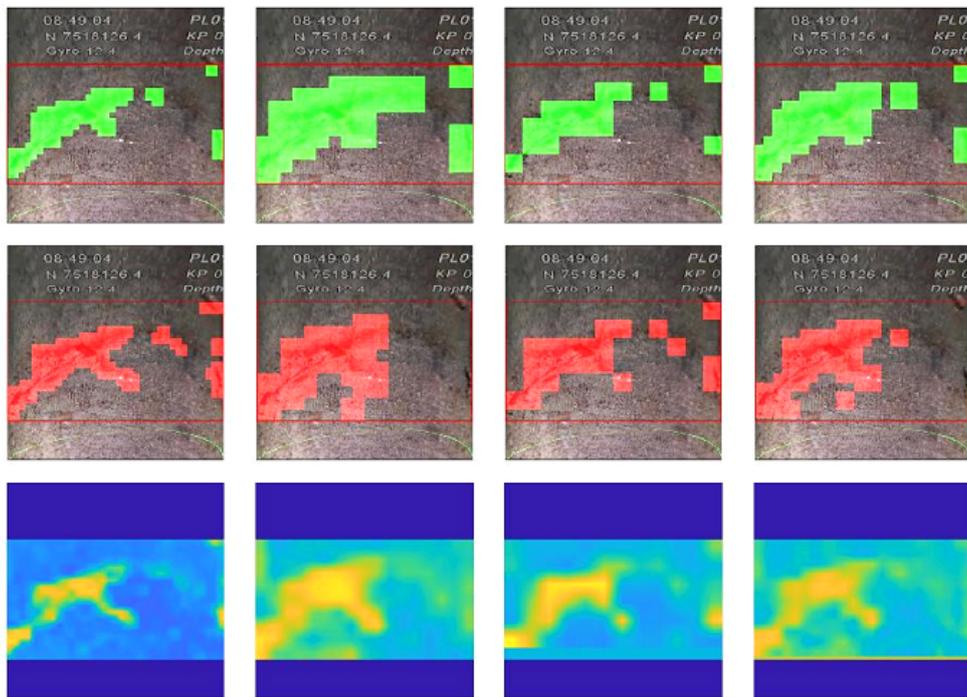


Figura 4.6: Segunda amostra positiva de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.

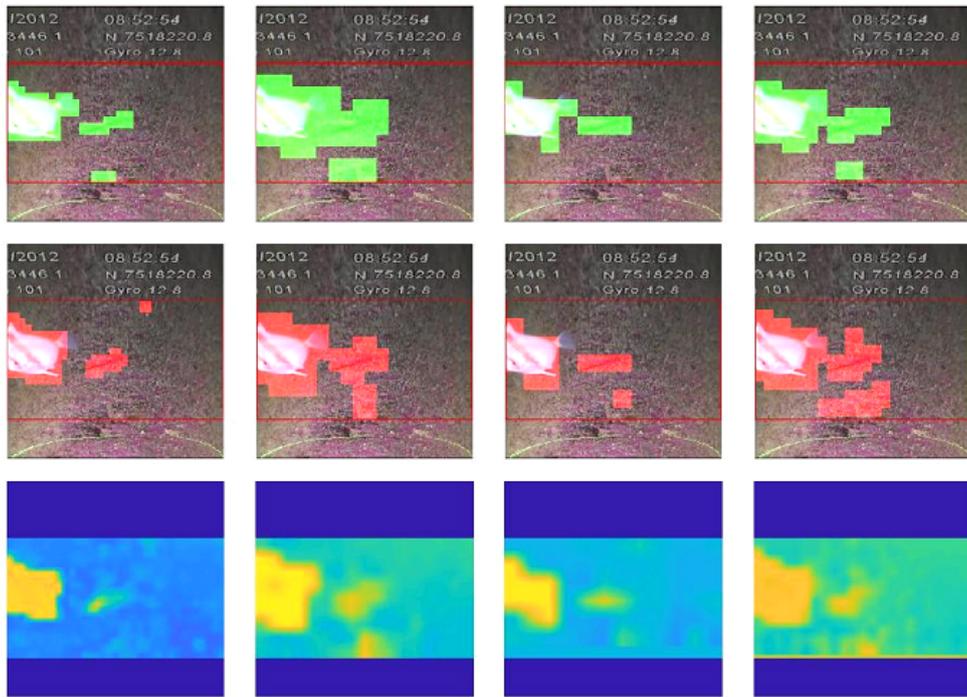


Figura 4.7: Terceira amostra positiva de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.

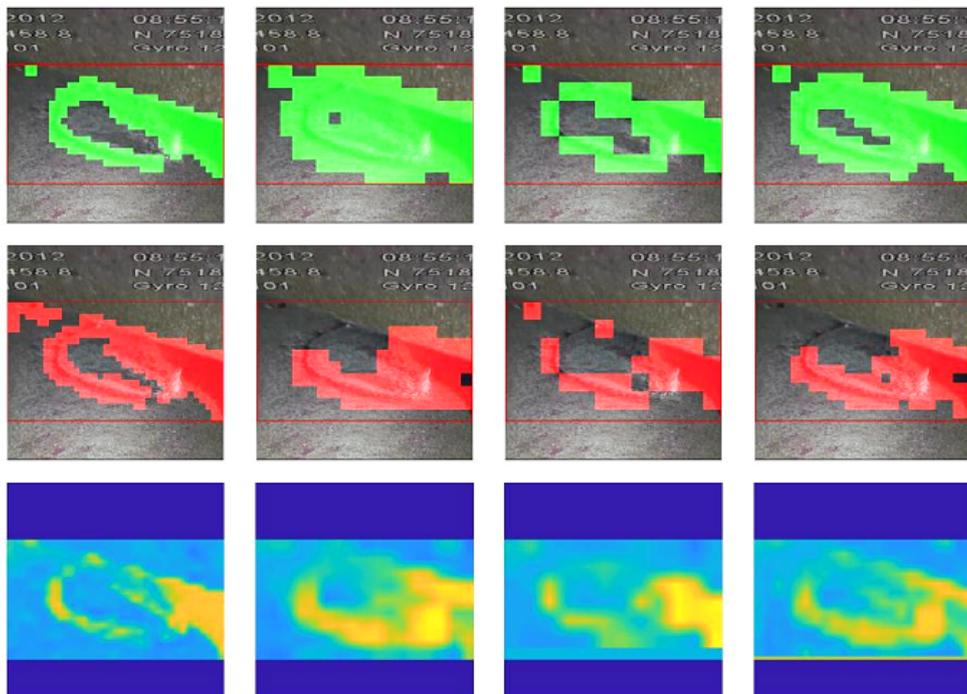


Figura 4.8: Quarta amostra positiva de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.

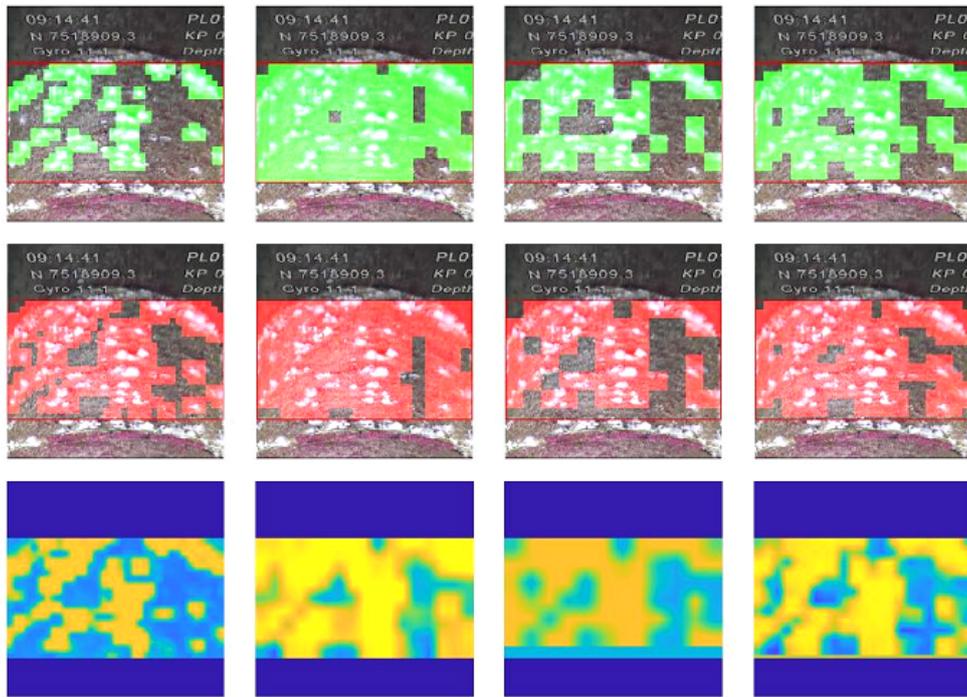


Figura 4.9: Quinta amostra positiva de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.

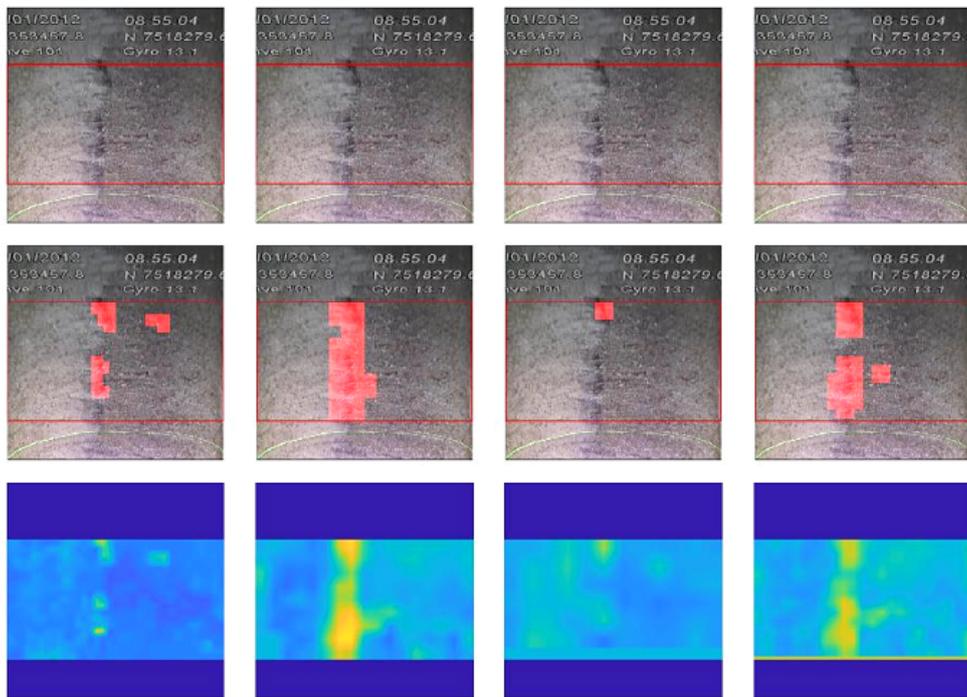


Figura 4.10: Primeira amostra negativa de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.

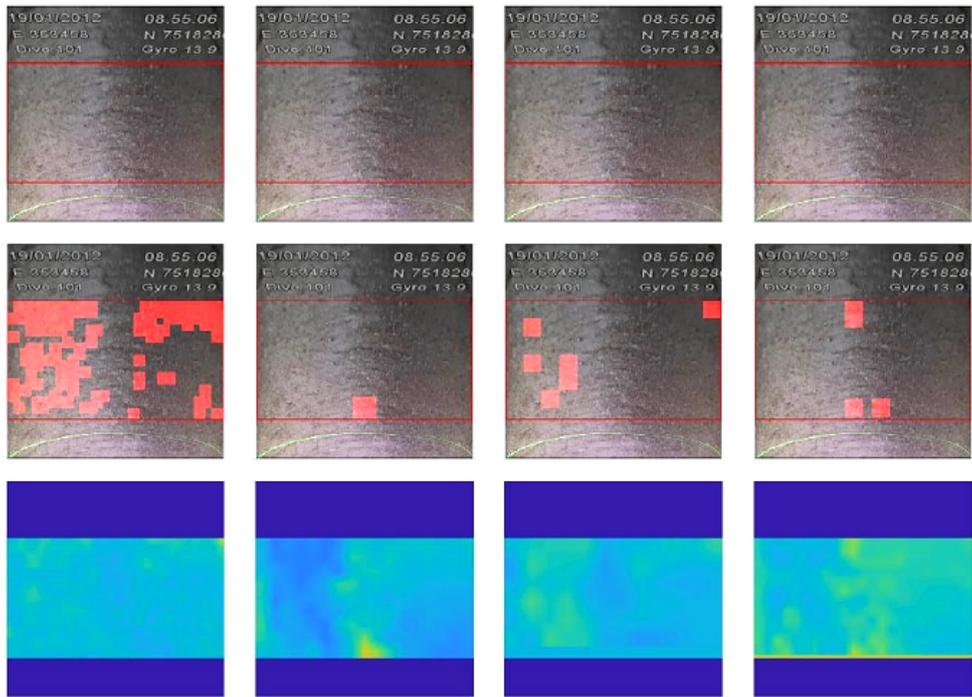


Figura 4.11: Segunda amostra negativa de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.

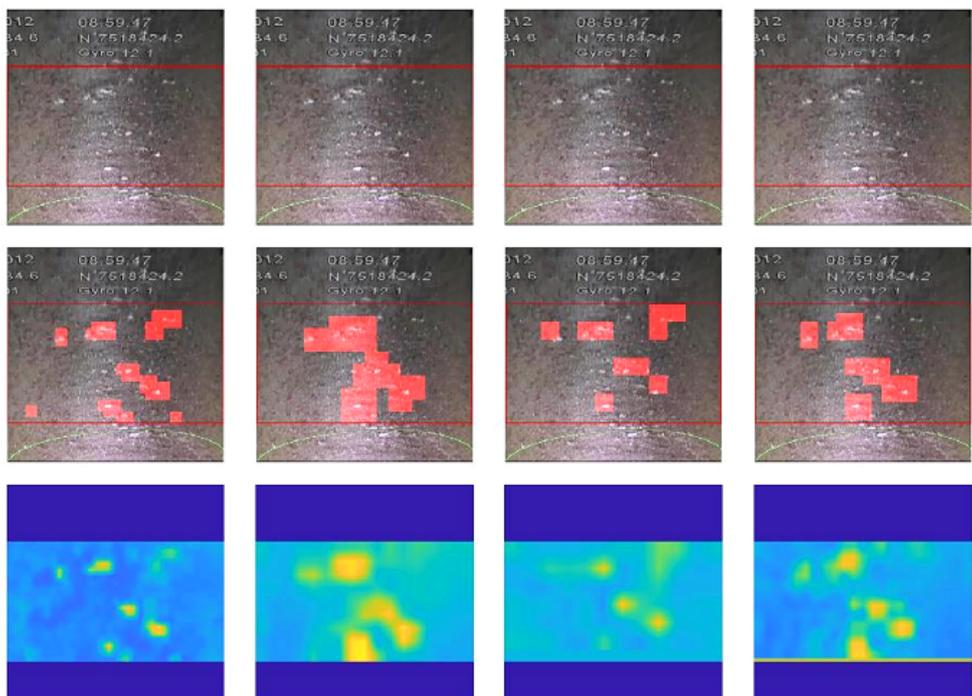


Figura 4.12: Terceira amostra negativa de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.

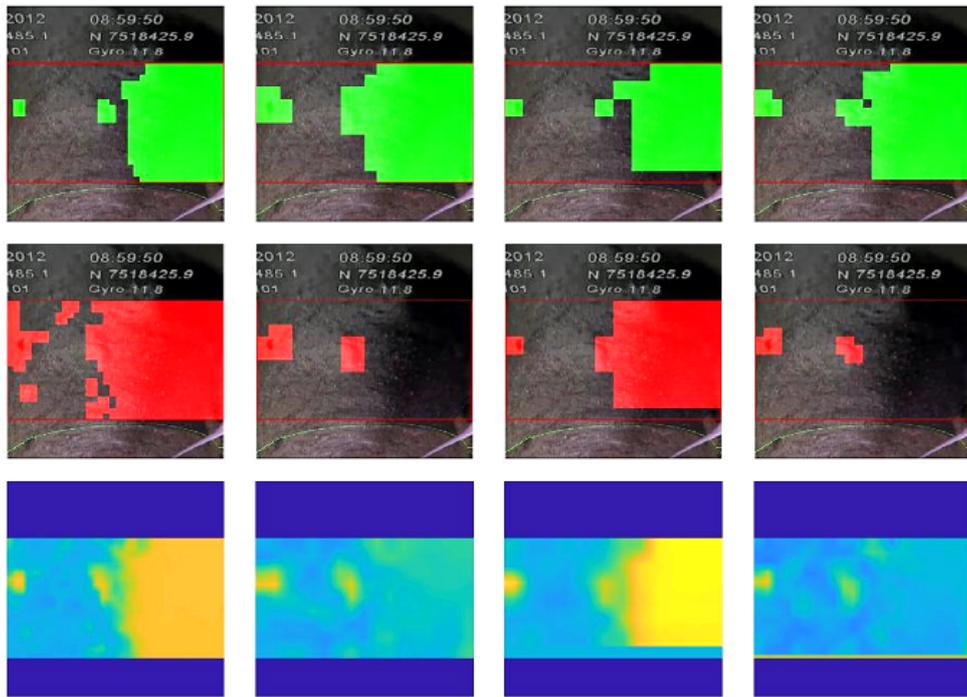


Figura 4.13: Quarta amostra negativa de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.

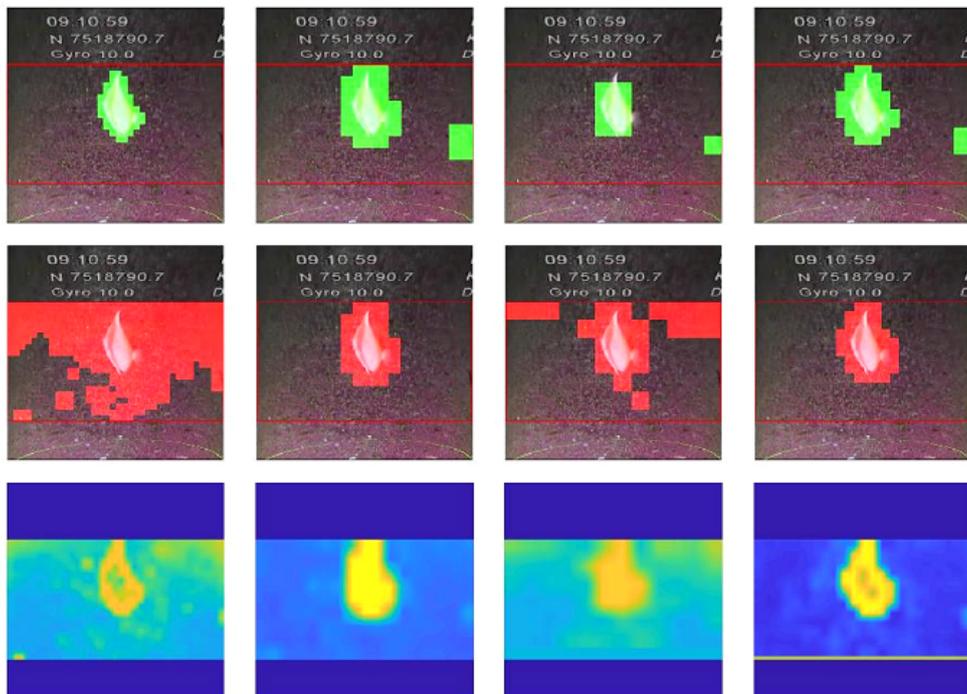


Figura 4.14: Quinta amostra negativa de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.

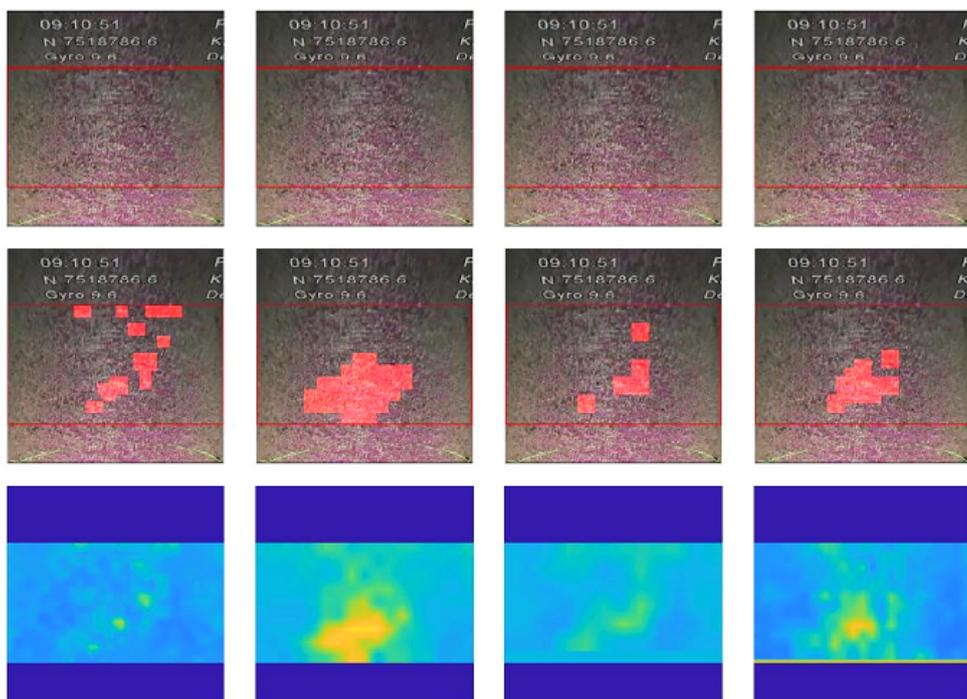


Figura 4.15: Sexta amostra negativa de detecção de anomalias aplicada aos dados de treinamento para TFP de 5%.

Ponto de Operação 1 - Teste

Os resultados para os dados de teste apresentaram os mesmos traços que foram observados na fase de treinamento, isto é, todos os algoritmos apresentam desempenho semelhante na correta detecção das anomalias, conforme ilustrado nas Figuras 4.16 até 4.23). Além disso, conforme disposto nas Figuras 4.24 até 4.29, também apresentaram problemas de detecção em ambientes com variação grande variação de luminosidade. Esses problemas ocorreram em ambientes onde a imagem é homogênea, o que pode indicar que os atributos foram microestruturas que são incorretamente pontuadas com os detectores de anomalias globais.

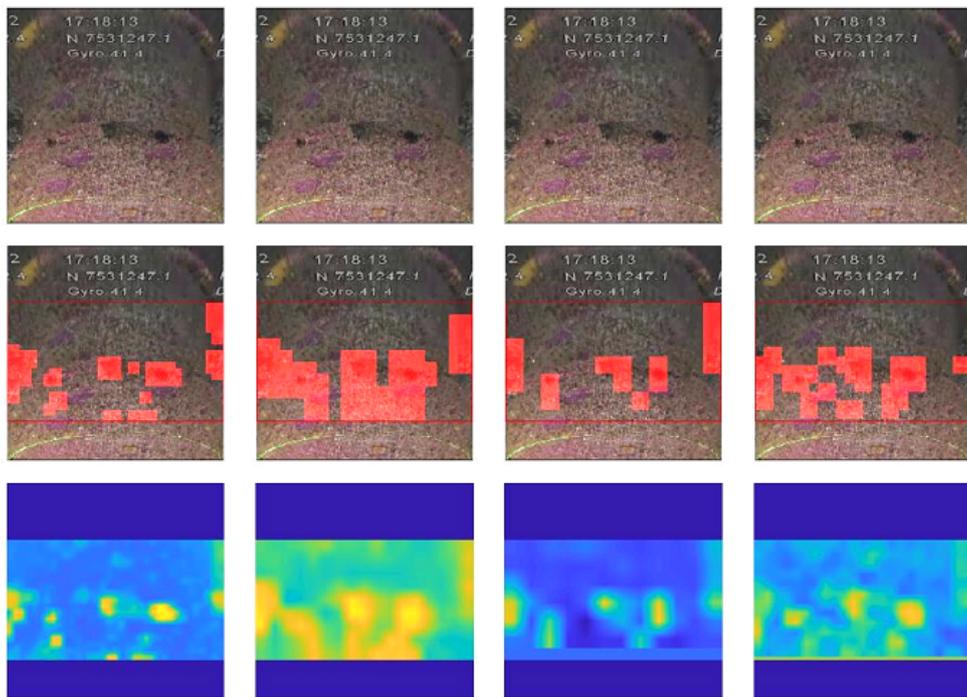


Figura 4.16: Primeira amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

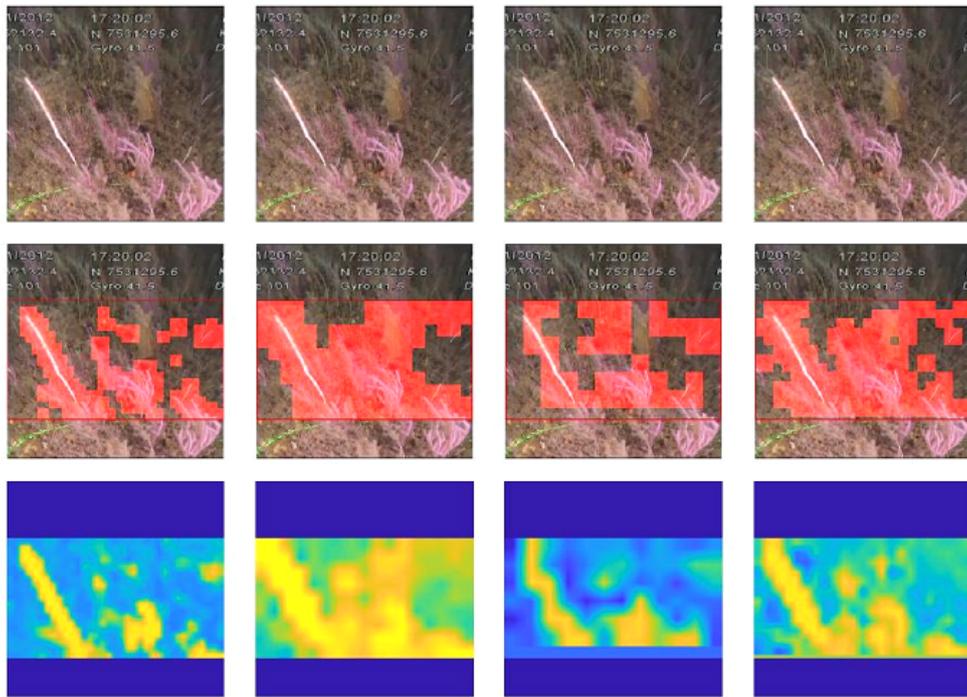


Figura 4.17: Segunda amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

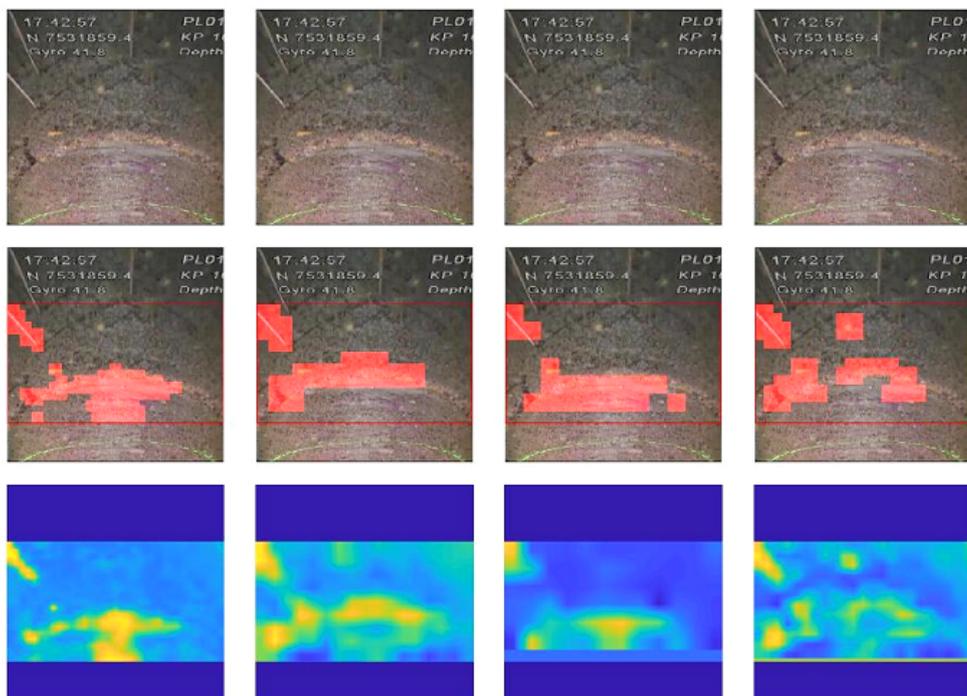


Figura 4.18: Terceira amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

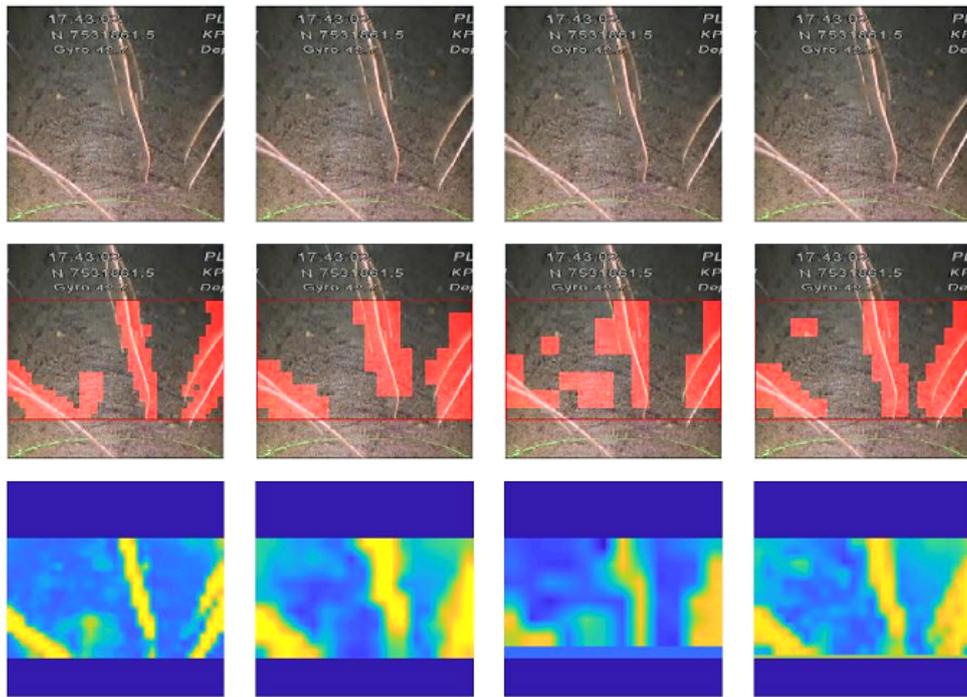


Figura 4.19: Quarta amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

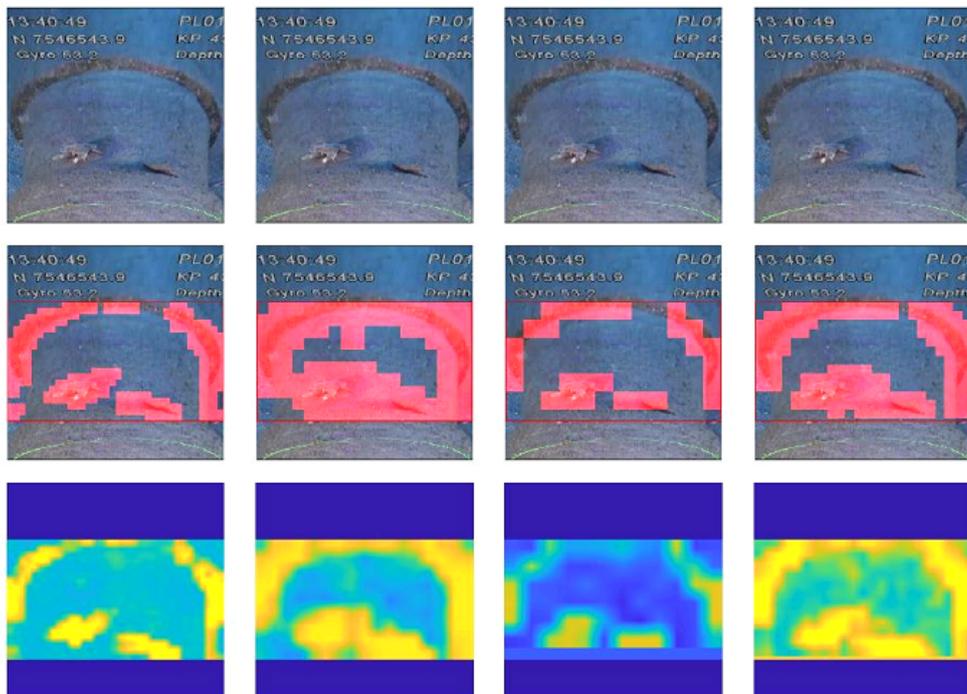


Figura 4.20: Quinta amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

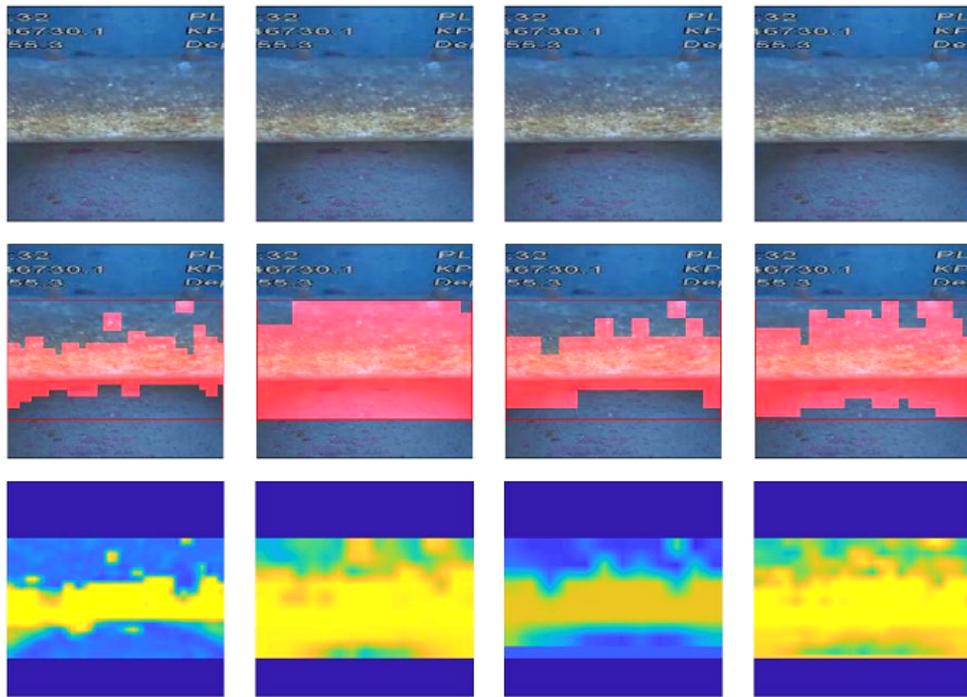


Figura 4.21: Sexta amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

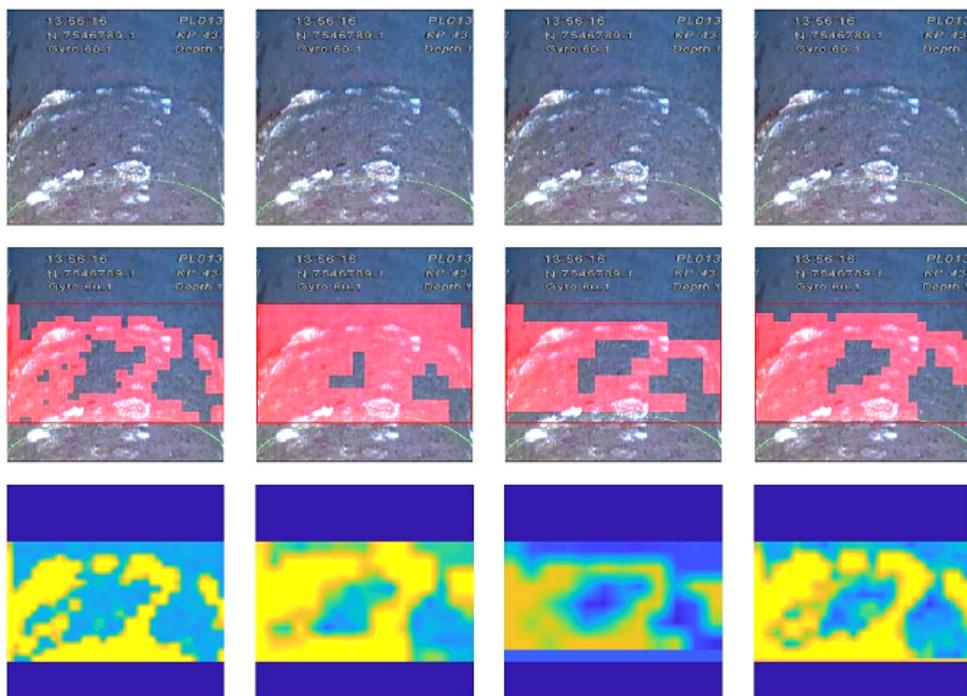


Figura 4.22: Sétima amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

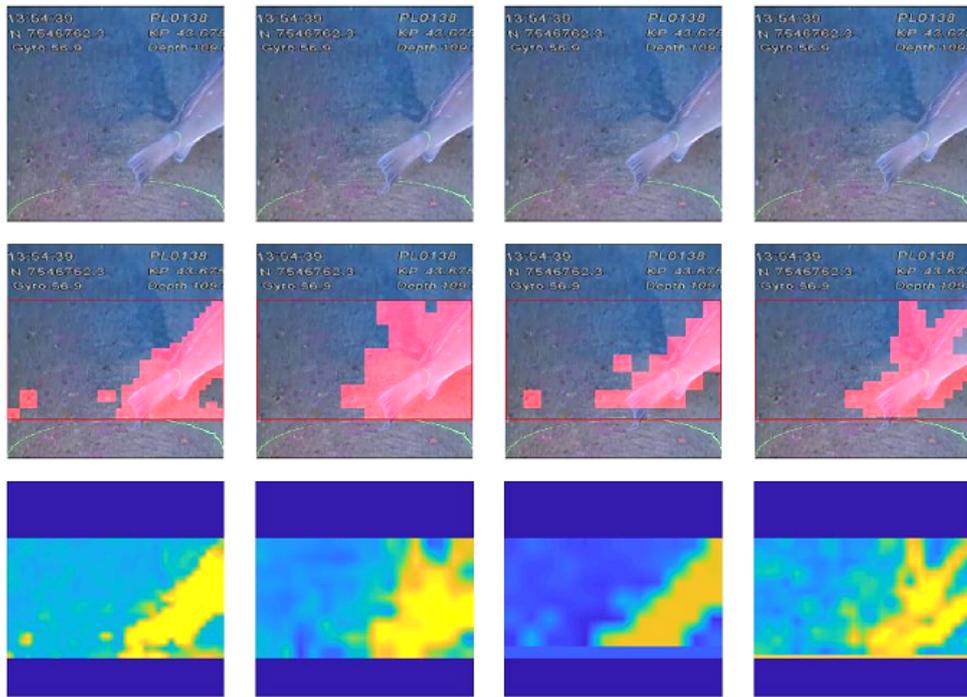


Figura 4.23: Oitava amostra positiva de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

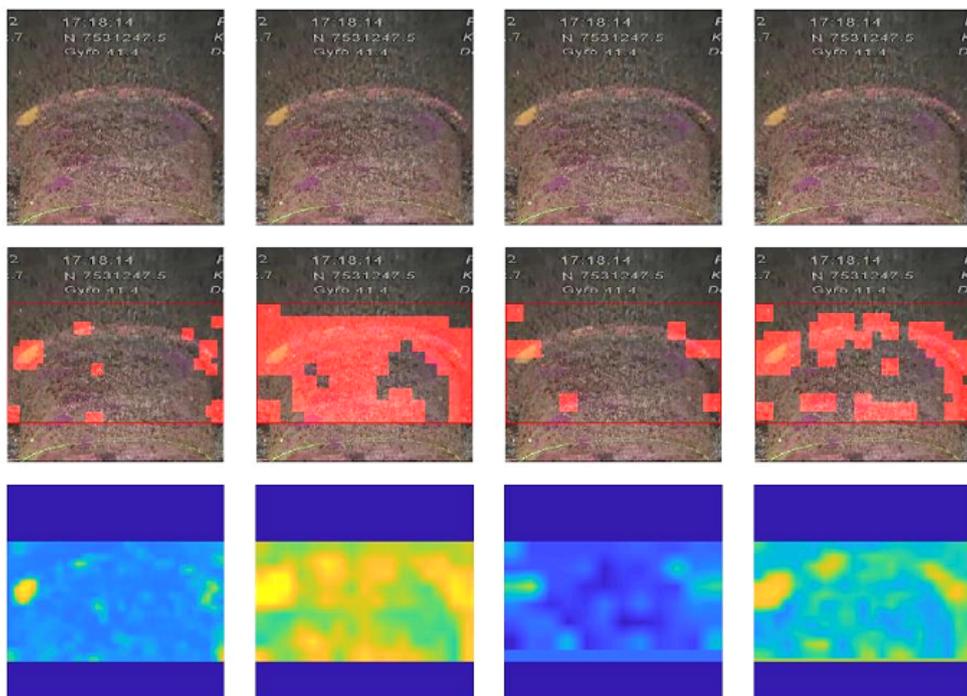


Figura 4.24: Primeira amostra negativa de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

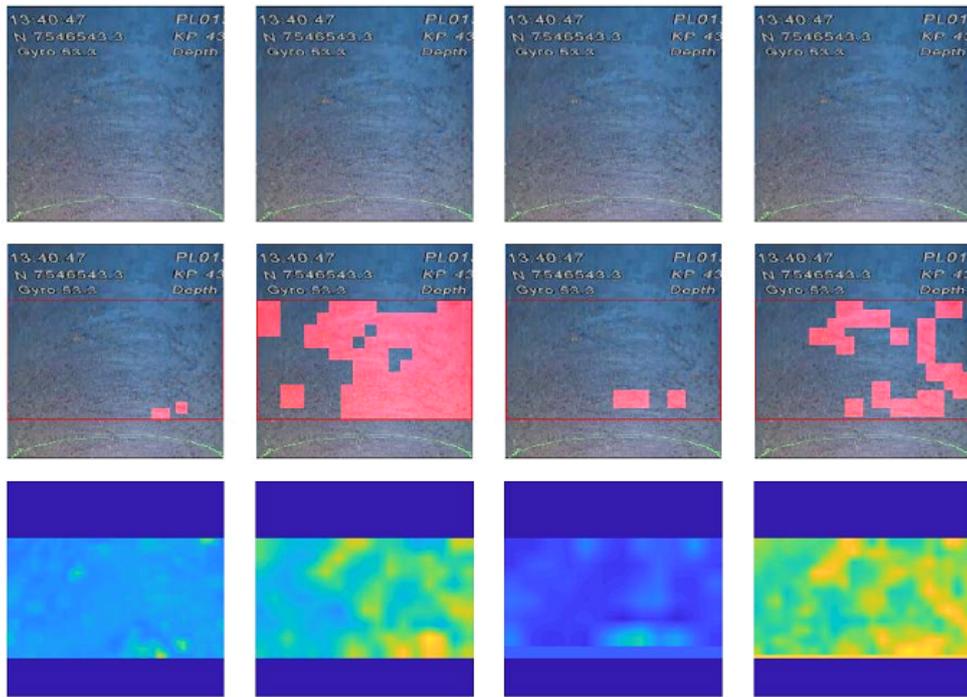


Figura 4.25: Segunda amostra negativa de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

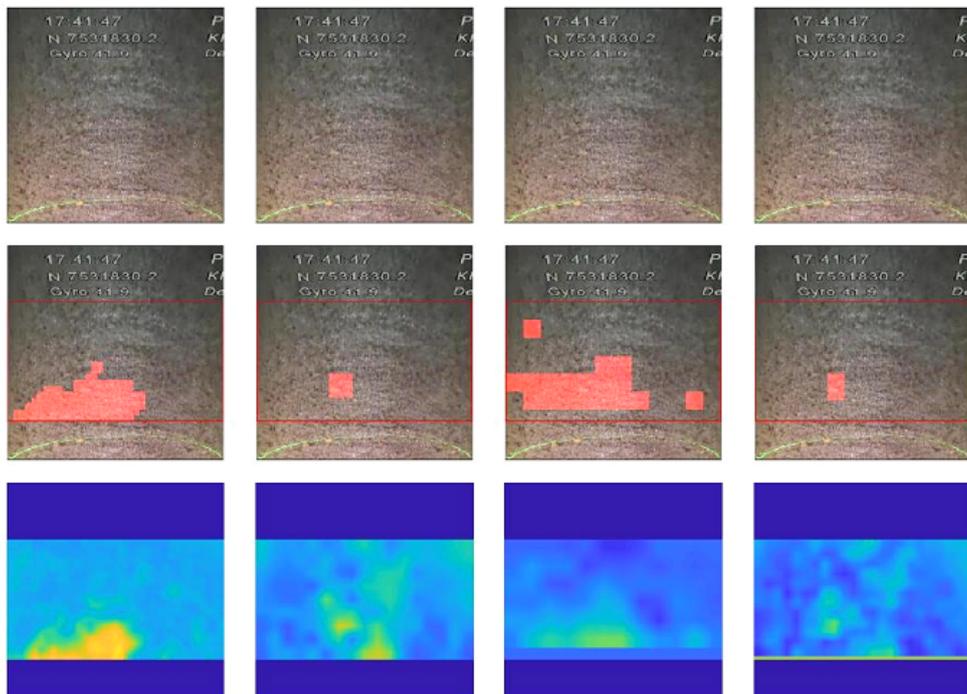


Figura 4.26: Terceira amostra negativa de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

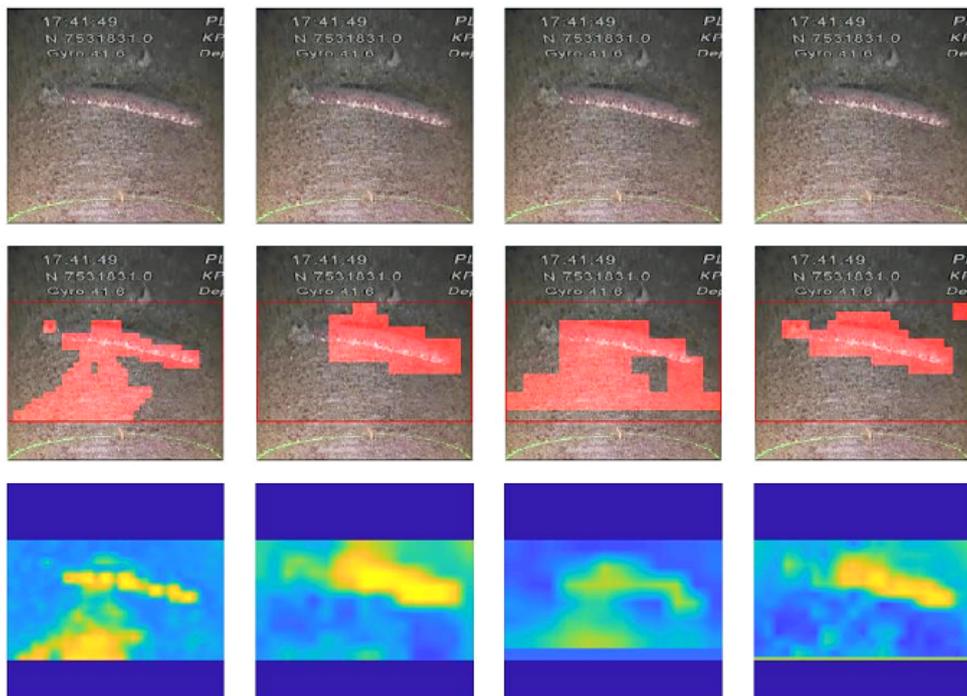


Figura 4.27: Quarta amostra negativa de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

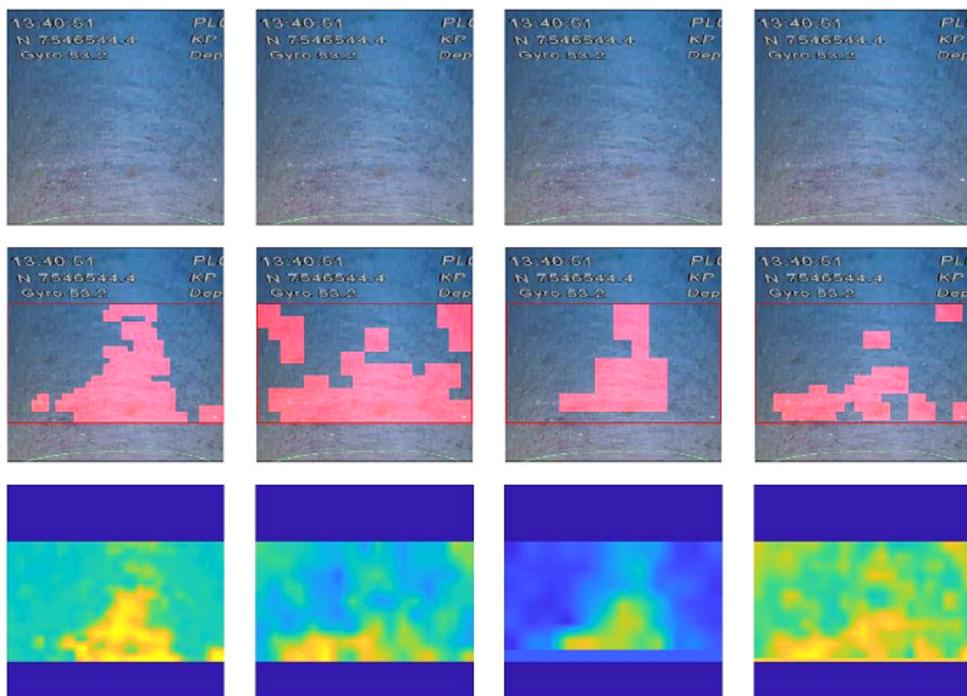


Figura 4.28: Quinta amostra negativa de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

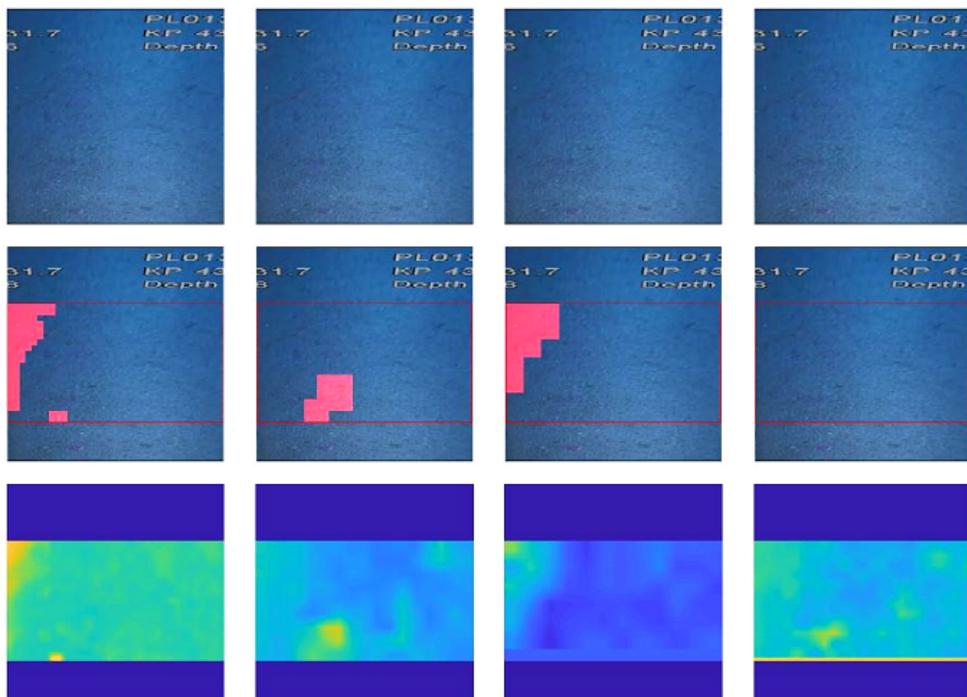


Figura 4.29: Sexta amostra negativa de detecção de anomalias aplicada aos dados de teste para TFP de 5%.

Ponto de Operação 2 - Treinamento e Teste

Independentemente do ponto de operação escolhido, as pontuações de anomalia permanecem as mesmas. A diferença, portanto, está nos resultados binários de classificação de anomalias resultantes da escolha do limiar de detecção. O propósito da avaliação de algoritmos que definam limiares automáticos é a verificação da capacidade de livrar o usuário da tarefa de escolha de limiares arbitrários, ou, na pior das hipóteses, é a definição de um valor inicial que sirva como limite superior na detecção de anomalias.

Os resultados para os dados de treinamento (Figuras 4.30 e 4.31) e de teste (Figuras 4.32 a 4.35) estão apresentados de maneira conjunta a seguir e demonstram que os algoritmos 2 e 4 são mais sensíveis à utilização de limiares automáticos, produzindo muitos falsos alarmes. Esse resultado era esperado para os dados de treinamento, conforme indicado pela alta TFP da Tabela 4.5.

Através das imagens de mapa de calor da Figura 4.30, é possível notar que os algoritmos 2 e 4 produzem muitos falsos alarmes em cenas homogêneas. Além disso, mesmo havendo pontos de calor intenso nas imagens, o resultado das detecções são muito amplos, conforme ilustrado nas Figuras 4.31 à 4.35. Por último, nota-se que sensibilidade desses algoritmos é maior nas filmagens de teste nas quais os dutos possuem tonalidade azulada (Figuras 4.34 e 4.35).

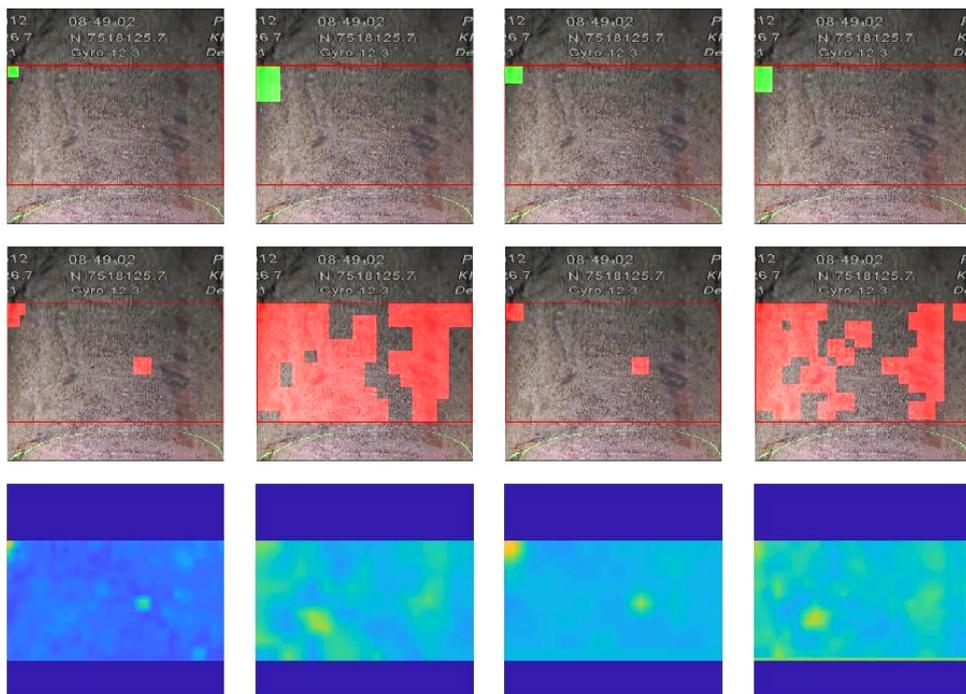


Figura 4.30: Primeira amostra de detecção de anomalias aplicada aos dados de treinamento para TFP automática.

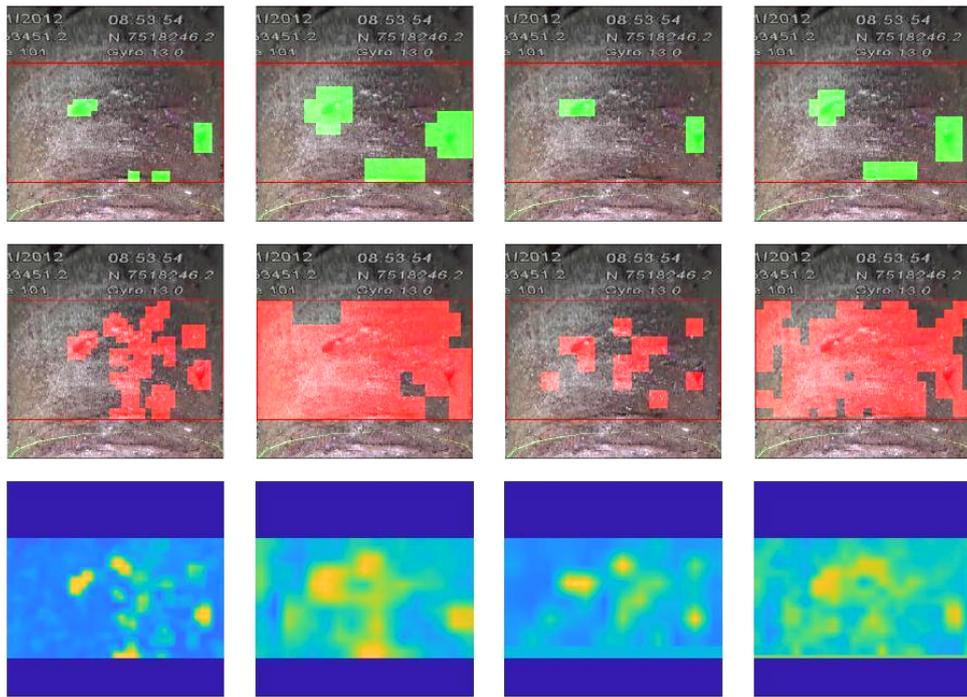


Figura 4.31: Segunda amostra de detecção de anomalias aplicada aos dados de treinamento para TFP automática.

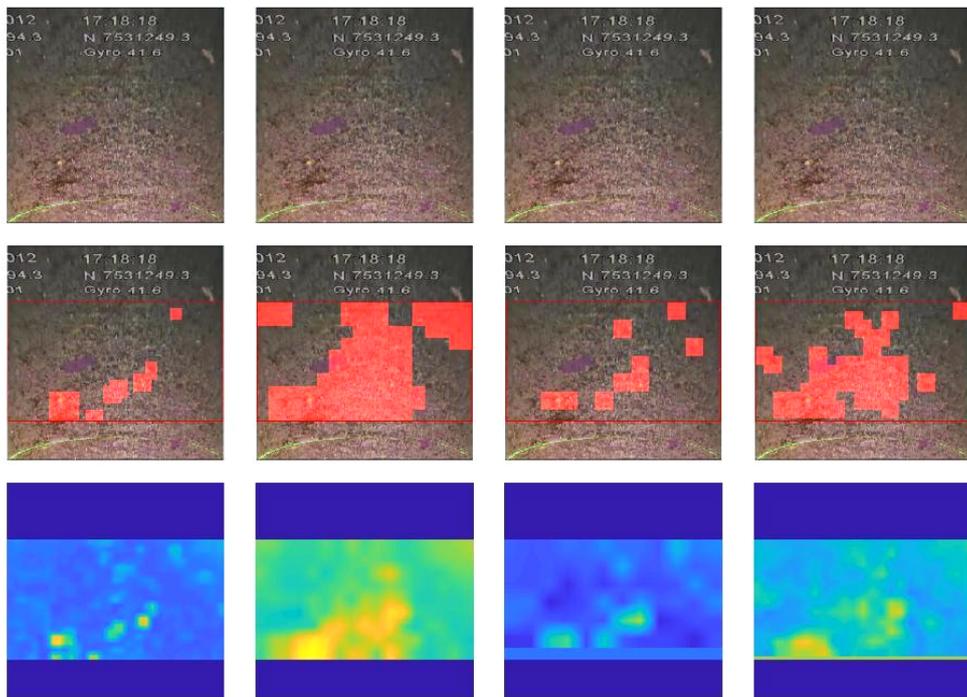


Figura 4.32: Primeira amostra de detecção de anomalias aplicada aos dados de teste para TFP automática.

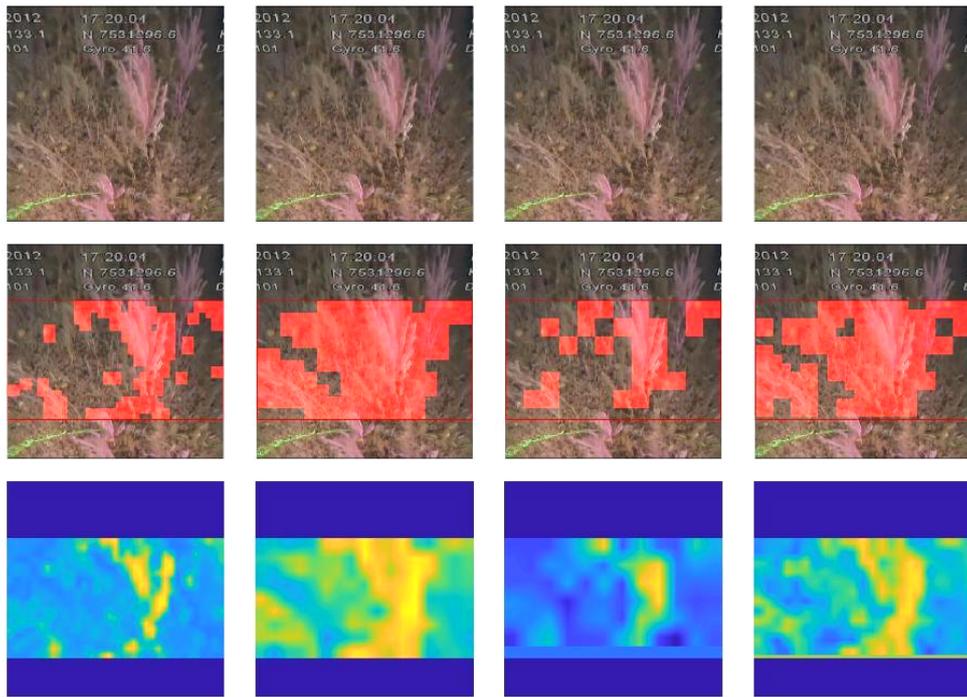


Figura 4.33: Segunda amostra de detecção de anomalias aplicada aos dados de teste para TFP automática.

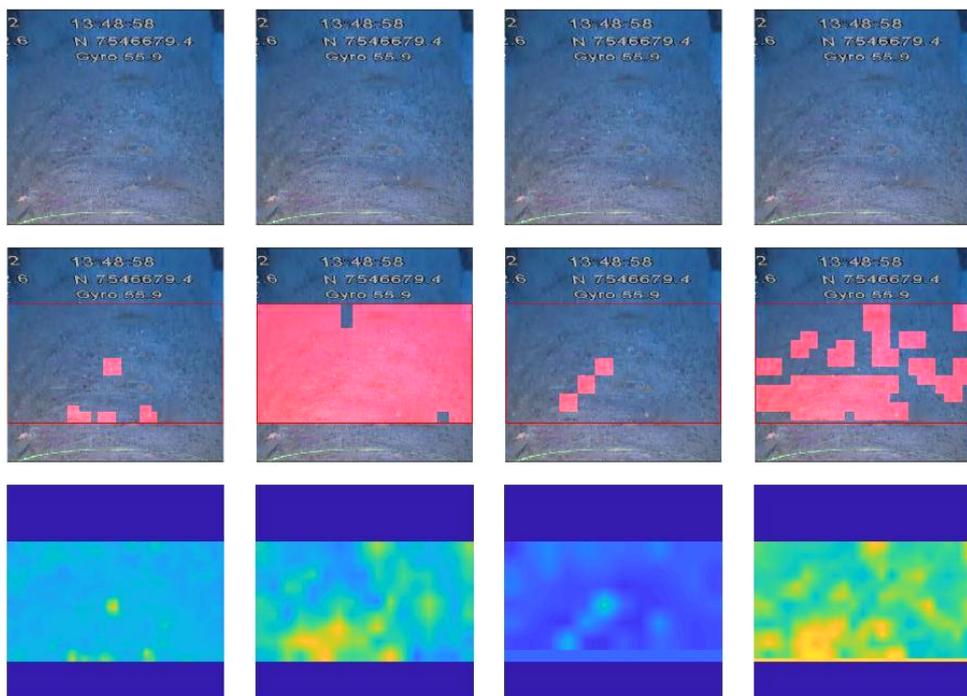


Figura 4.34: Terceira amostra de detecção de anomalias aplicada aos dados de teste para TFP automática.

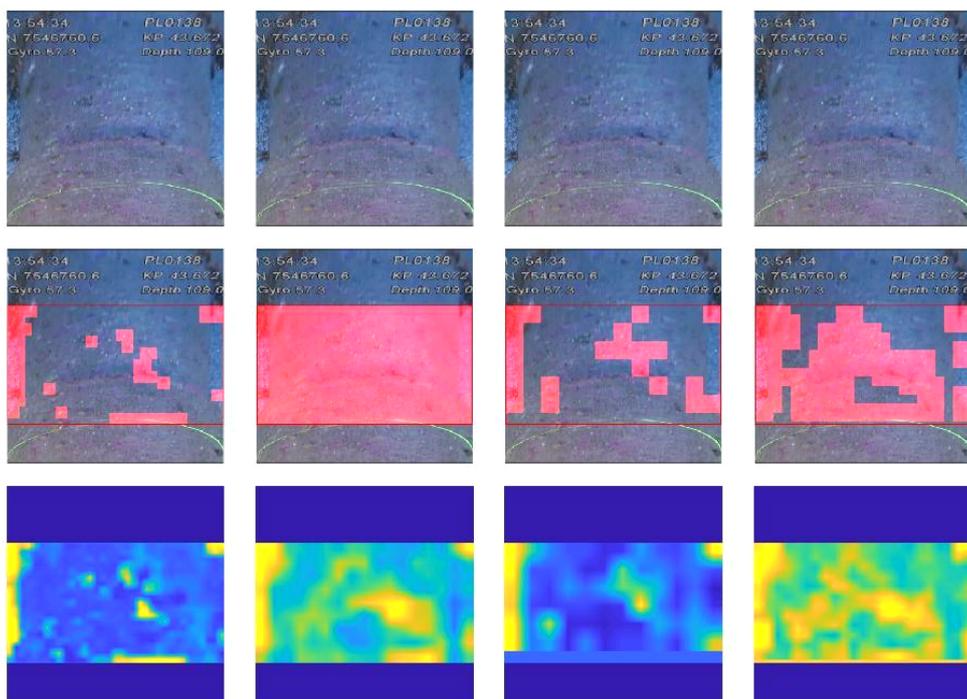


Figura 4.35: Quarta amostra de detecção de anomalias aplicada aos dados de teste para TFP automática.

Capítulo 5

Conclusões

Neste trabalho foram apresentados os conceitos e técnicas mais comumente utilizados na detecção não-supervisionada de anomalias e como eles puderam ser aplicados na detecção de regiões de interesse em vídeos de inspeção de dutos submarinos.

Inicialmente, as imagens dos dutos foram preparadas para a localização das anomalias através da remoção da distorção de perspectiva do duto seguida da segmentação de fragmentos de imagens. Esses fragmentos serviram de base para a extração de atributos com intenção de criar um espaço de observações densas que representam padrões comumente observados. Dessa forma, observações que se distanciem desse conjunto-padrão terão maior probabilidade de serem classificadas como anômalas.

Em seguida, através de classificadores não-supervisionados, que, em sua grande maioria, foram baseados em distância ou densidade, foi possível a atribuição de pontuações para os atributos capazes de realçar a diferença entre casos muito observados de casos pouco observados.

Posteriormente, com a pontuação de anomalias e a escolha de um limiar, foi possível a classificação binária das anomalias que, em conjunto com as imagens binárias das anomalias geradas das anotações manuais, viabilizou a construção de gráficos que puderam ser utilizados como medida de desempenho entre diferentes estratégias de classificação de anomalias.

Finalmente, a aplicação dos melhores algoritmos de detecção de anomalia nos vídeos de teste, que apresentam imagens bastante diferentes das imagens de treinamento, demonstrou a capacidade das técnicas apresentadas de revelar detalhes incomuns nas imagens.

A etapa de verificação de desempenho dos diferentes algoritmos só foi possível através da anotação manual das anomalias nas imagens de treinamento. Visto que essa base de dados de anotações é pequena e não possui as mesmas características dos dados de teste, há a necessidade da expansão da base de dados de treinamento, com anotações das anomalias, para aprimorar a qualidade dos testes. Essa fase poderia ser executada por mais de um anotador, para que casos falhos não influenciem

grandemente no resultado da classificação, e deve incluir grande variedade de vídeos. Além disso, com essa inclusão, outros algoritmos de classificação poderão ser investigados, como por exemplo redes neurais profundas (*deep learning*), que necessitam de uma extensa base de treino para operar corretamente.

Uma decisão de projeto adotada nesse trabalho foi a remoção da distorção perspectiva das imagens dos dutos, que foi feita apenas para padronizar as imagens em quadrados de tamanho fixo. Há a possibilidade da obtenção de fragmentos da imagem ao longo das linhas internas ao duto que possuem o mesmo ponto focal que suas bordas.

Como foi observado nos resultados, as pontuações de anomalias são sensíveis ao valor do limiar global utilizado. A escolha inadequada dessa variável pode provocar a perda de muitas detecções, inclusive entre quadros adjacentes, ou fazer com que muitos falsos alarmes dominem a cena. Como trabalho futuro, seria interessante a adoção de limiares locais a cada quadro para tentar resolver esses problemas.

Outra investigação interessante para trabalhos futuros seria a combinação de atributos e escalas de fragmentos de imagens diferentes para incorporar os pontos fortes de cada configuração e reduzir a quantidade de falsos alarmes gerados.

Cabe ressaltar que as técnicas introduzidas neste trabalho têm intuito de detectar as anomalias apresentadas no vídeo, e não obter qualquer tipo de classificação sobre os tipos de anomalia. Esse fato, aliado à possibilidade de detecção de inúmeros falsos positivos, faz com que essas detecções possam ser beneficiadas por uma etapa de pós-processamento para separar os casos de maior interesse de detecções falhas.

O algoritmo que obteve melhor pontuação na métrica de AUC da ROC utilizou como atributo as estatísticas de primeira ordem de média, variância e valor máximo de fragmentos de imagem de tamanho e passo, respectivamente, 40 e 20 píxeis. Como classificador utilizou o OCSVM-M de memória $M = 1$, com parâmetro $\nu = 0,1$ e taxa de substituição de dados no modelo de 1%.

Esse algoritmo obteve pontuação de 0,953 de para um valor máximo igual a 1, apresentando TVP de 85,81% para uma TFP de 5% obtida através da seleção manual de um limiar de classificação. Adicionalmente, com a escolha automática do limiar de classificação, obteve TVP de 89,54% para uma TFP de apenas 7,90%. Esses resultados, aliados às imagens do vídeo de teste apresentadas no Capítulo 4, demonstram que é possível a utilização desse algoritmo de sem intervenção inicial do usuário na escolha de um limiar de classificação de anomalias.

Por último, é importante notar que as técnicas utilizadas são simples o suficiente para serem utilizadas em sistemas embarcados e seu uso resultaria na redução do número de imagens a serem analisadas por um especialista. O limiar automático poderia ser utilizado inicialmente e reduzido pelo operador até atingir um ponto de operação adequado para a aplicação.

Referências Bibliográficas

- [1] MAI, C., PEDERSEN, S., HANSEN, L., et al. “Subsea Infrastructure Inspection: A Review Study”, *Proceedings of IEEE 6th International Conference on Underwater System Technology: Theory and Applications (USYS)*, pp. 71—76, 2016.
- [2] YAZDCHI, M., YAZDI, M., MAHYARI, A. G. “Steel Surface Defect Detection Using Texture Segmentation Based on Multifractal Dimension”, *2009 International Conference on Digital Image Processing*, mar. 2009.
- [3] GUO, Y., SUN, Z., SUN, H., et al. “Texture feature extraction of steel strip surface defect based on gray level co-occurrence matrix”, *2015 International Conference on Machine Learning and Cybernetics (ICMLC)*, jul. 2015.
- [4] NISKANEN, M., SILVÉN, O., KAUPPINEN, H. “Color and Texture Based Wood Inspection with Non-Supervised Clustering”. In: *Proceedings of the 12th Scandinavian Conference on Image Analysis*, pp. 336—342, 2001.
- [5] COHEN, F. S., FAN, Z., ATTALI, S. “Automated Inspection of Textile Fabrics Using Textural Models”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 13, n. 8, pp. 803–808, ago. 1991.
- [6] KUMAR, A., SHANMUGAM, K., DINSTEN, I. “Computer-Vision-Based Fabric Defect Detection: A Survey”, *IEEE Transactions on Industrial Electronics*, v. 55, n. 1, pp. 348–363, jan. 2008.
- [7] NGAN, H. Y. T., PANG, G. K. H., YUNG, N. H. C. “Automated Fabric Defect Detection - A Review”, *Image and Vision Computing*, v. 29, n. 7, pp. 433–498, jun. 2011.
- [8] CHAMBON, S., MOLIARD, J. M. “Automatic Road Pavement Assessment with Image Processing : Review and Comparison”, *International Journal of Geophysics*, 2011.
- [9] MARQUES, A. G. C. S. *Automatic Road Pavement Crack Detection Using SVM*. MSc. dissertation, Universidade Técnica de Lisboa, 2012.

- [10] O'BYRNE, M., SCHOEFS, F., GHOSH, B., et al. "Texture Analysis Based Damage Detection of Ageing Infrastructural Elements", *Computer-Aided Civil and Infrastructure Engineering*, v. 28, n. 3, pp. 162—77, 2013.
- [11] CHA, Y. J., CHOI, W., BUYUKOZTURK, O. "Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks", *Computer-Aided Civil and Infrastructure Engineering*, v. 32, n. 5, pp. 361—78, 2017.
- [12] TSAI, D. M., HUANG, T. Y. "Automated Surface Inspection for Statistical Textures", *Image and Vision computing*, v. 21, n. 4, pp. 307–323, abr. 2003.
- [13] XIE, X., MIRMEHDI, M. "TEXEMS: Texture Exemplars for Defect Detection on Random Textured Surfaces", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 29, n. 8, pp. 1454–1464, jun. 2007.
- [14] XIE, X. "A review of recent advances in surface defect detection using texture analysis techniques", *Electronic Letters on Computer Vision and Image Analysis*, v. 7, pp. 1–22, 2008.
- [15] SINDAGI, V. A., SRIVASTAVA, S. "Oled Panel Defect Detection Using Local Inlier-Outlier Ratios and Modified LBP", *International Conference on Machine Vision Applications*, 2015.
- [16] REN, R., HUNG, T., TAN, K. C. "A Generic Deep-Learning-Based Approach for Automated Surface Inspection", *IEEE Transactions on Cybernetics*, v. 48, n. 3, pp. 929–940, 2018.
- [17] FORESTI, G. L. "Visual Inspection of Sea Bottom Structures by an Autonomous Underwater Vehicle", *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, v. 31, n. 5, pp. 691–705, out. 2001.
- [18] NA, W. B., KUNDU, T. "Underwater Pipeline Inspection Using Guided Waves", *Journal of Pressure Vessel Technology*, v. 124, n. 2, 2002.
- [19] PETRAGLIA, F. R. *Classification of Underwater Pipeline Events Using Deep Convolutional Neural Networks*. MSc. dissertation, Universidade Federal do Rio de Janeiro, 2017.
- [20] HARALICK, R. M., SHANMUGAM, K., DINSTEN, I. "Textural Features for Image Classification", *IEEE Transactions on Systems, Man, and Cybernetics*, v. SMC-3, n. 6, pp. 610–621, nov. 1973.

- [21] HARALICK, R., SHAPIRO, L. *Computer and Robot Vision: Vol. 1*. Addison-Wesley, 1992.
- [22] OJALA, T., PIETIKÄINEN, M., HARWOOD, D. “A Comparative Study of Texture Measures with Classification Based on Featured Distribution”, *Pattern Recognition*, v. 29, n. 1, pp. 51–59, 1996.
- [23] OJALA, T., PIETIKÄINEN, M., MÄENPÄÄ, T. “Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 24, n. 7, pp. 971–987, jul. 2002.
- [24] LIAO, S., ZHU, X., LEI, Z., et al. “Learning Multi-Scale Block Local Binary Patterns for Face Recognition”, *Proc. International Conference on Biometrics*, pp. 828–837, 2007.
- [25] ZHAO, G., PIETIKAINEN, M. “Dynamic Texture Recognition Using Local Binary Patterns with an Application to Facial Expressions”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007.
- [26] DAUGMAN, J. G. “Uncertainty Relations for Resolution in Space, Spatial Frequency, and Orientation Optimized by Two-Dimensional Visual Cortical Filters”, *Journal of the Optical Society of America A*, v. 2, pp. 1160–1169, 1985.
- [27] JAIN, A. K., FARROKHNI, F. “Unsupervised Texture Segmentation Using Gabor Filters”, *Pattern Recognition*, v. 24, n. 12, pp. 1167–1186, 1991.
- [28] KUMAR, A., PANG, G. K. H. “Defect Detection in Textured Materials Using Gabor Filters”, *IEEE Transactions on Industry Applications*, v. 38, n. 2, pp. 425–440, abr. 2002.
- [29] PETROU, M., SEVILLA, P. G. *Image Processing: Dealing with Texture*. 1 ed., Wiley, 2006.
- [30] TURK, M., PENTLAND, A. “Eigenfaces for Recognition”, *Journal of Cognitive Neuroscience*, v. 3, n. 1, pp. 71–86, 1991.
- [31] CANDS, E., LI, X., MA, Y., et al. “Robust Principal Component Analysis?” *Journal of the ACM (JACM)*, dez. 2009.
- [32] RAHMANI, M., ATIA, G. K. “Coherence Pursuit: Fast, Simple, and Robust Principal Component Analysis”, *IEEE Transactions on Signal Processing*, v. 65, n. 23, pp. 71–86, dez. 2017.

- [33] GOLDSTEIN, M., UCHIDA, S. “A comparative Evaluation of Unsupervised Anomaly Detection Algorithms for Multivariate Data”, *PLoS One*, v. 11, n. 4, abr. 2016.
- [34] PIMENTEL, M. A. F., CLIFTON, D. A., CLIFTON, L., et al. “A Review of Novelty Detection”, *Signal Processing (2014)*, pp. 215–249, 2014.
- [35] KIRAN, B. R., THOMAS, D. M., PARAKKAL, R. “An Overview of Deep Learning Based Methods for Unsupervised and Semi-Supervised Anomaly Detection in Videos”, *Journal of Imaging*, v. 4, n. 2, pp. 36–60, 2018.
- [36] ANS H. P. KRIEGEL, M. M. B., NG, R. T., SANDER, J. “LOF: Identifying Density-Based Local Outliers”. In: *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*, p. 93–104, Dallas, Texas, USA, 2000.
- [37] GOLDSTEIN, M., DENGEL, A. “Histogram-based Outlier Score (HBOS): A fast Unsupervised Anomaly Detection Algorithm”, *Wölfel S, editor. KI-2012: Poster and Demo Track. Online*, p. 59–63, 2012.
- [38] AMER, M., GOLDSTEIN, M., ABDENNADHER, S. “Enhancing One-class Support Vector Machines for Unsupervised Anomaly Detection”. In: *Proceedings of the ACM SIGKDD Workshop on Outlier Detection and Description (ODD’13)*, pp. 8–15, New York, NY, USA, 2013.
- [39] MAXION, R. A., ROBERTS, R. R. *Proper Use of ROC Curves in Intrusion/Anomaly Detection*. In: Report CS-TR-871, School of Computing Science, University of Newcastle upon Tyne, Claremont Tower, Claremont Road, Newcastle upon Tyne, NE1 7RU, UK, 2004.
- [40] AGGARWAL, C. C. *Data Mining: The Textbook*. 1 ed. , Springer, 2015.
- [41] FKI, F., OMRI, M. N. “Information Retrieval from Unstructured Web Text Document Based on Automatic Learning of the Threshold”, *International Journal of Information Retrieval Research*, v. 2, n. 4, pp. 12–30, 2012.

Apêndice A

Imagens de Treinamento e Teste da Aplicação Experimental

Este trabalho utilizou três filmagens diferentes de inspeção de dutos submarinos para a formação dos dados experimentais na detecção de anomalias. A primeira filmagem foi utilizada para gerar os dados de treinamento dos detectores de anomalia, enquanto que as outras duas filmagens foram utilizadas como dados de teste para verificação de desempenho dos algoritmos.

As filmagens foram segmentadas em sequências de dez segundos, com um total de sessenta quadros por sequência. Os dados de treinamento são compostos por dez sequências de imagens e os dados de teste possuem cinco sequências para cada filmagem.

As figuras a seguir apresentam amostras das anomalias das sequências de imagens usadas neste Trabalho. Em cada linha são ilustradas sete amostras das sessenta possíveis imagens de cada sequência.

Nas Figuras A.1 e A.2 são apresentadas, respectivamente, as imagens da filmagem usada como base de treinamento e as anotações de suas anomalias.

Na Figura A.3 são apresentadas conjuntamente as imagens das duas filmagens utilizadas como base para teste dos algoritmos de detecção de anomalia.

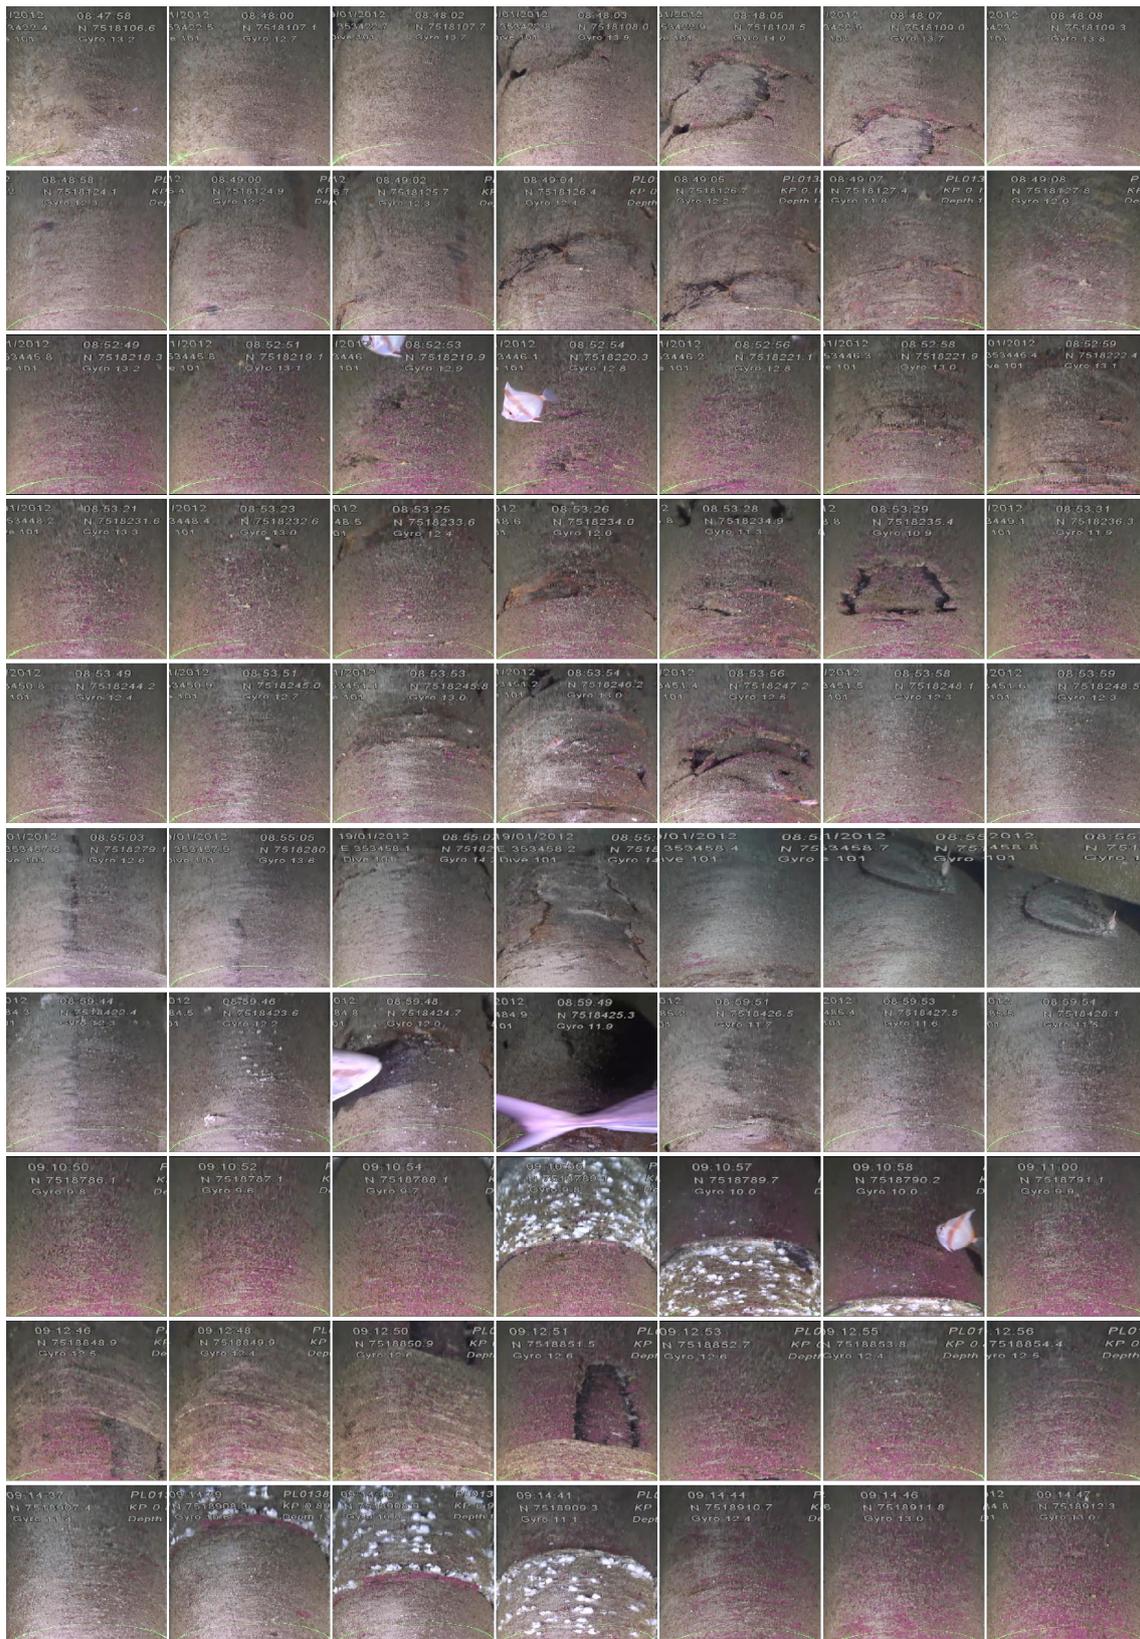


Figura A.1: Amostra das sequências de imagens usadas na fase de treinamento.

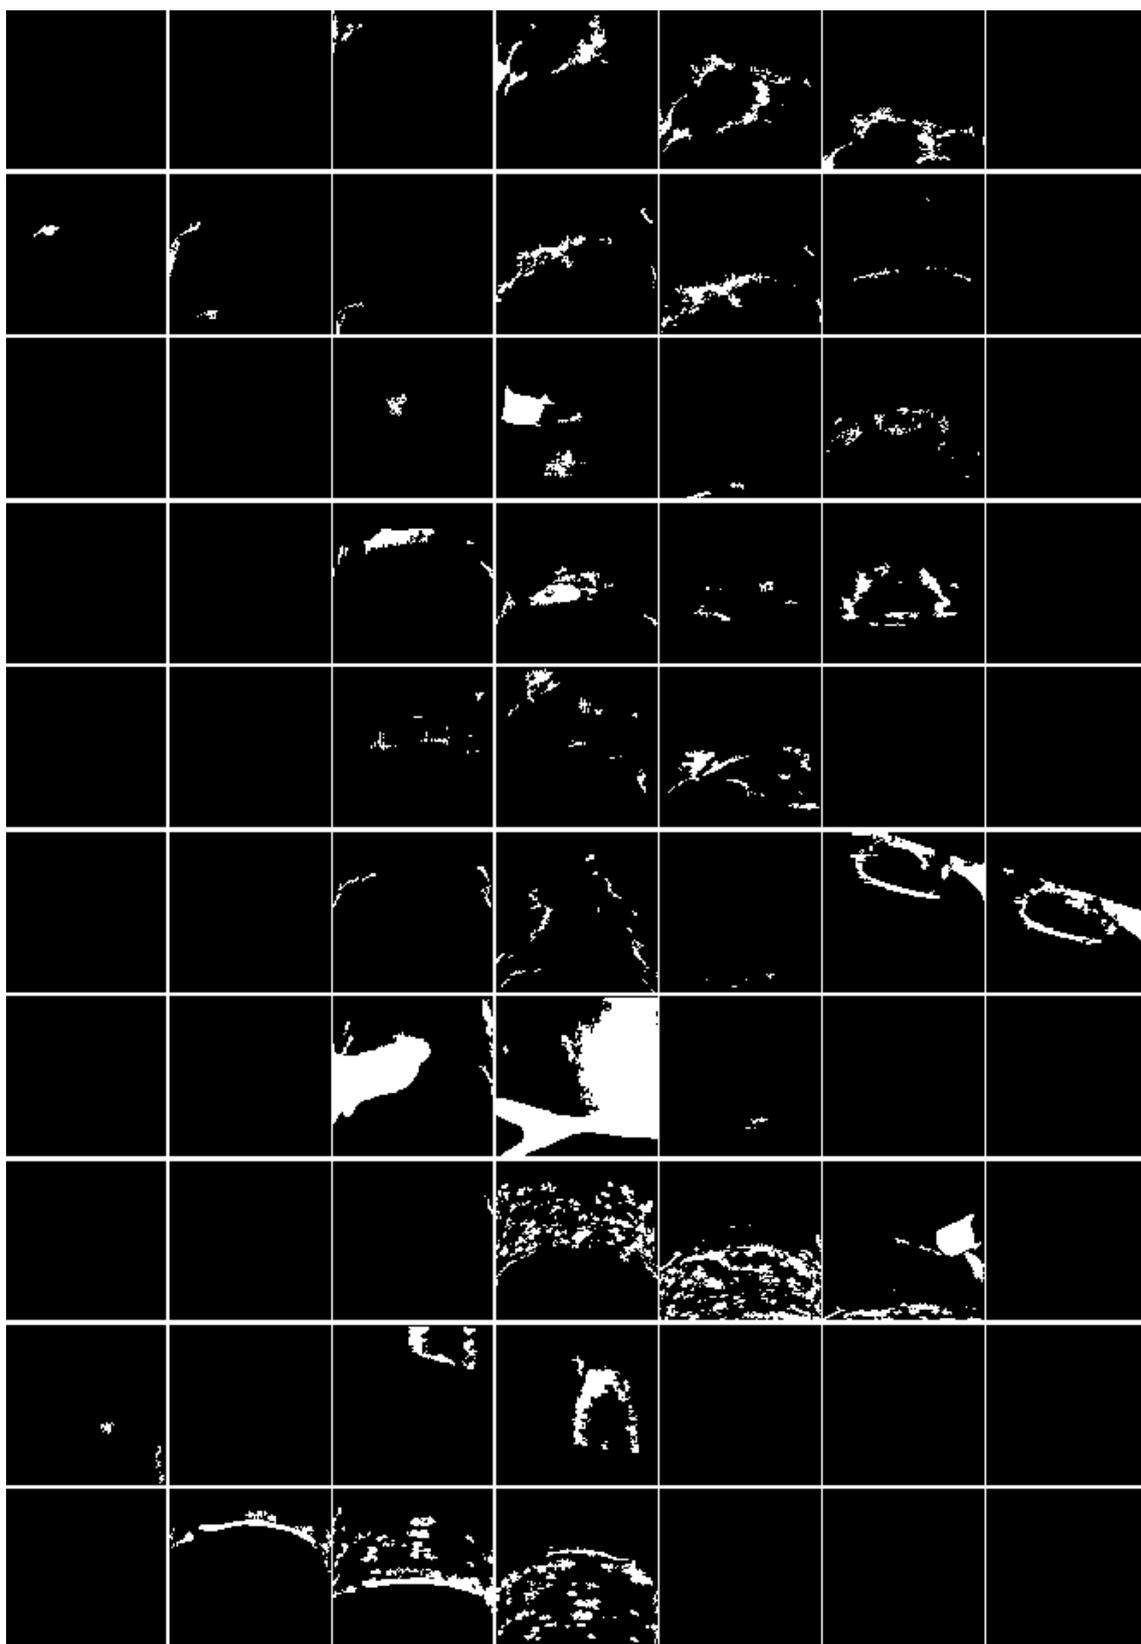


Figura A.2: Amostra das sequências de anotações de anomalias da sequência de treinamento.

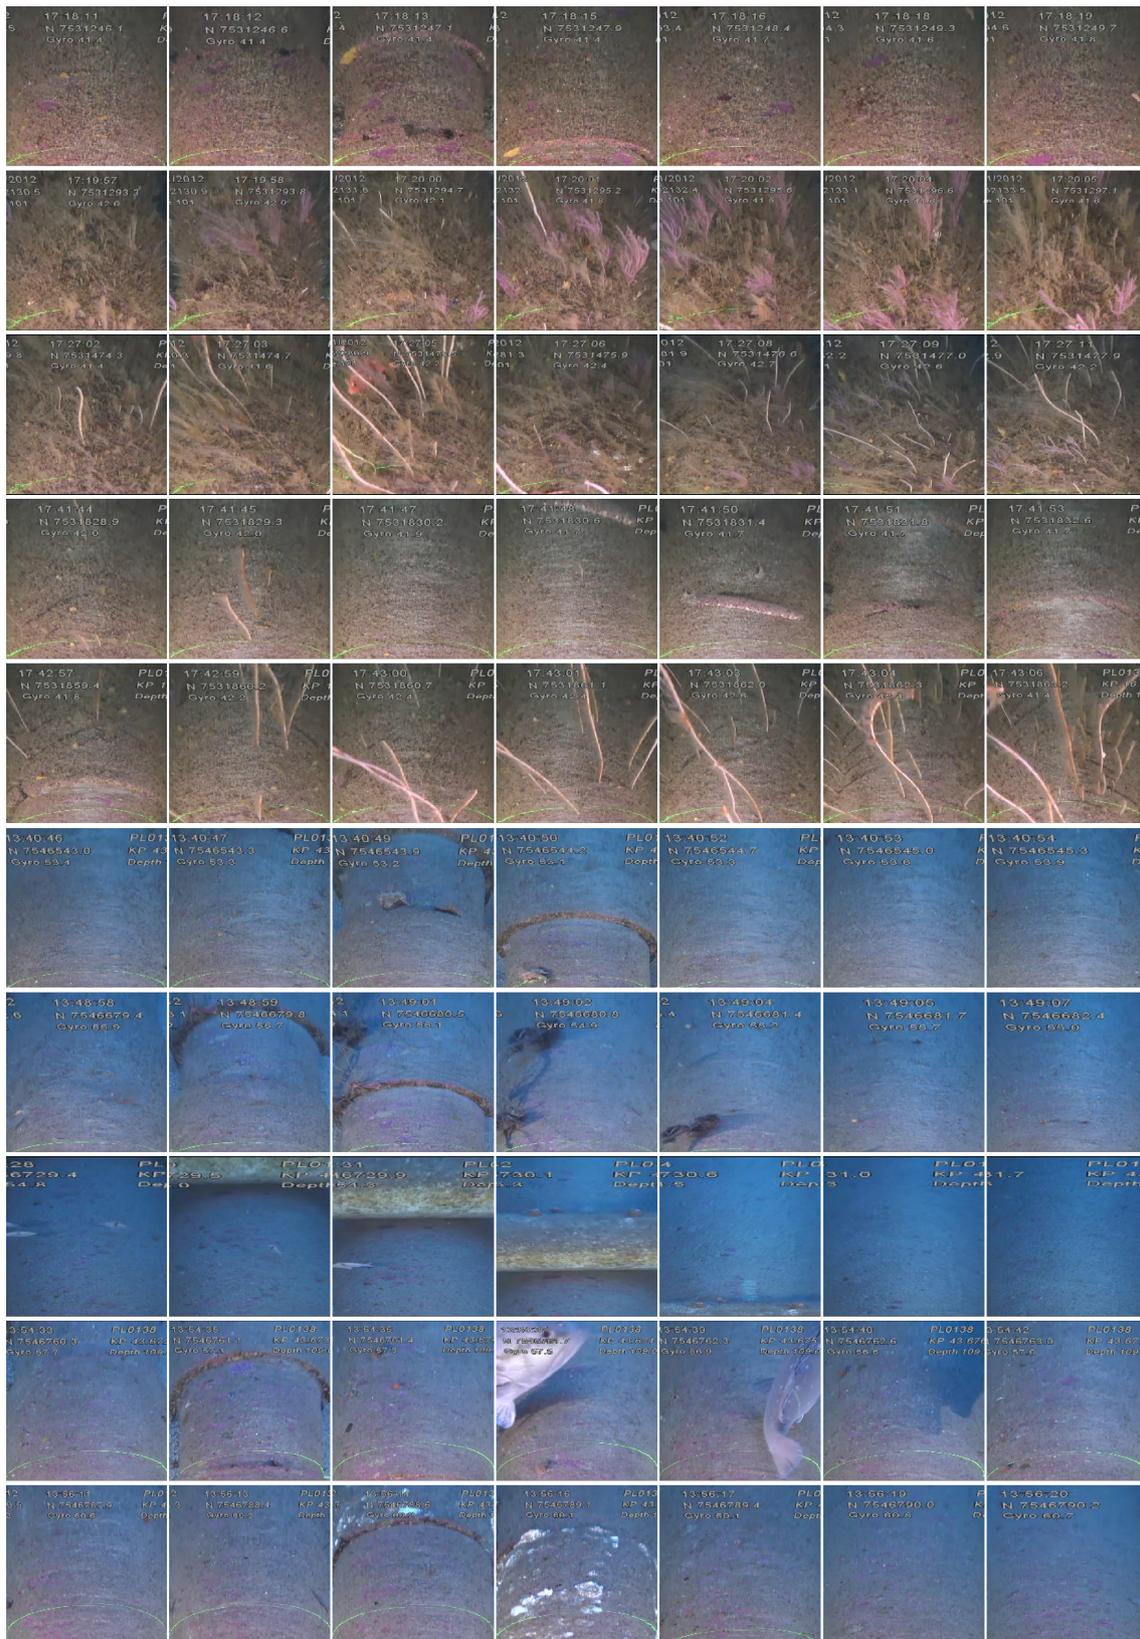


Figura A.3: Amostra das seqüências de imagens usadas na fase de teste.

Apêndice B

Imagens Resultantes da Aplicação Experimental

Neste apêndice são apresentadas amostras dos resultados de pontuação de anomalia das melhores configurações de detecção de anomalias, conforme apresentado no Capítulo 4. Essas configurações estão resumidas na Tabela B.1

Tabela B.1: Algoritmos com melhores resultados médios de AUC e p-AUC.

	Critério (Classificação)	Parâmetro dos Fragmentos de Imagem	Atributo	Detector
Algoritmo 1	AUC médio (1º lugar)	(40, 20)	STAT, média, variância e valor máximo	OCSVM-M, 1%
Algoritmo 2	AUC médio (2º lugar)	(80, 40)	PCA, 10 componentes principais	OCSVM-M, 2%
Algoritmo 3	p-AUC médio (1º lugar)	(60, 60)	STAT, média, variância e valor máximo	OCSVM-M, 1%
Algoritmo 4	p-AUC médio (2º lugar)	(60, 30)	PCA, 10 componentes principais	OCSVM-M, 6%

As sequências e quadros das imagens dos resultados de pontuação de anomalia seguem o mesmo modelo das Figuras apresentadas no Apêndice A. Nessas imagens, cores mais amareladas indicam maior pontuação de anomalia e cores azuladas indicam padrões comuns.

Nas Figuras B.1 à B.4 são apresentadas as imagens das pontuações de anomalia referentes às imagens de treinamento e nas B.5 à B.8 são apresentadas as imagens das pontuações de anomalia referentes às imagens de teste. Em ambos os casos, a disposição das Figuras respeitam a ordem de configurações apresentadas na Tabela anterior.

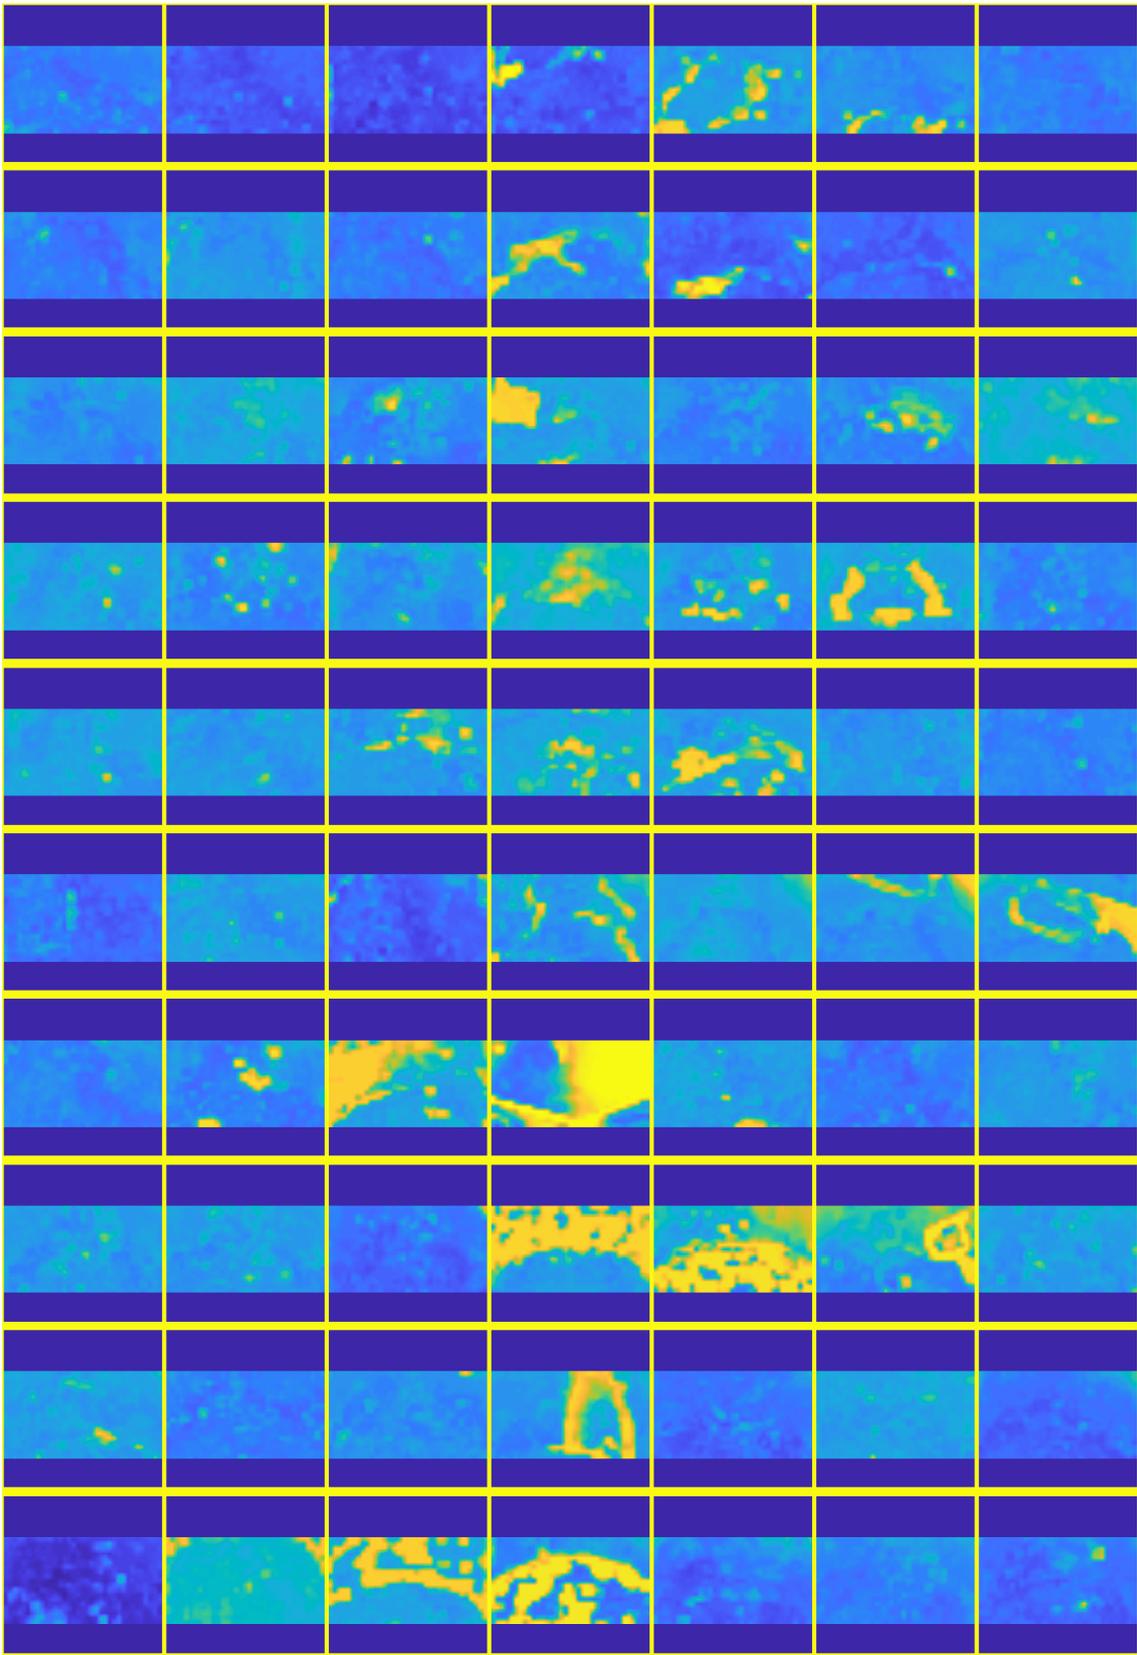


Figura B.1: Amostra das seqüências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 1 às imagens de treinamento.

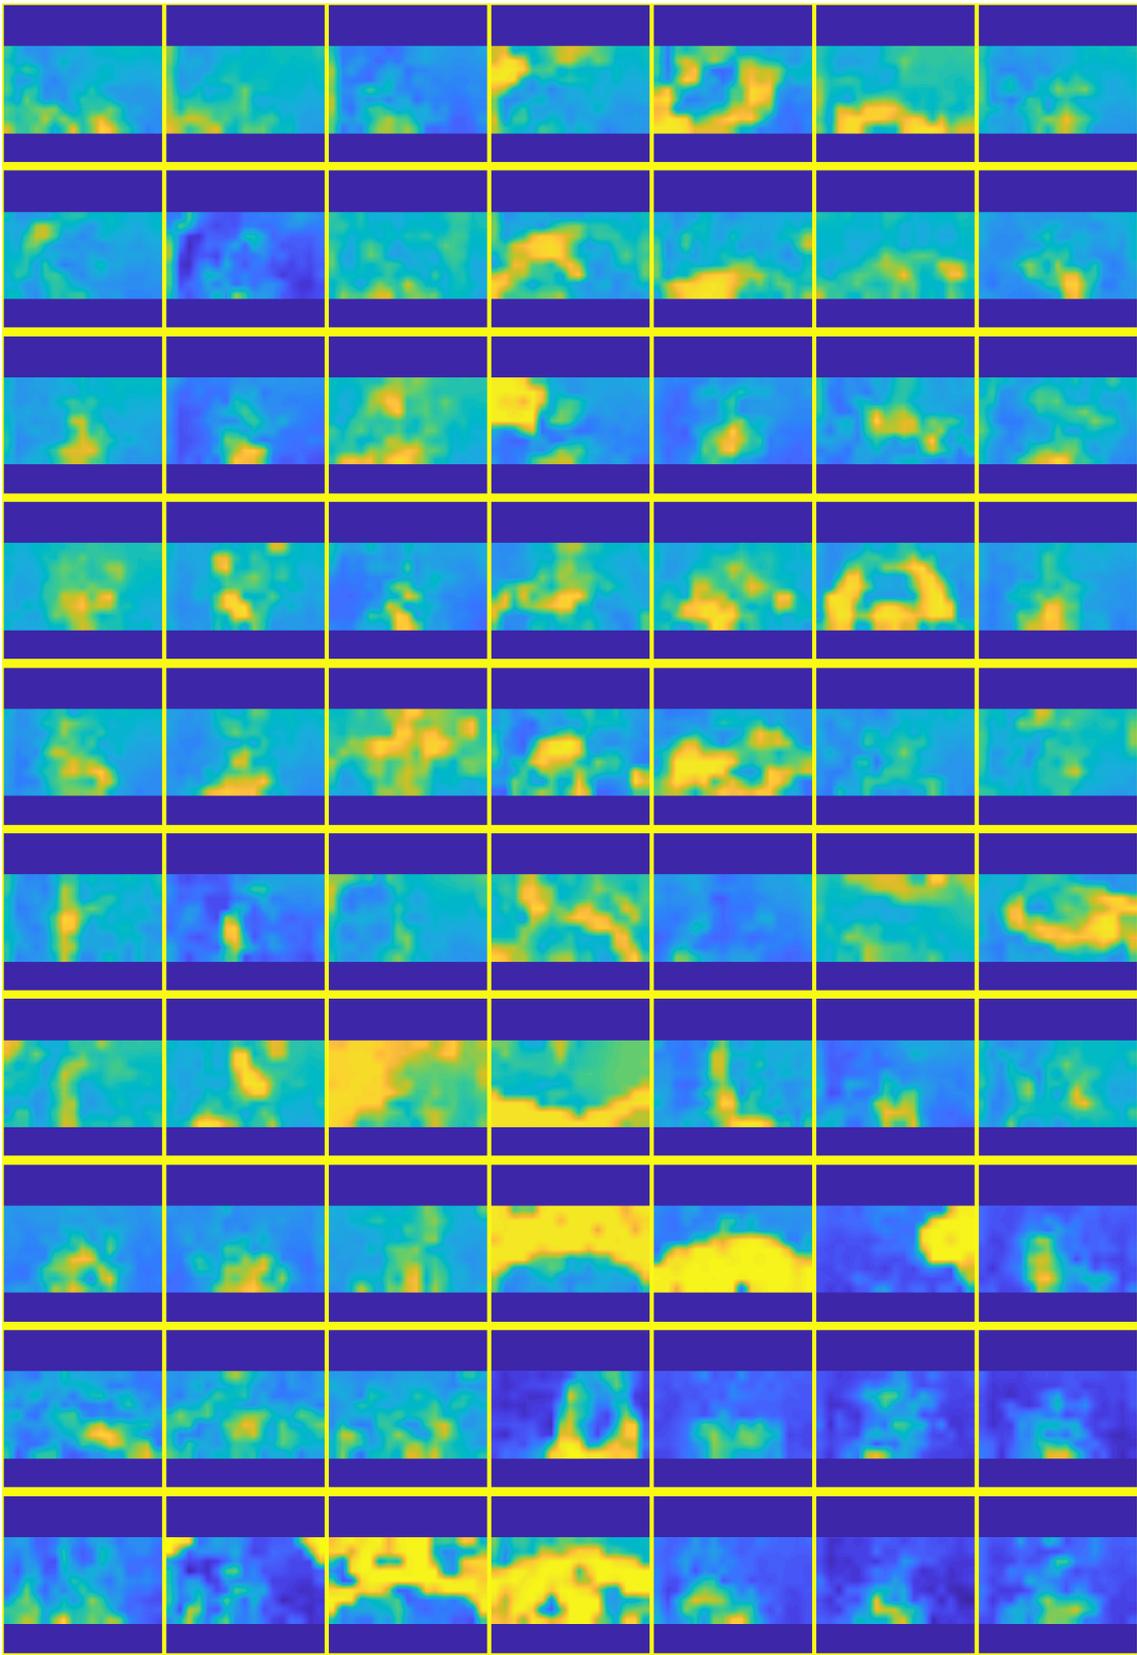


Figura B.2: Amostra das seqüências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 2 às imagens de treinamento.

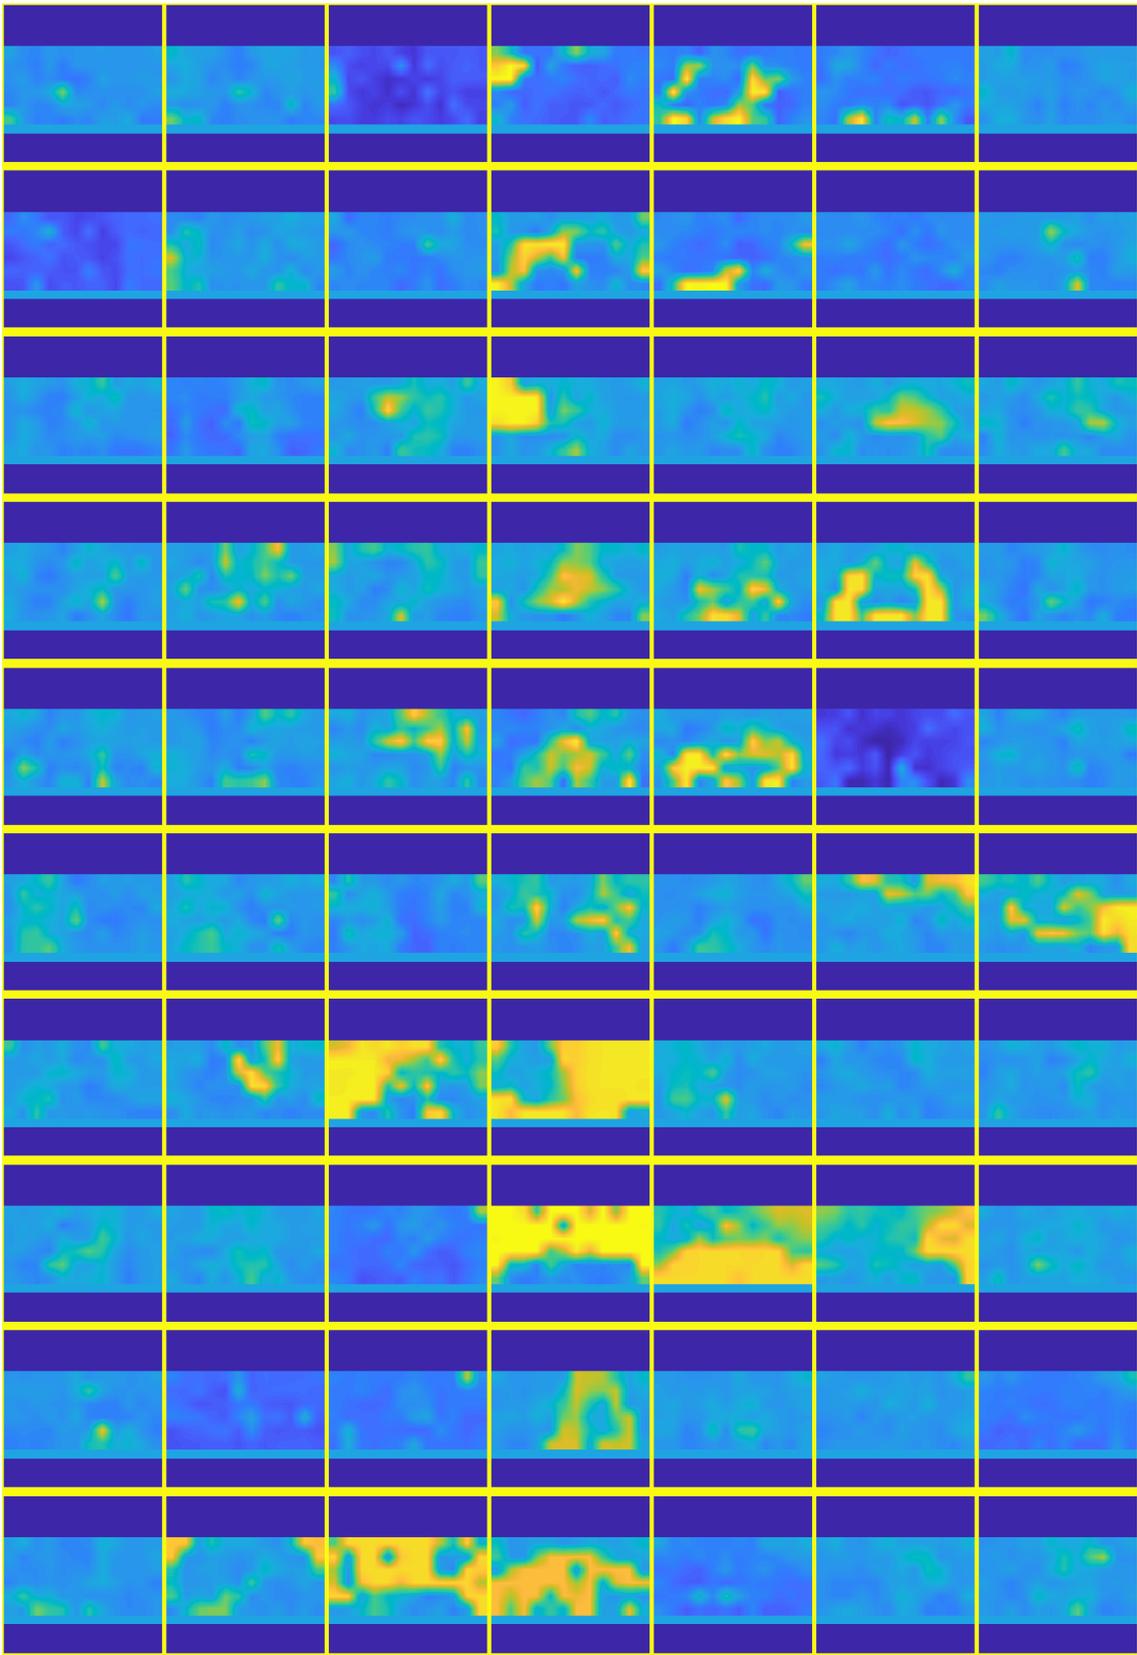


Figura B.3: Amostra das seqüências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 3 às imagens de treinamento.

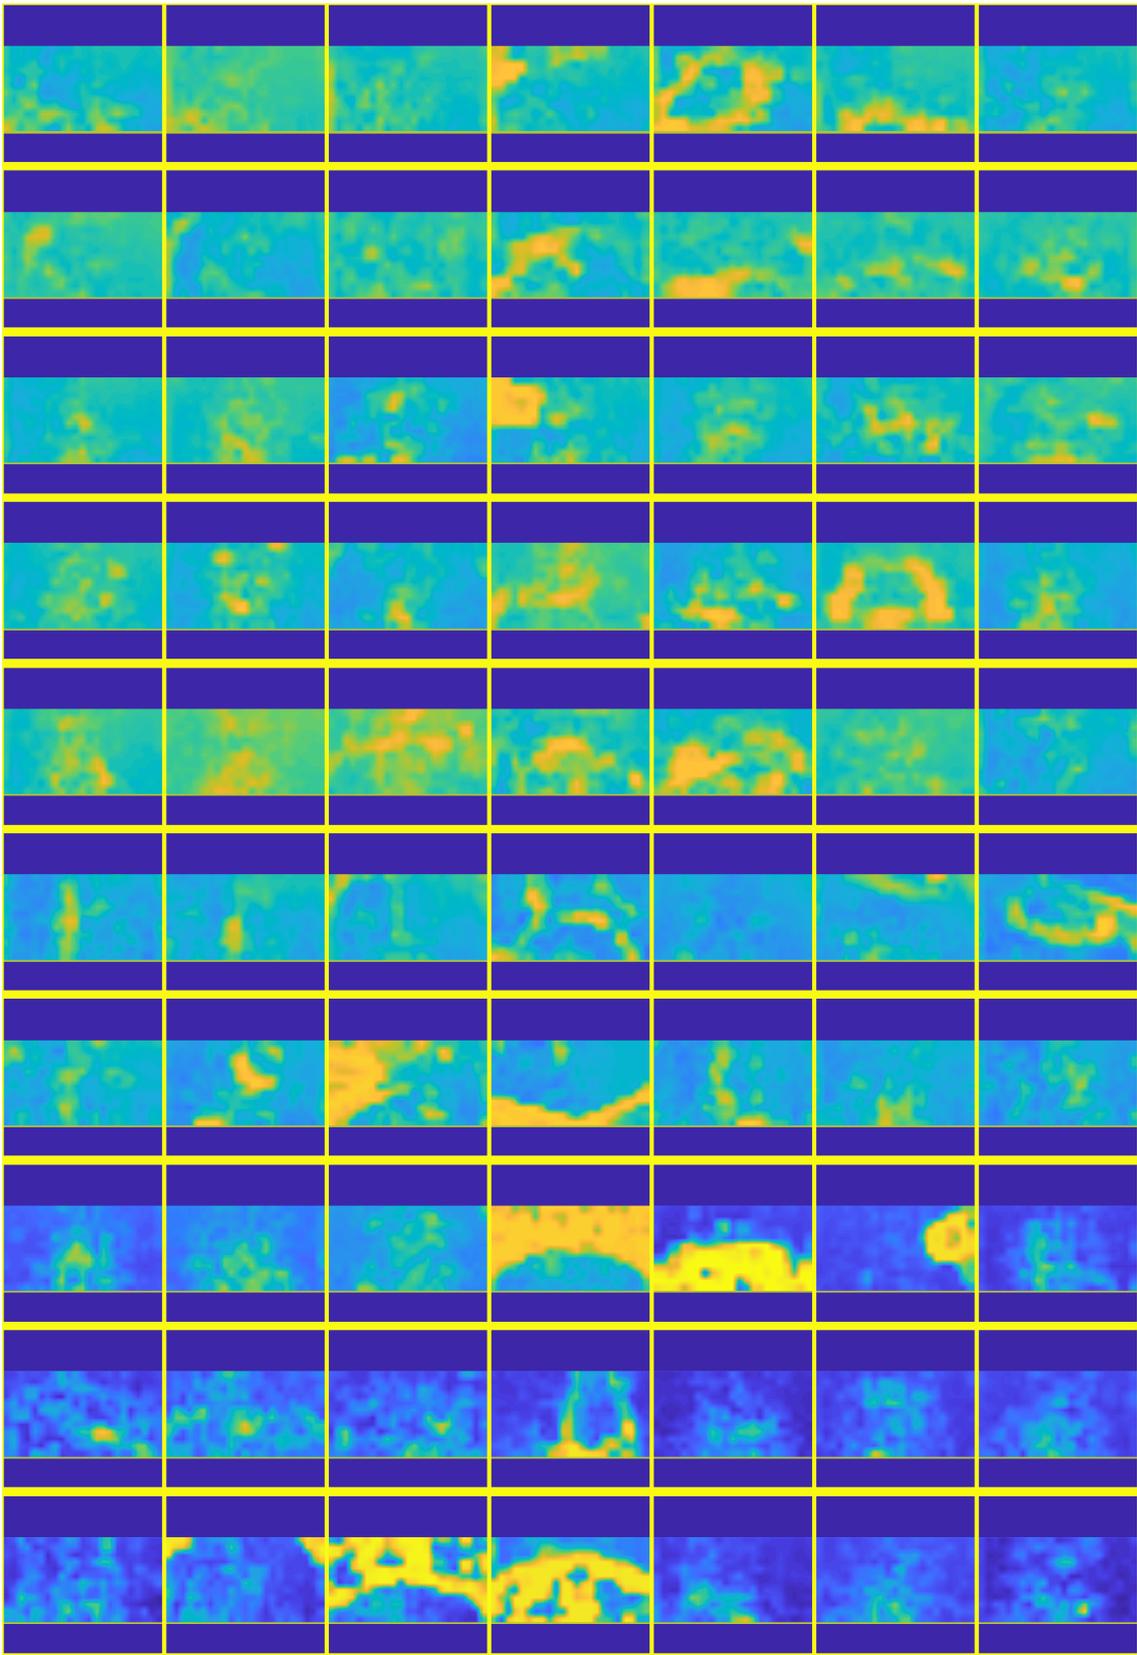


Figura B.4: Amostra das seqüências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 4 às imagens de treinamento.

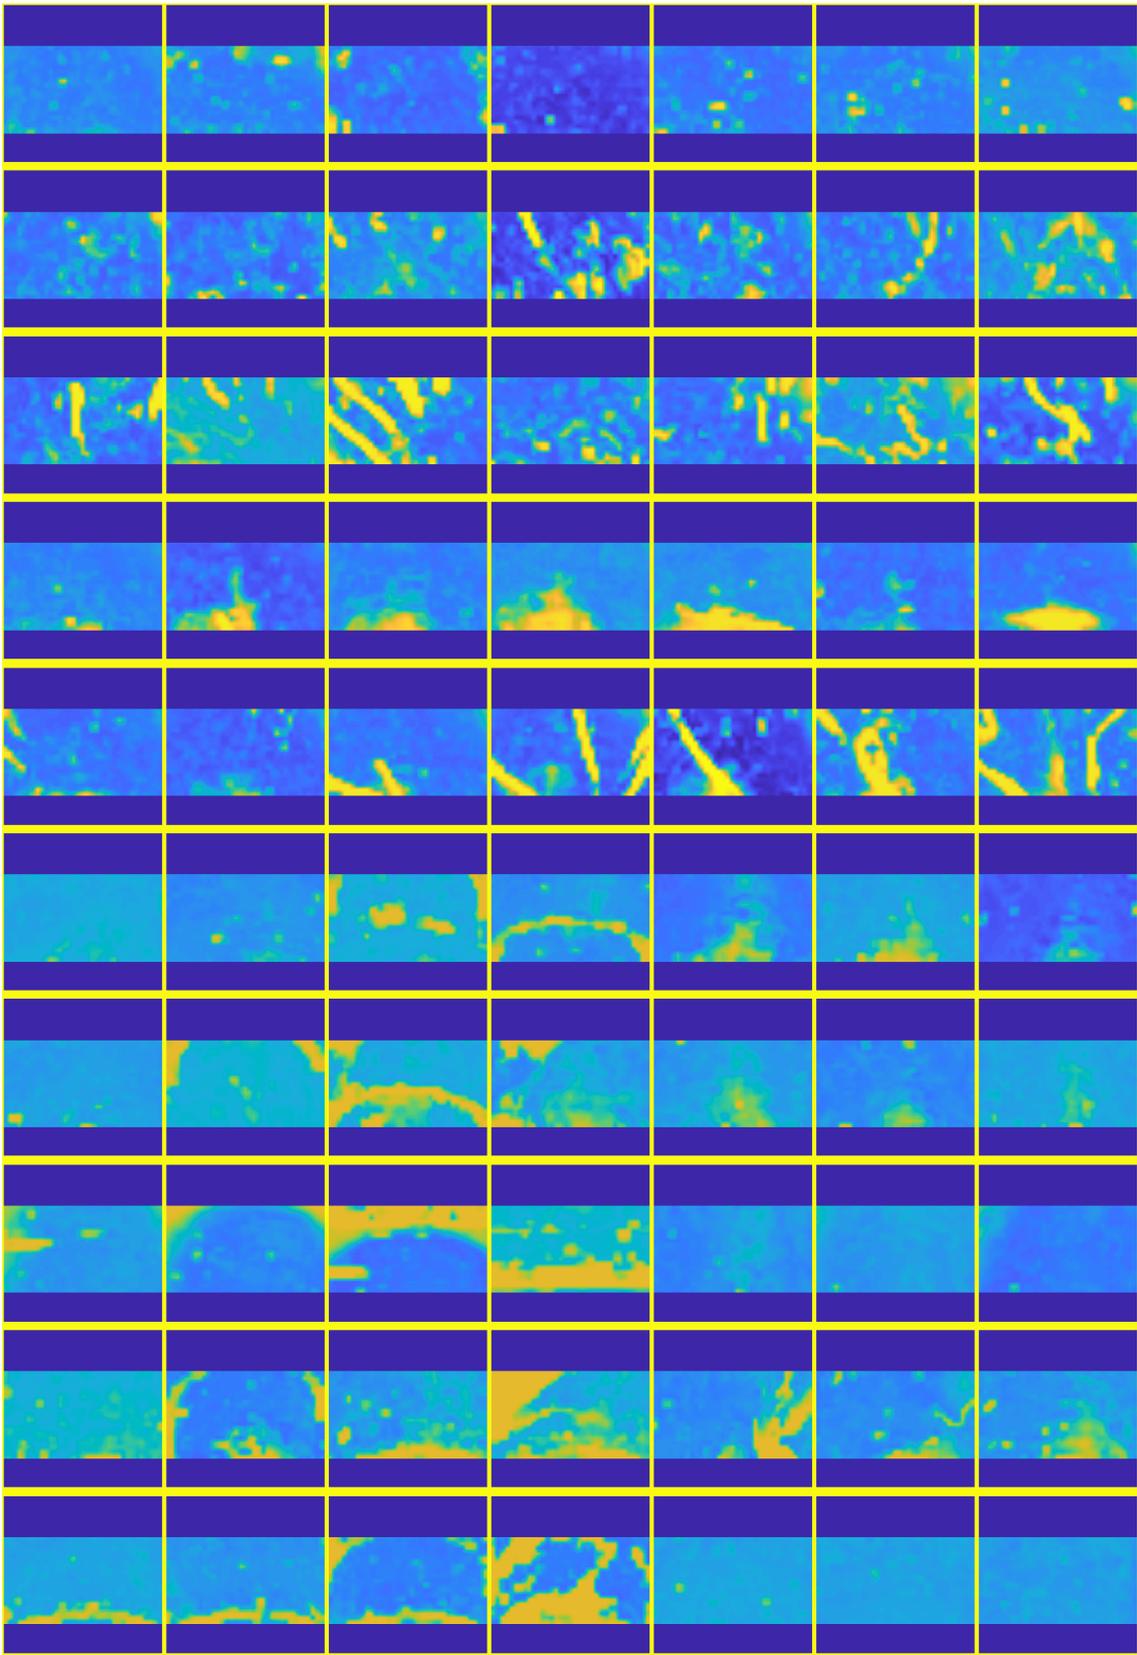


Figura B.5: Amostra das seqüências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 1 às imagens de teste.

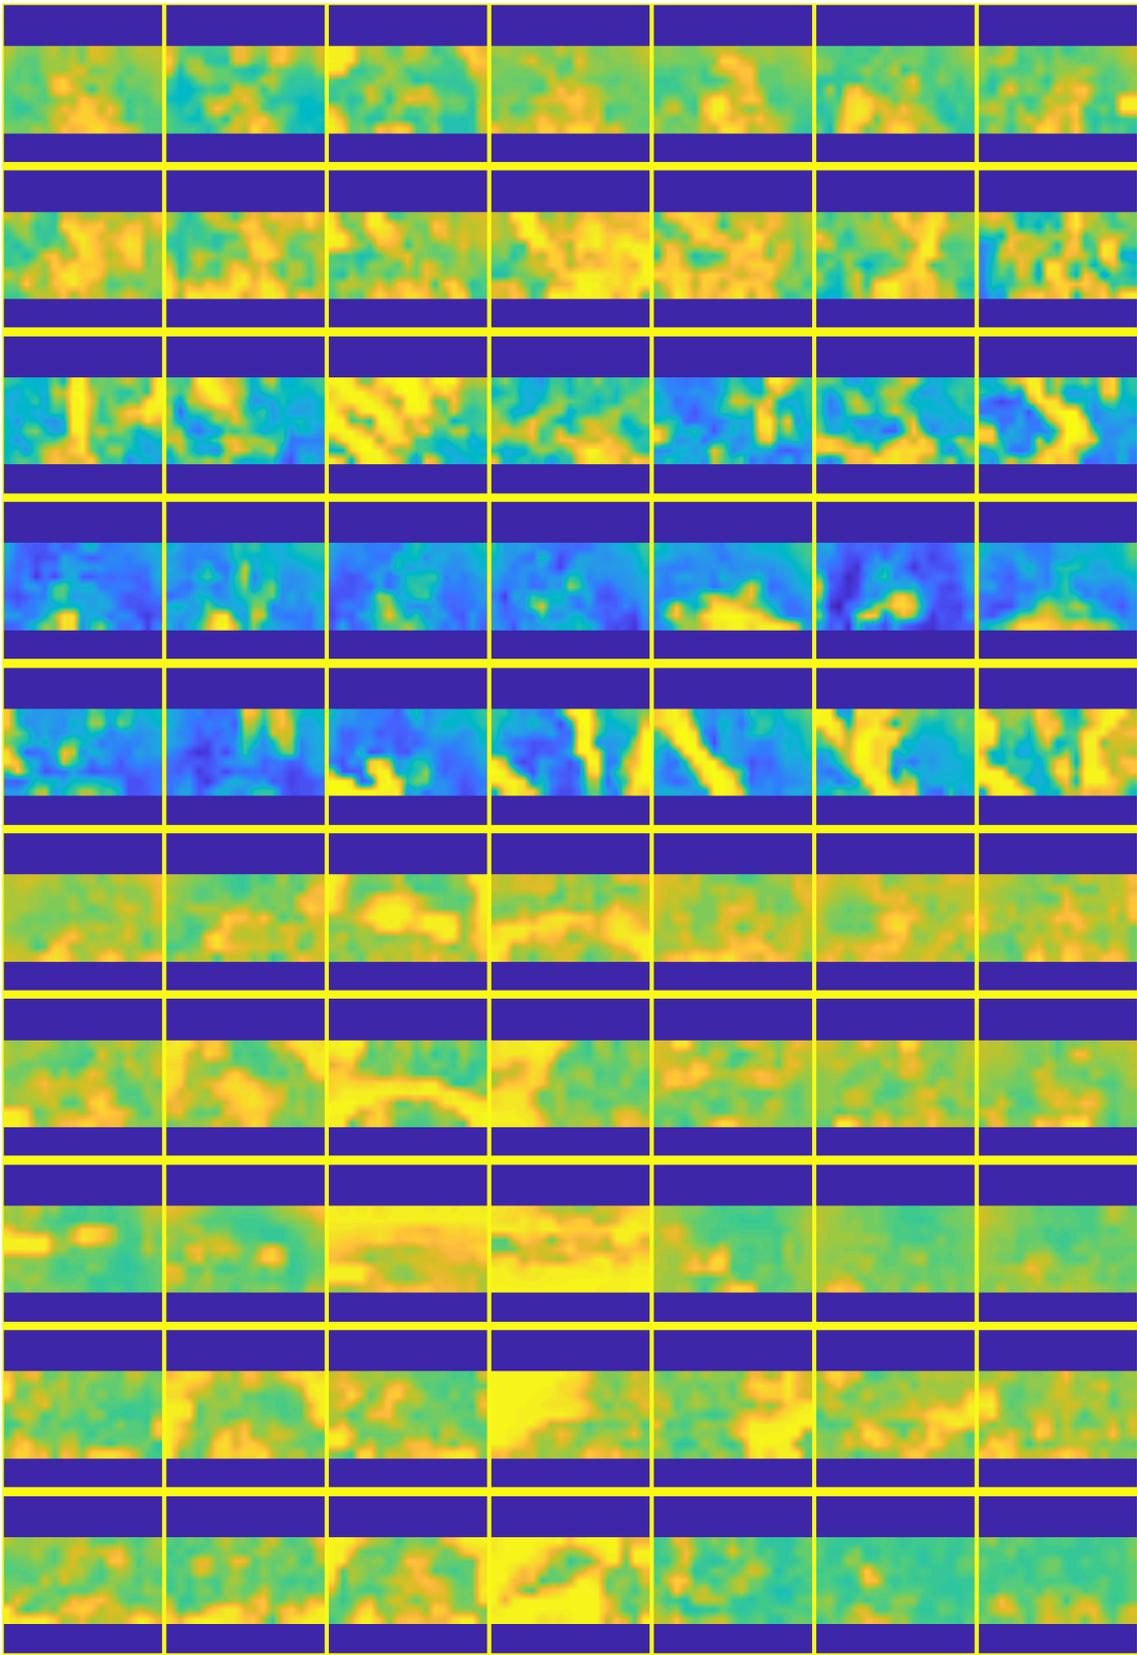


Figura B.6: Amostra das sequências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 2 às imagens de teste.

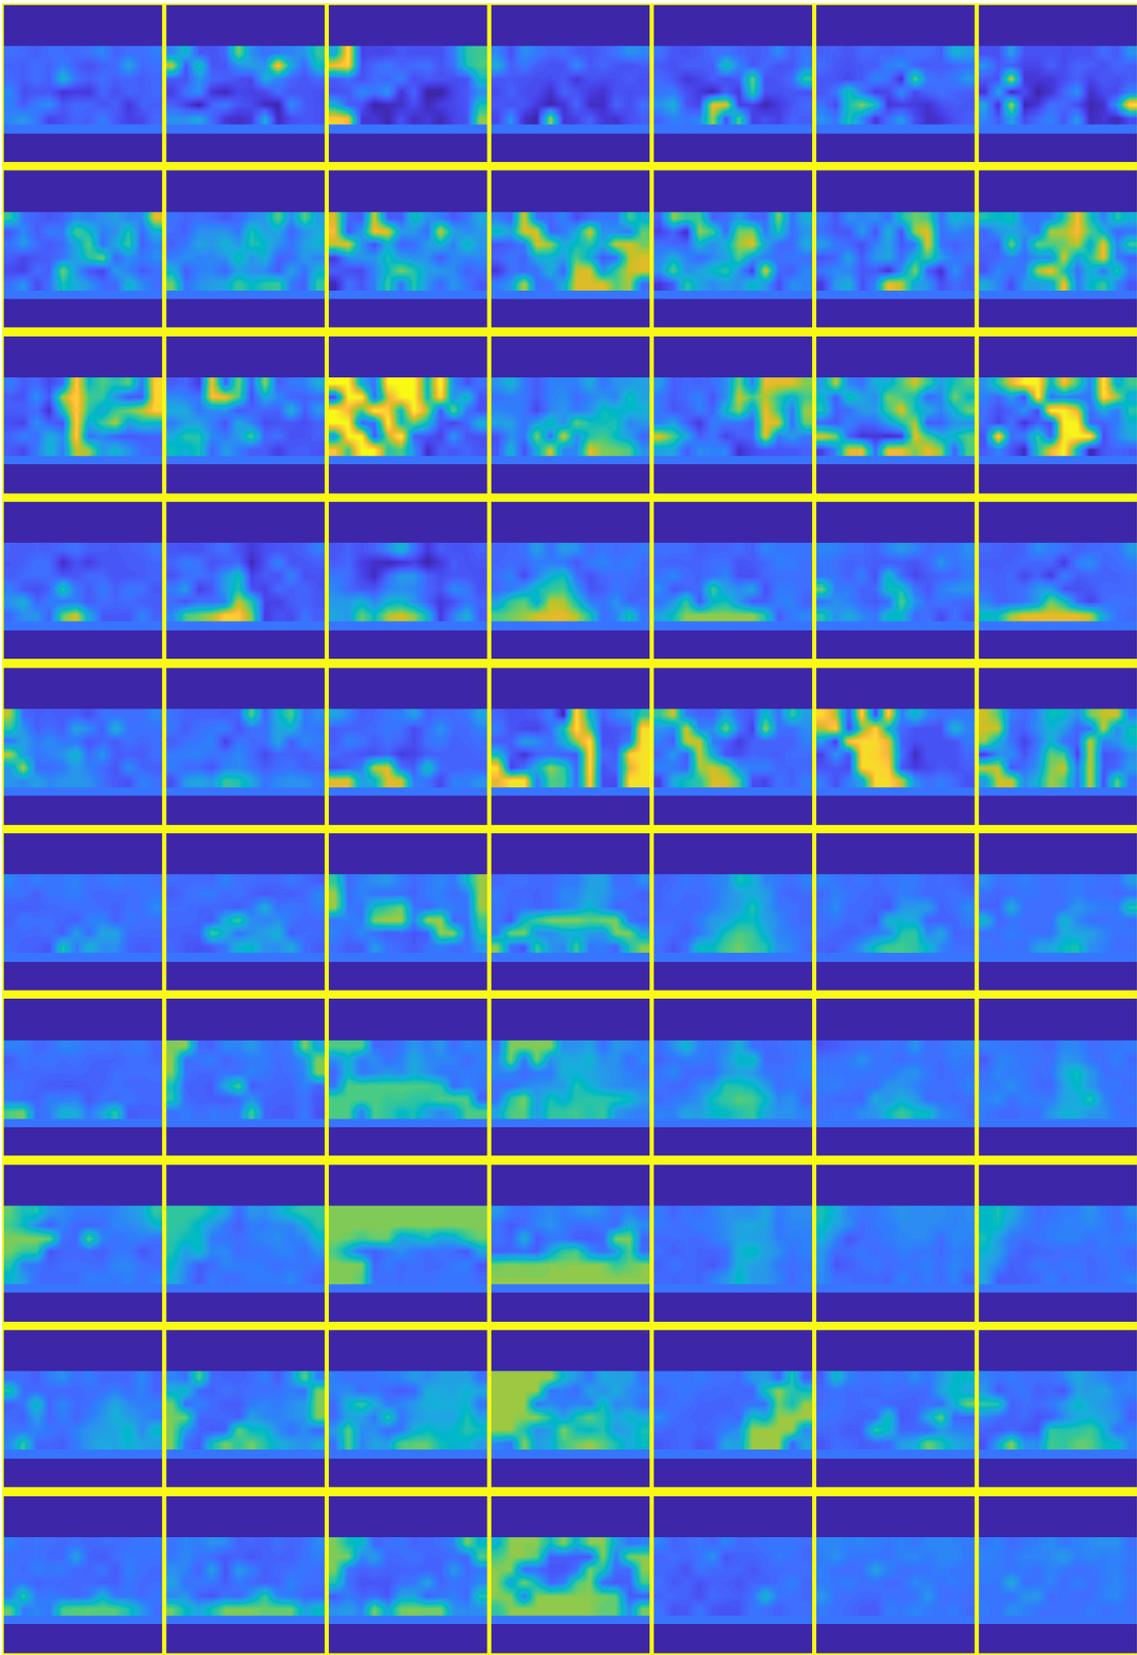


Figura B.7: Amostra das seqüências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 3 às imagens de teste.

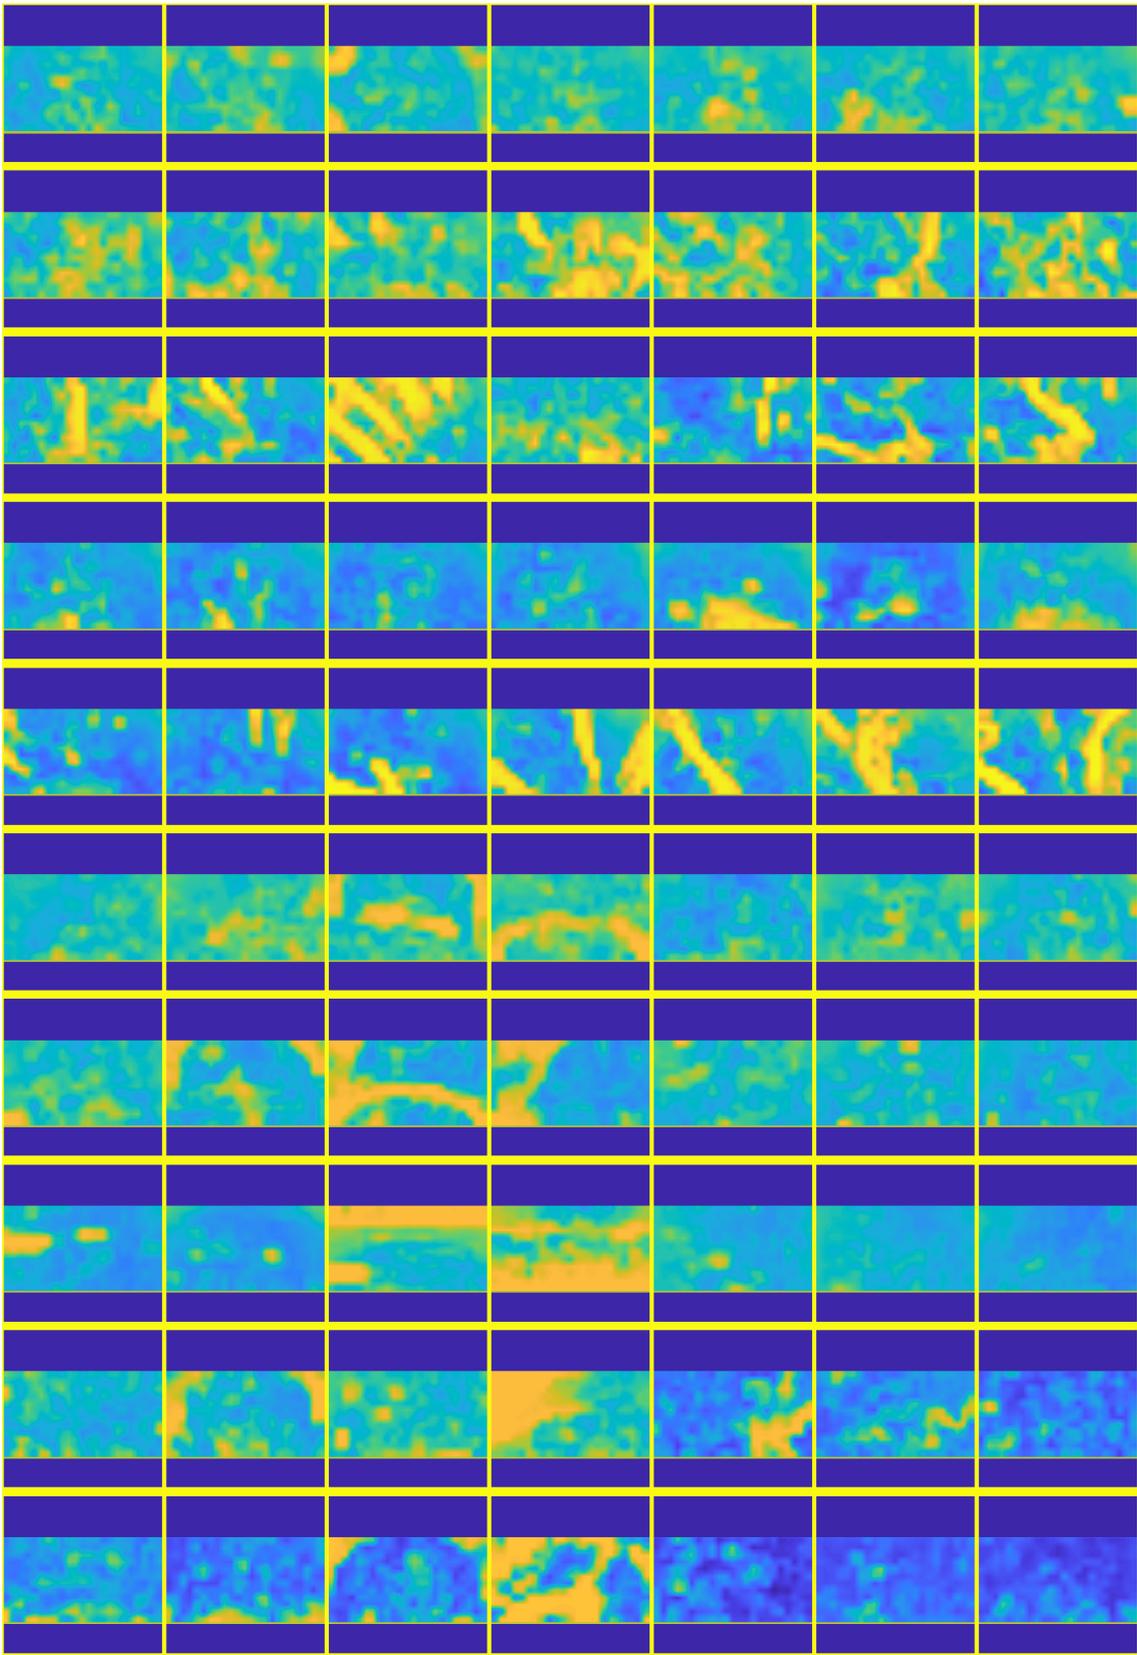


Figura B.8: Amostra das seqüências de imagens de pontuação de anomalia obtidas da aplicação do algoritmo 4 às imagens de teste.