

Fish Species Recognition using Template Matching and Local Descriptors

Uéilton de Paula Freitas,

Universidade Federal de Mato Grosso do Sul - UFMS
Cidade Universitária. Campo Grande - MS
E-mail: freitas.ueliton@gmail.com

Rafael Sanches Telles, Gercina Gonçalves da Silva,
Hemerson Pistori

Universidade Católica Dom Bosco – UCDB
Avenida Tamandaré, 6000. Jardim Seminário.
Campo Grande -MS
E-mail: rafael.sanches@tecsinapse.com.br,
gercina.goncalves@gmail.com, pistori@ucdb.br

Abstract— This paper presents some preliminary results regarding the use of local feature extractors and template matching for fish species classification. A dataset comprising 30 images of each of the 5 species of fish chosen has been produced and used in the experiments. Several combinations of features extractors and template matching strategies have been tested and the experimental results using F-score, precision and recall metrics are reported.

Keywords— visão computacional; reconhecimento de padrões; SURF; SIFT; casamento de modelos

I. INTRODUÇÃO

Com o desenvolvimento constante da tecnologia, computadores convencionais vêm perdendo espaço para outros dispositivos como, por exemplo, os celulares. Isso ocorre porque os dispositivos móveis têm obtido ganhos de melhorias em hardware, tais como sensores, processadores, memórias e câmeras, podendo superar um computador convencional. Assim, as aplicações com alto custo de processamento, relacionadas a imagens passaram a ser desenvolvidas com maior ênfase. Aplicações que utilizam análises e processamento de imagens estão diretamente relacionadas à Visão Computacional a qual une uma gama de algoritmos voltados para extração de atributos de um conjunto de imagens. O foco deste trabalho é em uma análise inicial de uma aplicação de algoritmos de extração de atributos em imagens de peixes, a fim de encontrar as características que melhor as definam, e assim, classificar sua espécie de forma automática. Por fim, com os resultados das análises, a aplicação será migrada para dispositivos móveis.

A classificação de espécies de peixes também é um problema recorrente da indústria, pois os peixes chegam por meio de um caminhão e são deixados nas esteiras, para posteriormente serem catalogados com informações referentes a tamanho, peso, quantidade e espécie [1]. Essa classificação é realizada por seres humanos que muitas vezes podem estar cansados prejudicando a classificação, que não é uma tarefa fácil, pois existem 47 características diferentes e importantes para cada espécie para que se consiga um nível bom de exatidão na identificação [2]. Jin Hu [3] utilizou dispositivos móveis para a classificação de peixes, contudo a utilização do dispositivo se limitou a obtenção de imagens e a classificação era realizada em um computador.

No Estado de Mato Grosso do Sul, especificamente na cidade de Campo Grande, um aquário intitulado “Aquário do Pantanal” está em construção. Esse fato pode levar a uma necessidade de mercado para reconhecimento de espécies de peixes com o uso de uma aplicação móvel, possibilitando a identificação da espécie visualizada, bem como informações adicionais sobre a espécie, a exemplo dos locais onde é mais comum encontrar tal espécie, tamanho aproximado, família, origem, peso aproximado e informações corporais.

Identificar diferentes espécies de peixes em um aquário exige conhecimento sobre as espécies, e, além disso, os peixes se movimentam de forma rápida dificultando a rápida identificação [2]. Portanto, uma aplicação é proposta neste trabalho objetivando a identificação das espécies de peixes, especificamente as encontradas no Pantanal sul mato-grossense. Para tanto, várias imagens de espécies de peixes encontradas no Pantanal foram obtidas a partir de imagens dos peixes em aquários. Foram escolhidas cinco espécies para os testes iniciais.

Para o desenvolvimento da aplicação foi utilizada a biblioteca de Visão Computacional OpenCV, desenvolvida na linguagem C. A aplicação utiliza os algoritmos SURF (*Speeded-UpRobustFeatures*) e SIFT (*Scale-InvariantFeatureTransform*) para detecção de padrões utilizados para diferenciar imagens. Com os padrões das várias imagens de treinamento detectados, o método conhecido como *TemplateMatching* é utilizado para medir a semelhança entre as imagens de treinamento e uma nova imagem a ser analisada [4]. Também foram implementadas duas técnicas de *TemplateMatching* juntamente com os extratores de atributos citados: FLAN e Força Bruta.

A seção 2 apresenta as espécies de peixes pantaneiras utilizadas nos experimentos e formas de obtenção. Na seção 3 constam as informações sobre a detecção de padrões. A seção 4 descreve os tipos de casamento de modelos utilizados, e a descrição detalhada dos experimentos está na seção 5. Na seção 6 encontram-se os resultados dos experimentos e as conclusões estão descritas na seção 7.

II. BANCO DE IMAGENS

Segundo o Instituto Chico Mendes de Conservação da Biodiversidade – ICMBio, o Brasil possui cerca de 5.164

espécies de peixes distribuídos nos diversos tipos de biomas existentes. O Estado de Mato Grosso do Sul está dividido entre os biomas do pantanal e do cerrado totalizando cerca de 1.500 espécies de peixes. Devido à dificuldade da obtenção das diversas imagens de espécies nativas do estado, este trabalho tratará, inicialmente, sobre espécies ornamentais, pois a captura de imagens dessas espécies é mais simples. Após realizar pesquisa junto a proprietários de lojas especializadas na venda de peixes ornamentais, concluiu-se que as 5 principais espécies de peixes são:



Figura 1 - Molinésia Negra (*Poecilia latipinna*)



Figura 2 - Platy (*Xiphophorus maculatus*)



Figura 3 - Kinguio (*Carassius auratus*)



Figura 4 - Acará Bandeira (*Pterophyllum scalare*)



Figura 5 - Tricogaster Azul (*Trichogaster trichopterus*)

Constatou-se a indisponibilidade de bancos de imagens que possuíssem as características necessárias para a realização do trabalho proposto. Assim, buscou-se locais que pudessem ceder as imagens das espécies de peixes citadas, para, a partir de então, criar um banco de imagens. O local que possuía maior variedade de espécies de peixes foi a Flor de Liz, localizada em Campo Grande- MS.

Na captura de imagens para a primeira versão do banco de imagens, utilizou-se uma câmera Sony 14.1MP modelo DSC-W610, com uma distância média de 10cm entre a câmera e o aquário e inicialmente sem zoom, porém devido a quantidade de peixes em alguns aquários foi dado zoom de 2x, para conseguir uma melhor imagem da espécie.

Todo o ambiente local possui uma iluminação a partir de uma única fonte. Contudo, cada aquário possui uma iluminação local, variando a luminosidade de cada aquário. Os vidros eram de 5mm e foram limpos fornecendo total transparência. Foram tiradas 30 fotos das espécies de peixes. Em cada imagem havia vários peixes, conforme Figura 6, contudo, inicialmente, a aplicação classifica apenas um único peixe.



Figura 6: Exemplo de imagem capturada no formato original.

A partir das imagens com vários peixes foram retiradas imagens as quais continham apenas um, sendo extraídas em média 35 imagens de cada espécie de peixes. Os recortes das imagens foram feitos de forma manual tentando minimizar ao máximo a quantidade de pixels correspondentes ao fundo da imagem. Foram armazenadas imagens das espécies de peixes em vários ângulos para facilitar a classificação.

III. DETECÇÃO DAS CARACTERÍSTICAS DAS ESPÉCIES DE PEIXES

Cada espécie de peixe possui características únicas que as descrevem, tais como: tamanho de suas nadadeiras, padrões de cores, tamanho do espécime. Para melhor caracterizar cada espécie foram utilizados os algoritmos para extração de atributos SURF e SIFT. Christian Lana Rachid [5] utilizou o SURF em dispositivos móveis, e este mostrou-se com um bom desempenho juntamente com um baixo custo computacional.

O SIFT também foi utilizado na classificação de peixes [6]. Os resultados podem ser melhores aumentando o dataset [7]. O algoritmo SURF encontra os pontos de maior relevância em uma imagem, para que posteriormente esses pontos possam ser comparados com pontos encontrados em outras imagens [8]. Assim os pontos são encontrados mesmo quando há ruídos na imagem, ou o objeto a ser analisado sofre variações tais como: rotação, escala e iluminação. Através da comparação dos pontos de interesse de duas imagens pode-se concluir se as imagens contêm os mesmos objetos. Neste trabalho os objetos serão as espécies de peixes.

De acordo com [8] o algoritmo SURF consiste em detectar os pontos de interesse utilizando os conceitos de imagens integrais e matriz Hessiana. Posteriormente utiliza o conceito de supressão de não máximo em 3D para detectar os pontos de interesse em diversas escalas. Após a detecção, inicia o processo de descrição, utilizando o conceito de cálculo de orientação dominante para invariância a rotação, e aplicando distribuição de respostas de HaarWavelets. Assim gera-se um vetor de 64 atributos para cada ponto de interesse.

A Figura 7 ilustra a execução do algoritmo SURF utilizando o ImageJ em uma imagem de um Acará Bandeira. Cada ponto de interesse gerado representa os pontos de maior importância na imagem. As linhas originadas em cada ponto representam a direção em que a partir do ponto há maior variação.

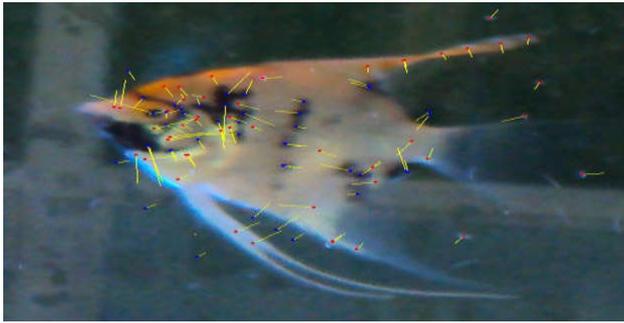


Figura 7 - Pontos de Interesse encontrados pelo SURF em um Acará Bandeira.

Observa-se que as bordas do peixe, e as manchas, listras, local de mudança de cor, são os locais onde há maior variação, tornando evidente que os objetos a serem descritos pelo SURF devem se destacar em relação ao fundo da imagem, caso contrário, muitos pontos podem ser encontrados mesmo não sendo pontos do objeto propriamente dito. O SURF foi criado baseado no SIFT [6] contudo o SURF possui um desempenho melhor em relação ao tempo de processamento quando comparado ao SIFT. No SIFT também são encontrados pontos de interesse invariantes a iluminação, rotação, escala e ruídos. A classificação da imagem é realizada utilizando o conceito de *TemplateMatching*.

IV. TEMPLATE MATCHING (CASAMENTO DE MODELOS)

Com os descritores gerados pelo SURF e SIFT, de cada imagem do conjunto de treinamento, deseja-se classificar uma determinada imagem de um peixe, definindo em qual espécie o mesmo pertence. Para realizar a classificação, os extratores de atributos (SURF e SIFT) são executados na imagem a ser classificada, e os descritores são extraídos. Comparam-se os pontos de interesse de todas as imagens do conjunto de treinamento com os pontos de interesse da nova imagem. Estas comparações não podem ser feitas de forma igual ou diferente, pois é muito difícil encontrar pontos exatamente iguais. Utilizam-se então de técnicas de busca aproximada, como por exemplo: distância euclidiana, distância de mahalanobis, distância de coseno. Na literatura foram encontradas duas técnicas que já possuíam implementações disponíveis na biblioteca OpenCV: FLANN e Força Bruta.

A. FLANN (*Fast Library for Approximate Nearest Neighbors*)

Neste trabalho, utilizou-se da FLANN, uma variedade de casamento de modelos, que de acordo com [6] trata-se de uma biblioteca para realizar pesquisas rápidas aproximadas utilizando o método do vizinho mais próximo em espaços dimensionais grandes. O método do vizinho mais próximo (KNN - K-NearestNeighbors) consiste em atribuir uma classe a um elemento desconhecido observando a classe que predomina entre os seus vizinhos, utilizando uma determinada distância. Assim, a FLANN possui um conjunto de algoritmos embutidos para realizar a busca por meio do vizinho mais próximo, além de possuir também um sistema para escolher automaticamente o melhor algoritmo e os parâmetros ideais de acordo com o conjunto de dados fornecido ao algoritmo.

B. Força Bruta

O algoritmo de força bruta (BruteForce) é o algoritmo mais simples a ser utilizado no casamento de modelos, onde a verificação é feita de maneira simplória, elemento por elemento. No contexto da aplicação, uma das principais desvantagens do uso do algoritmo da força bruta é o seu alto custo computacional, uma vez que todos os pontos de interesse da imagem são percorridos, sem a utilização de nenhuma lógica para melhorar o custo.

V. -DELINEAMENTO EXPERIMENTAL

O módulo foi inicialmente desenvolvido no sistema operacional Ubuntu 12.04 com auxílio da biblioteca de visão computacional OpenCV na versão 2.4.4, e a aplicação foi desenvolvida na linguagem C. A aplicação desenvolvida realiza o reconhecimento de apenas um peixe por vez, podendo ser como entrada uma imagem já disponível ou uma imagem de uma webcam no computador onde a aplicação esteja sendo executada, a exemplo da Figura 8. Para esse primeiro momento a imagem que foi utilizada como “entrada” do algoritmo conteve apenas um peixe1.



Figura 8 - Exemplo de imagem de entrada da aplicação.

Para testar a solução adotada inicialmente, utilizando dois extratores de atributos e duas técnicas de Casamentos de Modelos as seguintes combinações foram utilizadas: 1) SURF + FLANN; 2) SURF + ForçaBruta; 3) SIFT + FLANN, e 4) SIFT + ForçaBruta. Para obter um resultado médio estatístico, realizou-se três repetições para cada combinação, alterando o conjunto de treinamento e de testes para cada uma das repetições, gerando três resultados distintos para cada métrica. A partir dos resultados, foram calculadas as médias para cada métrica. As médias foram utilizadas para realizar o teste de Friedman. Ao final de cada execução o software descreve os resultados em um arquivo do tipo texto.

O banco de imagens contou com 229 imagens. Foram utilizadas 70% das imagens para treinamento e 30% para testes em cada experimento. Assim, todas as repetições realizadas nos conjuntos de treinamento e de testes eram distintas. Os algoritmos implementados foram comparados entre si, utilizando o banco de imagens descrito anteriormente. Para cada algoritmo testado, foi calculado o desempenho médio referente às métricas abrangência, precisão, medida-f, acurácia, taxa de verdadeiros positivos e taxa de falsos positivos, através do software estatístico R versão 2.15.1, utilizando o teste de

¹Há imagens que tem mais de um peixe, nesse caso o importante foi centralizar a imagem do peixe que deseja realizar o reconhecimento.

Friedman [9] com cada bloco correspondendo a uma das classes dos problemas, onde verificou-se se os algoritmos testados diferem estatisticamente em relação ao desempenho. Para cada métrica foi utilizado o menor valor-*p* para realizar o teste *post-hoc*.

VI. ANÁLISE E DISCUÇÕES

Considerando os resultados obtidos através das métricas utilizadas para medir estatisticamente a solução adotada, verificou-se que, em todas as métricas, a combinação SIFT+BRUTE obteve melhor resultado, com exceção da taxa de falsos positivos que obteve um resultado médio igual ao da combinação SIFT+FLANN, conforme Tabela 1.

TABLE I. MEDIÇÃO ESTATÍSTICA

Taxa de Verdadeiro Positivo				
	SURF + FLANN	SURF + BRUTE	SIFT + FLANN	SIFT + BRUTE
Acará Bandeira	0,44	0,43	0,37	0,34
Kiguio	0,53	0,67	0,72	0,78
Molinésia Preta	0,42	0,67	0,62	0,79
Platy Sangue	0,00	0,33	0,33	0,50
Tricogaster	0,34	0,32	0,57	0,58
Médias	0,34	0,48	0,52	0,60
Falso Positivo				
Acará Bandeira	0,16	0,15	0,11	0,11
Kiguio	0,16	0,15	0,15	0,14
Molinésia Preta	0,19	0,19	0,16	0,15
Platy Sangue	0,18	0,18	0,18	0,17
Tricogaster	0,04	0,06	0,07	0,06
Médias	0,15	0,14	0,13	0,13
Abrangência				
Acará Bandeira	0,44	0,43	0,37	0,37
Kiguio	0,53	0,67	0,72	0,78
Molinésia Preta	0,42	0,67	0,62	0,79
Platy Sangue	0,00	0,33	0,33	0,50
Tricogaster	0,30	0,32	0,57	0,48
Médias	0,34	0,48	0,52	0,58
Medida-F				
Acará Bandeira	0,48	0,51	0,51	0,49
Kiguio	0,29	0,38	0,35	0,38
Molinésia Preta	0,12	0,16	0,34	0,42
Platy Sangue	0,00	0,05	0,09	0,17
Tricogaster	0,45	0,46	0,64	0,64
Médias	0,27	0,31	0,39	0,42
Acurácia				
Acará Bandeira	0,70	0,70	0,59	0,55
Kiguio	0,82	0,83	0,84	0,85
Molinésia Preta	0,79	0,81	0,82	0,85
Platy Sangue	0,82	0,82	0,82	0,83
Tricogaster	0,59	0,63	0,83	0,85
Médias	0,74	0,76	0,78	0,79
Precisão				
Acará Bandeira	0,56	0,63	0,83	0,83
Kiguio	0,21	0,28	0,24	0,25
Molinésia Preta	0,07	0,09	0,24	0,29
Platy Sangue	0,00	0,03	0,05	0,10
Tricogaster	0,90	0,85	0,74	0,72
Médias	0,35	0,38	0,42	0,44

Aplicou-se o teste *post hoc* e valor *p*. Para a métrica taxa de verdadeiros positivos, seu valor *p* foi de 11,62% (Figura 9), e para a métrica taxa de falsos positivos o valor *p* foi igual a 10,47%, conforme Figura 10.

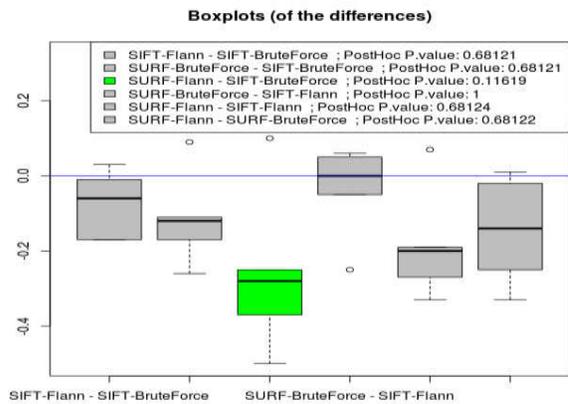


Figura 09 – Análise post hoc - métrica: taxa de verdadeiros positivos

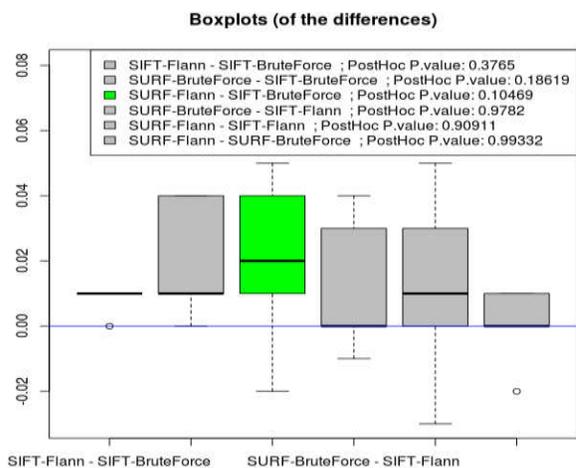


Figura 10 - Análise post hoc para a métrica taxa de falsos positivos

Observa-se também, que as combinações SURF+BRUTE e SIFT+FLANN obtiveram resultados próximos. Uma das possíveis justificativas dessa proximidade é que essas combinações envolvem o extrator que obteve melhor resultado com o casamento de modelos e também obteve um bom resultado para esse problema.

As Figuras 11 e 12 representam os diagramas de caixa das métricas abrangência e medida-F, respectivamente. Para a métrica abrangência (Figura 11) o valor *p* encontrado foi 19,56% e para a métrica medida-F foi de 1,32%, conforme Figura 12.

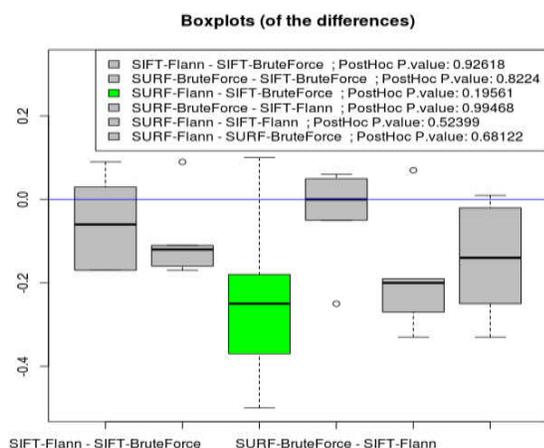


Figura 11- Resultado da análise post hoc para a métrica abrangência

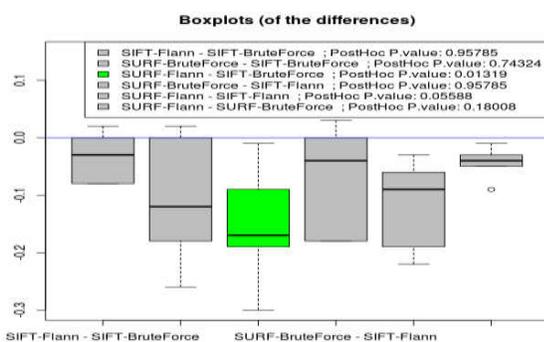


Figura 12 - Resultado da análise post hoc para a métrica medida-f

Para a métrica acurácia o valor p encontrado foi 11,58% (Figura 13) e para a métrica precisão foi utilizado o valor p igual a 24,74%, conforme Figura 14. Para todos os diagramas de caixas exibidos é possível visualizar que a combinação SIFT+FLANN obteve uma diferença estatística em relação ao SURF+BRUTE.

O bom resultado obtido pelo algoritmo SIFT em relação ao SURF nesse problema, deve-se a algumas etapas que o SIFT realiza com mais “cuidado” em relação ao algoritmo SURF. Uma das etapas é busca por pontos de interesse, onde o algoritmo SURF realiza uma aproximação, tornando o algoritmo menos eficiente para o esse problema. Em relação aos casamentos de modelos, é possível observar que a força bruta (Brute Force) obteve um melhor resultado, isso deve-se ao seu algoritmo percorrer todos os pontos da imagem em diferentes ângulos. Não houve uma diferença significativa entre o tempo de execução entre as diversas combinações.

É possível observar também que para as métricas taxa de verdadeiros positivos, abrangência, medida-f e precisão quando foi utilizado o SURF+FLANN da espécie Platy Sangue o resultado foi igual à zero. Um possível motivo é ao seu formato do Platy Sangue ser semelhante a de outras espécie, como por exemplo o Molinésia Preta e o Tricogaster. O algoritmo acaba

se perdendo, e com isso acaba classificando erroneamente a espécie. Por outro lado é possível observar que o SIFT+BRUTE classificou as espécies, mesmo não tendo um bom nível de exatidão.

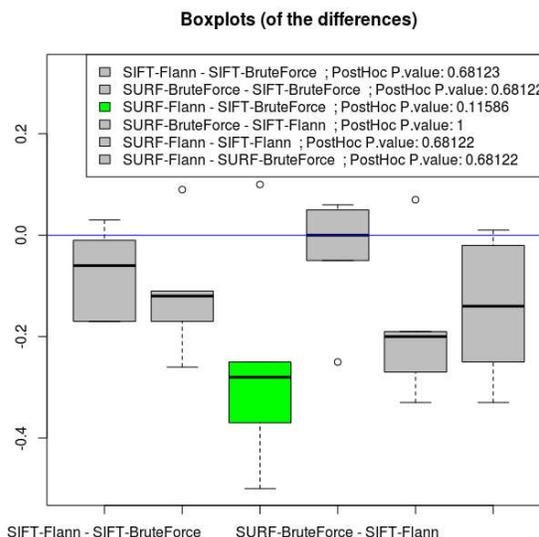


Figura 13 - Resultado da análise post hoc para a métrica acurácia

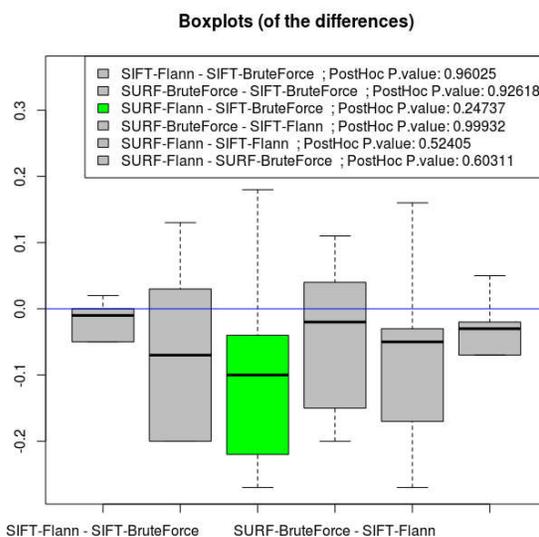


Figura 14- Resultado da análise post hoc para a métrica precisão

Os algoritmos SURF assim como o SIFT, transformam as imagens originais para tons de cinza. Esse fato pode ser uma das possíveis causas para a baixa taxa de acerto do algoritmo (em torno de 41%). A cor pode ser considerada uma grande influenciadora para a classificação de das espécies. Utilizando o SURF e SIFT essas informações tem baixa importância, devido que a imagem original é transformada em tons de cinza, além dos algoritmos encontrar em pontos de interesse pertencentes ao fundo da imagem e não somente dos peixes. A

Figura 15 ilustra vários pontos de interesse detectados pelo algoritmo SURF.

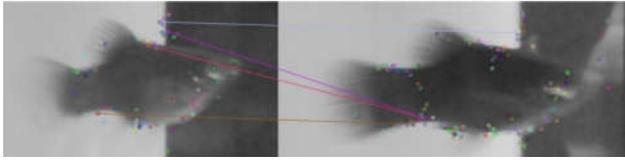


Figura 15 - Espécie de peixe *Platy Sangue*. A reta traçada entre pontos de interesse de imagens distintas representa os pontos de interesse semelhantes.

Como é possível visualizar, alguns pontos de interesse irrelevantes para o reconhecimento foram identificados. Esses pontos de interesse não deveriam influenciar na classificação de tal espécie e estão sendo utilizados pelo algoritmo, e muitas vezes estão influenciando diretamente na classificação de tal espécie. Um exemplo de informação que não deveria ser levada em conta é o fundo do aquário, todavia foram determinados pontos de interesse na faixa preta na extremidade direita da imagem que não pertencem ao peixe. Os pontos de interesse indesejados foram detectados pelo algoritmo e utilizados para realizar a classificação. É importante salientar alguns pontos em que o algoritmo obteve um bom resultado. Visualizando a Figura 16 é possível notar os pontos de interesse detectados em ambas as figuras, e com isso observar que um conceito importante do algoritmo SURF foi atendido para esse problema.

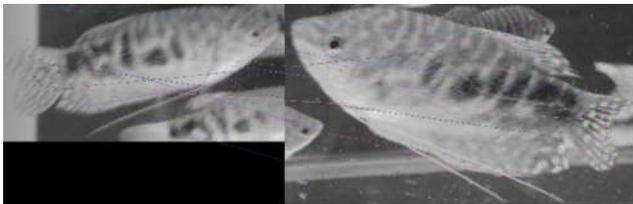


Figura 16 - Espécie de peixe *Tricogaster*. A reta traçada entre pontos de interesse de imagens distintas representa os pontos de interesse semelhantes nas duas imagens.

O conceito que se trata é o de cálculo de orientação dominante para invariância à rotação, e como é possível visualizar na figura, alguns pontos de interesse da parte de trás do peixe foram detectados em ambas as figuras.

VII. CONCLUSÃO

A classificação de diferentes espécies de peixes permanece sendo um problema desafiador. Classificar diferentes espécies de peixes em ambientes públicos, como por exemplo, o Aquário do Pantanal, torna-se uma tarefa complicada devido a dificuldade que pessoas leigas têm para classificar visualmente as espécies de peixes. Um sistema de Visão Computacional foi proposto para resolver esse problema, e ajudar o público de forma geral a encontrar informações sobre as diferentes espécies que ali estarão presentes.

Para esse estudo, foi realizado um experimento, realizando algumas combinações entre os algoritmo para reconhecimento de padrões e os algoritmo de casamento de modelos. Foram realizadas três repetições para cada combinação e foram extraídos os resultados das métricas taxa de verdadeiros

positivos, taxa de falsos positivos, abrangência, medida-f, acurácia e precisão. A repetição das combinações contribuiu para que não houvesse nenhum desvio na obtenção dos resultados, e uma média entre os valores das métricas pudesse ser obtida.

Com o experimento, foi possível observar que a combinação do algoritmo SIFT com o casamento de modelos baseado na força bruta obteve o melhor desempenho, em torno de 60%, seguido da combinação do SIFT com o FLANN, que foi de 52%. O resultado foi satisfatório para o problema, porém, alguns problemas foram identificados nos algoritmo de reconhecimento de padrões. Um dos principais problemas foi a não completa utilização da informação da cor do peixe, diminuindo a precisão das classificações. O teste de Friedman que foi aplicado nas métricas apontou que houve uma diferença estatística entre as combinações SURF+FLANN e SIFT+BRUTEFORCE.

VIII. AGRADECIMENTOS

Este trabalho recebeu apoio financeiro da Universidade Católica Dom Bosco - UCDB, da Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do Estado de Mato Grosso do Sul – FUNDECT, do Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPQ e da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES.

IX. REFERÊNCIAS

- [1] M. T. Rodrigues, "Classificação Automática de Espécies de Peixes Baseada em Técnicas Robustas para Extração de Características e Sistemas Imunológicos Artificiais". Belo Horizonte: Centro Federal de Educação Tecnológica de Minas Gerais, 2009.
- [2] M. S. Nery, "Determining the Appropriate Feature Set for Fish Classification Tasks. Graphics, Patterns and Images", SIBGRAPI Conference on, pp. 173-180. 2005.
- [3] J. Hu, "Fish species classification by color, texture and multi-class support vector machine using computer vision". Comput. Electron. Agric., pp. 133-140. 17 de Julio de 2012.
- [4] R. V. Brunelli, "Template Matching Techniques in Computer Vision: Theory and Practice the code companion". Technologies of Vision, 2009.
- [5] L. C. Christien Lana Rachid, "Algoritmos de Busca SIFT e SURF no Uso de Dispositivos Móveis". II SEMULT - II Encontro Multidisciplinar da Unipac Ubá. 2009.
- [6] D. G. Lowe, "Distinctive Image Features from Scale-Invariant Pontos de interesse". Int. J. Comput. Vision. Junho de 2004.
- [7] C. R. Kresimir Williams, "Automated Techniques for Detection and Recognition of Fishes using Computer Vision Algorithms". Report of the National Marine Fisheries Service Automated Image Processing Workshop. U.S. Dep. Commer., NOAA Tech. Memo. NMFS-F/SPO-121, 48 p., 2012.
- [8] H. A. Bay, "Speeded-Up Robust Features (SURF)". Computer Vision and Image Understanding. Julho de 2008.
- [9] M. Friedman, "The Use of Ranks to Avoid the Assumption of Normality Implicit in the Analysis of Variance". American Statistical Association. Journal of the American Statistical Association, 1937.