

Aprendendo Características para Identificação de Golfinhos *

Kaiser Magalde¹, Adelardo Medeiros¹, Luiz M. G. Gonçalves¹

¹Universidade Federal do Rio Grande do Norte

DCA-CT-UFRN, Campus Universitário Lagoa Nova, 59076-970, Natal, RN, Brazil

E-mails: {kaiser, adelardo, lmarcos}@dca.ufrn.br

Abstract

Neste trabalho, descrevemos um sistema desenvolvido para identificação automática de golfinhos a partir de imagens digitais. Propomos técnicas para reduzir problemas causados por transformações afins (rotação e escala), geralmente presentes em fotos de golfinhos não submersos, tomadas de posições genéricas, seja a partir de um barco ou mesmo da praia. Descrevemos técnicas desenvolvidas especialmente para a extração de multi-características usadas como entrada para classificadores que guardam uma assinatura para cada animal. Dois classificadores foram testados em experimentos visando identificação. O primeiro método, direto e simples, através de um casamento de padrões, obtém um escore para cada indivíduo. Em outro método, usamos uma rede do tipo perceptron em multi-camadas treinada com um algoritmo do tipo backpropagation (BPNN). Foi desenvolvido para este último um mecanismo de auto-crescimento visando encontrar e inserir de forma automática indivíduos novos, eventualmente não presentes em sua memória a um dado tempo. Ou seja, este mecanismo consegue lidar com representações para instâncias já conhecidas e eventualmente descobrir animais novos numa família de golfinhos. Mostramos resultados práticos incluindo a performance de cada algoritmo e uma comparação entre ambos.

1. Introdução

Os golfinhos são mundialmente conhecidos principalmente por suas habilidades de mergulho e saltos ao nível da água que encantam as pessoas. Uma característica importante usada na distinção entre indivíduos diferentes é a nadadeira dorsal. Ela não possui ossos, o tamanho varia de espécie para espécie e a forma varia para indivíduos de uma mesma espécie. Além dessa peculiaridade da forma, nela ficam registradas para sempre marcas de agressores naturais o que permite usá-la para distinguir entre animais diferentes. Isso, aliado a peculiaridades da forma, funciona exatamente como se fosse uma impressão digital. Muitas pesquisas são realizadas através da contagem desses animais em ambientes parcialmente “demarcados” em praias ou rios com diversos objetivos, dentre eles o estudo comportamental

entre grupos de animais[1]. A maior dificuldade encontrada reside exatamente no fato de que essas áreas não possuem limites exatos, além disso, ainda existe a dificuldade observacional humana. Outra dificuldade comentada reside exatamente na aquisição de imagens dos golfinhos com qualidade. A maior parte das espécies de golfinhos, ao notarem a presença de embarcações, procuram manter sempre uma distância considerável do barco ou simplesmente “desaparecem”. o processo de foto-identificação, praticado por diversos biólogos, pode fornecer informações sobre o movimento dos animais e também tamanho e dinâmica das populações [2]. Este método vem sendo aplicado há quase três décadas, principalmente em golfinhos-nariz-de-garrafa (*Tursiops truncatus*) e em orcas (*Orcinus orca*), além de muitas outras espécies de cetáceos [3] , [4], [2]. Como estas fotos são tiradas em dias, horários e condições naturais as mais diversas, a foto-identificação, através da observação puramente humana fica sujeita a muitas falhas e à subjetividade entre os diversos analisadores. Os golfinhos analisados neste trabalho residem numa área costeira do estado do Rio Grande do Norte conhecida como Baía dos Golfinhos, ao sul de Natal, entre as praias de Tabatinga e Búzios.

A proposta deste trabalho é construir um sistema que seja capaz de extrair características eficientes para posterior identificação de diferentes golfinhos em fotos realizadas a uma distância de cerca de 15 metros dos animais por equipes de biólogos e estudantes. Essas fotos são caracterizadas por uma grande área de mar e a presença do golfinho, normalmente, de forma centralizada no frame da foto. A eficiência aqui comentada refere-se à reunião de várias características capazes de identificar os diversos animais em um único sistema integrado. Nota-se aqui que deve haver uma certa padronização do momento fotográfico, com o objetivo de se ressaltar a nadadeira dorsal do animal observado. Fotos de animais mesclados com outros animais ou barcos ao fundo prejudicam fortemente a identificação, assim como foto de animais cuja nadadeira esteja parcialmente submersa. Propomos o uso de duas técnicas para identificação propriamente dita dos golfinhos. A primeira técnica executa uma busca num espaço de prioridades, atribuindo escores a medidas estatísticas de confiabilidade. A segunda técnica utiliza-se de uma memória associativa baseada num perceptron em multi-camadas treinado com um algoritmo do tipo “Backpropagation” (BPNN) [5]. Dotamos este perceptron com um mecanismo de auto-crescimento que facilita

*This work is supported by CNPQ/Brasil

a inclusão de novos indivíduos porventura descobertos no ambiente. Assim, a extração e abstração de características (features) combinada com os mecanismos de classificação com capacidade de auto-crescimento são os ingredientes chaves do sistema, permitindo seu emprego mesmo em condições não tão ideais. Uma das principais dificuldades encontradas é que as imagens trabalhadas geralmente são obtidas de diversos ângulos, com diversas escalas, com os golfinhos em posicionamentos diversos. Desenvolvemos também uma metodologia de normalização que contorna estes problemas, tornando o sistema robusto.

2 Estado da Arte

Encontramos na literatura um número reduzido de pesquisas sobre reconhecimento e análise de barbatanas de cetáceos. Ressaltamos uma avaliação de modelos invariantes na foto-identificação de golfinhos proposta por Araabi [6], onde foi concluído que métodos baseados na análise da curvatura da nadadeira dorsal são bem mais eficientes (invariantes diferencial, algébrico e semi-diferencial). Um problema ressaltado no trabalho em questão é que erros de digitalização podem comprometer sensivelmente os resultados, caso seja usado um modelo de invariância algébrica. O uso de modelos de invariância semi-diferencial é praticável, desde que o número de derivadas requeridas, assim como o número de pontos na correspondência, seja limitado a dois. Noutra referência encontrada [7], Hillman testa duas possibilidades. Na primeira, a curva da nadadeira é reduzida a um conjunto de coeficientes de Fourier e são extraídos alguns invariantes de similaridades, resultando em uma invariância em relação a posição da câmera, ângulo e distância do golfinho. A outra técnica baseia-se na localização de fendas, usando-se de uma curva rígida (*stiff snake*), através de um polinômio de quarto grau que determina uma aproximação da curvatura da nadadeira. Em seguida, é computada a diferença desta curva para os pontos reais da nadadeira dorsal. Essa última técnica produziu um conjunto de características mais promissoras.

Esta idéia é reforçada por Cesar e Costa [8] que explicam como diagramas de energia de curvatura de multi-escala podem ser facilmente obtidos de *curvogramas* [9] e usados como uma característica robusta geral para a caracterização morfométrica de células neurais. Ou seja, a energia de curvatura é uma característica global interessante para a caracterização de formas, expressando a quantidade de energia necessária para transformar uma forma específica dentro do seu estado de energia mais baixo (isto é, um círculo). O *curvograma*, que pode ser obtido precisamente através de técnicas de processamento de imagens (mais especificamente, através das transformadas de Fourier e sua inversa) provê uma representação de multi-escala de curvatura de contornos digitais. Eles discutem também que, pela normalização da energia de curvatura com respeito ao círculo padrão de perímetro unitário, essa característica torna-se eficiente para expressar formas complexas de modo a ser invari-

antes a rotação, translação e escala, além de ser robusta a ruídos e outros artefatos que implicam na aquisição da imagem.

3 Estrutura do sistema proposto

O diagrama mostrado na Figura 1 mostra a arquitetura básica do sistema proposto. O sistema divide-se basicamente em 7 módulos ou fases de processamento.




Figura 1: Diagrama de blocos do sistema proposto




Figura 2: Imagem original digitalizada (reamostrada).

Sistema de aquisição. A imagem adquirida é digitalizada, obtendo-se uma imagem na memória do computador (doravante denominada imagem original). A figura 2 mostra uma imagem digitalizada original.

Visualização e Delimitação. Nesta etapa, um operador humano é responsável pela re-apresentação adequada da imagem original. Presume-se que esta imagem esteja digitalizada com resolução alta, geralmente com dimensões médias de 1500 x 1500 pixels. Nesta fase, apresentamos a imagem ao operador com dimensões reduzidas apenas para controle da ferramenta de re-apresentação pelo usuário. Ou seja, o processamento todo será realizado na imagem original, evitando assim perdas na precisão dos dados. Nesta etapa, é empregado ainda um algoritmo para delimitação manual da região de interesse (região contendo golfinhos). Em seguida, a região delimitada é mapeada na imagem original. Isso resulta em uma sub-imagem na mesma resolução, que poderá aparecer geralmente “borrada”. Para melhorar o efeito visual dessa imagem para o usuário (além do processamento posterior) é aplicada uma técnica conhecida como auto-contraste [10].

Pré-processamento. Neste módulo são efetivamente aplicadas técnicas de pré-processamento, entre elas a transformada de Karhunen-Loève (KLT) [10] e o auto-contraste. A transformada KLT é aplicada com o objetivo de obter uma transformação que decorrelacione as variáveis do processo, mudando cada píxel para uma nova base. Isto é, levando a imagem transformada para um novo espaço de cores. A aplicação do auto-contraste na imagem consiste em elevar o contraste da imagem até

obter uma certa distribuição de níveis de cinza ou das componentes RGB, no caso de imagens coloridas.

Auto-segmentação. Utiliza-se a metodologia de segmentação não supervisionada através de uma rede neural artificial competitiva para realizar a segmentação da imagem baseada na sua textura. O que gera uma outra imagem com 2 rótulos, onde teremos fundo e objetos. Para rotular cada pixel da imagem com um destes rótulos, utilizamos como atributos para entrada na rede competitiva a média dos valores dos pixels vizinhos aos pixels selecionados, sendo que é tirada uma média de cada uma das componentes R,G e B. Ao final, obtém-se três atributos para cada pixel.

Padronização. Nesta etapa, são utilizados diversos algoritmos com a finalidade de padronizar a imagem provida pela etapa anterior. É importante que a imagem conduzida para a etapa seguinte seja padronizada, afim de que sejam obtidos descritores corretos. Um caso claro da real necessidade desta etapa é que as imagens podem vir com golfinhos em diferentes ângulos de rotação, como por exemplo imagens com golfinhos voltados para a esquerda do vídeo e outras com golfinhos voltados à direita do vídeo. Nesta fase, o operador humano escolhe três pontos de definição da nadadeira do golfinho. Esses três pontos são essenciais para o funcionamento correto dos algoritmos de detecção e extração de características. Note que seria difícil uma ferramenta de processamento de imagens capaz de extrair automaticamente apenas a nadadeira do animal. É empregada ainda nesta fase uma ferramenta visual onde o usuário posiciona (alinha) um golfinho sintético, visualizado tridimensionalmente numa janela gráfica auxiliar, à mesma pose (direção e sentido) atual do golfinho na imagem original. Este alinhamento pode ser controlado na janela gráfica com o uso do teclado e mouse. Após realizado o alinhamento, os ângulos de rotação (ângulos de euler) que foram aplicados são a base para uma transformação de rotação na imagem 2D necessária a compatibilização da nadadeira do golfinho mapeados corretamente para a apresentação 2D em vídeo.

Operadores morfológicos. As técnicas de morfologia matemática são utilizadas para extração de bordas, esqueletos e auxílio em outros algoritmos. Esses procedimentos serão úteis para a extração de descritores de forma da barbatana do golfinho para próxima etapa, além de servirem de base também para auxiliar em algoritmos de análise de curvatura, detecção de pico, entre outros.

Extração de características. Neste módulo são extraídas algumas características representativas da forma da barbatana dorsal do golfinho tais como: largura e altura da nadadeira, localização do pico, número e posição de fendas presentes na nadadeira, e também outros descritores que serão apresentados adiante.

Identificação. As características extraídas são fornecidas ao classificador, sendo fornecida uma resposta de identificação do golfinho.

4 Extrair características

Neste trabalho, usamos a forma da nadadeira e o número de fendas como características por serem estas menos sensíveis a variações, com algumas restrições. A figura 3 mostra um animal que apresenta uma rotação relativamente grande em relação ao eixo y (considere um sistema de coordenadas 3D com origem no centro de projeção da câmera). Neste caso, mesmo que o animal possua várias fendas, mesmo sendo de tamanho considerável, a maior parte delas simplesmente não são detectadas. Além disso a extração das curvas também será fortemente afetada. Para extrair estas características, faz-se necessário aplicar uma sequência de processamento que as preserve ao máximo. O diagrama 4 mostra a sequência de processamento usada neste trabalho para extração de características.



Figura 3: Golfinho com rotação elevada

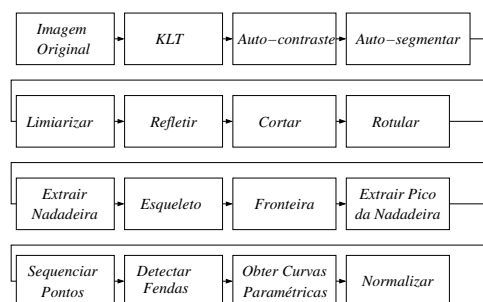


Figura 4: Sequencia do processamento realizado

Inicialmente, aplicamos um algoritmo de *Corte* para fazer um corte na parte inferior da nadadeira, usando a equação da reta formada pelos pontos que a delimitam. O usuário informa manualmente os pontos da base da nadadeira do golfinho. Todos os pontos inferiores a essa reta são colocados para "0" e farão parte do fundo da imagem. Aplicamos então um método de reflexão de imagem que faz uma reflexão tridimensional da imagem limiarizada em torno do eixo y, ou seja, apenas reconfigurando as coordenadas x da imagem. O processo subsequente de rotulação da imagem é fundamental para a identificação de aglomerados de pontos. Usamos quantização vetorial para separar esta imagem em classes. Devido a ruídos presentes na imagem após essas fases iniciais, é comum existirem vários objetos presentes, sendo que só nos interessa a nadadeira. Assim, é feita uma filtragem na imagem de forma a passar apenas o maior objeto presente (a própria nadadeira) para a próxima fase do processamento. A fronteira e o esqueleto são extraídos, sendo usados para extração do pico da nadadeira. A forma superior do esqueleto aponta para o pico da nadadeira. A seguir, pode-se buscar pontos que

estejam em seqüência na fronteira. O resultado do algoritmo é armazenado em dois vetores X e Y , ou seja, a seqüência adequada de pontos da nadadeira. A figura 5 mostra a fronteira de uma nadadeira e a seqüência de pontos obtidos e plotados novamente.




Figura 5: Pontos extraídos a partir da fronteira.




Figura 6: Modelo gráfico das curvas paramétricas usadas

Diferentemente de Araabi [6] e Hillman [7], o método aqui usado gera dois polinômios de terceiro grau, cada um representando um lado da nadadeira. A junção desses dois polinômios forma a nadadeira. A figura 6 mostra como é feita a parametrização das curvas. Note que as duas curvas são coincidentes em $\lambda = 0$. Esse ponto é exatamente o pico da nadadeira. A obtenção dos coeficientes paramétricos em x e y destas curvas se dá através da resolução de um sistema linear. A equação matricial final pode ser representada simplesmente por:

$$\Lambda.C_X = X \quad (1)$$

Uma padronização é então obtida através da aplicação de rotações. Dados os ângulos de Euler (rotação em torno de cada um dos eixos coordenados), e usando algumas simplificações, são determinadas facilmente as equações para mapear uma imagem em configuração genérica em uma imagem padronizada. Estes ângulos são entrados pelo operador humano numa interface de posicionamento do golfinho. Deve-se lembrar que essas transformações são aplicadas às equações paramétricas dos dois polinômios que representam a nadadeira do golfinho. Assim, chegamos às equações que representam a nadadeira sem qualquer rotação, ou seja, alinhada ao eixo x .

Para tentar capturar a noção de formato da nadadeira, foram definidos dois descritores: os raios de curvatura dos dois lados da barbatana e os índices de discrepância ao círculo que medem a semelhança entre um lado da barbatana e um arco de círculo. Estes descritores de curvatura baseiam-se na obtenção do centro do arco de círculo que melhor se ajusta aos polinômios descritores de um lado da barbatana do animal. Para o cálculo do índice de discrepância, efetua-se o somatório do quadrado das diferenças entre o valor do raio médio e a distância a cada um dos n pontos considerados. Note-se que, se a forma geométrica de um lado da nadadeira

fosse exatamente a de um arco de um círculo, o índice de discrepância seria zero.

Deve ser realizada ao final uma normalização nos dados obtidos. Vale lembrar aqui que essa normalização não é aplicada à uma imagem, mas aos coeficientes que descrevem as duas curvas cúbicas paramétricas. Para efeitos de extração de características e posterior comparação com outros animais essa etapa é de fundamental importância.

4.1 Características propriamente ditas

Após todo o processamento apresentado anteriormente, as características propriamente ditas são calculadas usando as duas curvas polinomiais resultantes.

Estas características são em número de 16:

- duas coordenadas X e Y do pico;
- número de fendas em cada curva (um número entre 0 e um máximo de 4 foram consideradas);
- 4 localizações de fendas para cada curva (em no máximo 4 locais), sendo dada pelo valor da posição do parâmetro da curva na posição respectiva;
- raio de curvatura correspondente a cada curva paramétrica;
- índice de discrepância ao círculo para cada curva paramétrica.

5 Identificação e reconhecimento

Foram usadas duas técnicas básicas para identificação e reconhecimento. A primeira técnica usa um simples template matching para determinar a distância a que se encontra o vetor de características de um vetor já existente numa tabela interna. É calculada a diferença entre cada elemento do vetor de características dado para cada elemento dos vetores de características na memória, sendo atribuído um escore a cada vetor. Ao final, o que possuir maior escore será o vencedor, portanto o golfinho identificado. Note que teremos sempre um vencedor com um maior ou menor escore. Este método não permite determinar um limiar para identificar um novo golfinho, caso o escore não satisfaça um limite mínimo. Esta técnica de identificação permitiu confirmar a qualidade das características extraídas.

Numa segunda implementação, usamos um perceptron em multi-camadas treinado com um algoritmo do tipo "Backpropagation" (BPNN) [5]. A BPNN é uma rede totalmente conectada, com ativação avante, isto é, da camada de entrada para a última camada. O conhecimento adquirido fica codificado nas sinapses (ligações ou pesos), em cada conexão entre as unidades da rede (nós ou neurônios). Os pesos são ajustados por um processo de treinamento que envolve basicamente duas fases. Na primeira delas, dada um vetor na camada de entrada, o sistema calcula a ativação avante, usando os pesos correntes. Na segunda fase, o erro na última camada é calculado como a diferença entre a saída atual da rede e a saída

desejada. O erro é propagado para trás, para as camadas intermediárias visando corrigir os pesos destas camadas segundo uma função de ajuste. Após treinada, a ativação obtida na última camada representa uma resposta a um determinado vetor de valores entrado na rede. O algoritmo da BPNN encontra-se correntemente bem definido e pode ser encontrado em vários trabalhos [11, 12, 5].




Figura 7: Topologia da BPNN usada.

A Figura 7 mostra a estrutura da rede usada neste trabalho. Ela possui uma entrada para cada característica determinada acima (total de 16). O número de nós da camada intermediária muda de acordo com o número corrente de golfinhos conhecidos. O número de nós na camada de saída pode ser mudado dinamicamente (e automaticamente) pelo sistema se mais golfinhos ainda não conhecidos forem detectados, na Baía dos Golfinhos por exemplo. Introduzimos um mecanismo de auto-crescimento, ou seja, definimos experimentalmente um limiar que informa se uma representação é nova; se a ativação para um determinado padrão encontra-se abaixo deste limiar, um módulo de aprendizado supervisionado é automaticamente acionado, inserindo o novo padrão na memória de longo termo do sistema, incrementa (cria novos nós ou neurônios) e re-treina a BPNN. Ou seja, a rede aprende de forma automática uma representação para o novo padrão e a insere na memória do sistema. Para determinar se um golfinho ainda não é conhecido, usamos uma função que considera uma ponderação entre os erros mínimo e máximo da rede, dados pela fase de treinamento. O número de nós na camada intermediária também muda. Empiricamente, determinamos que 1,5 vezes o número de nós da camada de saída produz bons resultados. A Equação 2 é usada para a ativação avante (determinar a melhor identificação). A Equação 3 é usada para o treinamento da rede.

$$o_i = (1 + e^{-\sum_{i=0}^A \omega_{ij} x_i})^{-1} \quad (2)$$

$$\Delta\omega_{ij}(t+1) = \epsilon\delta_j o_i + \alpha\Delta\omega_{ij}(t), \quad (3)$$

onde o_i foi definido acima e

$$\delta_j = \begin{cases} o_j(1-o_j)(y_j-o_j), & \forall j \in output \\ o_j(1-o_j)\sum_{k=1}^B \delta_k \omega_{jk}, & \forall j \in other \end{cases}$$

Rede	.95	.04	.00	.00	.01	.00	.02	.00
Dese	1.0	.00	.00	.00	.00	.00	.00	.00
Rede	.03	.92	.04	.00	.01	.00	.00	.01
Dese	.00	1.0	.00	.00	.00	.00	.00	.00
Rede	.00	.04	.94	.03	.00	.00	.02	.03
Dese	.00	.00	1.0	.00	.00	.00	.00	.00
Rede	.00	.00	.02	.97	.00	.01	.00	.02
Dese	.00	.00	.00	1.0	.00	.00	.00	.00
Rede	.01	.01	.00	.00	.97	.01	.00	.01
Dese	.00	.00	.00	.00	1.0	.00	.00	.00
Rede	.01	.00	.00	.00	.01	.98	.00	.02
Dese	.00	.00	.00	.00	.00	1.0	.00	.00
Rede	.03	.00	.03	.00	.01	.00	.97	.00
Dese	.00	.00	.00	.00	.00	.00	1.0	.00
Rede	.00	.04	.03	.02	.01	.03	.00	.96
Dese	.00	.00	.00	.00	.00	.00	.00	1.0

Tabela 1: Ativação dada pela última camada da rede e ativação ideal. Foram inseridos 8 golfinhos na rede.

6. Experimentos e resultados

Nos experimentos realizados, ambas técnicas de classificação foram aplicadas à identificação de golfinhos e os resultados foram aceitáveis. Basicamente, algumas instâncias de animais foram escolhidas e calculadas as características para eles. Estas características foram usadas em ambos classificadores, numa fase de treinamento (BPNN) ou numa tabela (*template matching*). A seguir, algumas outras imagens das mesmas instâncias de golfinhos foram escolhidas e apresentadas ao sistema.

A Tabela 1 mostra as ativações dos nós de saída da rede BP para vetores de entrada correspondentes a 8 golfinhos, após 500 épocas de treinamento, em pose ideal. Todos eles foram identificados positivamente, como era esperado. O erro máximo ficou em 0.076041. O erro médio em 0.015358. Isso demonstra que o algoritmo funciona da maneira desejada, convergindo para um treinamento adequado.

A ativação para golfinhos presentes na memória, mas cuja imagem era diferente da imagem com que ele foi inserido inicialmente na memória foi de mais de 0,9 em todos os caso testados (testamos 8 casos assim). ou seja, pudemos verificar que as rotações foram bem suportadas pelo classificador. Quanto ao tempo de treinamento, o gráfico mostrado na Figura 8 mostra o tempo em segundos versus número de golfinhos na rede. Pode-se notar que para 21 golfinhos a rede gasta cerca de 22 segundos. o gráfico mostrado na Figura 9 mostra o número de épocas versus número de golfinhos (nós na última camada).

Notamos que os vetores eram compostos com 16 entradas e que a rede possui 22 neurônios na camada intermediária, em algumas sistações. Os gráficos mostram uma função aparentemente exponencial. Isto não é um problema, uma vez que o número de golfinhos em uma dada família não deve ultrapassar de 50. Ainda, numa




Figura 8: Tempo versus número de golfinhos.




Figura 9: Épocas versus número de golfinhos.

situação prática, o sistema é treinado off-line e os pesos salvos para serem usados na ocasião em que for necessário. Isto certamente não interfere na performance do sistema.

Ainda, fizemos uma comparação entre os resultados dados pela rede neural e pelo método de *template matching*. A rede, apesar de mais lenta, foi ligeiramente superior, produzindo ativações com valores mais confiáveis nas identificações que o método de escores. Em alguns casos, o método simples apresentou escore de 6,0 num máximo de 10,0, enquanto que a rede deu 0,99 de confiança num máximo de 1,00.

7. Discussões, conclusões e perspectivas

Desenvolvemos um sistema completo para identificação de golfinhos, que vai desde a aquisição de imagens, o seu processamento visando extração de características e sua posterior utilização por dois tipos de classificadores diferentes. Apesar da ênfase deste texto ser nos classificadores, convém ressaltar a importância e generalidade das técnicas de processamento de imagens usada. O sistema procedeu da forma esperada no tocante a identificação. Outras alternativas de classificadores deverão ser testadas em seguida, por exemplo, as redes bayesianas, os mapas auto-organizáveis (SOM) ou as funções de base radial (RBF).

Vale ressaltar que o conjunto de características utilizado pode ser melhorado. Um bom conjunto deve, sem dúvida, considerar a textura. Para o uso de textura, deve ser definida uma maneira de se contornar os efeitos da água na iluminação da imagem. Apesar disso, destacamos a importância das características apresentadas, com bons resultados. Há algumas restrições a serem observadas na obtenção das características. Por exemplo, caso ocorra uma rotação em y elevada (próximo a 90 graus), as fendas e contornos podem não ser visíveis. Isso

certamente irá prejudicar o funcionamento do sistema, pois algumas fendas podem não ser detectadas, gerando dados falsos.

A rede BP usada mostrou-se eficiente no tocante a inclusão de novos indivíduos na memória de longo termo, devido ao seu mecanismo de auto-crescimento. Ainda, alguma estratégia pode ser desenvolvida para que o sistema consiga aprender qual classe de características pode ser melhor empregada no problema em questão. Desta forma, um conjunto menor de características pode ser empregado, diminuindo o tempo de processamento da rede. Algo baseado em inferência estocástica deverá ser tentado a título de trabalho futuro nesta linha.

Referências

- [1] L. d. O. Link. Ocorrência, uso do habitat e fidelidade ao local do boto cinza. Master's thesis, Universidade Federal do Rio Grande do Norte, 2000.
- [2] J. Mann, R. Connor, P. Tyack, and H. Whitehead. *Cetaceans societies - field studies of dolphins and whales*. The University Chicago Press, Chicago, 2000.
- [3] R. H. Defran, G. M. Shultz, and D. Weller. A technique for the photographic identification and cataloging of dorsal fins of the bottlenose dolphin (*tursiops truncatus*). Technical report, International Whaling Commission (Report - Special issue 12), 1990.
- [4] P. Flores. Preliminary results of photoidentification study of marine tucuxi, *Sotalia fluviatilis* in southern brazil. *Marine Mammal Science*, 15(3):840-847, 1999.
- [5] M. Riedmiller and H. Braun. A direct adaptive method for faster backpropagation learning: The rprop algorithm. In *Proc. of the International Conference on Neural Networks (ICNN'93)*, pages 123-134. IEEE Computer Society Press, 1993.
- [6] B. N. Araabi, N. Kehtarnavaz, G. Hillman, and B. Wursig. Evaluation of invariant models for dolphin photo-identification.
- [7] G. R. Hillman, T. H. E. K., D. A., W. D., and W. B. Shape descriptors computed from photographs of dolphins dorsal fins for use as database indices. In *Proc. of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, volume 20, 1998.
- [8] R. Cesar Jr. and L. d. F. Costa. Application and assessment of multiscale bending energy for morphometric characterization of neural cells. *Rev. Sci. Instrum.*, 68(5):2177-2186, 1997.
- [9] R. Cesar Jr. and L. d. F. Costa. Pattern recognition. *Pattern Recognition*, 29:1559, 1996.
- [10] A. K. JAIN. *Fundamentals of Digital Image Processing*. Prentice-Hall, October 1989.
- [11] D. E. Rumelhart, G. E. Hinton, and R. J. Williams. *Learning internal representations by error propagation*. In D. E. Rumelhart and J. L. McClelland, editors, *Parallel Distributed Processing: Explorations in the microstructure of cognition*, volume 1: Foundations. The MIT Press, Cambridge, Massachusetts, 1986.
- [12] P. Werbos. Backpropagation: Past and future. *IEEE International Conference on Neural Networks*, pages 343-353, 1988.