
Estimativa da Massa de Alevinos utilizando Visão Computacional

Adair da Silva Oliveira Junior

Orientador: *Prof. Dr. Hemerson Pistori*

Plano de Trabalho

Sumário

1	Antecedentes e Justificativas	1
2	Objetivos	3
2.1	Geral	3
2.2	Específicos	3
3	Revisão de Literatura	4
3.1	Visão Computacional	4
3.1.1	Componentes e etapas de um sistema de visão computacional	4
3.2	Segmentação	5
3.2.1	SLIC <i>superpixels</i>	5
3.3	Esqueletização	6
3.4	Extração de Atributos	7
3.5	Aprendizagem Automatizada	8
3.5.1	Regressão Linear	9
3.5.2	Maquinas de Vetores de Suporte	9
3.5.3	Adaboost	9
3.6	Estimativa de Massa	10
4	Metodologia	11
4.1	Aprofundamento e atualização sobre as técnicas de visão computacional, e outras áreas da computação que forem necessárias, para o desenvolvimento do <i>software</i> proposto	11
4.2	Estudo sobre o manejo e produção de alevinos, assim como os aspectos morfológicos das espécies que serão empregadas no desenvolvimento do trabalho	11
4.3	Criação de um banco de imagens (<i>dataset</i>) que permita a realização de experimentos de estimativa da massa de alevinos	12
4.4	Desenvolvimento do <i>software</i> para a realização da estimativa de massa de alevinos, a partir do banco de imagens criado	12
4.5	Realização de experimentos para validação do <i>software</i>	12
4.6	Registro e divulgação dos resultados obtidos	13
5	Cronograma	14
	Referências Bibliográficas	15

Capítulo 1

Antecedentes e Justificativas

O peixe é a proteína animal mais consumida no mundo, porém, o grande crescimento populacional e a necessidade dos seres humanos de se obter uma alimentação cada vez mais saudável, fazem com que haja a necessidade de avanços na produção piscícola, principalmente no Brasil, país com produção em ascensão. A exploração da pesca extrativa, atividade que possui maior produção atualmente, aliada à degradação ambiental gerou um desequilíbrio nas populações de pescado, trazendo a algumas espécies até mesmo o risco de extinção, o que tem resultado em grandes restrições, causando a essa atividade limitações em sua produção. A produção piscícola é uma atividade sustentável devido a propagação artificial de alevinos, seja ela de reprodução natural ou induzida. O peixe é uma classe de animais que possui mais de 22.000 espécies catalogadas, segundo Buckup et al. (2007) no Brasil são mais de 2.000 espécies de água doce, trazendo à piscicultura uma grande quantidade de potenciais espécies para cultivo, diferenciando-a das atividades como suinocultura e avicultura onde o número de espécies para cultivo é reduzido (Andrade & Yasui, 2003).

O Brasil terá um crescimento de 100% em sua produção de pesca e aquicultura até o ano de 2025. Esse crescimento será o maior da região, seguido pelo México e Argentina sendo na sequência 54% e 53%. Segundo dados da Embrapa, o Brasil possui 8.500 km de costa marítima e cerca de 12% do total da água doce do mundo, ou seja, possui todas as condições favoráveis para a pesca e aquicultura. O Brasil também possui condições climáticas ideais, em grande parte do seu território, para a produção piscícola, principalmente para produção da espécie tilápia, umas das espécies de maior consumo no mundo. Outros fatores que contribuem para esse crescimento previsto, segundo a Organização das Nações Unidas para Alimentação e Agricultura (FAO), são os investimentos em pesquisa e inovação nos últimos anos (LA & LA (2016) e Sidonio et al. (2012)).

Devido aos fatos apontados, é evidente a necessidade de desenvolvimento tecnológico para dar suporte à produção de peixes, principalmente à piscicultura, atividade que deve ultrapassar a pesca extrativa em poucos anos. Esse suporte deve servir não só para o aumento da produção, mas também para garantir a qualidade da mesma. Há uma dificuldade no manejo dos peixes, pois os mesmos são muito sensíveis, não podem por exemplo ser expostos à luz por muito tempo. Por isso o desenvolvimento tecnológico deve ser guiado tendo como base essas limitações, além

da preocupação de operação dos equipamentos sob a água ou em ambientes molhados. Técnicas de visão computacional, mesmo que atualmente não sejam muito usadas na aquicultura, podem suprir as necessidades apontadas (Zion, 2012).

A visão computacional tem como objetivo o emprego de técnicas computacionais para a extração de informações úteis a partir de imagens (Prince, 2012). Zion (2012) aponta que a visão computacional pode dar suporte em diversas atividades da aquicultura, como por exemplo, contagem, medição, estimativa da massa, identificação de sexo, avaliação da qualidade das cores de peixes ornamentais, identificação de espécies e monitoramento do bem-estar. A aplicação da visão computacional à piscicultura se torna viável, uma vez que a mesma pode reduzir o estresse dos peixes, pois, diminui a necessidade da utilização de redes e a exposição dos mesmos à luz.

A aprendizagem de máquina, ou aprendizagem automatizada, subárea da inteligência artificial, possui técnicas computacionais para o reconhecimento de padrões, técnicas as quais podem ser utilizadas em conjunto com as de visão computacional para a resolução dos problemas. A mesma pode ser aplicada em diversos problemas de classificação e regressão, tendo como premissa, o aprendizado através de exemplos. A regressão linear, uma das técnicas de aprendizagem de máquina, tem como objetivo encontrar modelos matemáticos lineares que correlacionem variáveis de entrada e de saída. Esta técnica permite o descobrimento de quais características em uma imagem melhor se correlacionam com o problema em questão.

Foi criado no ano de 2001 na Universidade Católica Dom Bosco o grupo de pesquisa INOVISÃO, sendo composto por pesquisadores e alunos de graduação, mestrado e doutorado, o qual busca através da inovação com técnicas de visão computacional o desenvolvimento científico e tecnológico, visando a resolução de problemas nas mais diversas áreas, como por exemplo o agronegócio e perícia criminal.

O grupo INOVISÃO possui um projeto denominado FISHCV, que tem como objetivo o desenvolvimento de tecnologias voltadas à piscicultura. O projeto FISHCV possui um contador de alevinos em fase de testes finais e inicia um estimador da massa de alevinos, proposta deste trabalho, que funcionará em conjunto com o contador. Para o desenvolvimento deste projeto, o grupo conta com a parceria da empresa Projeto Pacu, desde 2015, empresa piscícola sediada em Terenos, Mato Grosso do Sul, produtora de alevinos da espécie pintado-real. A empresa parceira cede o ambiente, os alevinos e todo o material necessário para coleta das imagens e execução dos experimentos.

As informações, geradas pela estimativa da massa dos alevinos, auxiliarão o produtor em diversas partes do processo de criação, como por exemplo, para saber a necessidade do aumento na quantidade de ração administrada aos tanques e a geração de relatórios de venda. Esses relatórios servem para que seus clientes tenham informações referentes aos produtos adquiridos, e assim, trazendo uma maior credibilidade ao piscicultor.

Capítulo 2

Objetivos

Neste capítulo serão apresentados o objetivo geral e os objetivos específicos que guiarão o desenvolvimento deste trabalho.

2.1 Geral

O objetivo geral deste trabalho é o desenvolvimento de um *software* que realize a estimativa da massa de alevinos baseado em visão computacional, com o intuito de melhorar os processos de criação de alevinos, oferecendo ao mercado aquícola uma ferramenta de baixo custo, portanto acessível a todos os tipos de produtores, e que não cause danos aos animais.

2.2 Específicos

Para a realização do objetivo geral proposto, pretende-se realizar os seguintes objetivos específicos:

- Aprofundamento e atualização sobre as técnicas de visão computacional, e outras áreas da computação que forem necessárias, para o desenvolvimento do *software* proposto.
- Estudo sobre o manejo e produção de alevinos, assim como aspectos morfológicos das espécies que serão empregadas no desenvolvimento do trabalho.
- Criação de um banco de imagens (*dataset*) que permita a realização de experimentos de estimativa da massa de alevinos.
- Desenvolvimento do *software* para a realização da estimativa da massa de alevinos, a partir do banco de imagens criado.
- Realização de experimentos com o *software* desenvolvido.
- Registro e divulgação dos resultados obtidos.

Capítulo 3

Revisão de Literatura

Neste capítulo serão apresentados alguns dos conceitos que serão necessários para a realização deste trabalho.

3.1 Visão Computacional

Segundo Prince (2012) a visão computacional tem como objetivo o emprego de técnicas computacionais para a extração de informações úteis a partir de imagens. Para Shapiro & Stockman (2001) o objetivo da visão computacional é criar decisões úteis sobre objetos reais e cenas através do uso de imagens.

A visão computacional se apresentou uma tarefa surpreendentemente desafiadora e tem despertado um grande interesse em milhares de pesquisadores nos últimos 40 anos. Embora grandes avanços vem acontecendo, estamos muito longe ainda de obter um desempenho próximo ao humano, isto se deve a complexidade dos dados visuais.

A visão computacional possui relações com diversas outras áreas do conhecimento, sendo elas: processamento de sinais, robótica, inteligência artificial, aprendizagem de máquina, matemática, neurobiologia, ótica, entre outras. Muitas das técnicas desenvolvidas nessas áreas podem ser aproveitadas na visão computacional, podemos dizer o mesmo do oposto (Prince, 2012).

3.1.1 Componentes e etapas de um sistema de visão computacional

Um sistema de visão computacional consiste, geralmente, em quatro componentes básicos, sendo eles: iluminação, câmera, *hardware* e *software*. A iluminação é um componente importante, pois se a mesma for bem administrada pode reduzir reflexão, sombras e ruídos, facilitando assim as fases de pré-processamento, em alguns casos até a eliminando, e processamento. A câmera tem como objetivo a captação de imagens codificadas em formato digital. Os parâmetros da câmera, como por exemplo resolução, afetam diretamente a fase de processamento, pois quanto maior a resolução mais informações terão que ser processadas, e assim aumentando o tempo para conclusão desta fase. Um contra ponto é que se a resolução da câmera for baixa, as informações disponíveis para processamento podem ser insuficientes. Por último

o *hardware* e o *software* são os elementos que formam o sistema computacional que irá processar as informações das imagens captadas (Szeliski, 2010).

Como o *software* proposto tem como objetivo estimar a massa de alevinos, é de extrema importância a preocupação com os componentes apontados. As imagens que servirão de entrada para o *software* serão capturadas em um ambiente que contém água, e a mesma poderá então causar uma série de ruídos, como por exemplo reflexão da luz. Portanto, a administração da iluminação deverá ser realizada de maneira a reduzir esses ruídos.

Podemos dividir um sistema de visão computacional em 5 principais etapas, sendo elas: aquisição de imagens, pré-processamento, extração de características, segmentação e processamento. Atualmente a terceira etapa, extração de características, pode ser substituída por algoritmos de aprendizagem de máquina, que através de um conjunto de treinamento aprendem características automaticamente. Em alguns sistemas podemos ainda adicionar a etapa de atuação, como por exemplo no campo da robótica que precisamos excitar atuadores para realizar ações.

3.2 Segmentação

A segmentação é uma técnica de visão computacional que tem como objetivo associar um rótulo para cada um dos *pixels* em uma imagem, de modo que as regiões que pertencem ao mesmo objeto são atribuídas ao mesmo rótulo (Prince, 2012). Existem diversas técnicas de segmentação, uma delas é a limiarização, considerada simples, que consiste em rotular os *pixels* de uma imagem verificando se os valores de seu espaço de cor, por exemplo o espaço de cores *RGB*, respeitam os limiares impostos (Sahoo et al., 1988). Essa técnica é muito útil quando os objetos em uma imagem possuem cores que se distanciam, no espaço de cores, do fundo da imagem. A Figura 3.1 representa um exemplo de limiarização aplicado a imagem de um alevino.

Achanta et al. (2012) apresentam em seu trabalho técnicas de *superpixel*, ou também conhecidas como técnicas de clusterização. Essas são técnicas de segmentação que tem como objetivo agrupar *pixels* que possuem características parecidas, criando assim regiões atômicas que representam uma informação conjunta. Com a clusterização, informações redundantes são descartadas, diminuindo assim o custo computacional nas tarefas de processamento.

3.2.1 SLIC *superpixels*

SLIC *superpixels* é uma técnica de segmentação proposta por Achanta et al. (2012) e que possui melhor desempenho, em tempo, do que as outras técnicas de *superpixels* existentes. Esta técnica é baseada no algoritmo de clusterização *k-means*, introduzida por Hartigan & Wong (1979).

Na técnica *k-means*, é dada uma coleção de pontos, os quais serão divididos em *k clusters*. Esta divisão é feita através do cálculo da distância Euclidiana de cada ponto até o ponto central de cada *cluster*, onde o ponto é designado para o *cluster* cuja distância calculada for a menor. Quando aplicada em uma imagem, os *clusters* tendem a ter uma forma mais rígida, se aproximando de figuras geométricas quadradas (Hartigan & Wong, 1979). Na técnica SLIC, além da análise da distância

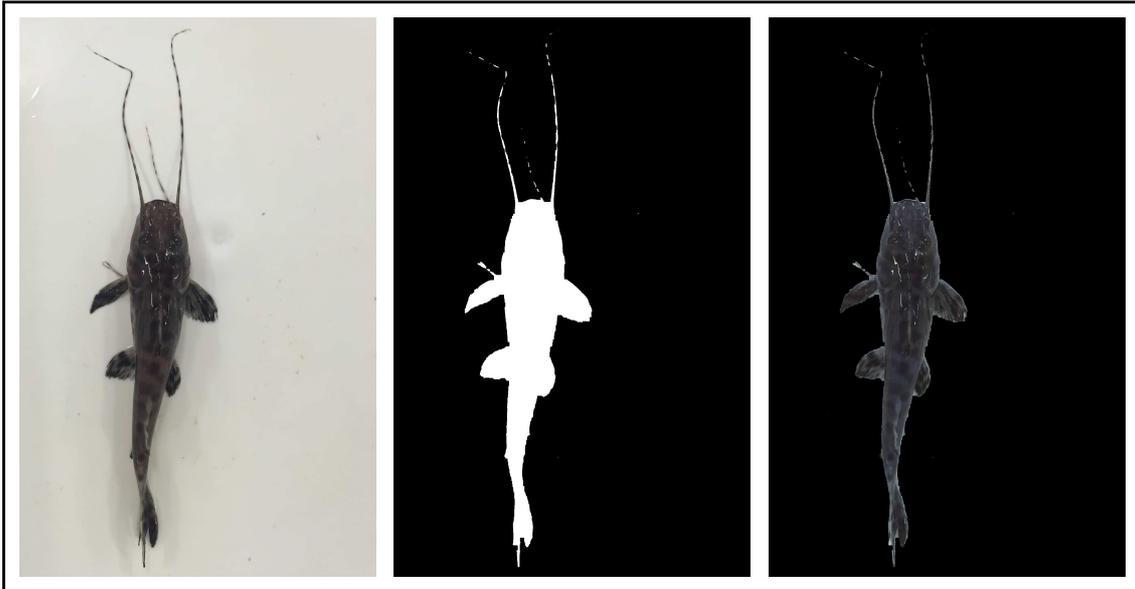


Figura 3.1: Exemplo de segmentação por limiarização. Da esquerda para direita, imagem original, imagem binária obtida através da limiarização e imagem com o objeto separado do fundo através de um operação de “E”lógico entre a imagem original e a binária.

euclidiana, é também feita a análise da distância no espaço de cores *CIELAB*. São atribuídos pesos para essas duas distâncias, os quais determinam o quão irregular os *superpixels* gerados podem ser (Achanta et al., 2012). A Figura 3.2 representa um exemplo da técnica SLIC, com 300 *kernels*, aplicada à imagem de um peixe palhaço.

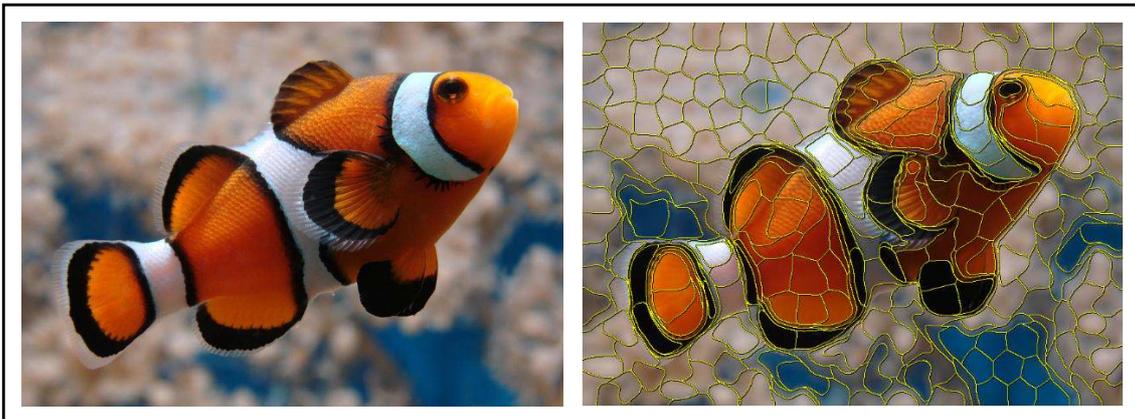


Figura 3.2: Exemplo da aplicação da técnica SLIC *superpixels*, com 300 *kernels*, à imagem de um peixe palhaço.

3.3 Esqueletização

A esqueletização é uma técnica de processamento digital de imagens que simplifica um objeto, reduzindo a quantidade de informações e preservando, ao mesmo tempo,

as características topológicas do mesmo (Idder & Laachfoubi, 2015). Na literatura esta técnica pode também ser encontrada pelos nomes esqueletomização e esqueletonização. Segundo Bium (1967) a esqueletização pode ser explicada através da propagação do fogo em um gramado. Imaginemos uma visão superior de um gramado onde ao longo de toda a sua borda fosse ateado fogo, e o mesmo se alastrasse de forma constante, uniforme e perpendicular à borda. O esqueleto é formado nos pontos onde o fogo se encontra. A Figura 3.3 apresenta um exemplo da técnica esqueletização aplicada à uma forma geométrica retangular.

Esta técnica pode ser empregada com o intuito de diminuir a quantidade de informação que será processada, diminuindo assim o custo computacional do *software*, neste caso tanto de memória quanto de processamento. Outros benefícios que esta técnica pode trazer são: a redução de ruído e a possibilidade de se obter informações referentes ao comprimento do alevino, já que os pontos que formaram o esqueleto se localizaram no centro do objeto, e formará assim uma espécie de espinha do mesmo. O comprimento do alevino é também uma característica que deve ser experimentada, no intuito de se obter uma correlação com a massa.

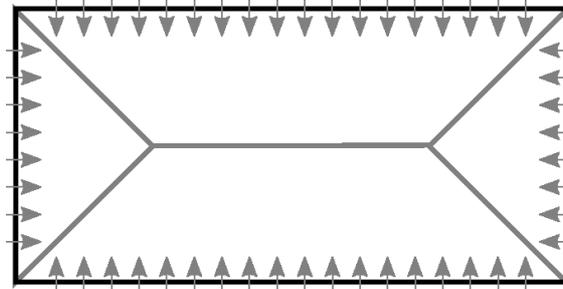


Figura 3.3: Exemplo de esqueletização. A forma original é o retângulo preto, as linhas em cinza dentro do retângulo são o resultado da esqueletização e as setas representam o sentido em que a esqueletização se propaga.

3.4 Extração de Atributos

Extração e correspondência de atributos são componentes essenciais de um sistema de visão computacional. Esses atributos, também conhecidos como pontos de interesse, podem ser descritos por um conjunto de *pixels* entorno de um ponto, contornos ou bordas (Szeliski, 2010).

Segundo Tuytelaars et al. (2008) bons extratores de atributos devem conter as seguintes propriedades:

- Repetibilidade: dada duas imagens de um mesmo objeto ou cenas, em visões diferentes, como por exemplo rotacionadas, atributos encontrados em uma imagem devem ser encontrados na outra também.
- Distintividade: os atributos devem possuir características as quais possam distinguir o mesmo de outros atributos, podendo assim ser rotulados e correspondidos em imagens distintas.

- **Localidade:** os atributos devem ser locais, permitindo assim aproximações de modelos simples.
- **Quantidade:** esses atributos devem ser encontrados em uma quantidade suficiente para que os mesmos possam identificar cenas e objetos. Não há um número ótimo, a quantidade ótima varia de aplicação para aplicação.
- **Precisão:** os atributos encontrados devem possuir precisão em sua localidade, escala, forma e orientação.
- **Eficiência:** a extração dos atributos em uma imagem devem ser rápida. Importante para sistemas que possui criticidade quanto ao tempo.

Após a detecção dos atributos, os mesmos são transformados em descritores de características locais ou descritores de pontos de interesse. A literatura atual conta com diversos algoritmos de extração de atributos, sendo os mais utilizados: DAISY (Tola et al., 2010), GLOH (Mikolajczyk & Schmid, 2005), HOG (Dalal & Triggs, 2005), SURF (Bay et al., 2008) e SIFT (Lowe, 1999).

Além dos algoritmos já citados, é possível realizar a extração de atributos utilizando algoritmos de aprendizagem de máquina, mais precisamente algoritmos de aprendizagem profunda. Esses algoritmos são construídos utilizando redes neurais com diversas camadas, as quais necessitam de uma grande quantidade informação, na ordem de milhares de exemplos, para serem treinadas. Durante seu treinamento as mesmas aprendem, automaticamente, extratores de atributos associando pesos aos mesmos, ou seja, as características que melhor representam o problema possuem pesos maiores que as que não representam. Esses extratores se encontram nas camadas próximas à entrada. Na aprendizagem profunda é possível realizar a transferência de aprendizagem, técnica que permite o aproveitamento das camadas de extratores de atributos treinadas em outros problemas, muito útil em problemas que possuem poucos dados para treinamento (Krizhevsky et al., 2012).

3.5 Aprendizagem Automatizada

A aprendizagem é um fenômeno que ocorre quando um agente melhora seu desempenho em atividades que serão realizadas no futuro através de experiências passadas e observações sobre o mundo. Um tipo de aprendizagem, a automatizada, é realizada a partir de uma coleção e pares de dados, entrada e saída, os quais são analisados e como consequência são derivadas funções que podem prever saídas para novas entradas. As informações de entrada são formadas por um único ou um conjunto de atributos, representados de maneira fatorada, que se relacionam com saídas que podem ser valores numéricos ou valores discretos (Thrun & Norvig, 2011).

A ferramenta WEKA, implementada na linguagem de programação *Java*, contém um conjunto de algoritmos capazes de realizar, a partir de um conjunto de dados, a criação de funções que possam prever futuros valores. Os dados são importados pela ferramenta através de arquivos ARFF, do inglês (Attribute-Relation File Format), arquivos de textos que descrevem uma lista de instâncias que compartilham um conjunto de atributos. Além da criação dessas funções, a ferramenta ainda conta com

funcionalidades de avaliação do modelo criado através de coeficientes de correlação, precisão, *recall*, medida-f, matriz de confusão entre outros (Hall et al., 2009).

3.5.1 Regressão Linear

A regressão linear é uma técnica de aprendizagem com origem na estatística. Em sua forma mais básica, com apenas uma variável, dada duas variáveis em um plano, X e Y , e um conjunto de pontos que associam valores entre essas variáveis, é realizada a dedução de uma equação em função de X que corresponda Y , portanto, a partir de qualquer valor de X é possível estimar o valor de Y . A dedução desta equação é realizada de modo a minimizar o somatório dos quadrados dos erros. A função gerada na regressão linear é dada pela equação reduzida da reta descrita na equação 3.1, onde a é a declividade da reta e c é o valor em que a reta cruza o eixo Y (Neter et al., 1996).

$$Y = a * X + b \tag{3.1}$$

O coeficiente de *Pearson*, ou também conhecido como coeficiente de correlação, mede o grau de correlação entre duas variáveis. O mesmo varia de -1 à 1, sendo que quanto mais próximo do valor 1 maior a correlação direta e quanto mais próximo do valor -1 maior é a correlação inversa.

A regressão linear pode ser realizada de maneira multivariada, ou seja, não apenas entre duas variáveis, e sim n variáveis, sendo representadas em n dimensões. Diferente da regressão linear, esta terá com resultado não uma reta, mas sim um plano.

3.5.2 Maquinas de Vetores de Suporte

Maquinas de Vetores de Suporte (SVM) é uma técnica de classificação introduzida por Boser et al. (1992) e Vapnik & Vapnik (1998), que dado um conjunto de classes, é criada uma função que as separe. Imaginemos um plano com dois conjuntos, positivos e negativos, máquinas de vetores de suporte separaria esses conjuntos com uma margem. Uma vez que possam existir diversas margens que divida o plano, e que em cada divisão haja apenas exemplo positivos e exemplos negativos, a margem escolhida será aquela que maximize a distância da margem aos exemplos, negativo e positivo, mais próximos (Guyon et al., 2002).

3.5.3 Adaboost

Boosting é uma técnica utilizada para otimizar o resultado de algoritmos de aprendizagem. A mesma executa repetidas vezes o algoritmo de aprendizagem alvo, com subconjuntos dos dados de treinamento, e em seguida realiza a combinação dos resultados, transformando-o em um único classificador agregado.

O algoritmo Adaboost é um algoritmo de *boosting* que possui duas versões a Adaboost.M1 e a Adaboost.M2, diferenciando entre si somente quando o problema possui mais de duas classes. Este algoritmo recebe como parâmetro um algoritmo de aprendizagem, chamado de algoritmo fraco, e um conjunto de casos de treinamento.

O algoritmo fraco é executado por várias iterações, e ao classificador resultante é associado a um peso que é inversamente proporcional à taxa de erro. A classe que possui o maior peso é escolhido como correto pelo algoritmo (Freund et al., 1996).

3.6 Estimativa de Massa

A estimativa de massa, apoiada por técnicas de visão computacional, vem sendo explorada para diversos tipos de animais (De Wet et al. (2003), Pastorelli et al. (2006), Negretti et al. (2010), Ozkaya & Bozkurt (2008), Odone et al. (2001), Lines et al. (2001), Zion (2012) e Viazzi et al. (2015)). Zion (2012) realizou uma revisão de como a visão computacional tem sido explorada para auxiliar a aquicultura, não só na estimativa de massa de peixes, mas também na contagem, medição, identificação do sexo, avaliação da qualidade de peixes ornamentais, identificação de espécies e monitoramento do bem-estar. A seguir serão apresentados alguns trabalhos que utilizam visão computacional para estimar a massa de peixes.

Viazi et al. (2015) estimaram a massa de peixes da espécie Jade Perch (*Scortum Barcoo*) dentro de tanques, de modo a minimizar o estresse e dano causado nos mesmos. Essa espécie é encontrada nos rios da Austrália. Foram realizados experimentos de regressão para criação de modelos, os quais correlacionam as formas do peixe com a sua massa. Através de um banco com 120 imagens, foi realizada a regressão utilizando-se a área do peixe, desconsiderando a cauda, e obtiveram erros entre 3 e 9%.

Lines et al. (2001) realizaram experimentos com câmeras estereoscópicas para estimar a massa de peixes da espécie salmão. Os mesmos usaram 5 dimensões lineares extraídas de diversas regiões do peixe e obtiveram modelos matemáticos de regressão com erros menores que 0.5%. A extração dessas medidas através das imagens são realizadas com erros menores que 10%. Os maiores problemas apontados foram a complexidade das imagens obtidas e a identificação dos modelos morfológicos que variam de acordo com a maturidade, tensão e cultura do salmão. Esses experimentos foram realizados com 60 imagens de 17 peixes com os pesos entre as faixas de 0.7 à 5.7 quilogramas.

Odone et al. (2001) propuseram a criação de um sistema de visão computacional treinável, através de máquinas de vetores de suporte, para estimativa da massa de peixes a partir de medidas extraídas das imagens. Diferente da visão estereoscópica utilizada por Lines et al. (2001), as imagens são capturadas por duas câmeras posicionadas em cima e a na lateral de um tubo retangular transparente, por onde os peixes passam nadando. As medidas extraídas das imagens capturadas pela câmera na lateral são: área, perímetro, tamanho, a relação área/comprimento, a relação área/perímetro, a menor e a maior largura. A câmera superior captura as mesmas medidas, exceto a largura mínima que causa instabilidade, pois depende da pose do peixe no momento em que a imagem é capturada. Nos experimentos foram usados 25 pares de entradas e saídas para treinamento e 25 entradas para teste, onde o sistema foi capaz de prever a massa com 4% de acurácia.

Capítulo 4

Metodologia

Neste capítulo serão apresentadas as metodologias que serão aplicadas no desenvolvimento dos objetivos apresentados na seção 2.2.

4.1 Aprofundamento e atualização sobre as técnicas de visão computacional, e outras áreas da computação que forem necessárias, para o desenvolvimento do *software* proposto

Será feita uma pesquisa de artigos em portais de periódicos, como o portal de periódicos da Capes, *IEEE Explore*, *Web of Science* e *Scopus*. A busca será focada em artigos relacionados com a estimativa da massa de animais, preferencialmente em peixes, que utilizem técnicas de visão computacional. Estes artigos serão revisados com o intuito de melhoramento do texto apresentado e a identificação de técnicas que podem ser exploradas no desenvolvimento deste trabalho. Na busca e na revisão dos trabalhos, será aplicada a revisão sistemática, técnica de revisão que consiste em um conjunto de métodos explícitos e sistemáticos para busca, separação e análise de informações. A mesma pode ser descrita em 5 passos: definição da pergunta, busca por evidências, revisão e seleção dos estudos, análise da qualidade metodológica dos estudos e apresentação dos resultados.

4.2 Estudo sobre o manejo e produção de alevinos, assim como os aspectos morfológicos das espécies que serão empregadas no desenvolvimento do trabalho

Será feito um estudo através de livros textos de disciplinas, como piscicultura e aquicultura, com o intuito de se obter informações sobre manejo e produção de alevinos em ambientes controlados, assim como da morfologia das espécies de alevinos que serão utilizadas no desenvolvimento deste trabalho. Serão feitas também buscas por

trabalhos recentes em portais de periódicos, para uma atualização sobre os conceitos estudados.

4.3 Criação de um banco de imagens (*dataset*) que permita a realização de experimentos de estimativa da massa de alevinos

Será criado um banco de imagens para que possa ser testado o *software* desenvolvido ao longo deste trabalho. Os peixes serão identificados, filmados e pesados, tornando viável os experimentos. Inicialmente o banco contará com imagens de peixes da espécie pintado-real e tilápia. Para a realização da pesagem dos alevinos, será utilizado essência de cravo, anestésico que imobiliza os alevinos, permitindo uma pesagem sem invariâncias devido à movimentação do alevino sobre a balança. Será utilizada uma balança de precisão, cedida pela secretária da pró-reitoria de pesquisa da Universidade Católica Dom Bosco.

4.4 Desenvolvimento do *software* para a realização da estimativa de massa de alevinos, a partir do banco de imagens criado

O *software* será desenvolvido na linguagem *Python* tendo como apoio a biblioteca *OpenCV*, biblioteca *Open Source* de livre utilização na academia e na indústria para o desenvolvimento de *softwares* na área de visão computacional. O mesmo será desenvolvido dentro dos padrões do grupo de pesquisa INOVISÃO, sendo versionado utilizando o repositório de versionamento *git* do próprio grupo.

4.5 Realização de experimentos para validação do *software*

Durante e após o desenvolvimento do *software* serão realizados experimentos estatísticos com o intuito de verificar a precisão do mesmo, resultados os quais irão guiar o trabalho na utilização ou não de novas técnicas. Essas verificações terão também a finalidade de validar o *software* desenvolvido. Esses experimentos serão organizados para serem posteriormente utilizados nas etapas de registro e divulgação dos resultados obtidos. Para a verificação de problemas de classificação, como por exemplo a separação das massas em classes como no peso, acima do peso e abaixo do peso, serão utilizadas métricas como acurácia, *F1 score*, precisão e *recall*. Para as abordagens de regressão, serão utilizadas as métricas erro quadrado médio (*MSE*), erro absoluto médio (*MAE*) e erro médio de porcentagem absoluta (*MAPE*).

4.6 Registro e divulgação dos resultados obtidos

Após o desenvolvimento do *software* e de sua validação, será feita a proteção do mesmo junto ao INPI, Instituto Nacional da Propriedade Industrial. Serão gerados textos para o programa de mestrado acadêmico em ciência da computação da Universidade Federal de Mato Grosso do Sul, que consiste em uma dissertação, com o objetivo de obtenção do grau de mestre. Serão gerados também artigos científicos, os quais serão publicados em periódicos ou em eventos sobre visão computacional e outras áreas correlacionadas à pesquisa, com o intuito de compartilhar os resultados obtidos. Os textos serão criados utilizando a ferramenta L^AT_EX, ferramenta para a produção de textos científicos que traz o benefício de fácil mudança na formatação do texto.

Capítulo 5

Cronograma

Atividade	(trimestres) 2017				(trimestres) 2018			
	01	02	03	04	01	02	03	04
1.1 Pesquisa de trabalhos correlatos	•	•	•					
1.2 Seleção e leitura dos trabalhos correlatos encontrados	•	•	•					
2.1 Realização de ajustes no equipamento de captura		•	•					
2.2 Realização da coleta de imagens		•	•	•				
3.1 Desenvolvimento do software			•	•	•			
3.2 Realização de experimentos com o software				•	•	•	•	
4.1 Realização de experimentos estatísticos						•	•	
4.2 Correções e ajustes no software						•	•	
5.1 Preparação dos textos para o programa de mestrado e dos artigos			•	•	•	•	•	•

Tabela 5.1: Cronograma.

Referências Bibliográficas

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., & Süsstrunk, S. (2012). Slic superpixels compared to state-of-the-art superpixel methods. *IEEE transactions on pattern analysis and machine intelligence*, 34(11), 2274–2282.
- Andrade, D. R. & Yasui, G. S. (2003). Manejo da reprodução natural e artificial e sua importância na produção de peixes no Brasil. *Revista Brasileira de Reprodução Animal*, 27(2), 166–172.
- Bay, H., Ess, A., Tuytelaars, T., & Van Gool, L. (2008). Speeded-up robust features (surf). *Computer vision and image understanding*, 110(3), 346–359.
- Bium, H. (1967). A transformation for extracting new descriptions of shape. In *Symposium on Models for the Perception of Speech and Visual Form*.
- Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory* (pp. 144–152): ACM.
- Buckup, P. A., Menezes, N. A., & Ghazzi, M. S. (2007). *Catálogo das espécies de peixes de água doce do Brasil*, volume 1. Museu Nacional Rio de Janeiro.
- Dalal, N. & Triggs, B. (2005). Histograms of oriented gradients for human detection. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, volume 1 (pp. 886–893): IEEE.
- De Wet, L., Vranken, E., Chedad, A., Aerts, J.-M., Ceunen, J., & Berckmans, D. (2003). Computer-assisted image analysis to quantify daily growth rates of broiler chickens. *British poultry science*, 44(4), 524–532.
- Freund, Y., Schapire, R. E., et al. (1996). Experiments with a new boosting algorithm. In *icml*, volume 96 (pp. 148–156).
- Guyon, I., Weston, J., Barnhill, S., & Vapnik, V. (2002). Gene selection for cancer classification using support vector machines. *Machine learning*, 46(1), 389–422.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., & Witten, I. H. (2009). The weka data mining software: an update. *ACM SIGKDD explorations newsletter*, 11(1), 10–18.

- Hartigan, J. A. & Wong, M. A. (1979). Algorithm as 136: A k-means clustering algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 28(1), 100–108.
- Idder, H. I. B. & Laachfoubi, N. (2015). Skeletonization algorithm using discrete contour map. In *International Conference on Image Analysis and Processing* (pp. 142–150).: Springer.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097–1105).
- LA, C. A. & LA, A. Y. (2016). El estado mundial de la pesca y la acuicultura. *FAO*.
- Lines, J., Tillett, R., Ross, L., Chan, D., Hockaday, S., & McFarlane, N. (2001). An automatic image-based system for estimating the mass of free-swimming fish. *Computers and Electronics in Agriculture*, 31(2), 151–168.
- Lowe, D. G. (1999). Object recognition from local scale-invariant features. In *Computer vision, 1999. The proceedings of the seventh IEEE international conference on*, volume 2 (pp. 1150–1157).: Ieee.
- Mikolajczyk, K. & Schmid, C. (2005). A performance evaluation of local descriptors. *IEEE transactions on pattern analysis and machine intelligence*, 27(10), 1615–1630.
- Negretti, P., Bianconi, G., & Finzi, A. (2010). Visual image analysis to estimate morphological and weight measurements in rabbits. *World Rabbit Science*, 15(1), 37–41.
- Neter, J., Kutner, M. H., Nachtsheim, C. J., & Wasserman, W. (1996). *Applied linear statistical models*, volume 4. Irwin Chicago.
- Odone, F., Trucco, E., & Verri, A. (2001). A trainable system for grading fish from images. *Applied Artificial Intelligence*, 15(8), 735–745.
- Ozkaya, S. & Bozkurt, Y. (2008). The relationship of parameters of body measures and body weight by using digital image analysis in pre-slaughter cattle. *Archiv fur Tierzucht*, 51(2), 120.
- Pastorelli, G., Musella, M., Zaninelli, M., Tangorra, F., & Corino, C. (2006). Static spatial requirements of growing-finishing and heavy pigs. *Livestock Science*, 105(1), 260–264.
- Prince, S. J. (2012). *Computer vision: models, learning, and inference*. Cambridge University Press.
- Sahoo, P. K., Soltani, S., & Wong, A. K. (1988). A survey of thresholding techniques. *Computer vision, graphics, and image processing*, 41(2), 233–260.
- Shapiro, L. & Stockman, G. (2001). Computer Vision. *October*, 2004(October), 608.

- Sidonio, L., Cavalcanti, I., Capanema, L., Morch, R., Magalhães, G., Lima, J., Burns, V., Alves Júnior, A. J., & Mungioli, R. (2012). Panorama da aquicultura no brasil: desafios e oportunidades. *BNDES setorial*, 35, 421–463.
- Szeliski, R. (2010). Computer Vision : Algorithms and Applications. *Computer*, 5, 832.
- Thrun, S. & Norvig, P. (2011). Introduction to artificial intelligence. *Retrieved November*, 5, 2011.
- Tola, E., Lepetit, V., & Fua, P. (2010). Daisy: An efficient dense descriptor applied to wide-baseline stereo. *IEEE transactions on pattern analysis and machine intelligence*, 32(5), 815–830.
- Tuytelaars, T., Mikolajczyk, K., et al. (2008). Local invariant feature detectors: a survey. *Foundations and trends® in computer graphics and vision*, 3(3), 177–280.
- Vapnik, V. N. & Vapnik, V. (1998). *Statistical learning theory*, volume 1. Wiley New York.
- Viazzi, S., Van Hoestenbergh, S., Goddeeris, B., & Berckmans, D. (2015). Automatic mass estimation of jade perch *scortum barcoo* by computer vision. *Aquacultural Engineering*, 64, 42–48.
- Zion, B. (2012). The use of computer vision technologies in aquaculture—a review. *Computers and electronics in agriculture*, 88, 125–132.