



UNIVERSIDADE FEDERAL DO MARANHÃO CENTRO DE CIÊNCIAS HUMANAS,
NATURAIS, SAÚDE E TECNOLOGIA
CURSO DE ENGENHARIA DE PESCA

JOSÉ NEUTON NUNES MENDES JUNIOR

**USO DA BIOACÚSTICA E APRENDIZADO DE MÁQUINA NA ALIMENTAÇÃO
DE PEIXES EM PISCICULTURA**

Pinheiro-MA

2022

Centro de Ciências, Humanas, Naturais, Saúde e Tecnologia – CCHNST Estrada de Pacas,
KM 10, Bairro Enseada - Pinheiro - MA - CEP: 65200-000 Fones: (98) 3272-9743 E-mail:

eng.pesca@ufma.br

JOSÉ NEUTON NUNES MENDES JUNIOR

**USO DA BIOACÚSTICA E APRENDIZADO DE MÁQUINA NA ALIMENTAÇÃO
DE PEIXES EM PISCICULTURA**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Pesca do Centro de Ciências Humanas, Naturais, Saúde e Tecnologia da Universidade Federal do Maranhão para a obtenção do grau de Bacharel em Engenharia de Pesca.

Orientador: Prof. Dr. Rodrigo Sávio Teixeira de Moura.

Pinheiro-MA

2022

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

NUNES MENDES JUNIOR, JOSE NEUTON.

USO DA BIOACÚSTICA E APRENDIZADO DE MÁQUINA NA
ALIMENTAÇÃO DE PEIXES EM PISCICULTURA / JOSE NEUTON NUNES
MENDES JUNIOR. - 2022.

26 p.

Orientador(a): RODRIGO SÁVIO TEIXEIRA DE MOURA.

Curso de Engenharia da Pesca, Universidade Federal do
Maranhão, UFMA, 2022.

1. AQUICULTURA. 2. BIOACÚSTICA. 3. REDES NEURAIS. I.
SÁVIO TEIXEIRA DE MOURA, RODRIGO. II. Título.

AGRADECIMENTOS

À Deus por permitir que chegasse até o final deste curso, podendo realizar meus sonhos, e por me guiar até aqui.

À minha família por sempre me aconselhar, e de todas as formas me apoiar no ingresso deste curso, em especial meu pai que foi o precursor de tudo desde o início, que me fez a proposta de me matricular neste curso.

Ao professor Rodrigo Sávio Teixeira de Moura por ter me orientado e por sempre acreditar nas ideias que nem eu mesmo achava que era possível fazer, inclusive a deste trabalho, e pelas oportunidades de trabalhar em seus projetos inovadores que foram um dos principais fatores da minha permanência neste curso.

A todos os membros do Laboratório TECAAP, especialmente a Danilo Pereira, Geilson do Remédio e Rodrigo Soares, que estiveram grande parte do tempo comigo, e aprendemos muito, trabalhando juntos e descobrindo coisas novas.

Ao Geilson do Remédio, Nivaldo Luis, a Nathalia Cristina, Gleiciane de Fatima, Anne Pinheiro e Denyse Rayanna, que estiveram comigo na caminhada do Centro Acadêmico e da Empresa Júnior.

A Amerson Lima, colega de trabalho e da Turma 2016.2, que estivemos juntos nessa reta final de estudar e trabalhar.

A todos os colegas da turma 2016.2, que estive junto nesses mais de 5 anos, todos sempre companheiros, tamo junto galera.

Ao professor Adilson Borges, pela elaboração do mapa do local de coleta de dados.

A todos os professores que contribuíram para minha formação do meu conhecimento hoje, agradeço muito pelas oportunidades.

A todas as amigadas que fiz ao longo do curso, com as outras turmas.

A todos que de qualquer forma contribuíram para este momento.

RESUMO

Um dos pontos positivos dos organismos aquáticos é o seu baixo Fator de Conversão Alimentar Aparente, uma vez que os mesmos precisam consumir menos alimento para aumentar de peso, comparativamente aos organismos da produção animal terrestre. Mesmo com uma alta conversão de alimento em biomassa, os gastos com ração na piscicultura representam de 50% a 80% do custo total de produção. Desta forma, o manejo alimentar eficiente, em frequência e horários corretos, procurando sempre oferecer a ração de forma fracionada ao longo do dia, é um ponto chave para diminuir custos na produção, e aumentar o desempenho produtivo, aumentando o lucro da atividade. O objetivo deste trabalho foi desenvolver um sistema de classificação de eventos relacionados à alimentação, para peixes em piscicultura. Foi construído um hidrofone (microfone subaquático) no intuito de monitorar os sons subaquáticos produzidos pelos peixes em cativeiro. Os hidrofones foram instalados em viveiros comerciais de produção de duas espécies de peixe, localizados na Fazenda Macielma, município de Pinheiro-MA, e os sons subaquáticos foram gravados durante o período de alimentação dos animais. Os sons adquiridos foram separados em três classes, relacionadas com os momentos da alimentação: Antes, Durante e Depois da alimentação. Foi então treinado um modelo de inteligência artificial baseado em aprendizagem profunda, para realizar a classificação dos sons entre as três classes (momentos da alimentação), com auxílio da plataforma online *Teachable Machine*. Ao todo foram gravados 100 minutos de áudio, durante 9 eventos de alimentação. O modelo treinado foi capaz de classificar corretamente os áudios entre as classes consideradas, com acurácia de 88%. Concluímos que tanto o hidrofone quanto o modelo de inteligência artificial elaborados foram adequados e conseguiram satisfatoriamente captar e analisar os sons produzidos pelos peixes e identificar os diferentes momentos da alimentação: 1) momento antes da alimentação, com peixes calmos; 2) momento de busca e ingestão de alimento, com peixes com alta agitação; e 3) momento após a alimentação, com peixes retornando a um estado de baixa agitação.

Palavras-chave: Aquicultura. Bioacústica. Redes Neurais.

SUMÁRIO

1. INTRODUÇÃO	5
2. METODOLOGIA	8
2.1 GRAVAÇÃO DE ÁUDIOS SUBAQUÁTICOS	8
2.2 ELABORAÇÃO DO MODELO DE INTELIGÊNCIA ARTIFICIAL	11
2.3 AVALIAÇÃO DO MODELO DE INTELIGÊNCIA ARTIFICIAL	12
3. RESULTADOS	13
3.1 ÁUDIOS SUBAQUÁTICOS	13
3.2 MODELO DE INTELIGÊNCIA ARTIFICIAL	20
4. DISCUSSÃO	21
5. CONCLUSÕES	23
REFERÊNCIAS	24

1. INTRODUÇÃO

A principal forma de criação de animais aquáticos atualmente é a piscicultura, com uma produção de 54,3 milhões de toneladas em 2018 (FAO, 2020). O Brasil produziu 802.930 toneladas de peixes de cultivo em 2020, com crescimento de 5,93% sobre o ano anterior (MEDEIROS, 2021). Um dos pontos positivos para a produção dos organismos aquáticos é o Fator de Conversão Alimentar Aparente (FCAA), definido como sendo o quanto de alimento consumido por um indivíduo é transformado em biomassa, que é inferior a FCAA encontrada para outros animais de produção, como os bovinos e as aves. Na produção de bovino são necessários de 6 a 7 kg de ração para produzir 1kg de carne; na produção do frango de corte, 2 kg de ração para produzir um 1kg de carne, enquanto a conversão da Tilápia-do-nilo (*Oreochromis niloticus*), por exemplo, é em torno de 1,2 kg de ração para produzir 1 kg de carne (MEDEIROS, 2019).

No ambiente de agricultura industrial intensiva, a otimização da alimentação é um fator primordial para melhorar a eficiência da criação e reduzir os custos, uma vez que o método de controle de alimentação afeta diretamente a taxa de conversão alimentar (WU et al., 2015). Apesar do reduzido FCAA na aquicultura, a aquisição da ração representa de 50% a 80% do custo total da produção (RIBEIRO et al, 2016), onerando consideravelmente a produção de peixes. Desta forma, o manejo alimentar adequado (balanceado, em horários adequados, bem distribuído no viveiro e de acordo com as condições da água) é um ponto chave para diminuir custos na produção, podendo até mesmo reduzir o tempo de cultivo, aumentando assim o lucro da atividade.

O comportamento alimentar dos peixes pode se manifestar de várias formas (ZHOU et al, 2018). Espécies de peixes teleósteos possuem uma diversidade de hábitos e comportamentos alimentares (RIBEIRO et al, 2012), ou seja, pode variar em diferentes condições do ambiente de cultivo, inclusive entre os períodos noturno e diurno. Desta forma, o manejo alimentar deve levar em consideração a constituição anatômica e fisiológica do trato digestivo de cada espécie, seu comportamento em cativeiro, bem como o sistema de cultivo adotado, sua produtividade natural, condições climáticas da região e características inerentes ao alimento fornecido aos animais (RIBEIRO et al, 2012). Esta diversidade de parâmetros a serem analisados torna difícil para o produtor se ater aos hábitos das espécies em cativeiro, pois conhecimento necessário deve abranger uma variedade de espécies de peixes, cujo comportamento alimentar e sensibilidade variam também com uma série de

parâmetros abióticos, entre os quais temperatura da água e iluminação (JESUS et al, 2020). Logo, encontrar os momentos ideais para oferta de ração e oferecer com maior frequência é um trabalho difícil e cansativo, necessitando de mão-de-obra qualificada. Sendo assim, é importante o desenvolvimento de ferramentas mais eficazes que possam auxiliar no fornecimento de ração nos momentos ideais para os peixes, podendo resultar em diminuição dos desperdícios de ração, aumento do bem-estar animal, melhora no crescimento e diminuição dos impactos na qualidade de água causados por sobras de ração.

O monitoramento do comportamento alimentar dos peixes pode auxiliar na tomada de decisão na oferta de ração. Na literatura, encontra-se estudos relacionados ao comportamento utilizando a visão computacional, como: um sistema de controle por retroalimentação, que pode determinar o momento final da alimentação, quantificando o comportamento de agregação de enguias durante a alimentação em cativeiro (CHANG et al. 2005); o nível da atividade alimentar de tilápias (*Oreochromis niloticus*) medida analisando a agregação e dispersão dos cardumes (ZHOU et al., 2017 e 2018); método para avaliação da atividade alimentar de tilápias (*Oreochromis niloticus*) em sistemas de recirculação com base no algoritmo de fluxo óptico e entropia do método Lucas-Kanade (YE et al., 2016). Classificação da intensidade alimentar de tilápias (*Oreochromis niloticus*) em RAS para avaliação do apetite, usando uma rede neural.

Outros estudos com finalidade de compreender o comportamento alimentar de peixes são encontrados na literatura. Pesquisadores analisaram as mudanças nos sinais sonoros durante a alimentação do pregado (*Scophthalmus maximus*) (MALLEKH et al. 1998). Os sons de alimentação do pregado (LAGARDERE et al. 2000) e das trutas (*Salmo trutta* e *Oncorhynchus mykiss*) (LAGARDERE et al. 2004) em ambientes de reprodução foram obtidos e analisados para verificar a viabilidade do uso do som para representar a atividade alimentar. Um algoritmo semelhante foi usado para detectar os sons de alimentação do pregado (MALLEKH et al. 2003) e camarão tigre gigante (*Penaeus monodon*) (SMITH et al. 2013), e os resultados mostraram uma relação entre a energia sonora e a taxa de consumo de ração.

A análise do comportamento alimentar em camarões possibilita melhorar a eficiência na alimentação, usando sistemas automáticos por demanda (KUBITZA, 2019). Estes sistemas se baseiam em uma característica do camarão, que são os seus sons ativos (cliques) durante a mastigação, possibilitando o desenvolvimento de um alimentador que detecta este

som e fornece a ração somente enquanto o animal está com fome, liberando a ração de acordo com a intensidade da atividade alimentar dos camarões, que é medida indiretamente pela intensidade do som da mastigação dos animais, capturada através de um microfone subaquático. Essa ferramenta pode proporcionar um aumento na eficiência da ração e da sustentabilidade da produção de camarões. No caso dos peixes usados em aquicultura, há uma dificuldade a mais do sistema para captar sons passivos, gerados nas atividades de busca e captura da ração, já que os peixes não produzem sons ativamente.

Sendo assim, o monitoramento em tempo real da atividade natatória (agitação) dos peixes por meio dos sons passivos pode auxiliar a identificar momentos em que estejam saciados (pouca ou nenhuma agitação na água provocada pelos peixes) ou com fome (maior agitação na água provocada pelos peixes). Visto que não terá a necessidade de analisar outros parâmetros, como do ambiente de cultivo para o fornecimento de ração, dado que mesmo que todos os parâmetros da qualidade de água indiquem um bom ambiente para a espécie cultivada, isto não indica quando os animais estão com fome ou saciados, além do mais, o comportamento do peixe transmite uma maior precisão na tomada de decisão por se tratar de uma análise direta do indivíduo. Deste modo, o objetivo do trabalho foi desenvolver um sistema de classificação de eventos relacionados à alimentação, para peixes em piscicultura.

2. METODOLOGIA

2.1 GRAVAÇÃO DE ÁUDIOS SUBAQUÁTICOS

Foi construído um sensor de áudio subaquático utilizando um disco piezoelétrico de 25 mm capaz de capturar sons na faixa de frequência de até 16 KHz. O mesmo foi fixado no interior de uma caixa cilíndrica de alumínio (Fig. 1). A caixa foi fechada e isolada com silicone para evitar a entrada de água, e revestida com verniz para evitar corrosão. Para manter o sensor submerso foi necessário construir uma boia de isopor, com um cabo ligando a boia a um lastro, de modo com que o sensor é fixado neste cabo (Fig. 2). Para fazer a gravação do áudio capturado, utilizou-se um smartphone, conectado com o sensor através de um conector de áudio P2.

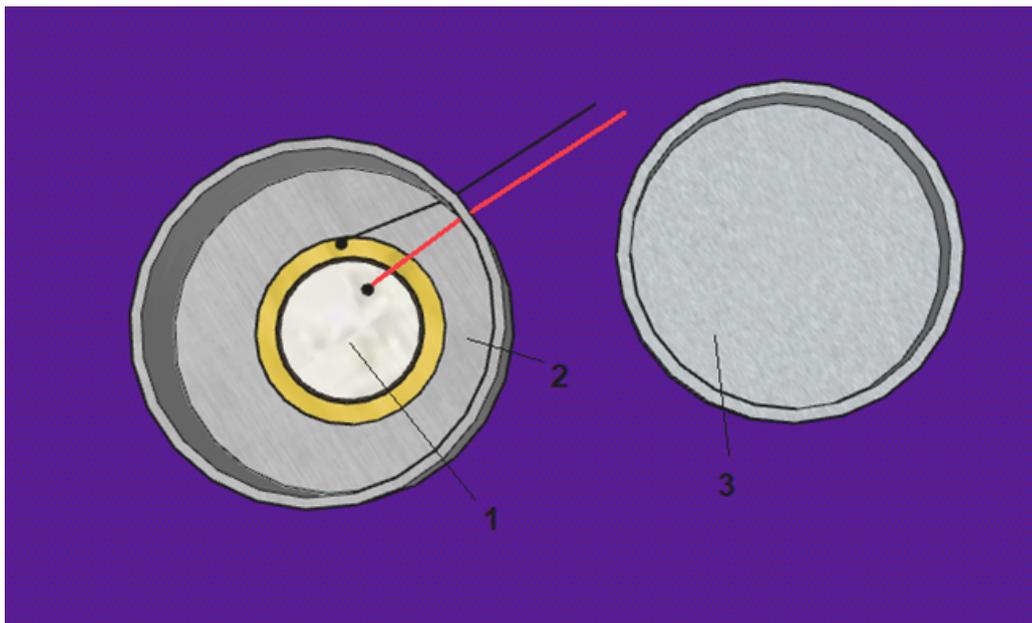


Figura 1. Exemplo do sensor de som subaquático. 1 = Disco piezoelétrico; 2 = Corpo da lata; 3 = Tampa da lata.

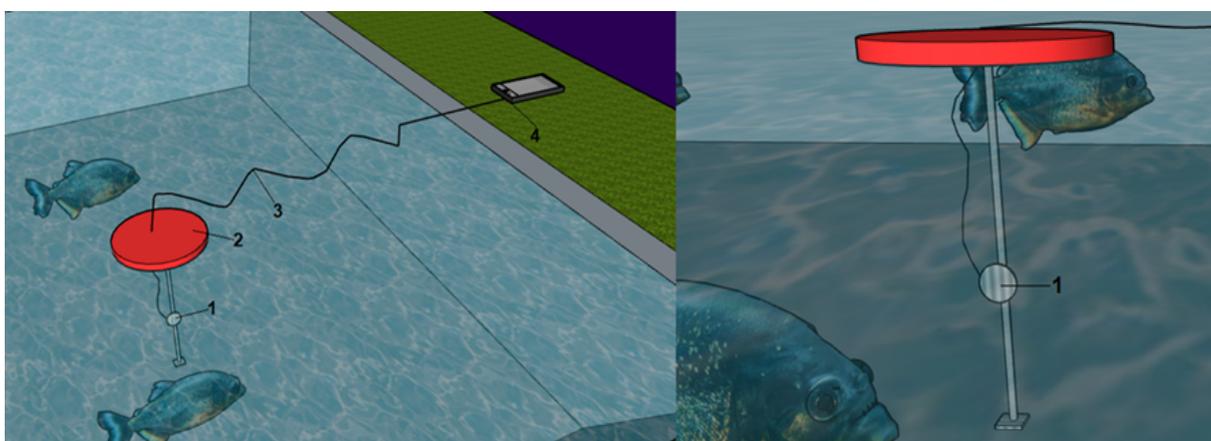


Figura 2. Esquema para instalação do sensor subaquático no viveiro de piscicultura. 1 = Sensor; 2 = Bóia; 3 = Cabo de Dados; 4 = Receptor (smartphone).

Os sensores de áudio desenvolvidos foram instalados em viveiros comerciais de produção dos peixes Bagrinho (*Trachelyopterus galeatus*) e Tambatinga (*Colossoma macropomum x Piaractus brachypomum*), localizados na Fazenda Macielma, município de Pinheiro-MA (Fig. 3). A dieta diária dos peixes nessa propriedade é dividida em 2 tratos, onde as gravações foram realizadas no primeiro trato do dia, iniciando às 8:00 horas da manhã, com a oferta da ração feita entre os 3 primeiros minutos após o início da gravação,

encerrando a gravação no momento em que notou-se menor saciedade dos peixes (menor agitação na água). Esse processo foi realizado em cinco viveiros diferentes, um viveiro de criação do híbrido tambatinga e quatro da espécie bagrinho, em três dias diferentes. Durante as gravações, foram registrados os tempos nos quais os peixes iniciaram a alimentação e quando pararam de se alimentar, dividindo o tempo de gravação em 3 momentos: Antes da Oferta de Ração, Oferta de Ração e Após a Oferta de Ração. Após a captura, os áudios foram processados com auxílio do programa *Audacity*, utilizando a ferramenta de “Amplificação” para aumentar a amplitude dos áudios em 30 decibéis de modo a facilitar a análise para sons com baixa intensidade. O *Audacity* foi utilizado também para poder visualizar os áudios em formato de espectrograma e, portanto, possibilitou analisar visualmente o comportamento das ondas sonoras de acordo com os eventos considerados.

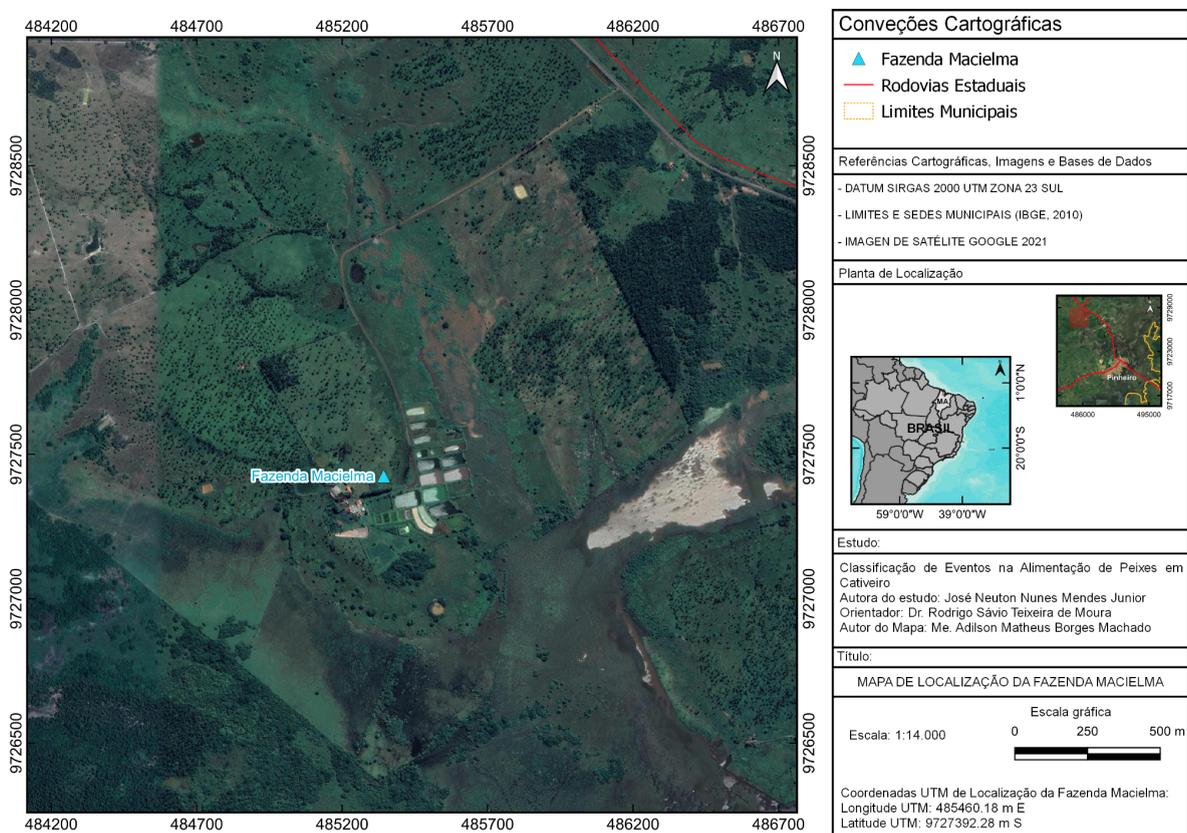


Figura 3. Mapa de localização da Fazenda Macielma, local de coleta de dados.

2.2 ELABORAÇÃO DO MODELO DE INTELIGÊNCIA ARTIFICIAL

Para o desenvolvimento do modelo de inteligência artificial foi utilizado um algoritmo de classificação baseado em Redes Neurais Profundas (*Deep Neural Networks*). Os algoritmos de classificação são um conjunto de ferramentas onde o objetivo do algoritmo é prever uma classe a partir de uma ou mais variáveis de entrada, neste caso, os áudios gravados. Inicialmente, o algoritmo deve ser treinado com um conjunto de dados com classes conhecidas, para depois poder ser utilizado para prever a classe de um novo dado, desconhecido. Este tipo de algoritmo, que o resultado somente pode pertencer a um conjunto de classes pré-definidas (e não um valor qualquer) são chamados de algoritmos de classificação, e fazem parte das técnicas de Aprendizagem Supervisionada, uma vez que o desenvolvedor precisa fornecer informações *a priori* sobre os dados utilizados (FONTANA, 2020). A Rede Neural Profunda foi implementada utilizando-se a plataforma *Teachable Machine*TM (®Google), gratuita e online. Esta plataforma utiliza algoritmos de Aprendizagem Profunda (*Deep Learning*), baseados em Redes Neurais (*Neural Networks*) e que conseguem aprender com os dados que lhes são fornecidos, em um processo conhecido como Aprendizado de Máquina (*Machine Learning*). Desse modo, estes algoritmos têm a capacidade de extrair características, padrões e tendências a partir de um conjunto de dados, sem a necessidade de se definir um modelo matemático específico; uma vez que a própria Rede Neural aprende as funções matemáticas que descrevem os eventos observados (por isso a nomenclatura “Aprendizado de Máquina”).

Cada segundo dos áudios gravados foi dividido em três classes: *Antes da Oferta de Ração*, momento de menor agitação dos peixes; *Oferta de Ração*, momento que lança-se a ração na água; e *Após a Oferta de Ração*, momento de maior agitação dos peixes. Um subconjunto de 85% dos trechos de áudio foi então utilizado para o treinamento da inteligência artificial na plataforma *Teachable Machine*TM, que consiste no processo de aprendizado em si, onde a Rede Neural irá analisar os dados fornecidos e extrair informações relevantes, relacionando os dados fornecidos com cada classe pré-definida. A principal vantagem dos algoritmos de *Deep Learning* (DP) é que estes utilizam várias camadas de extração de características dos dados, organizadas de forma hierárquica; desse modo a primeira camada recebe os dados de entrada (*input*), que são passados para várias camadas que analisam os padrões nos dados, chamadas camadas ocultas, sendo que cada camada passa as informações extraídas para as camadas seguintes; e por fim, existe uma camada que reúne

todas essas informações para fazer a classificação daquele dado de entrada em uma das classes pré-determinadas (*output*), predizendo a qual classe ele pertence.

A plataforma *Teachable Machine*TM também utiliza uma técnica chamada Aprendizado por Transferência (*Transfer Learning*), que faz uso de uma Rede Neural pré-treinada, com o objetivo de aumentar a performance e o desempenho nas predições da nova Rede Neural. Funciona de modo que uma Rede Neural treinada anteriormente em um conjunto de dados com muitas observações é re-treinada em um novo conjunto de dados, geralmente com poucas observações. Este segundo treinamento acontece de maneira mais rápida e melhora os resultados obtidos para o novo conjunto de dados, uma vez que a nova Rede Neural usa todo o aprendizado adquirido pela Rede Neural anterior (TAN et al., 2018). Desse modo, utilizando a Transferência de Aprendizado conseguimos não só acelerar o aprendizado da Rede Neural, como melhorar o desempenho dela, o que é particularmente importante para conjuntos de dados com poucas observações. No caso da classificação de áudio usando a plataforma *Teachable Machine*TM, é feita a transferência do aprendizado de uma Rede Neural pré-treinada em um conjunto de dados com aproximadamente 50 mil áudio em 20 classes diferentes (GITHUB, 2022).

O treinamento foi executado durante 50 *epochs*, onde 1 *epoch* significa dizer que a Rede Neural analisou todos os dados 1 vez. A avaliação do desempenho do modelo foi feita com base nos dados que não foram utilizados para o treinamento, ou seja, um conjunto de 15% dos áudios gravados, conhecido como conjunto de dados de teste. Este conjunto contém dados que a Rede Neural desconhece, portanto, pode ser utilizado para testar como o modelo criado se comporta com dados novos.

2.3 AVALIAÇÃO DO MODELO DE INTELIGÊNCIA ARTIFICIAL

Após o treinamento do modelo é mensurada a sua *Acurácia*, medida de desempenho dada pela razão entre as predições corretas feitas pelo modelo e o número total de predições realizadas, ou seja, a porcentagem de acertos do modelo. Por exemplo, se o modelo classifica 70 observações corretamente, de um total de 100 observações, a acurácia é de $70/100 = 0,7$ ou 70% (CARNEY et al. 2020). A acurácia pode ser medida para os dados de treinamento e para os dados de teste, sendo a acurácia de teste mais relevante, uma vez que representa os acertos do modelo em dados novos.

Para mensurar o erro do modelo desenvolvido foi avaliada a curva da Função de Custo (*Loss Function*), que calcula a distância entre o resultado correto e o resultado produzido pela rede neural. Este valor indica o erro total do modelo, representando sua perda de informação, ou seja, o quanto de informação que o modelo não é capaz de extrair dos dados, de modo que quanto mais próximo de 0 (zero) for esse número, melhor é o desempenho do modelo (GOOGLE, 2020). Na prática, modelos com menores valores para a função de custo produzem resultados mais confiáveis, com menos falsos positivos ou falsos negativos (CARNEY et al 2020). Através da curva da Função de Custo, foi possível avaliar se o modelo está em *Underfitting*, quando o aprendizado não foi suficiente para representar o conjunto de dados, portanto o modelo gera respostas pouco confiáveis; ou se está em *Overfitting*, quando o aprendizado foi tão rigoroso que só funciona para os dados de treino, mas produz resultados errados para dados novos (ZHANG et al. 2019). O *underfitting* pode ser identificado quando a curva da função de custo nos dados de treino e teste não diminuem ao longo dos treinamentos. Já o *overfitting* é visualizado quando a curva da função de custo nos dados de treino diminui, mas para os dados de teste ela aumenta ou se estabiliza.

3. RESULTADOS

3.1 ÁUDIOS SUBAQUÁTICOS

Ao total foram gravados 1 hora, 2 minutos e 9 segundos de áudios nos viveiros de cultivo da espécie bagrinho (Tab. 1), enquanto para tambatinga foram registrados 37 minutos e 7 segundos (Tab. 2). Somando-se as duas espécies, resultou em um total de 1 hora, 40 minutos e 6 segundos de gravações a partir de um total de nove áudios, com os eventos relacionados à alimentação para cada um deles devidamente registrados.

Tabela 1. Áudios gravados e eventos relacionados à alimentação em viveiros de bagrinhos.

Áudio	Comprimento do áudio	Antes da oferta de ração	Oferta de Ração	Depois da oferta de ração
Nº1	00:15:01	00:00:00	00:04:02	00:03:14
		á	00:04:46	á

		00:04:00	00:08:21	00:15:01
			00:03:21	
		00:00:00	00:04:58	00:03:20
Nº2	00:10:01	á	00:05:43	á
		00:03:19	00:07:00	00:10:01
			00:09:20	
		00:00:00	00:03:28	00:03:28
Nº3	00:10:34	á	00:04:43	á
		00:03:28	00:07:36	00:10:34
		00:00:00	00:01:08	00:01:08
Nº4	00:10:02	á	00:03:11	á
		00:01:08	00:05:13	00:10:02
			00:07:05	
			00:01:01	
		00:00:00	00:01:27	00:01:01
Nº5	00:09:01	á	00:02:56	á
		00:01:01	00:03:45	00:09:01
			00:05:00	
			00:06:14	
		00:00:00	00:01:03	00:01:02
Nº6	00:07:30	á	00:02:11	á
		00:01:02	00:03:02	00:07:30
			00:03:57	

Tabela 2. Áudios gravados e eventos relacionados à alimentação em viveiros de Tambatinga.

Áudio	Comprimento do áudio	Antes da Oferta de Ração	Ofertas de Ração	Depois da Oferta de Ração
Nº1	00:17:16	00:00:00	00:05:03	00:05:03
		á	00:05:08	á
		00:05:03	00:08:51	00:17:16
			00:10:03	
Nº2	00:10:00	00:00:00	00:02:58	00:02:58
		á	00:04:47	á
		00:02:58		00:10:00
Nº3	00:09:51	00:00:00	00:01:10	00:01:10
		á	00:05:43	á
		00:01:10		00:09:51

Em cada trecho de áudio foi possível notar que antes da primeira oferta de ração houve pouca emissão sonora (indicando menor agitação dos peixes), porém após a oferta da ração, houve um aumento progressivo dos sinais sonoros, provocado pelo ato de abocanhar a ração realizado quando os peixes estão se alimentando, tanto para o Bagrinho (Fig. 4 e 5) quanto para a Tambatinga (Fig. 6 e 7). O aumento da intensidade sonora pode ser influenciado pelo apetite do peixe, voracidade e quantidade de indivíduos no ambiente.

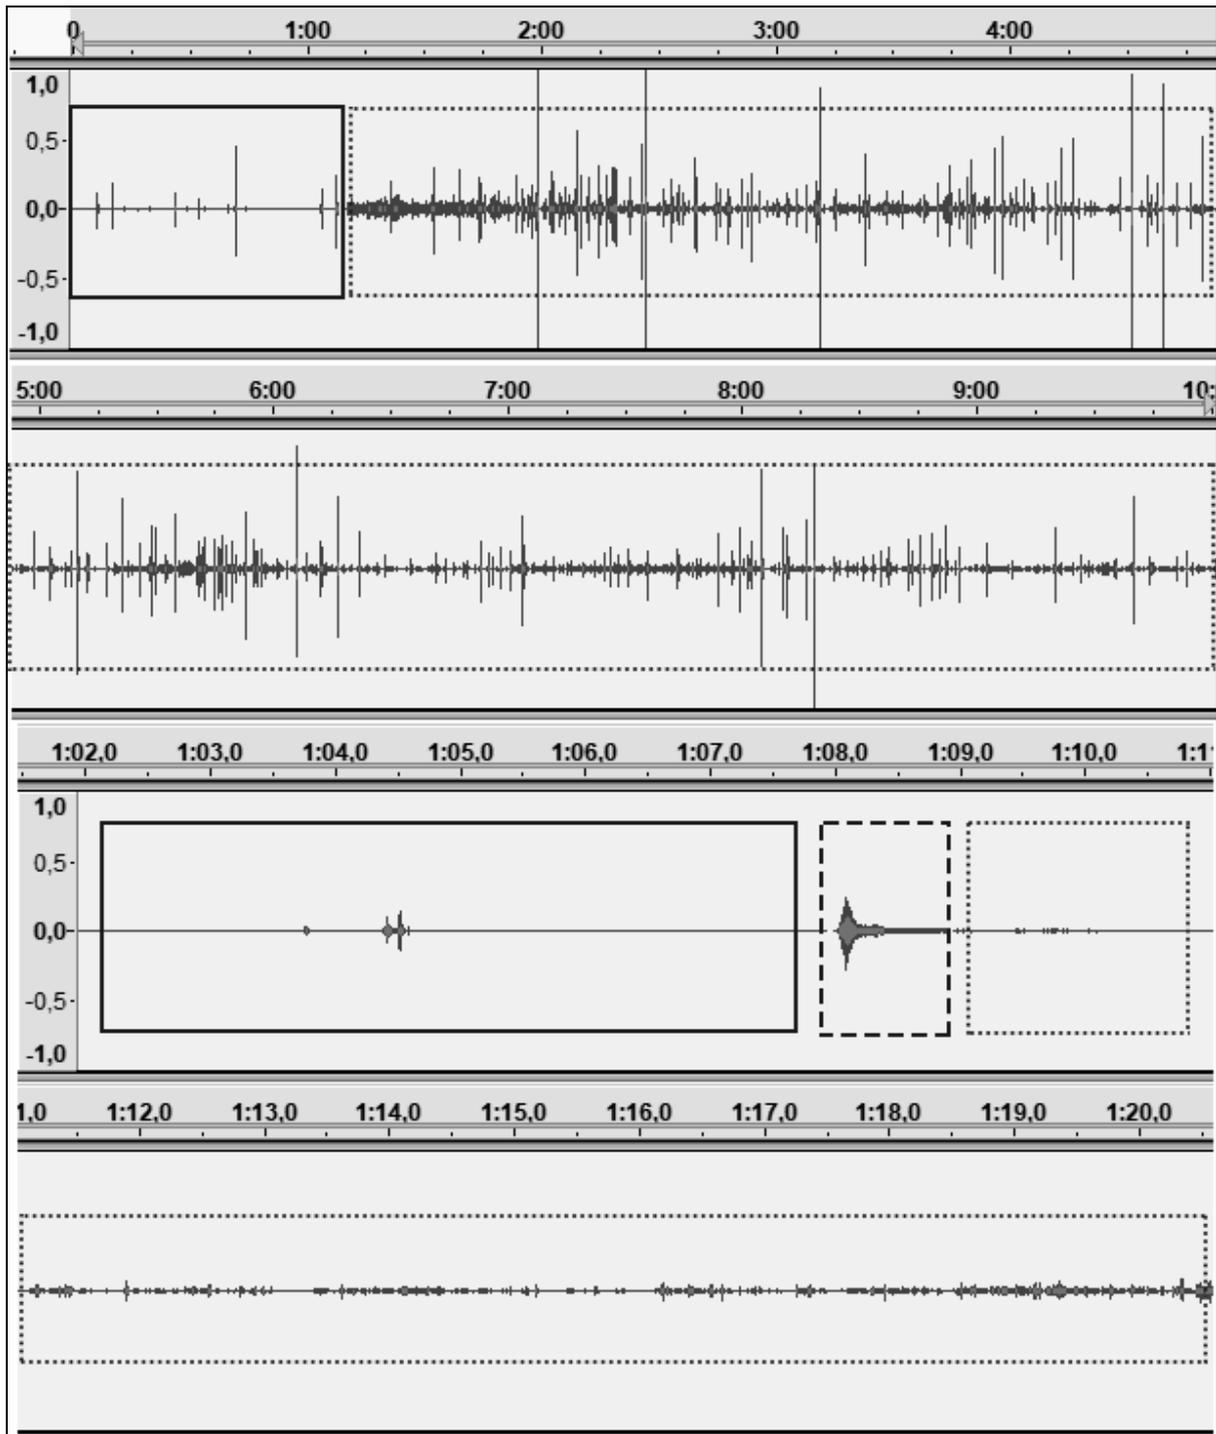


Figura 4. Espectrograma de áudio subaquático (áudio N^o4) gravado em viveiros de Bagrinho. Retângulo de linha contínua indica o trecho de áudio antes da *Oferta de Ração*; retângulo de linha tracejada indica o momento da *Oferta de Ração*; retângulo de linha pontilhada indica o trecho de áudio *Após a Oferta de Ração*.

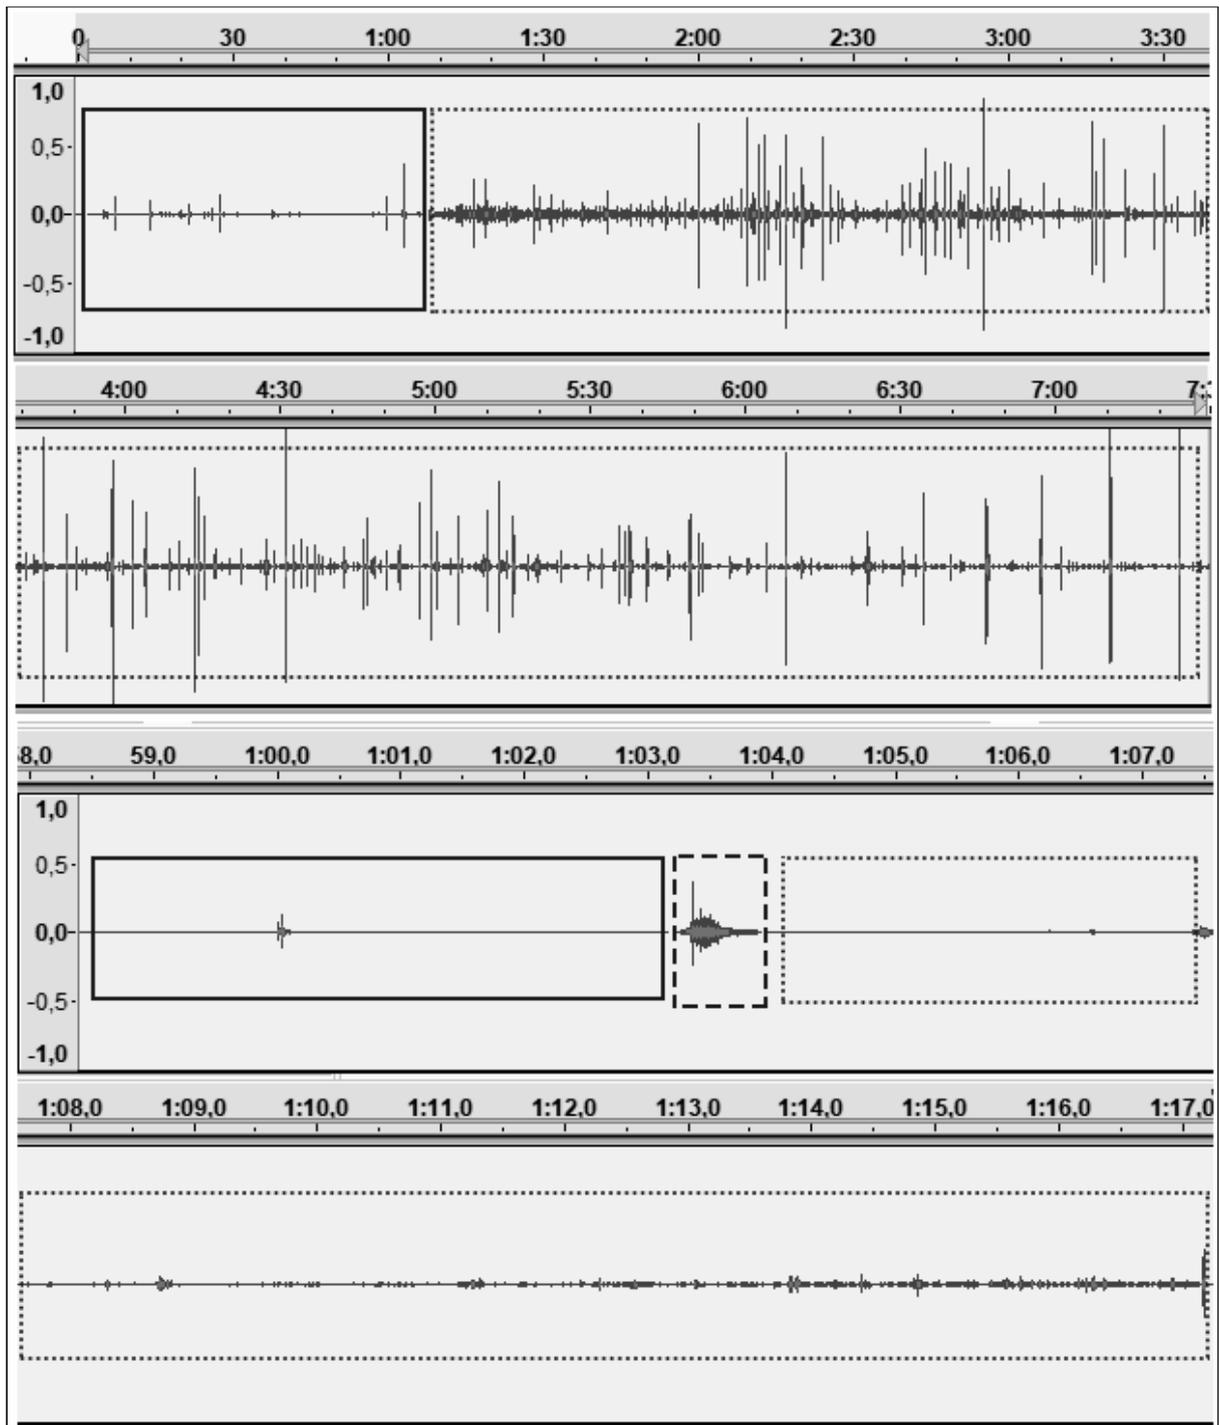


Figura 5. Espectrograma de áudio subaquático (áudio N°6) gravado em viveiros de Bagrinho. Retângulo de linha contínua indica o trecho de áudio antes da *Oferta de Ração*; retângulo de linha tracejada indica o momento da *Oferta de Ração*; retângulo de linha pontilhada indica o trecho de áudio *Após a Oferta de Ração*.

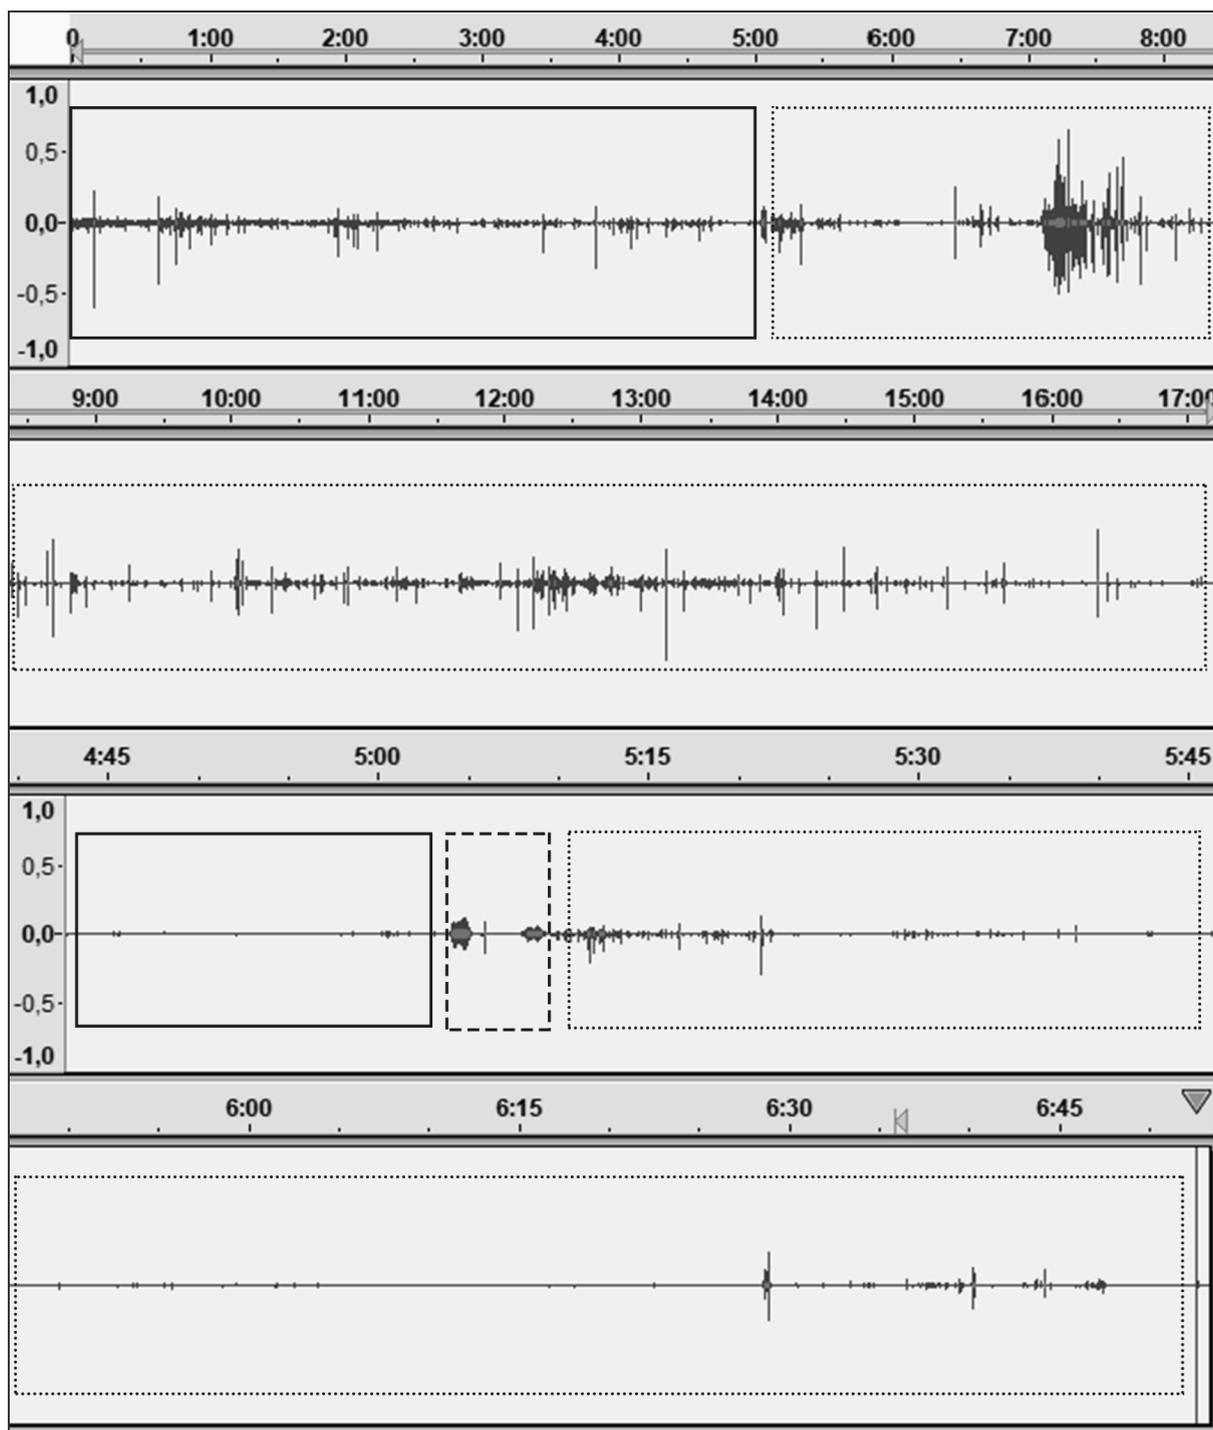


Figura 6. Espectrograma de áudio subaquático (áudio N°1) gravado em viveiros de Tambatinga. Retângulo de linha contínua indica o trecho de áudio antes da *Oferta de Ração*; retângulo de linha tracejada indica o momento da *Oferta de Ração*; retângulo de linha pontilhada indica o trecho de áudio *Após a Oferta de Ração*.

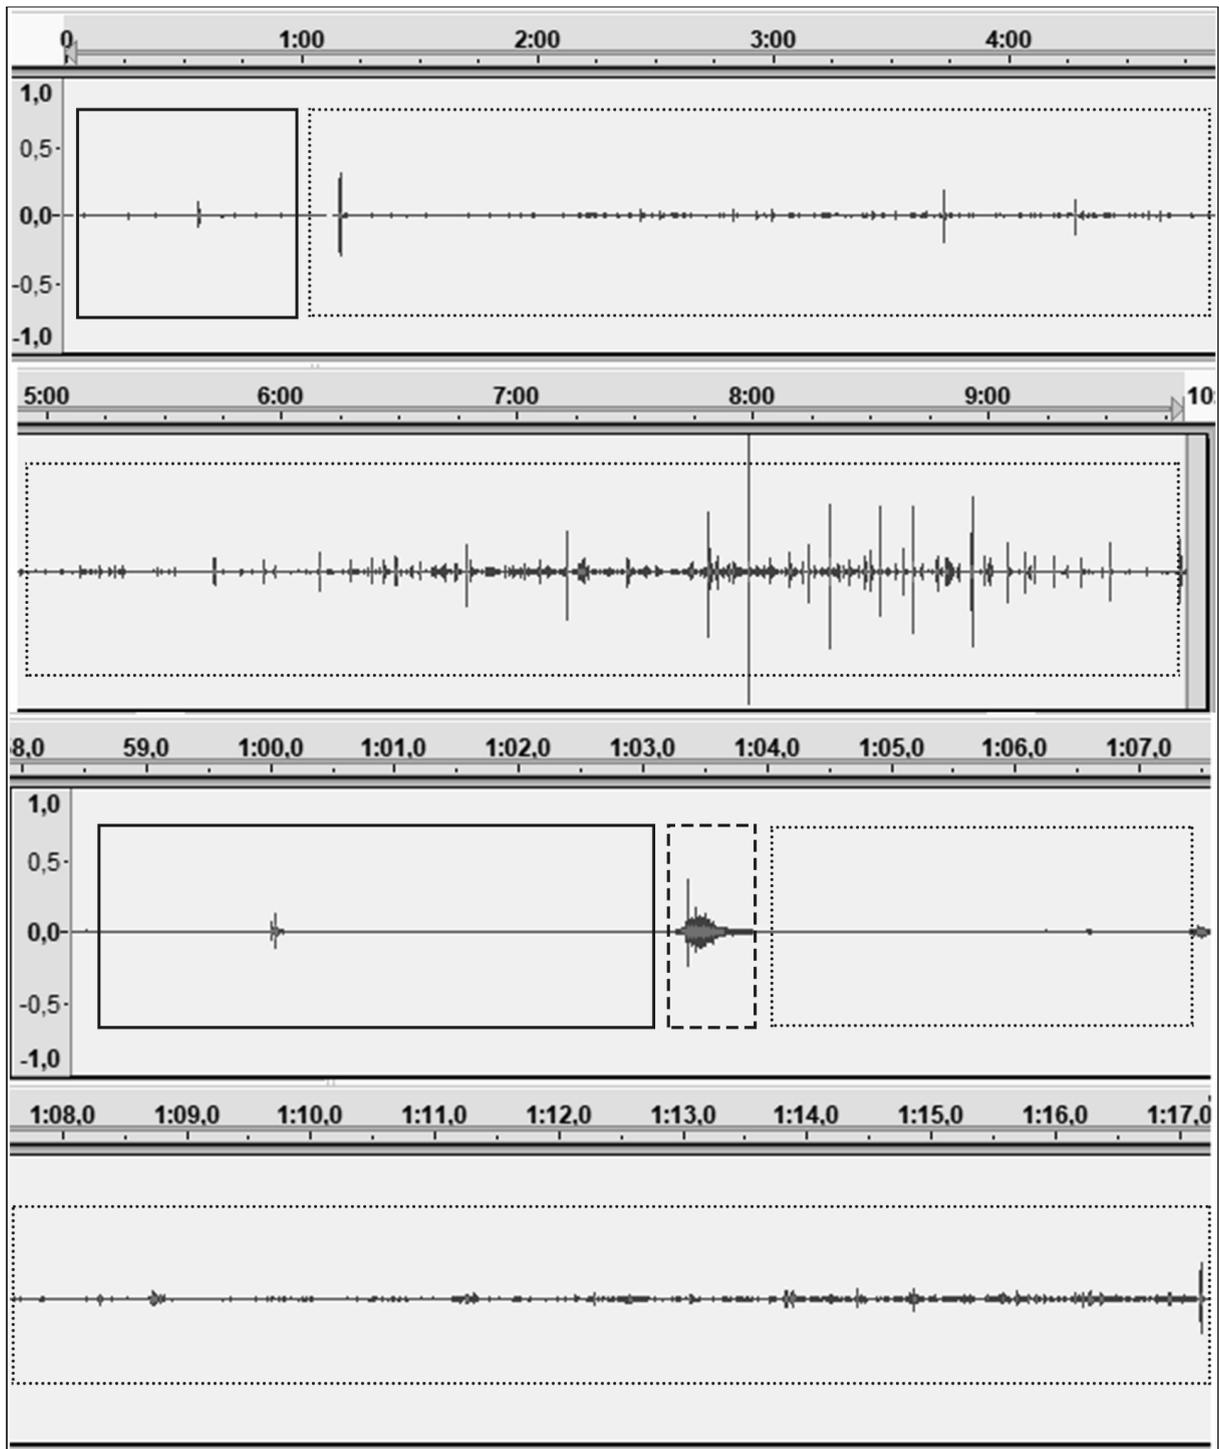


Figura 7. Espectrograma de áudio subaquático (áudio N°3) gravado em viveiros de Tambatinga. Retângulo de linha contínua indica o trecho de áudio antes da *Oferta de Ração*; retângulo de linha tracejada indica o momento da *Oferta de Ração*; retângulo de linha pontilhada indica o trecho de áudio *Após a Oferta de Ração*.

3.2 MODELO DE INTELIGÊNCIA ARTIFICIAL

O modelo treinado atingiu uma acurácia de 88% nos dados de teste, ao longo de 50 *epochs* (Figura 8). O comportamento da curva de acurácia, que representa a taxa de acertos do modelo, apresentou o padrão esperado, com o aumento da acurácia ao longo do treinamento, indicando que a rede neural está aprendendo os padrões dos áudios, e errando menos como consequência, com a estabilização aproximadamente a partir do *epoch* 35.

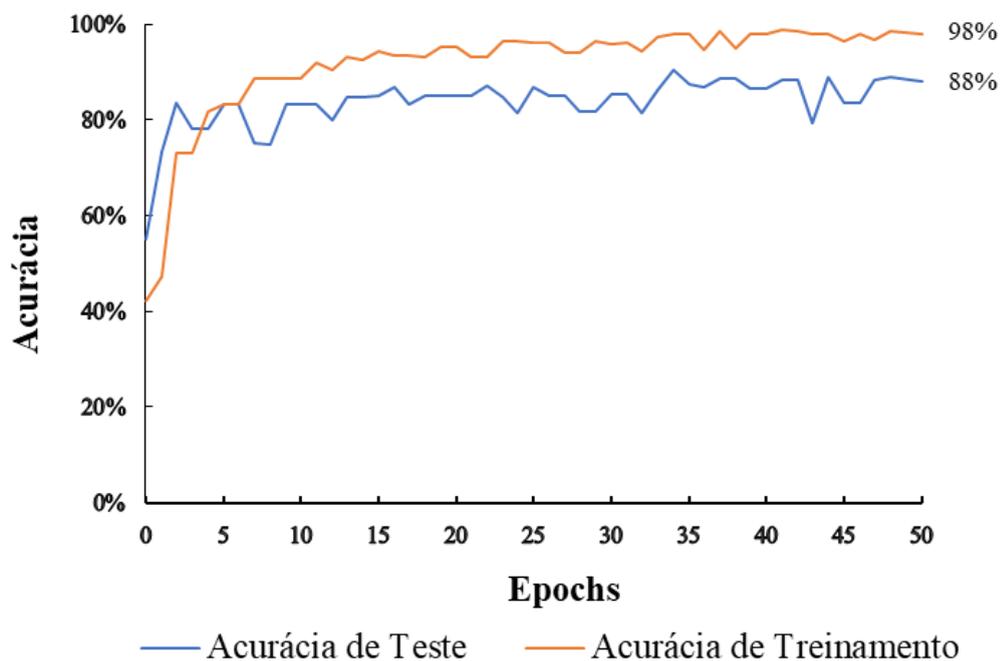


Figura 8. Acurácia do modelo desenvolvido nos dados de Teste e de Treino ao longo de 50 *epochs*. *Acurácia de Teste* = Acurácia do modelo no teste; *Acurácia de Treinamento* = Acurácia do modelo no treinamento; *Epochs* = Ciclos de treinamento.

O modelo atingiu um valor de custo de 0,36 nos dados de teste, ao longo de 50 *epochs* (Figura 10). A curva da função de custo apresentou o comportamento esperado, com um erro inicial grande momento em que (modelo ainda está no início do treinamento e portanto não aprendeu sobre os dados), e ao longo dos ciclos de treinamento o custo apresentou diminuição, pois o modelo passou a aprender as características dos dados gerou menos erro como consequência. A curva da função de custo atingiu a estabilidade aproximadamente a partir do *epoch* 35. O modelo mostrou uma boa acurácia, evidenciando uma alta taxa de

acertos nas predições; além disso, o modelo não foi considerado com *Overfitting* ou *Underfitting*, indicando que as respostas produzidas são confiáveis.

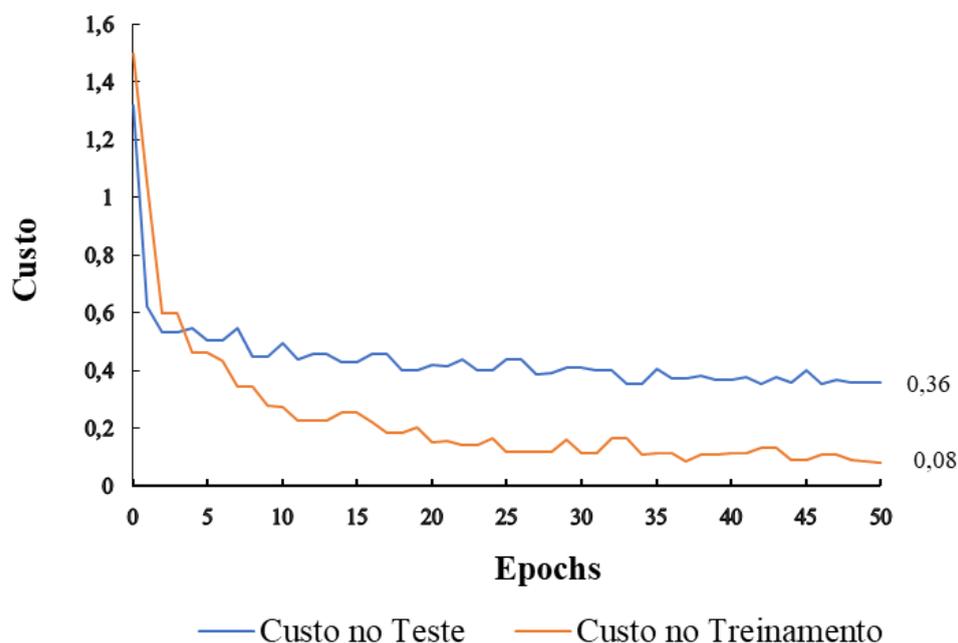


Figura 9. Função de Custo do modelo desenvolvido nos dados de Teste e de Treino ao longo de 50 *epochs*. *Custo de Treinamento* = Valor da função de custo do modelo no treinamento; *Custo de Teste* = Valor da função de custo do modelo no teste; *Epochs* = Ciclos de treinamento.

4. DISCUSSÃO

A Rede Neural, treinada com dados de acústica passiva, se mostrou um modelo eficiente na classificação da atividade alimentar de bagrinho e tambatinga em cativeiro, tendo grande potencial para utilização como método inteligente no controle de alimentação em sistemas de pisciculturas de acordo com o comportamento alimentar. Atualmente, a principal tecnologia que se usa para avaliação da alimentação de forma automatizada é o monitoramento por câmeras, entretanto nem sempre a captura de imagens permite a correta avaliação. Em um trabalho feito por ZHOU et al. (2019), uma Rede Neural Convolutiva (CNN) usada para aprendizado profundo mostrou ser uma maneira eficaz de aprender as características de intensidade da alimentação de peixes através de imagens e que poderia ser utilizada para controlar a alimentação dentro da piscicultura. A Rede Neural treinada com

imagens obteve uma acurácia maior que o método utilizando sons, proposto neste trabalho, sendo 2% mais acurado na identificação dos momentos de atividade alimentar dos peixes.

Entretanto, o uso de câmeras subaquáticas é geralmente limitado à ambientes com água mais transparente, e não funciona bem em locais com águas mais turvas. Da mesma forma, se um grande número de peixes estiver na parte inferior da gaiola/viveiro ou longe da fonte de luz, por exemplo, o sistema de câmeras pode não ser capaz de fornecer uma imagem precisa dos animais. Embora artificios como a luz infravermelha possam ser usados para melhorar a visibilidade, a qualidade da imagem embaixo d'água nem sempre é suficiente para monitorar o movimento dos peixes (ZHOU et al., 2018).

Assim, embora o monitoramento com câmeras seja de grande precisão, erros podem ser introduzidos por uma série de fatores como mudanças na iluminação, turbidez da água, ondas e bolhas (PARSONAGE et al. 2003; IBÁÑEZ *et al.*, 2012). Na aquicultura de alta densidade, a qualidade da imagem adquirida normalmente é muito ruim devido ao baixo contraste da imagem, pouca luz e alto ruído. Ao mesmo tempo, comumente ocorrem oclusão e sobreposição entre os peixes durante a alimentação. Esses fatores dificultam a extração de informações pelos algoritmos de aprendizado, podendo resultar em baixa precisão na identificação do comportamento alimentar dos peixes (YANG et al., 2021). Essas deficiências podem ser superadas através do uso de métodos acústicos, uma vez que estes não necessitam de fonte de luz, águas claras e de baixa turbidez, sendo possível sua aplicação 24h em sistemas de pisciculturas, inclusive ser usado em espécies de peixes que têm hábitos alimentares noturnos, sem necessidades de mudanças ou adaptações no sistema, além de não ser prejudicado pelo grande número de peixes em sistemas de alta densidade.

Em sistemas de piscicultura que utilizam métodos automatizados e inteligentes para alimentação nem sempre são detectadas melhorias no desempenho zootécnico dos animais. Por outro lado, comumente são encontradas melhorias no FCAA, que passa a ser reduzido. Um método de controle de alimentação baseado em visão computacional no infravermelho próximo e modelo neuro-fuzzy foi desenvolvido para tilápia com base em seus apetites. Comparando com os resultados quantitativos de apetite obtidos por observação humana, a precisão do modelo foi de 97%, indicando que a saída de tomada de decisão do modelo foi geralmente semelhante aos resultados da observação humana. Em um experimento realizado com o modelo desenvolvido, onde um grupo (1) de peixes foi alimentado com o modelo, e outro grupo (2) com taxa de alimentação de 2%, os resultados não mostraram diferenças

significativas no estado de crescimento entre os dois grupos. No entanto, o valor da FCAA para o grupo 1 foi melhor que o grupo 2, resultando em uma melhora na taxa de conversão alimentar de 10,77% (ZHOU. et al., 2018). Isto acontece principalmente devido à diminuição no desperdício de ração, o que tem como consequência ainda a menor liberação de resíduos e reduzida poluição aquática, além de potencialmente melhorar o resultado econômico da atividade, uma vez que o uso de ração foi diminuído. O método desenvolvido neste trabalho utilizando bioacústica, precisa ser testado em campo, para avaliação do desempenho dos peixes e dos parâmetros de qualidade de água, a fim de obter uma avaliação do desempenho mais completa do modelo.

Os resultados encontrados neste trabalho podem ser melhorados com novas aquisições de dados (áudios) e modelos de redes neurais diferentes. Um sistema de alimentação automatizada baseado no monitoramento acústico passivo, como demonstrado neste trabalho, pode ser de grande utilidade para controlar a oferta de ração para peixes em sistemas de aquicultura. De modo que com o uso de equipamentos simples como um hidrofone é possível monitorar adequadamente a atividade alimentar dos peixes e otimizar o uso de um dos principais insumos da atividade, a ração.

5. CONCLUSÕES

O modelo de inteligência artificial desenvolvido teve um desempenho considerado adequado, sendo capaz de monitorar e detectar satisfatoriamente os momentos relativos à alimentação de peixes em piscicultura. Assim, a inteligência artificial treinada neste trabalho pode ser utilizada para monitorar os três momentos relevantes para a alimentação de peixes: 1) momento antes da alimentação, com peixes calmos; 2) momento de busca e ingestão de alimento, com peixes com alta agitação; e 3) momento após a alimentação, com peixes retornando a um estado de baixa agitação. Logo, o método de controle de alimentação inteligente através da intensidade da atividade alimentar dos peixes pode reduzir bastante o desperdício de ração e melhorar o benefício econômico sob a premissa de garantir o crescimento normal dos peixes, reduzindo assim a poluição da água e promovendo o bem-estar dos peixes. Mais estudos são necessários para melhorar ainda mais a acurácia do modelo e permitir um monitoramento alimentar em sistemas de produção de peixes.

REFERÊNCIAS

CARNEY, M; WEBSTER, B; ALVARADO, I; PHILLIPS, K; HOWELL, N; GRITH, J; JONGEJAN, J; PITARU, A; CHEN, A. Teachable Machine: Approachable Web-Based Tool for Exploring Machine Learning Classify. **CHI '20 Extended Abstracts**, 25–30 de abril de 2020, Honolulu, HI, EUA, 2020.

CHANG, C.M; FANG, W; JAO, R.C; SHYU, C.Z; LIAO, I.C. Development of an inteligente feeding controller for indoor intensive culturing of eel. **Aquaculture Engineering**, v. 32, n. 2, p. 343–353, 2005.

GITHUB. **TFJS-MODELS: Speech Command Recognizer**. Disponível em: <https://github.com/tensorflow/tfjs-models/tree/master/speech-commands>. Acesso em: 5. Jan. 2022

GOOGLE. **Descending into ML: Training and Loss**. 2020. Disponível em: <https://developers.google.com/machine-learning/crash-course/descending-into-ml/training-and-loss>. Acesso em: 5. Jan. 2022

IBÁÑEZ, C; CAIOLA, N; ROVIRA, A; REAL, M. Monitoring the effects of floods on submerged macrophytes in a large river. **Science of the Total Environment**, v. 440, p. 132–139, 2012.

JESUS, S. M; HUGHES, A. P. **Relatório de dados do experimento EPPO 2019**: Detecção acústica do comportamento dos peixes, 17 de janeiro de 2020.

FAO. 2020. **The State of World Fisheries and Aquaculture 2020**. Sustainability in action. Rome. (SOFIA). 2020.

KUBITZA, F. Ração de soja otimizada e alimentadores automáticos incrementam a produção de camarão: A combinação do uso de ração à base de soja e alimentadores de alta tecnologia pode trazer vantagens únicas aos produtores. **Panorama da Aquicultura**, v. 29, n. 171, p. 22-29, 2019.

LAGARDERE, J.P; MALLEKH, R. Feeding sounds of turbot (*Scophthalmus maximus*) and their potential use in the control of food supply in aquaculture: I. Spectrum analysis of the feeding sounds. **Aquaculture**, v. 189, p. 251–258, 2000.

LAGARDERE, J.P; MALLEKH, R; MARIANI, A. Acoustic characteristics of two feeding modes used by brown trout (*Salmo trutta*), rainbow trout (*Oncorhynchus mykiss*) and turbot (*Scophthalmus maximus*). **Aquaculture**, v. 240, p. 607–616, 2004.

MEDEIROS, F. **Anuário Peixe BR da Piscicultura 2021**. São Paulo: Associação Brasileira da Piscicultura, 2021.

MEDEIROS, F. **Anuário Peixe BR da Piscicultura 2019**. São Paulo: Associação Brasileira da Piscicultura, 2019.

MALLEKH, R; LAGARDERE, J.P; ENEAU, J.P; CLOUTOUR C. An acoustic detector of turbot feeding activity. **Aquaculture**, v. 221, p. 481–489, 2003.

MALLEKH, R; LAGARDERE, J.P; BEGOUT ANRAS ML, LAFAYE JY. Variability in appetite of turbot, *Scophthalmus maximus* under intensive rearing conditions: the role of environmental factors. **Aquaculture**, v. 165, p. 123–138, 1998.

PARSONAGE, K.D; PETRELL, R.J. Accuracy Of A Machine-Vision Pellet Detection System. **Aquacultural Engineering**, v. 29, p. 109–123, 2003.

RIBEIRO, F.M; FREITAS, P.V.D.X; SANTOS, E.O; SOUSA, R.M; CARVALHO, T.A; ALMEIDA, E.M; SANTOS, T.O; COSTA, A.C. Alimentação e nutrição de Pirapitinga (*Piaractus brachypomums*) e Tambaqui (*Colossoma macropomum*): Revisão. **Pubvet**, v. 10, n. 12, p. 873–82, 2016.

RIBEIRO, P. A. P; MELO, D. C; COSTA, L. S; TEIXEIRA, E. A. **Manejo Nutricional E Alimentar De Peixes De Água Doce**. Belo Horizonte: FEPMVZ-Editora, 2012.

SMITH, D.V; TABRETT, S. The use of passive acoustics to measure feed consumption by *Penaeus monodon* (giant tiger prawn) in cultured systems. **Aquacultural Engineering**, v. 57, p. 38–47, 2013.

TAN, C; SUN, F; KONG, T; ZHANG, W; YANG, C; LIU, C; KŮRKOVÁ, V; MANOLOPOULOS, Y; HAMMER, B; ILIADIS, L. A. Survey on Deep Transfer Learning. In: Maglogiannis I. (eds) Artificial Neural Networks and Machine Learning – ICANN 2018. ICANN 2018. **Lecture Notes in Computer Science** vol 11141. Springer, Cham., 2018.

WU, T.H; HUANG, Y.I; CHEN, J.M. Development of an adaptive neural-based fuzzy inference system for feeding decision-making assessment in silver perch (*Bidyanus bidyanus*)

culture. **Aquaculture Engineering**, v. 66, n. 41-51. <https://doi.org/10.1016/j.aquaeng.2015.02.001>.

YANG, L; HUIHUI, Y; CHENG, Y; MEI, M; DUAN, Y; LI, D; CHEN, Y. A dual attention network based on efficientNet-B2 for short-term fish school feeding behavior analysis in aquaculture. **Computers and Electronics in Agriculture**, v. 187, 2021.

YE, Z.Y; ZHAO, J; HAN, Z.Y; ZHU, S.M; LI, J.P; LU, H.D; RUAN, Y.J. Behavioral characteristics and statistics-based imaging techniques in the assessment and optimization of tilapia feeding in a recirculating aquaculture system. Trans. **American Society of Agricultural and Biological Engineers**, v. 59, n. 1, p. 345–355. 10.13031/trans.59.11406. 2016.

ZHANG, H; ZHANG, L; JIANG, Y. H. Overfitting and Underfitting Analysis for Deep Learning Based End-to-end Communication Systems. 2019. **11th International Conference on Wireless Communications and Signal Processing (WCSP)**, IEEE, pp. 1-6. 2019.

ZHOU, C; XU, D; CHEN, L; ZHANG, S; SUN, C; YANG, X; WANG, Y. Evaluation of fish feeding intensity in aquaculture using a convolutional neural network and machine vision, **Aquaculture**, v. 507, p. 457-465, ISSN 0044-8486, 2019.

ZHOU, C; LIN, K; XU, D; CHEN, L; GUO, Q; SUN, C; YANG, X. Near infrared computer vision and neuro-fuzzy model-based feeding decision system for fish in aquaculture. **Computers and Electronics in Agriculture**, v. 146, p. 114-124, ISSN 0168-1699, 2018.

ZHOU, C; ZHANG, B; LIN, K; XU, D; CHEN, C; YANG, X; SUN, C. Near-infrared imaging to quantify the feeding behavior of fish in aquaculture. **Computers and Electronics in Agriculture**, v. 135, p. 233–241. 2017.