

UNIVERSIDADE FEDERAL DE ITAJUBÁ

**- TRABALHO FINAL -
DETECÇÃO COMPORTAMENTAL DE GADO LEITEIRO**

TINYML - IESTI01

SAMUEL AMADEU LOUREIRO - 2022003960

FLÁVIO ROSIM DE SOUSA - 2022003844

ITAJUBÁ

2025

1. OBJETIVOS

Este trabalho tem como objetivo principal o desenvolvimento de um sistema vestível baseado na plataforma Arduino Nano 33 BLE Sense para a identificação de padrões comportamentais de vacas leiteiras compreendidos como, andando, comendo e parada, por meio da aplicação de técnicas de aprendizado de máquina em dispositivos embarcados.

Buscou-se testar o sistema em ambiente real em um sítio, avaliando sua eficácia e estabilidade em condições práticas de uso. Espera-se analisar a viabilidade técnica de um sistema vestível e embarcado de baixo custo para monitoramento comportamental de bovinos, com potencial aplicação em fazendas leiteiras que desejam automatizar o acompanhamento do bem-estar e da produtividade dos animais.

2. INTRODUÇÃO

O monitoramento automatizado do comportamento animal tem se tornado uma área de crescente interesse no contexto da agropecuária de precisão. A análise do comportamento de vacas leiteiras, como caminhar, deitar, comer e ruminar, é fundamental para o acompanhamento do bem-estar, detecção precoce de doenças e otimização da produção. No entanto, os métodos tradicionais de observação manual são limitados por sua subjetividade, tempo e custo.

Nesse cenário, o uso de tecnologias vestíveis equipadas com sensores inerciais (IMU) e técnicas de aprendizado de máquina embarcado (TinyML) surge como uma solução promissora. Ao permitir a coleta contínua de dados diretamente do animal e a realização de inferência local, esses sistemas possibilitam a identificação automática de comportamentos em tempo real, com baixo consumo de energia e sem a necessidade de conectividade com servidores externos.

O projeto desenvolvido envolveu 3 etapas principais: Coleta de dados, em que foram coletados dados dos sensores inerciais com a vaca em um sítio com gado leiteiro. Treinamento do modelo na plataforma EdgeImpulse que auxiliou em todo processo de processamento e treinamento da rede neural utilizada para o modelo. Teste e deploy do modelo na prática, verificando se o comportamento indicado está de acordo com o comportamento real na vaca.

O projeto se justifica pela necessidade de soluções de monitoramento acessíveis, portáteis e eficientes para a pecuária, alinhando-se às tendências de digitalização do campo e de adoção de tecnologias inteligentes na produção agropecuária. Ao explorar o potencial de do TinyML aplicadas a dispositivos de baixo custo, o trabalho busca demonstrar a viabilidade técnica e prática de um sistema inteligente para a detecção de padrões comportamentais em vacas leiteiras, com potencial de aplicação em propriedades reais.

3. METODOLOGIA

Coleta e Processamento dos dados

Para a execução deste projeto, os equipamentos utilizados foram uma coleira, um powerbank, um celular e um Arduino Nano 33 BLE Sense. Os dispositivos foram fixados à coleira utilizando fita silver tape e fita isolante, garantindo que o Arduino fosse posicionado na região esquerda do pescoço da vaca para uma aferição precisa dos dados.

Inicialmente, buscou-se alimentar a placa Arduino utilizando duas baterias CR2032 conectadas em série. No entanto, devido a falhas de mau contato, a alimentação apresentava interrupções, o que comprometia o funcionamento adequado da placa. Em virtude dessa dificuldade, optou-se por utilizar um powerbank para o fornecimento de energia. Foi observado que o powerbank tendia a desligar automaticamente devido à baixa corrente consumida pelo Arduino. Para contornar essa questão e manter o fornecimento de energia contínuo, um celular foi conectado ao powerbank, garantindo que este permanecesse ativo. A conexão entre a placa Arduino e o notebook foi estabelecida via Bluetooth, permitindo que a vaca permanecesse livre durante a coleta de dados.

O monitoramento das interações da vaca (comer, andar e ficar parada) foi realizado através da captura de 10 segundos de dados do sensor para cada atividade. Após a captura, os dados eram classificados manualmente no terminal de acordo com a atividade observada, gerando um arquivo CSV com 51 linhas classificadas para cada período. No total, foram coletados 22 minutos e 28 segundos de dados, distribuídos da seguinte forma: 5 minutos e 47 segundos de dados com a vaca parada, 5 minutos e 1 segundo de dados com a vaca andando e 5 minutos de dados com a vaca comendo.

A divisão dos dados para o treinamento e teste do modelo foi de 79% designada para o conjunto de treino e 21% para o conjunto de teste.



Figura 1 - Tempo de coleta e divisão dos dados

Configuração e Treinamento do Modelo no Edge Impulse

A plataforma Edge Impulse foi utilizada para o desenvolvimento e treinamento do modelo de classificação das atividades da vaca. O processo de configuração envolveu diversas etapas, incluindo a quantização dos dados para otimizar o modelo especificamente

para ambientes TinyML, garantindo sua eficiência em dispositivos embarcados de baixo consumo de energia. Na configuração do impulso na plataforma, selecionou-se o bloco de análise espectral e foram usados os seis eixos disponíveis do acelerômetro e giroscópio (ax, ay, az, gx, gy, gz) como eixos de entrada como base para análise. Esta parte é crucial por transformar os dados do sensor do domínio do tempo para o domínio da frequência, extraíndo informações sobre os padrões repetitivos presentes nas atividades da vaca. As características geradas por esta análise espectral (as "Spectral features") permitem que o modelo de classificação identifique eficientemente os comportamentos, uma vez que as variações de frequência são indicadores distintos para o monitoramento da vaca.




Figura 2 - Gráfico da disposição das features

Subsequentemente, escolheu-se o bloco Classificador para o treinamento, sua principal função é, a partir das "Spectral features" fornecidas como entrada, aprender a diferenciar os padrões e atribuir cada segmento de dados a uma das categorias de atividade pré-definidas, ou seja, "andando", "comendo" e "parada".

Arquitetura da Rede Neural e Parâmetros de Treinamento

A arquitetura da rede neural empregada para a classificação das atividades da vaca foi estruturada com uma camada de entrada (Input layer) de 78 características. Em seguida, foram utilizados três blocos de camadas densas (Dense layer), cada uma com 256 neurônios, seguidas por camadas de dropout (Dropout) com uma taxa de 0.2, visando prevenir o *overfitting* do modelo. A camada de saída (Output layer) consistiu em 3 classes, correspondendo às atividades a serem classificadas.

As configurações específicas para o treinamento do modelo incluíram 25 ciclos de treinamento. A opção "Use learned optimizer" não foi selecionada, e a taxa de aprendizado (Learning rate) foi definida em 0.0005. O treinamento foi executado utilizando a CPU como processador de treinamento.

The image shows the configuration interface for training a neural network. The top section contains training parameters: 'Number of training cycles' is set to 25, 'Use learned optimizer' is unchecked, 'Learning rate' is 0.0005, and 'Training processor' is set to CPU. Below this is a section for 'Advanced training settings' which is currently collapsed. The 'Neural network architecture' section is expanded, showing a sequence of layers: an 'Input layer (78 features)' in blue, followed by three identical blocks of a 'Dense layer (256 neurons)' and a 'Dropout (rate 0.2)' layer, and finally an 'Output layer (3 classes)' in dark blue.

Figura 3 - Parâmetros da rede neural

Implementação e Verificação do Modelo

Após a geração do modelo de classificação no Edge Impulse, a biblioteca correspondente foi importada para o ambiente da Arduino IDE. O código embarcado na placa Arduino foi então modificado para permitir a verificação do modelo em tempo real. Para cada comportamento detectado da vaca (comer, andar ou ficar parada), uma cor específica do LED era ativada (verde: comendo, branco: parado e azul: andando), indicando visualmente a classificação. É crucial ressaltar que, para o teste de campo, tentou-se posicionar a placa na mesma orientação e localização no pescoço da vaca em que se encontrava durante a fase de depuração e coleta dos dados, garantindo a consistência das aferições.

4. RESULTADOS

A avaliação do modelo de classificação de comportamento da vaca foi realizada com base nas métricas de acurácia, perda (loss) e matriz de confusão, tanto no conjunto de validação quanto no classificador geral.

A Figura 4 apresenta o desempenho do modelo no conjunto de validação. Observa-se uma acurácia geral de 86.7% e um valor de loss de 0.57. Estes resultados iniciais sugerem um bom aprendizado do modelo na distinção entre os comportamentos observados.




Figura 4 - Performance e matriz de confusão da validação

A matriz de confusão detalha o desempenho por classe. O modelo demonstrou alta precisão na identificação dos comportamentos "Andando" (90.8%) e "Comendo" (89.2%), com baixas taxas de confusão entre si e com a classe "Parada".

No entanto, a classe "Parada" apresentou a menor acurácia de classificação, com 81.3%. O modelo teve uma tendência maior a confundir o estado "Parada" com "Andando" (10%) e "Comendo" (8.8%) em comparação com as outras classes.

A Figura 5 mostra as métricas gerais do teste do modelo e a matriz de confusão, com uma acurácia total de 81.45%. A acurácia foi um pouco menor, como esperado da etapa de teste, mas ainda apresentou um valor razoável




Figura 5 - Performance, métricas e matriz de confusão do teste do modelo

Nesta matriz de confusão geral, que pode incluir o conjunto de teste ou ser uma visão consolidada, a tendência observada no conjunto de validação se mantém e, em alguns aspectos, se acentua. A classe "Parada" continua a ser a classe com a menor acurácia, com 77%. Por outro lado, "Comendo" (87.5%) e "Andando" (80.5%) mantêm um bom desempenho.

A acurácia consistentemente menor da classe "Parada" em ambas as matrizes de confusão (81.3% no conjunto de validação e 77% no classificador geral) sugere uma dificuldade do modelo em classificar esse estado.

É provável que esta menor acurácia esteja relacionada à quantidade de dados coletados para a classe "Parada" ser inferior em comparação com as classes "Andando" e "Comendo". Além disso, atividades como "Parada" podem ter variações sutis que se assemelham a inícios ou fins de outras atividades, ou mesmo a pequenos ajustes posturais.

Implementação e Resultados práticos

No final, com a implementação do código de teste com o modelo na vaca, analisou-se se as inferências estavam sendo feitas corretamente, o que pode ser observado no vídeo a seguir:

 ClassificaçãoVaca - 1751341007178.mp4

Apesar de alguns momentos demonstrarem inconsistência, provavelmente devido a pequena janela de tempo que o programa classifica entre os comportamentos, ao passo que as amostras eram feitas em janelas de 10 segundos, nota-se com base na indicação visual do LED que o modelo consegue apresentar uma boa inferência dos comportamentos analisados.

5. CONCLUSÃO

O projeto demonstrou a viabilidade técnica e prática de um sistema vestível e embarcado de baixo custo para monitoramento comportamental de vacas leiteiras. Utilizando a plataforma Arduino Nano 33 BLE Sense e técnicas de TinyML, o sistema foi capaz de identificar padrões comportamentais, como andar, comer e ficar parada.

Os resultados obtidos no conjunto de validação apresentaram uma acurácia geral de 86.7% . No entanto, a classe "Parada" apresentou a menor acurácia, com 81.3% no conjunto de validação e 77% no classificador geral, sugerindo uma dificuldade do modelo em classificar esse estado. Isso pode ser devido à menor quantidade de dados coletados para essa classe e às variações sutis que podem se assemelhar a inícios ou fins de outras atividades.

A implementação prática do modelo na vaca, com indicação visual por meio de LEDs, demonstrou que o sistema consegue apresentar uma boa inferência dos comportamentos analisados , apesar de alguns momentos de inconsistência, provavelmente relacionados à pequena janela de tempo de classificação em comparação com as amostras de 10 segundos.

Em suma, o projeto atende à necessidade de soluções de monitoramento acessíveis, portáteis e eficientes para a pecuária, alinhando-se às tendências de digitalização do campo e de adoção de tecnologias inteligentes na produção agropecuária. O sucesso na detecção comportamental abre portas para aplicações em fazendas leiteiras que buscam automatizar o acompanhamento do bem-estar e da produtividade dos animais com inferência e processamento local.

Para futuras melhorias, aprimorar a coleta de dados é crucial, especialmente aumentando a quantidade de dados e de classes que possam definir melhor comportamentos específicos e anomalias, além de coletar dados em diferentes condições. Com essas melhorias e ampliando o escopo do projeto, os modelos gerados podem ser usados em contextos práticos, como a detecção precoce de estados de doença (pela alteração de padrões de movimento e alimentação) ou a identificação precisa do período de cio do animal.

AGRADECIMENTOS

Agradecimento especial ao colega Renan por ter disponibilizado o transporte e auxílio na logística do projeto, assim como ao Francisco por fornecer o sítio para a estadia e realização do projeto. Por último, mas não menos importante, um agradecimento à vaca Dalila que por livre e espontânea vontade, serviu de modelo para nossa pesquisa.