

# ROB: Uma abordagem para identificação automática de bovinos usando OCR

Igor Schneider<sup>1</sup>, Edimar Manica<sup>1</sup>

<sup>1</sup>Instituto Federal do Rio Grande do Sul - *Campus* Ibirubá  
Rua Nelsi Ribas Fritsch, 1111 – CEP: 98200-000 – Ibirubá – RS – Brasil

**Abstract.** *A individual identification of cattle plays a strategic role in dairy farm management, allowing the recording of essential data such as feeding frequency, water consumption, and milk production. In small farms, however, this process is often carried out manually, which limits efficiency. This paper presents the ROB approach (Optical Ear Tag Recognition), whose main contribution is the evaluation of camera positions and the creation of a real annotated image dataset of handwritten cattle ear tags, including cases with partial occlusion. The images were processed with Microsoft Azure OCR, and the results achieved 77.78% precision and 61.40% recall in the best setup. In addition to demonstrating the feasibility of OCR in this context, this work highlights its potential as a low-cost alternative to RFID for small farms.*

**Resumo.** *A identificação individual de bovinos desempenha um papel estratégico na gestão de propriedades leiteiras, permitindo o registro de dados como frequência de alimentação, consumo de água e produção de leite. Em pequenas propriedades, no entanto, esse processo ainda é realizado manualmente, limitando a eficiência. Este trabalho apresenta a abordagem ROB (Reconhecimento Óptico de Brincos), cuja principal contribuição é a avaliação de posições de câmera e a criação de uma base de dados anotada de imagens reais de brincos manuscritos, incluindo casos de oclusão parcial. As imagens foram processadas com o Microsoft Azure OCR, alcançando 77,78% de precisão e 61,40% de revocação no melhor cenário. Além de demonstrar a viabilidade do OCR nesse contexto, o trabalho reforça seu potencial como alternativa de menor custo em comparação ao RFID para pequenas propriedades.*

## 1. Introdução

A identificação individual dos animais em propriedades leiteiras desempenha um papel estratégico para a eficiência e a gestão rural, possibilitando registros como a frequência de entrada na contenção de alimentação, o consumo de água e o controle da produção de leite. No entanto, em muitas pequenas propriedades, como no caso da propriedade Christina Schneider, esse processo ainda é realizado manualmente, por meio da anotação do número do brinco do animal e até mesmo a produção leiteira individual em planilhas. Alternativas tecnológicas para a identificação dos brincos, como a Identificação por Radiofrequência (RFID, do inglês *Radio-Frequency Identification*), permitem a leitura automatizada por meio de etiquetas com chips e antenas que utilizam ondas de rádio,

sem necessidade de contato visual ou físico. No entanto, esse tipo de tecnologia apresenta limitações práticas: a distância de operação normalmente varia entre alguns centímetros e poucos metros, dependendo da antena utilizada, e o tempo de leitura pode ser afetado pela presença de múltiplos animais ou pela posição do chip, o que impede que a identificação seja sempre instantânea. Contudo, o custo elevado desses equipamentos dificulta sua adoção em contextos de menor escala.

Neste contexto, este trabalho propõe a abordagem **ROB** (Reconhecimento Óptico de Brincos), cujo objetivo é reconhecer automaticamente os números escritos nos brincos de identificação de bovinos a partir de imagens capturadas por câmeras. A abordagem compreende: (i) a coleta de vídeos dos animais; (ii) a segmentação desses vídeos em quadros/imagens em que o brinco esteja visível; (iii) a aplicação de uma tecnologia de Reconhecimento Óptico de Caracteres (OCR, do inglês *Optical Character Recognition*) para identificar os números presentes nos brincos; e (iv) a avaliação da eficácia da abordagem. A principal contribuição deste trabalho consiste na análise da posição mais adequada da câmera para capturar os brincos em uma propriedade rural, bem como na criação de uma base de dados anotada de imagens reais de brincos escritos à mão, contendo casos de oclusão parcial por sujeira, pelos e movimento dos animais. Além disso, avalia-se a eficácia do OCR aplicado a esse conjunto de dados, o que representa uma contribuição relevante para pesquisas futuras no contexto agropecuário.

Foram testadas quatro posições diferentes de instalação da câmera, sendo que a maioria delas contou com dois ângulos distintos em cada posição. A melhor combinação entre posição e ângulo possibilitou a geração de 57 imagens em que o número do brinco estava totalmente visível. Nesse cenário, a abordagem proposta alcançou 77,78% de precisão e 61,40% de revocação.

O restante deste trabalho está organizado da seguinte forma: na Seção 2 são apresentados os principais conceitos e tecnologias utilizados; a Seção 3 analisa e compara os trabalhos correlatos; a Seção 4 descreve a abordagem **ROB**; a Seção 5 apresenta e discute os resultados obtidos; e, por fim, a Seção 6 apresenta a conclusão e as sugestões para trabalhos futuros.

## 2. Conceitos e tecnologias

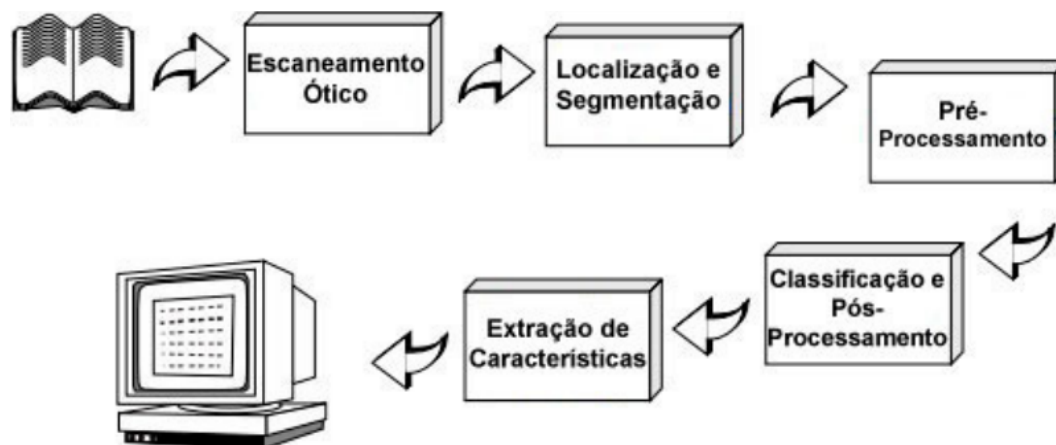
Esta seção apresenta os principais conceitos e tecnologias que fundamentam o desenvolvimento da abordagem proposta. Inicialmente, discute-se o Reconhecimento Óptico de Caracteres (OCR), explicando seu funcionamento e etapas principais. Em seguida, são descritas as tecnologias utilizadas no projeto, como Microsoft Azure OCR e OpenCV, destacando suas contribuições para a solução proposta.

### 2.1. Reconhecimento Óptico de Caracteres

A tecnologia de Reconhecimento Óptico de Caracteres (**OCR**) desempenha um papel central em aplicações que necessitam transformar informações contidas em imagens em texto digital. Essa abordagem é amplamente usada em áreas como automação de processos administrativos, análise de documentos e, no caso deste trabalho, para identificação de dados em brincos.

Segundo Eikvil (1993), o processo de OCR pode ser compreendido como um conjunto de etapas interconectadas, conforme ilustrado na Figura 1. Esse processo envolve

os seguintes componentes principais: escaneamento óptico, localização e segmentação, pré-processamento, classificação e pós-processamento, por fim, a extração de características.



**Figura 1. Componentes de uma tecnologia OCR**

Fonte: (EIKVIL, 1993)

O escaneamento óptico é a etapa inicial do processo, responsável por capturar as imagens que servirão de entrada para a tecnologia de OCR. A qualidade do escaneamento é fundamental, pois afeta diretamente a precisão das etapas subsequentes. Segundo Eikvil (1993), a escolha de dispositivos de captura, como *scanners* ou câmeras de alta resolução, deve garantir que os caracteres sejam nítidos e visíveis para processamento posterior.

Na etapa de localização e segmentação, as áreas de interesse contendo texto são identificadas e isoladas. Essa fase é crítica, pois uma segmentação inadequada pode levar a erros no reconhecimento. Técnicas como binarização e detecção de contornos são frequentemente utilizadas para separar o texto do restante da imagem. Kuhn, Cervi e Mânica (2019) destacam que a segmentação de caracteres é especialmente desafiadora em imagens com baixa qualidade ou com texto distribuído de forma irregular.

O pré-processamento busca melhorar a qualidade da imagem para otimizar as etapas seguintes. Isso inclui remoção de ruído, ajuste de contraste e alinhamento dos caracteres. Segundo Bomfim, Lima e Monteiro (2014), essas técnicas são indispensáveis para preparar imagens capturadas em condições não ideais, como iluminação inadequada ou superfícies irregulares.

A classificação é a etapa onde os caracteres são interpretados com base nas características extraídas. Modelos baseados em aprendizado de máquina ou redes neurais profundas são amplamente utilizados para mapear as características em caracteres específicos. Ferramentas modernas, como Tesseract e Microsoft Azure OCR, utilizam classificadores treinados em grandes conjuntos de dados para maximizar a precisão (GOOGLE, 2024; MICROSOFT, 2024).

O pós-processamento valida e corrige os resultados gerados na classificação. Essa etapa pode incluir a aplicação de regras gramaticais ou contextuais para corrigir possíveis erros. Segundo Lima (2024), o pós-processamento é essencial em aplicações que exigem alta precisão, como leitura de manuscritos médicos.

Por fim, na etapa de extração de características, padrões geométricos e texturais dos caracteres são identificados e representados em um formato que pode ser interpretado pelos modelos de classificação. Essa fase é fundamental para diferenciar caracteres similares, como “O” e “0” ou “1” e “l”. Conforme descrito por Smith (1987), o uso de redes neurais ajuda a identificar essas características de forma mais robusta.

## 2.2. Tecnologias Utilizadas

Existem diversas tecnologias no mercado voltadas ao reconhecimento óptico de caracteres, como o Tesseract e o Microsoft Azure OCR. A escolha da ferramenta depende do tipo de aplicação, da qualidade das imagens e do nível de precisão esperado. Considerando que, neste projeto, os brincos de bovinos possuem números escritos manualmente, optou-se pelo uso do Microsoft Azure OCR, em um cenário semelhante ao encontrado no estudo de Lima (2024).

O Microsoft Azure OCR é uma solução em nuvem, com custo baseado no volume processado, que se destaca pela capacidade de reconhecer manuscritos com alta precisão (MICROSOFT, 2024). Além disso, oferece integração com outros serviços da Microsoft, como armazenamento e análise de dados, o que o torna adequado para projetos que demandam escalabilidade. Um diferencial importante é a possibilidade de realizar testes preliminares gratuitos, reduzindo custos nas fases iniciais do desenvolvimento. A plataforma disponibiliza uma versão gratuita com limite de processamento de até 20 imagens por minuto e um total de 5.000 imagens por mês. Esses valores referem-se às condições vigentes na data de desenvolvimento deste trabalho. Embora suficientes para experimentos e validações iniciais, tais limitações podem restringir o uso contínuo em sistemas de larga escala, exigindo a contratação de planos pagos conforme o volume de dados processados aumenta.

O Tesseract OCR, por sua vez, é uma ferramenta de código aberto amplamente utilizada em pesquisas acadêmicas e aplicações práticas. Ele oferece flexibilidade na configuração e treinamento de modelos personalizados, sendo uma alternativa de baixo custo em comparação a soluções comerciais (GOOGLE, 2024).

No contexto deste projeto, o OpenCV foi utilizado como ferramenta auxiliar no tratamento das imagens capturadas pela câmera, otimizando o desempenho do OCR. Segundo OpenCV Development Team (2024), o OpenCV (Open Source Computer Vision Library) é uma biblioteca de código aberto amplamente empregada em sistemas de visão computacional, fornecendo algoritmos de pré-processamento de imagens que auxiliam na segmentação e extração de características.

Técnicas como binarização, remoção de ruído e ajuste de contraste, disponíveis no OpenCV, são essenciais para destacar os caracteres e preparar a imagem para o reconhecimento. Segundo Kuhn, Cervi e Mânica (2019), a aplicação dessas técnicas melhora significativamente a precisão do OCR em imagens capturadas em condições adversas. Além disso, a documentação oficial do OpenCV Development Team (2024) destaca o suporte a filtros avançados e algoritmos de transformação, que facilitam a identificação e extração de regiões de interesse.

### 3. Trabalhos Correlatos

Esta seção apresenta estudos que, embora não estejam diretamente ligados ao reconhecimento de brincos em animais, contribuem para o entendimento do uso de tecnologias de OCR em diferentes contextos de automação e leitura de caracteres. Os trabalhos foram selecionados a partir de pesquisas no Google Acadêmico<sup>1</sup> utilizando as palavras-chave "OCR em automação", "reconhecimento de manuscritos", "ear tag identification", e "leitura de caracteres em imagens", de modo a identificar soluções relacionadas e avaliar sua aplicabilidade ao contexto do reconhecimento de brincos de identificação de bovinos.

No trabalho de Neto e Sá (2023), foi desenvolvido um sistema de reconhecimento automático de placas veiculares do Mercosul, utilizando o Tesseract OCR. O estudo abordou etapas de captura de imagem, pré-processamento e segmentação, alcançando taxa de acerto acima de 90% em placas bem iluminadas. No entanto, houve queda significativa em cenários com baixa luminosidade ou ângulos desfavoráveis.

O estudo de Lima (2024) comparou ferramentas de OCR na leitura de datas manuscritas em prescrições médicas. Foram avaliados Tesseract OCR, EasyOCR, Google Cloud Vision API e Microsoft Azure OCR. Os resultados mostraram desempenho superior das soluções em nuvem (Google Cloud e Azure), com acurácia acima de 95% para manuscritos, enquanto as ferramentas de código aberto tiveram resultados mais modestos, porém de menor custo.

Já Kuhn, Cervi e Mânica (2019) exploraram metodologias de extração de texto em imagens com linhas inclinadas. O estudo utilizou técnicas de correção de inclinação e segmentação antes da aplicação do OCR, obtendo até 85% de sucesso em textos com inclinações de até 15 graus. Esse tipo de abordagem é relevante quando se considera a movimentação natural dos animais, que pode gerar ângulos desfavoráveis na captura dos brincos.

Em Bomfim, Lima e Monteiro (2014), foi implementado um sistema de reconhecimento automático de placas veiculares combinando MATLAB e Tesseract OCR. O algoritmo obteve 92% de precisão em ambientes controlados, mas apresentou queda em condições de iluminação variada, novamente evidenciando limitações ligadas à qualidade da captura.

De forma complementar, Andrade (2016) desenvolveu um sistema de OCR para caracteres manuscritos em documentos administrativos. O trabalho demonstrou que o Tesseract é eficiente em textos estruturados, mas sofre com manuscritos sem padronização, atingindo precisão média de 87%.

Além desses, destaca-se o estudo de Bastiaansen et al. (2022), que propôs um sistema de leitura contínua de brincos em tempo real a partir de vídeos transmitidos em *live-stream*. O modelo, baseado em redes neurais convolucionais, alcançou 87% de acurácia na leitura dígito a dígito e 93% na identificação do animal, embora com sensibilidade de apenas 41%, evidenciando dificuldades em capturar todas as passagens corretamente.

Por fim, Pretto et al. (2024) desenvolveram um método de baixo custo para identificar bovinos de corte utilizando câmeras convencionais e YOLOv3 para detecção dos brincos. A aplicação de OCR com correção de erros resultou em um mAP@0.50 de 89%

---

<sup>1</sup><https://scholar.google.com.br/>

e em 71% de taxa de identificação correta após validação dos IDs. O estudo reforça a viabilidade de sistemas acessíveis como alternativa ao RFID em pequenas e médias propriedades.

A Tabela 1 resume os principais aspectos dos estudos analisados. Alguns dos trabalhos correlatos apresentam relação direta com a proposta deste estudo, abordando o uso de OCR em contextos de identificação de animais ou aplicações no setor agropecuário. Outros contribuem de forma indireta, oferecendo *insights* sobre limitações, técnicas de pré-processamento e boas práticas no reconhecimento de caracteres. Dessa forma, os estudos reforçam tanto a relevância quanto a aplicabilidade da abordagem **ROB** no contexto da automação da identificação de bovinos.

**Tabela 1. Resumo comparativo dos principais trabalhos relacionados**

<b>Autores</b>	<b>Contexto</b>	<b>Ferramentas</b>	<b>Resultados</b>
Neto e Sá (2023)	Placas veiculares (Mercosul)	Tesseract OCR	>90% de acerto em boas condições; queda em baixa iluminação
Lima (2024)	Datas manuscritas em prescrições médicas	Tesseract, EasyOCR, Google Vision, Azure OCR	Serviços em nuvem com >95% de acurácia; soluções abertas mais baratas porém menos eficazes
Kuhn, Cervi e Mânica (2019)	Textos inclinados	Correção de inclinação + OCR	Até 85% de sucesso em inclinações de até 15°
Bomfim, Lima e Monteiro (2014)	Placas veiculares	MATLAB + Tesseract OCR	92% de precisão em condições controladas
Andrade (2016)	Documentos administrativos manuscritos	Tesseract OCR	87% de precisão média; problemas em manuscritos não padronizados
Bastiaansen et al. (2022)	Brincos bovinos em vídeo ao vivo	CNN + modelo ajustado	87% acurácia por dígito, 93% de identificação correta; 41% de sensibilidade
Pretto et al. (2024)	Bovinos de corte em fazenda	YOLOv3 + EasyOCR + correção de IDs	mAP@0.50 de 89%; 71% de taxa de identificação correta após correção

Fonte: Autor

#### 4. Abordagem ROB

A abordagem **ROB** (Reconhecimento Óptico de Brincos) tem como objetivo identificar os bovinos por meio do reconhecimento dos números presentes em seus brincos. A Figura 2 apresenta o fluxograma geral das etapas envolvidas no desenvolvimento da abordagem **ROB**. Cada etapa corresponde a uma fase essencial do processo, desde a obtenção das imagens até a análise da eficácia do reconhecimento automático dos números.



**Figura 2. Fluxograma das etapas que compõe a Abordagem ROB**

Fonte: Autor

A primeira etapa, **coleta**, teve como objetivo registrar os vídeos das vacas no momento em que passavam pela contenção. Em seguida, a **segmentação** buscou extrair automaticamente as imagens relevantes a partir dos vídeos, delimitando regiões que possuíam maior probabilidade de conter brincos de identificação. Com as imagens segmentadas, foi realizada a etapa de **OCR**, cujo objetivo foi reconhecer automaticamente os números escritos nos brincos. Por fim, a **avaliação** consistiu em comparar os resultados do OCR com uma rotulagem manual das imagens a fim de avaliar a eficácia da abordagem. As subseções seguintes detalham cada uma dessas etapas.

#### 4.1. Coleta

O objetivo desta etapa foi capturar vídeos das vacas no momento em que passavam pela contenção, em ângulos que possibilitassem a visualização do brinco de identificação, assegurando que as condições de aquisição não prejudicassem a leitura posterior pelo OCR. Para isso, foi utilizada uma câmera **Intelbras iM7 Full Color**, capaz de capturar imagens em alta resolução mesmo em ambientes com baixa luminosidade. A câmera foi posicionada em locais fixos na contenção (Figura 3), de modo a não interferir no fluxo dos animais nem ficar exposta a possíveis danos.


Foram definidas quatro posições de teste: duas no cocho de alimentação (posições 1 e 2) e duas na parede lateral em diferentes alturas (posições 3 e 4). Nos casos em que havia mais de um ângulo na mesma posição, a diferenciação foi feita por letras (A e B). Os vídeos foram gravados de forma contínua e, posteriormente, utilizados para a extração de frames relevantes. A Figura 4 apresenta exemplos do resultado visual dessas gravações.

#### 4.2. Segmentação

Esta etapa tem como objetivo obter imagens que possivelmente contenham brincos de identificação. Para atingir esse objetivo, foi implementado um software em Python, utilizando a biblioteca OpenCV, devido à sua eficiência nas tarefas de visão computacional. A Figura 5 ilustra o fluxo da segmentação, que recebe um vídeo como entrada e, após quatro fases, retorna as imagens que possivelmente possuem brincos dos bovinos.

A primeira fase consiste na conversão dos *frames* do vídeo do espaço de cor RGB (*Red, Green, Blue* - Vermelho, verde, azul) para o espaço de cor HSV (*Hue, Saturation, Value*). O objetivo dessa conversão é facilitar a identificação de cores, uma vez que o espaço HSV permite separar informações de cor (matriz) das informações de brilho e saturação. Essa separação é especialmente útil para detectar o amarelo dos brincos, mesmo quando há variações de iluminação. A função utilizada foi `cv2.cvtColor(frame, cv2.COLOR_BGR2HSV)`.

Após a conversão para HSV, foi aplicada a binarização através da geração de uma máscara binária em que pixels dentro da faixa de cor especificada aparecem em



**Figura 3. Posições e ângulos da câmera para captura das imagens.**

Fonte: Autor


branco (255) e os demais em preto (0) utilizando a função `cv2.inRange(hsv, amarelo_minimo, amarelo_maximo)`. Os parâmetros iniciais foram definidos como HSV mínimo (20, 100, 100) e máximo (30, 255, 255), mas esses valores resultaram em falsos positivos, detectando também partes da parede com coloração semelhante ao amarelo dos brincos. Após testes e ajustes, os parâmetros foram calibrados para HSV mínimo (22, 90, 125) e máximo (33, 180, 255), o que reduziu os falsos positivos, embora ainda haja limitações na detecção em áreas com baixa iluminação.

Com a máscara binária gerada, a próxima fase foi a identificação dos contornos dos objetos detectados. Essa identificação foi realizada com a função `cv2.findContours()`, que retorna todos os contornos encontrados na imagem. Cada contorno representa uma região potencialmente correspondente a um brinco. Esta fase é fundamental para isolar as regiões de interesse no processamento subsequente.


Alguns contornos identificados na fase anterior não correspondem a brincos de identificação. Para eliminar esses contornos irrelevantes, foi utilizada a função `cv2.contourArea()`, que mede a área dos contornos. Inicialmente, o valor mínimo foi definido como 300, capturando apenas brincos próximos, e deixando sem limite máximo. Após testes em posições mais distantes, o valor mínimo foi calibrado para 200, permitindo detectar brincos em diferentes distâncias.

### 4.3. OCR


O objetivo da etapa de OCR foi reconhecer automaticamente os caracteres numéricos nos brincos de identificação. Foram realizados testes preliminares com o Tesseract



Resultado da imagem da posição 1 ângulo (A) e (B)



Resultado da imagem da posição 2 ângulo (A) e (B)




Resultado da imagem da posição 3 ângulo (A)



Resultado da imagem da posição 4 ângulo (A) e (B)

**Figura 4. Resultado das imagens capturadas nas diferentes posições e ângulos**  
Fonte: Autor



**Figura 5. Etapas do processamento de imagem para detecção de brincos.**

Fonte: Autor

e com o Microsoft Azure OCR. Apenas o Azure apresentou resultados satisfatórios, pois os números estavam escritos à mão, o que dificultava a leitura pelo Tesseract.

Para o funcionamento, foram configurados no portal da Microsoft a chave de acesso e o *endpoint* (ponto de acesso), que foram incorporados ao código por meio da biblioteca oficial. Considerando a limitação da assinatura gratuita — até 20 imagens por minuto — o processamento foi realizado respeitando esse intervalo.

O resultado gerado pelo Microsoft Azure OCR passou por um pós-processamento com o objetivo de eliminar ruídos causados principalmente por sujeiras presentes nos brincos. Foram removidos os pontos, as vírgulas e os espaços identificados entre os caracteres numéricos.

#### 4.4. Avaliação

O objetivo dessa etapa foi avaliar a eficácia da abordagem **ROB** para reconhecer os números de identificação dos bovinos, garantindo uma medida objetiva da qualidade dos resultados. O método de avaliação foi escolhido considerando que o *OCR* é a etapa central deste trabalho, sendo fundamental verificar se a solução realmente atende ao propósito de identificar corretamente os números presentes nas imagens.

Para atingir esse objetivo, foram utilizadas duas métricas amplamente reconhecidas em problemas de reconhecimento de padrões: **precisão** e **revocação**. A **precisão** (*P*) mede a proporção de identificações corretas em relação ao total de identificações realizadas pela abordagem e foi calculada conforme a Equação 1. Por outro lado, a **revocação** (*R*) avalia a capacidade da abordagem em identificar corretamente todos os brincos e foi calculada conforme a Equação 2. Em conjunto, essas métricas permitem analisar tanto a confiabilidade quanto a abrangência da abordagem.

$$P = \frac{VP}{VP + FP} \quad (1)$$

$$R = \frac{VP}{VP + FN} \quad (2)$$

No contexto deste trabalho, foram considerados como:

- **VP (Verdadeiro Positivo)**: casos em que havia número visível no brinco e a abordagem reconheceu corretamente o valor;
- **FP (Falso Positivo)**: situações em que não havia um número visível e a abordagem retornou algum valor, ou quando havia um número visível mas a abordagem retornou um número diferente do que estava na imagem;
- **FN (Falso Negativo)**: casos em que havia número visível, mas a abordagem não conseguiu reconhecê-lo ou reconheceu incorretamente.

## 5. Resultados e discussão

Esta seção descreve os experimentos realizados para avaliar a eficácia da abordagem **ROB** e apresenta os resultados obtidos. Na subseção 5.1, são detalhados os experimentos voltados à etapa de segmentação; na subseção 5.2, aqueles relacionados à avaliação. Por fim, a subseção 5.3 discute os principais casos de falha identificados.

### 5.1. Experimento de segmentação

O objetivo deste experimento foi verificar se as imagens geradas na etapa de segmentação continham brincos de identificação bovina com números legíveis. Para isso, realizou-se um processo de verificação manual das imagens. Cada uma delas foi analisada e classificada conforme os critérios apresentados na Tabela 2, que reúne as seguintes informações: **posição** – posição e ângulo da câmera; **total** – número total de imagens geradas a partir do vídeo obtido naquela posição e ângulo; **legível** – número de imagens com o brinco contendo um número totalmente legível; **ilegível** – número de imagens em que o brinco estava presente, mas o número não pôde ser identificado devido a movimento ou sujeira; **parcial** – número de imagens em que o número do brinco estava apenas parcialmente visível, em razão de obstrução parcial pelos animais ou por obstáculos; e **falso** – número de imagens em que não havia brinco visível.

**Tabela 2. Resultado da rotulagem manual.**

<b>Posição</b>	<b>Total</b>	<b>Legível</b>	<b>Ilegível</b>	<b>Parcial</b>	<b>Falso</b>
1A	382	132 (34,6%)	178 (46,6%)	72 (18,8%)	0 (0,0%)
1B	14	0 (0,0%)	8 (57,1%)	0 (0,0%)	6 (42,9%)
2A	2374	1 (0,04%)	22 (0,9%)	3 (0,1%)	2348 (98,9%)
2B	176	57 (32,4%)	82 (46,6%)	37 (21,0%)	0 (0,0%)
3A	43	4 (9,3%)	4 (9,3%)	0 (0,0%)	35 (81,4%)
4A	5	1 (20,0%)	3 (60,0%)	1 (20,0%)	0 (0,0%)
4B	3	2 (66,7%)	1 (33,3%)	0 (0,0%)	0 (0,0%)

Fonte: Autor

Observa-se que as posições com maior número de imagens geradas foram **1A**, **2A** e **2B**, com 382, 2.374 e 176 imagens, respectivamente. No entanto, na posição **2A** apenas uma imagem apresentou o número do brinco de forma legível. Assim, as configurações de câmera consideradas mais adequadas foram **1A** e **2B**, cujas imagens foram utilizadas na análise do experimento seguinte.

Além disso, foi disponibilizada no GitHub<sup>2</sup> a base de dados referente às posições **1A** e **2B**, acompanhada das planilhas de classificação manual correspondentes, permitindo consulta e reuso em pesquisas futuras.

Esses resultados reforçaram a importância do posicionamento adequado da câmera e da qualidade do algoritmo de segmentação, visto que ajustes inadequados resultaram em grandes quantidades de imagens descartáveis, reduzindo a proporção de dados realmente úteis para o OCR.

<sup>2</sup><<https://github.com/Subinobarranco/BrincoIdentificadorOCR>>

## 5.2. Experimento de Avaliação

O objetivo deste experimento foi avaliar a eficácia da abordagem **ROB** para identificar os bovinos por meio do reconhecimento dos números presentes em seus brincos. Para atingir esse objetivo, foi calculada a precisão e a revocação da abordagem para as imagens das posições **1A** e **2B**. É importante destacar que as imagens rotuladas manualmente como **parciais** foram excluídas do cálculo das métricas, uma vez que, ainda que a abordagem pudesse reconhecer o número visível, este não correspondia ao identificador correto do animal.

A Tabela 3 apresenta os resultados obtidos neste experimento. Observa-se que a Posição **2B** apresentou a melhor eficácia, atingindo 77,78% de precisão e 61,40% de revocação. Embora a Posição **1A** tenha alcançado uma precisão relativamente próxima (75%), sua revocação foi significativamente inferior (38,64%), indicando que, apesar da abordagem identificar corretamente os números em algumas imagens, ela deixou de reconhecer uma parcela maior das ocorrências. Portanto, a combinação de posição e ângulo da câmera é um fator crítico para maximizar tanto a precisão quanto a cobertura do reconhecimento dos brincos.

**Tabela 3. Eficácia da abordagem.**

Posição	Precisão (%)	Revocação (%)
1A	75,00	38,64
2B	77,78	61,40

Fonte: Autor

## 5.3. Casos de falha

Esta seção apresenta os principais casos de falha da abordagem **ROB**, que podem subsidiar seu aperfeiçoamento e orientar futuros trabalhos. Uma das principais causas identificadas foi o movimento do animal, que, como ilustrado na Figura 6, comprometeu o foco da câmera e reduziu a visibilidade do número.

Outra situação recorrente ocorreu quando o brinco estava parcialmente encoberto por sujeira ou pelos, resultando em leituras incorretas ou na identificação apenas parcial do número, conforme exemplificado na Figura 7. Em casos menos frequentes, reflexos da luz solar — por exemplo, no olho do animal — foram interpretados pelo OCR como caracteres em outro idioma, ainda que estivesse configurado para reconhecer apenas textos em português. Esse tipo de falha também pode ser observado na Figura 7.



**Figura 6. Brinco em movimento**

Fonte: Autor



55

أبو

**Figura 7. Exemplo de erros de leitura do OCR**

Fonte: Autor

## 6. Conclusão

Este trabalho propôs a abordagem **ROB** que visa identificar automaticamente os bovinos, utilizando tecnologias de visão computacional e OCR. Foram descritas as etapas de coleta de imagens, segmentação, reconhecimento dos números nos brincos e avaliação dos resultados por meio de métricas de precisão e revocação.

Os experimentos demonstraram que a eficácia da abordagem depende fortemente do posicionamento da câmera e da qualidade da segmentação. Na configuração mais adequada, posição 2A, foram alcançados 77,78% de precisão e 61,40% de revocação, comprovando a viabilidade da abordagem. Em contrapartida, posições desfavoráveis resultaram em altas taxas de falsos positivos ou em dificuldades de reconhecimento, reforçando que ajustes finos na captura são determinantes para o sucesso da abordagem.

Um ponto relevante é a comparação entre o OCR em nuvem (Microsoft Azure) e a

tecnologia RFID. Apesar da limitação da assinatura gratuita do Azure, que restringe o uso a 20 imagens por minuto e 5000 ao mês, o custo geral da solução permaneceu significativamente mais baixo que a adoção de leitores RFID especializados. Estes podem operar em diferentes distâncias, mas exigem investimento elevado, o que inviabiliza a aplicação em pequenas propriedades rurais. Assim, mesmo com restrições, o OCR mostrou-se uma alternativa economicamente viável.

Outro aspecto que merece destaque é a necessidade de melhorar a etapa de segmentação. O processo atual gerou grande volume de imagens redundantes ou incorretamente segmentadas, o que impactou negativamente na eficiência do sistema. Investir em técnicas mais robustas de segmentação pode reduzir consideravelmente o número de imagens processadas, eliminando falsos positivos e aumentando a taxa de aproveitamento para o OCR.

Como contribuições, este trabalho mostrou que é possível propor uma solução de baixo custo para pequenas propriedades, aproveitando os brincos de identificação já existentes e utilizando apenas câmeras convencionais e serviços de OCR. A avaliação indicou resultados promissores, mesmo em um cenário limitado por assinatura gratuita do serviço em nuvem.

Para trabalhos futuros, recomenda-se o uso de conjuntos de imagens sequenciais para reduzir erros de leitura, além da exploração de técnicas avançadas de pré-processamento e segmentação, que podem aumentar a confiabilidade do sistema em condições adversas. Também sugere-se a integração com sistemas de armazenamento e análise em nuvem, ampliando o potencial de uso da solução em escala real.

## Referências

ANDRADE, R. P. *Desenvolvimento de um aplicativo móvel com OCR e reconhecimento de voz para leitura de consumo de água e gás em condomínios*. Monografia (Bacharelado em Sistemas de Informação) — Universidade de Caxias do Sul, 2016.

BASTIAANSEN, J. W. et al. Continuous real-time cow identification by reading ear tags from live-stream video. *Frontiers in Animal Science*, Volume 3, 2022.

BOMFIM, R. E. da C.; LIMA, R. T.; MONTEIRO, R. L. S. Algoritmo de reconhecimento automático de placas de veículos baseado em matlab e tesseract ocr. In: WORKSHOP DE PESQUISA TECNOLOGIA E INOVAÇÃO - PTI. DESAFIOS E OPORTUNIDADES PARA O DESENVOLVIMENTO INDUSTRIAL NO ESTADO DA BAHIA, 4., 2014, Salvador, Brasil. *Anais...* Salvador, Brasil: SENAI/CIMATEC, 2014. p. 334–348.

EIKVIL, L. *Optical Character Recognition*. [S.l.]: Norsk Regnesentral, 1993.

GOOGLE. *Tesseract OCR*. Tesseract OCR, 2024. Acesso em: 31 out. 2024. Disponível em: <<https://tesseract-ocr.github.io/>>.

KUHN, D.; CERVI, C.; MÂNICA, E. Toth: Uma abordagem para extração de elementos textuais em imagens com linhas de texto inclinadas. In: SEMINÁRIO INTEGRADO DE SOFTWARE E HARDWARE, 46., 2019, Belém, Brasil. *Anais...* Porto Alegre, Brasil: Sociedade Brasileira de Computação, 2019. p. 161–172.

LIMA, L. de S. *Reconhecimento de datas manuscritas em prescrições médicas: comparativo entre OCRs com Licença de Software Livre e uma solução comercial*. Monografia (Bacharelado em Ciência da Computação) — Universidade Federal de Campina Grande, Paraíba, 2024.

MICROSOFT. *Microsoft Azure OCR*. Microsoft Azure, 2024. Acesso em: 31 out. 2024. Disponível em: <<https://learn.microsoft.com/azure/cognitive-services/computer-vision/overview-ocr>>.

NETO, V.; Sá, A. de. *Reconhecimento automático de placas veiculares do Mercosul utilizando o Tesseract OCR*. Monografia (Graduação em Sistemas de Informações) — Instituto Federal do Espírito Santo, Serra, 2023.

OpenCV Development Team. *OpenCV*. OpenCV, 2024. Acesso em: 31 out. 2024. Disponível em: <<https://opencv.org>>.

PRETTO, A. et al. A novel low-cost visual ear tag based identification system for precision beef cattle livestock farming. *Information Processing in Agriculture*, v. 11, n. 1, p. 117–126, 2024.

SMITH, R. W. *The extraction and recognition of text from multimedia document images*. Tese (Doutorado) — University of Bristol, 1987.