

Avaliação da Capacidade de Retenção de Água em Amostras de Carne Suína

Renan Gomes de Andrade
Orientador: André Ricardo Backes

Universidade Federal de Uberlândia
andraderenan@yahoo.com.br

9 de julho de 2019

- 1 Introdução
- 2 Fundamentação Teórica
- 3 Metodologia
- 4 Experimentos e Análise dos Resultados
- 5 Conclusão

- 1 Introdução
- 2 Fundamentação Teórica
- 3 Metodologia
- 4 Experimentos e Análise dos Resultados
- 5 Conclusão

Introdução

- A carne suína é uma das fontes de proteína animal mais consumidas no Brasil e no mundo.
- Representa quase 40% de todo o consumo e produção.
- O controle da qualidade da carne oferecida aos consumidores é extremamente importante.
- Aspectos como sabor, aparência e higiene.
- Milhões de dólares deixam de ser comercializados todos os anos.



(a)



(b)

*Imagens adaptadas da internet: [1], [2].

- Algumas características importantes da carne suína:
 - Aparência
 - Cor
 - Textura
 - Quantidade de gordura
 - **Capacidade de Retenção de Água (CRA)**

- A água pode representar até 75% do peso total de um corte suíno.

Maior concentração de água = melhor qualidade

- Aspecto visual
- Suculência
- Maciez
- Rendimento durante o preparo

Capacidade de Retenção de Água (CRA)

Introdução

Método de Compressão

- Formação de áreas sobrepostas
- Quantificação das CRAs



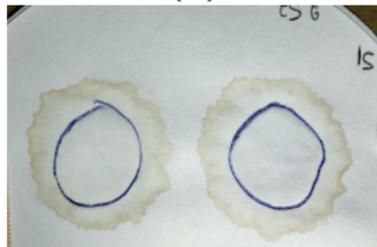
(a)



(b)



(c)



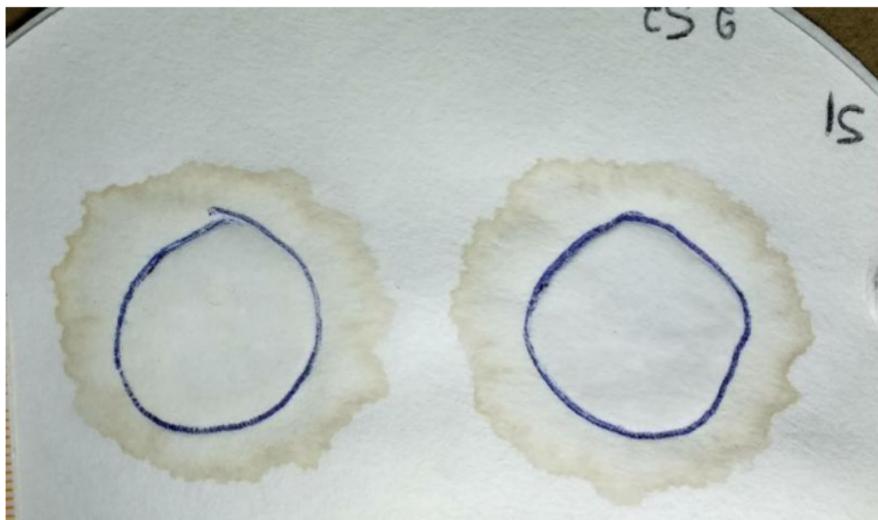
(d)

*Algumas imagens foram obtidas de [3].

Cálculo das CRAs

Introdução

- Região correspondente ao suco liberado (área externa)
- Região correspondente à porção de carne (área interna)



$$CRA = \frac{area_{int}}{area_{ext}}$$

(1)

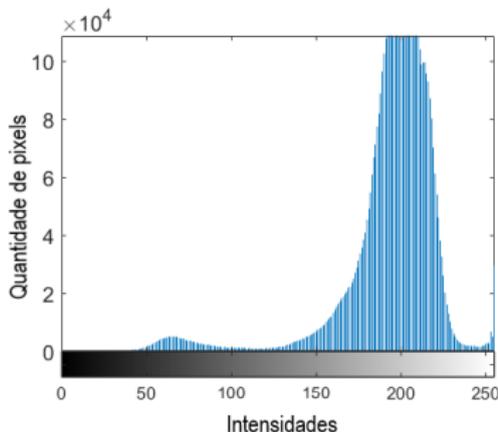
- Todo o processo de análise ainda é realizado manualmente por profissionais especialistas.
- Operação demorada
- Imprecisa
- Variável
- Cara
- Vulnerável a falhas e ao cansaço humano

- Relevância do tema
- Necessidade de automatização
- Poucos trabalhos relacionados ao tema utilizam PDI
- Auxiliar os profissionais da área

- Propor um método de segmentação automática de imagens capaz de identificar as regiões e quantificar as CRAs de amostras de carne suína.

- 1 Introdução
- 2 Fundamentação Teórica**
- 3 Metodologia
- 4 Experimentos e Análise dos Resultados
- 5 Conclusão

- Melhorar o aspecto visual e facilitar a interpretação de informações.
- **Brilho**: média de tons de intensidade.
 - Transformações de intensidade:
- **Contraste**: diversidade de níveis de intensidade.
 - Histograma: visualização das diferentes tonalidades.
 - Equalização: redistribui os níveis de intensidade.
 - Expansão: redistribui os níveis em uma nova faixa de valores inferiores e superiores.

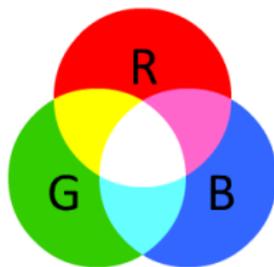


Modelos de Cores

Fundamentação Teórica

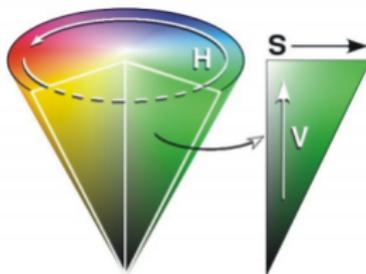
- Facilitar a especificação de cores em algum padrão.

- **RGB:**



- **HSV:**

- **H:** Matiz (*Hue*)
- **S:** Saturação (*Saturation*)
- **V:** Valor de intensidade (*Value*)



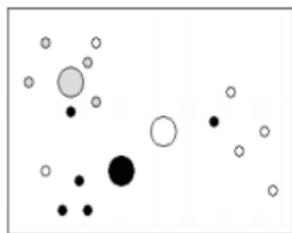
*A primeira imagem foi adaptada de [4].

- Analisar e extrair formas e estruturas de regiões da imagem.
 - Dilatação
 - Erosão
 - Abertura e Fechamento
 - Componentes Conexos
 - Preenchimento de Regiões
 - Esqueletização

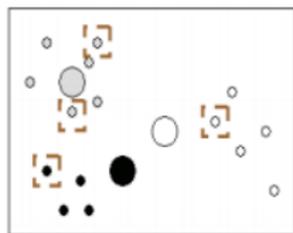
Algoritmo de agrupamento K -means

Fundamentação Teórica

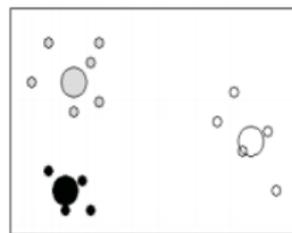
- Aprendizado não supervisionado
- Separa os dados em K grupos
- Agrupamento por similaridade
- Atualização dos centróides



(a)



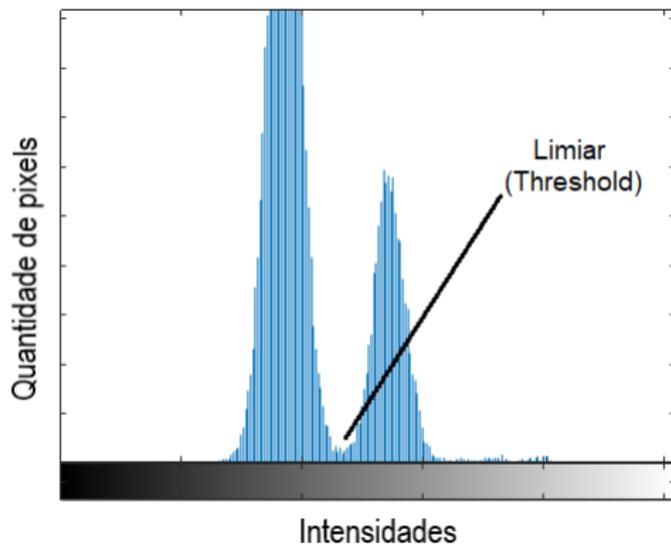
(b)



(c)

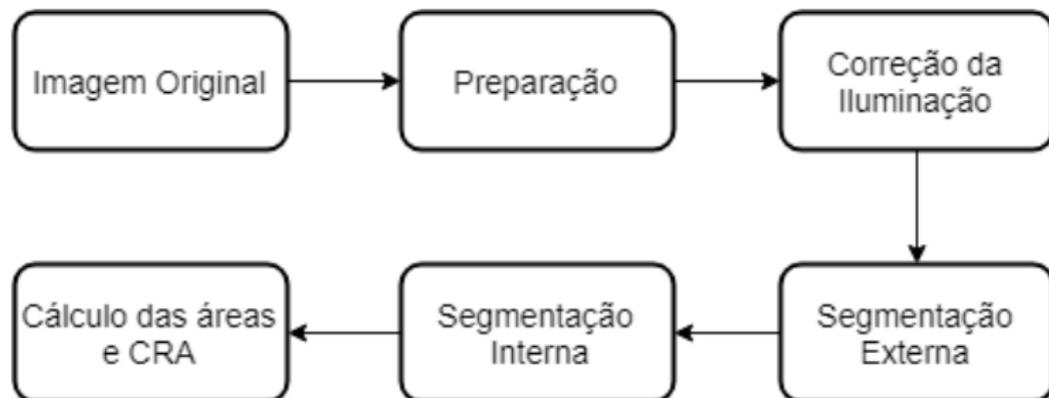
• Limiarização

- Segmentar regiões a partir de um limiar levando em consideração apenas os níveis de intensidade



- 1 Introdução
- 2 Fundamentação Teórica
- 3 Metodologia**
- 4 Experimentos e Análise dos Resultados
- 5 Conclusão

- Passos da metodologia:

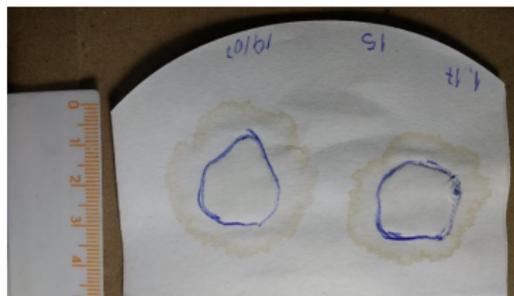


- **Reposicionamento da imagem**

- Verificar se o número de linhas é maior que o número de colunas
- Rotacionar a 90°



(a)



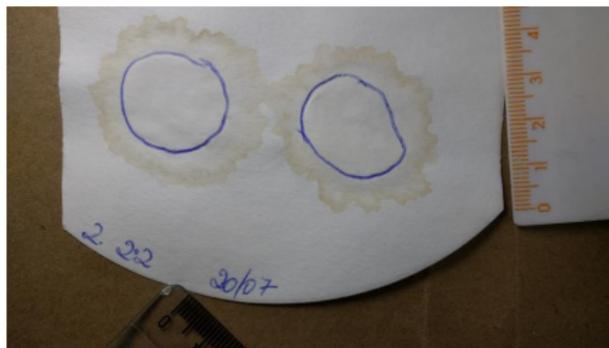
(b)

- **Recorte do fundo**

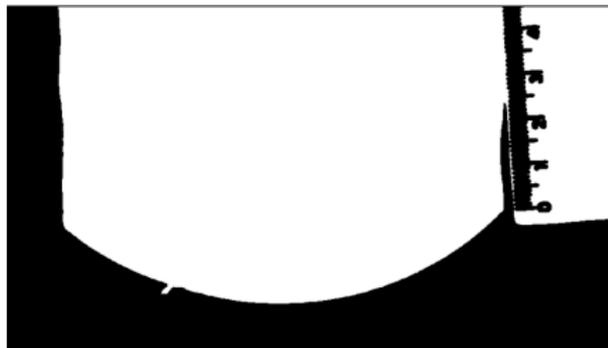
- Criação de uma máscara:

- **Primeira etapa:** suavização usando um disco de 10 pixels de raio.
- **Segunda etapa:** limiarização (saturação < 20 = objeto).
- **Terceira etapa:** isolamento da área correspondente ao papel (erosão com $ee =$ disco 5 pixels).
- **Quarta etapa:** preenchimento de regiões.

- **Recorte do fundo**
 - Resultado da criação da máscara



(a)



(b)

- **Recorte do fundo**

- Verificação das médias de intensidades de cada linha e coluna da máscara
- Determinar pontos iniciais e finais
- Recortar máscara

Preparação das Imagens

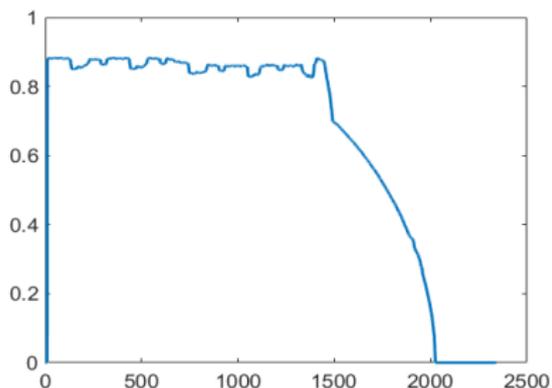
Metodologia

- **Recorte de colunas**

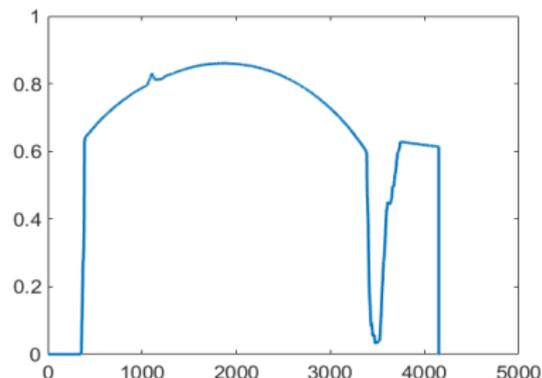
- $ponto_{inicial} > 0.45$ e $ponto_{final} < 0.45$

- **Recorte de linhas**

- $ponto_{inicial} > 0.6$ e $ponto_{final} < 0.6$

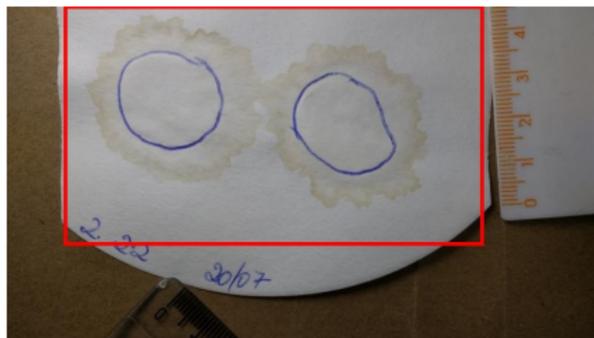


(a)



(b)

- **Recorte do fundo**



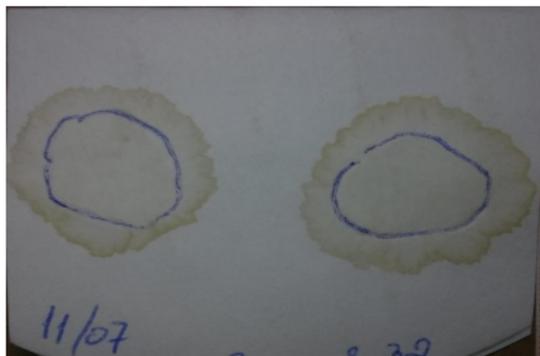
(a)



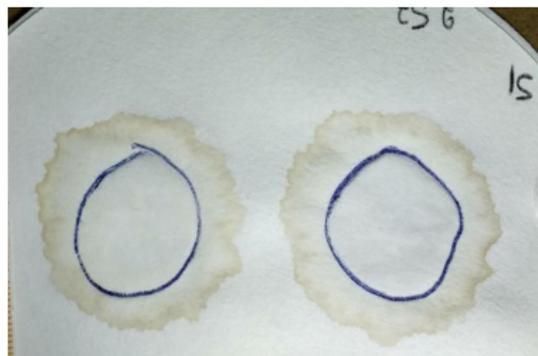
(b)

- **Correção da iluminação**

- Imagens com iluminação irregular
- Melhorar a identificação das regiões de interesse



(a)



(b)

Correção da iluminação

Metodologia

- Transformação logarítmica
- Manipulação do histograma
- Normalização de cores

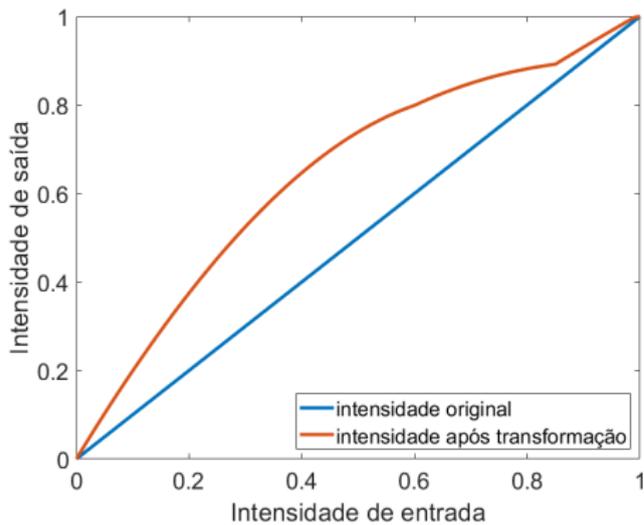
- **Transformação logarítmica**

- Aumentar os pontos com intensidades baixas e diminuir os de intensidade alta.

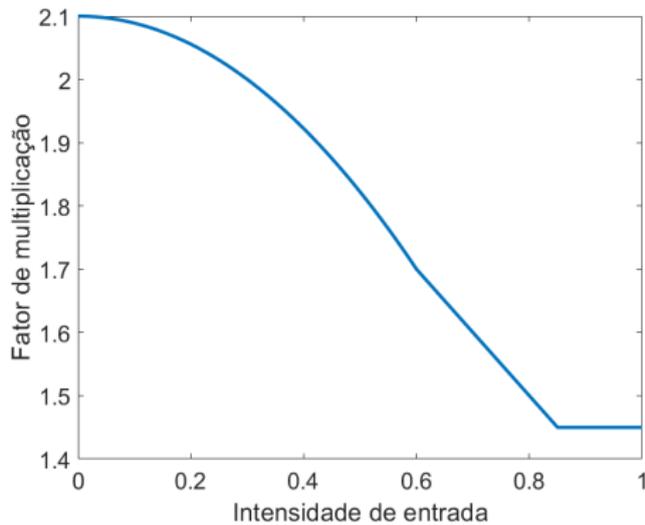
$$s = c * \log(1 + r) \quad (2)$$

$$c = \begin{cases} 2.1 - (m^2)/0.9, & \text{se } m \leq 0.6 \\ 2.3 - v, & \text{se } 0.6 < m < 0.85 \\ 1.45, & \text{se } m \geq 0.85 \end{cases} \quad (3)$$

● Transformação logarítmica



(a)



(b)

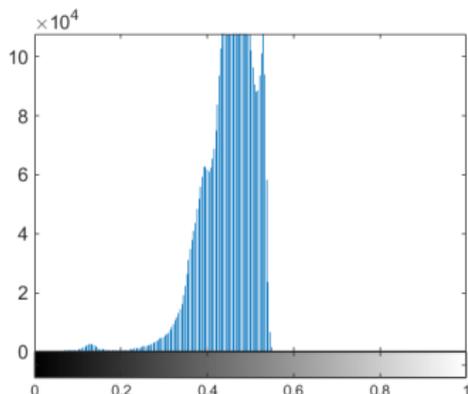
- **Manipulação do histograma**

- Deslocamento da média do brilho:

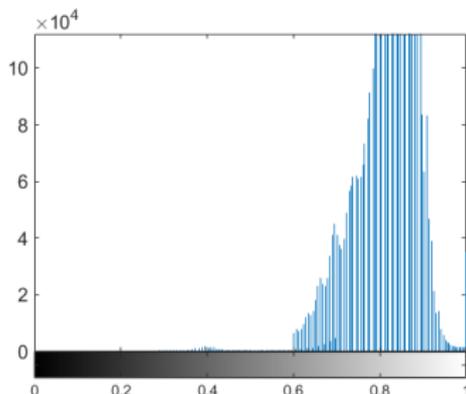
$$b = b - (m - 0.85) \quad (4)$$

- Expansão de parte do histograma:

- Novos limites inferiores
- De [0.7, 0.95] para [0.6, 0.95]

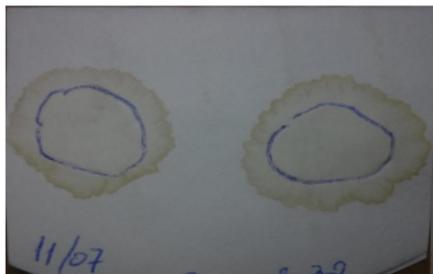


(a)

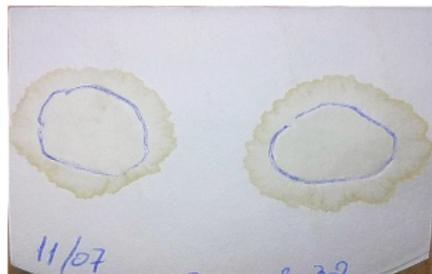


(b)

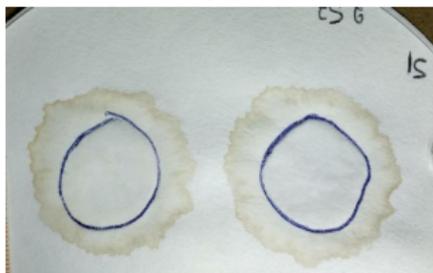
- Resultados da correções de brilho



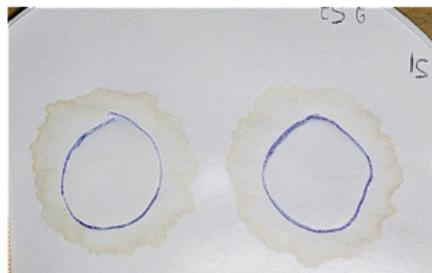
(a)



(b)



(c)



(d)

- **Normalização de cores**

- Imagens com aspectos azulados, esverdeados ou avermelhados

$$R(x, y) = R(x, y) - (\bar{R} - \bar{G}), \quad \text{if } \bar{R} > \bar{G} \quad (5)$$

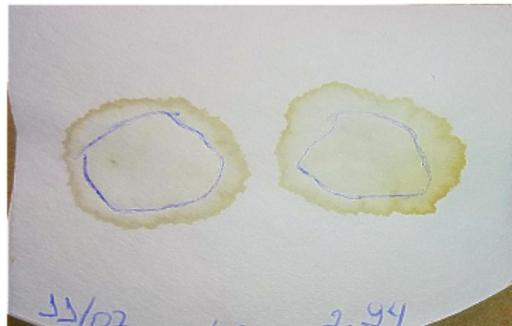
$$G(x, y) = G(x, y) - (\bar{G} - \bar{R}), \quad \text{if } \bar{G} > \bar{R} \quad (6)$$

$$B(x, y) = B(x, y) - (\bar{B} - \bar{G}), \quad \text{if } \bar{B} > \bar{G} \quad (7)$$

- Resultado após a normalização de cores



(a)



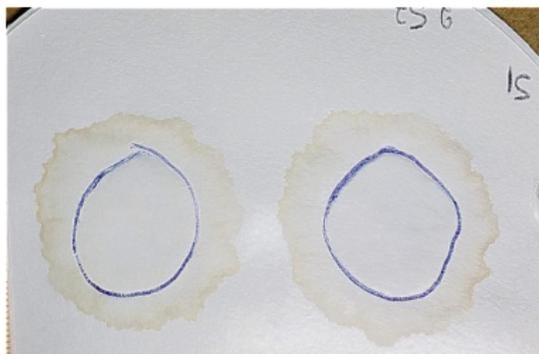
(b)

Segmentação da Área Externa

Metodologia

● Segmentação da área externa

- Realce do amarelo
- Limiarização
- Operações morfológicas
- Eliminação de falsos objetos
- *K-means*
- Ligar pontos extremos



(a)



(b)

● Realce do Amarelo

- A coloração das bordas das amostras é formada por suaves tons de amarelo
- Realçar o amarelo para facilitar a limiarização

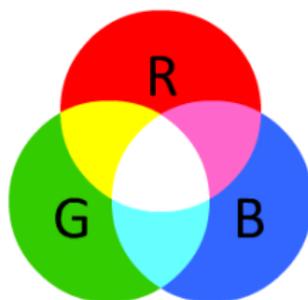


(a)



(b)

- **Realce do Amarelo**



$$B(x, y) = B(x, y) + 5 * d, \text{ se } |d| < 4.5 \quad (8)$$

$$d = B(x, y) - m \quad (9)$$

$$m = (R(x, y) + G(x, y))/2 \quad (10)$$

*Imagem adaptada de [4].

- **Limiarização**

- Segmentar bordas amarelas

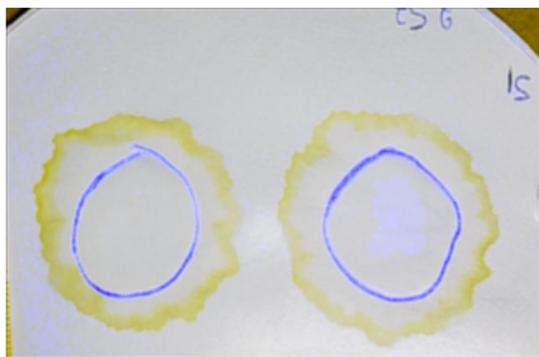
$$I(x, y) = \begin{cases} 1, & \text{se } G(x, y) - B(x, y) \geq \text{limiar} \\ 0, & \text{se } G(x, y) - B(x, y) < \text{limiar} \end{cases} \quad (11)$$

$$\text{limiar} = \begin{cases} \text{round}(meGB * 0.7), & \text{se } (meGB * 0.7) \leq 6 \\ 7, & \text{se } (meGB * 0.7) > 6 \end{cases} \quad (12)$$

$$meGB = \frac{1}{N * M} \sum_{x=1}^N \sum_{y=1}^M (G(x, y) - B(x, y)) \quad (13)$$

- **Limiarização**

- Resultado



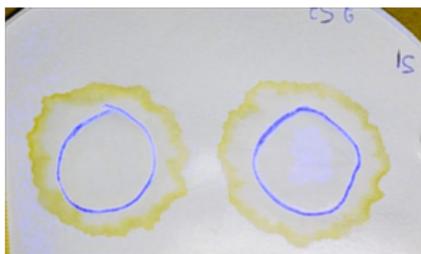
(a)



(b)

- **Operações morfológicas**

- Fechamento
- Preenchimento de regiões



(a)



(b)



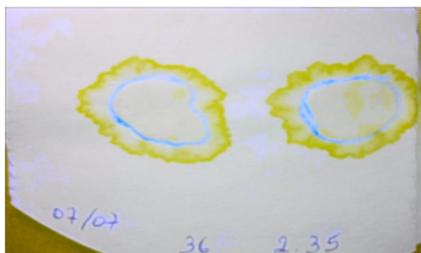
(c)



(d)

- **Eliminação de falsos objetos**

- Manter apenas os dois maiores componentes conexos
- Aplicar margens nas primeiras e últimas linhas e colunas (40 pixels)



(a)



(b)



(c)



(d)

- **K-means**

- Amostras muito próximas umas das outras
- São segmentadas como um só objeto



(a)



(b)

● K-means

- Verificar se o maior elemento é 10 vezes maior que o segundo
- Manter apenas o maior elemento
- Aplicar o *K-means* nas coordenadas (x,y) da imagem
- $k = 2$ (2 amostras)



(a)



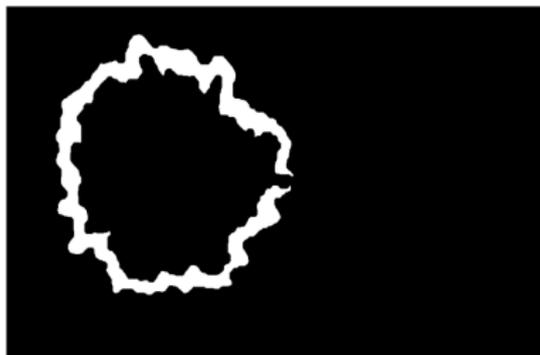
(b)



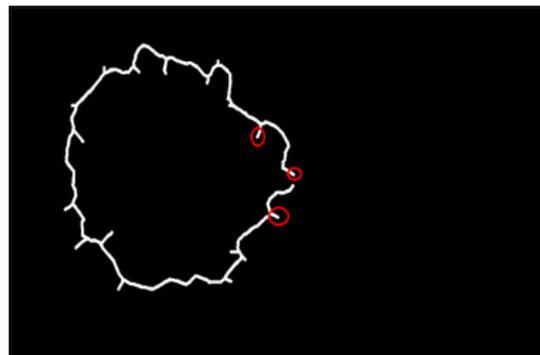
(c)

● Pontos Extremos

- Algumas amostras não são totalmente segmentadas
- Verificar se o objeto é menor do que 7.5% do tamanho total da imagem
- Esqueletização
- Identificar pontos extremos (pixels com menos de 2 vizinhos)



(a)



(b)

● Ligar pontos Extremos

- O esqueleto corresponde a um grafo, cada pixel representa um vértice
- A distância entre vértices vizinhos é 1
- Aplicar o Dijkstra e identificar o par de pontos extremos com o maior caminho entre eles
- Traçar uma reta ligando esses pontos
- Aplicar o preenchimento de regiões



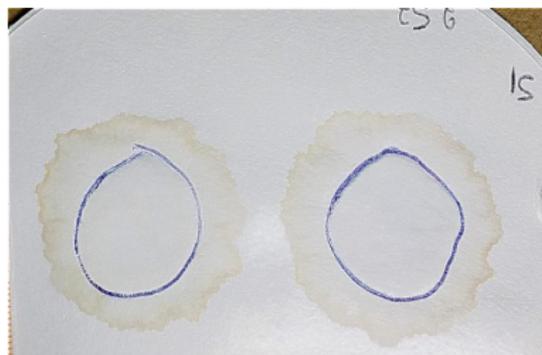
(a)



(b)

- **Segmentação da área interna**

- Recorte da região externa
- Limiarização
- Operações morfológicas
- Ligar pontos extremos



(a)



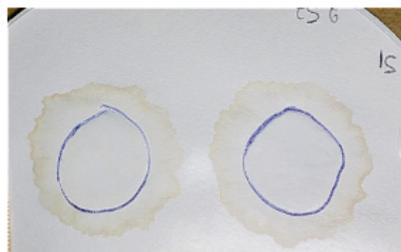
(b)

Segmentação da Área Interna

Metodologia

- **Recorte da região externa**

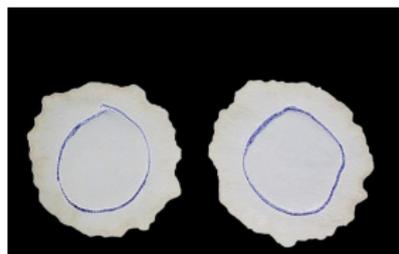
- Seleção da região da amostra
- Limitar as áreas de interesse



(a)



(b)



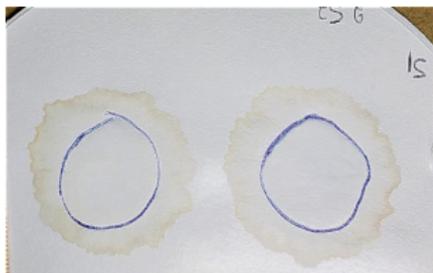
(c)

Segmentação da Área Interna

Metodologia

● Limiarização

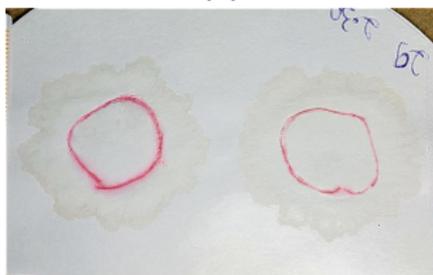
- Segmentar os diferentes tons de marcações
- Utilizar diferentes limiares



(a)



(b)



(c)



(d)

- **Limiarização**

- RGB + HSV

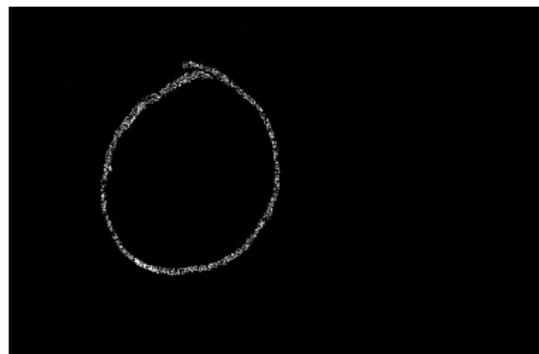
$$I(x, y) = \begin{cases} 1, & \text{se } B(x, y) - G(x, y) \geq 7 & \& \quad s(x, y) \geq 0.06 \\ 1, & \text{se } G(x, y) - R(x, y) \geq 15 & \& \quad s(x, y) \geq 0.06 & \& \quad v(x, y) \leq 0.7 \\ 1, & \text{se } R(x, y) - G(x, y) \geq 20 \\ 1, & \text{se } v(x, y) > 0.3 & \& \quad v(x, y) \leq 0.6 & \& \quad s(x, y) < 0.06 \\ 0, & \text{caso contrário} \end{cases} \quad (14)$$

- **Operações morfológicas**

- Eliminação de pequenos objetos
 - Aplicar erosão na máscara de segmentação externa
 - Posições dos pixels iguais a 0 são salvas em um vetor
 - Todas as posições da imagem recém segmentada que estão contidas no vetor passam a ser iguais a 0



(a)

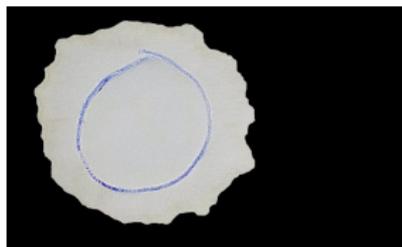


(b)

Segmentação da Área Interna

Metodologia

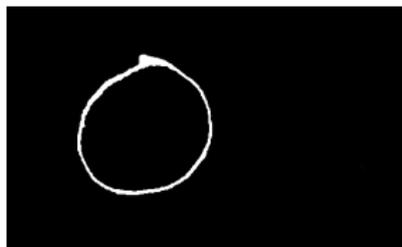
- **Operações morfológicas**
 - Fechamento
 - Preenchimento de regiões



(a)



(b)



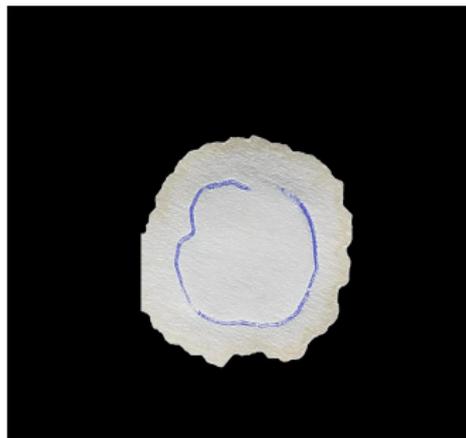
(c)



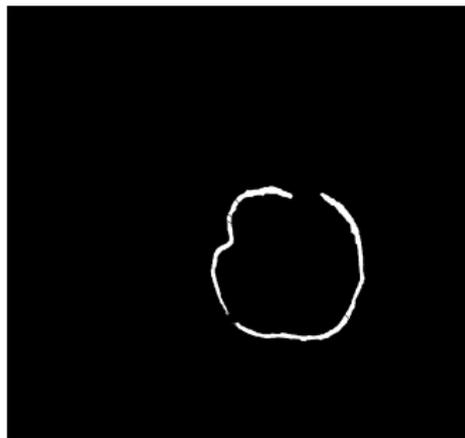
(d)

● Pontos Extremos

- Algumas regiões não são totalmente segmentadas
 - Semelhanças de intensidades
 - Falhas durante as marcações
- Verificar se a soma dos pixels dos objetos é menor do que 5% do tamanho da imagem



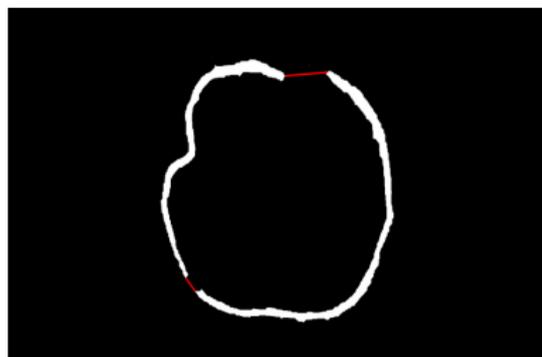
(a)



(b)

● Ligar pontos Extremos

- Esqueletização
- Dijkstra para identificar os pontos extremos de cada objeto
- Calcular a distância euclidiana entre cada extremidade
- Traçar uma reta entre as extremidades mais próximas
- Aplicar o preenchimento de regiões



(a)



(b)

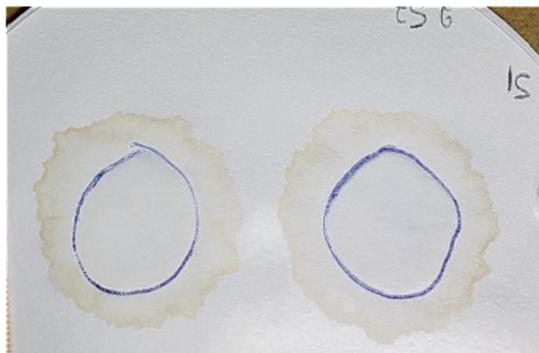
- 1 Introdução
- 2 Fundamentação Teórica
- 3 Metodologia
- 4 Experimentos e Análise dos Resultados**
- 5 Conclusão

- Conjunto de imagens
 - 665 imagens
 - Todas foram disponibilizadas pela pesquisadora Isaura Maria Ferreira Programa de Pós-Graduação em Ciências Veterinárias da UFU
 - Criação de um subconjunto com 16 imagens retratando as características do dataset
- Cálculo das áreas e das CRAs
- Análise experimental
- Avaliação dos resultados

Cálculo das Áreas de das CRAs

Experimentos e Análise dos Resultados

- As quantidades de pixels das áreas internas e externas são contabilizadas



(a)



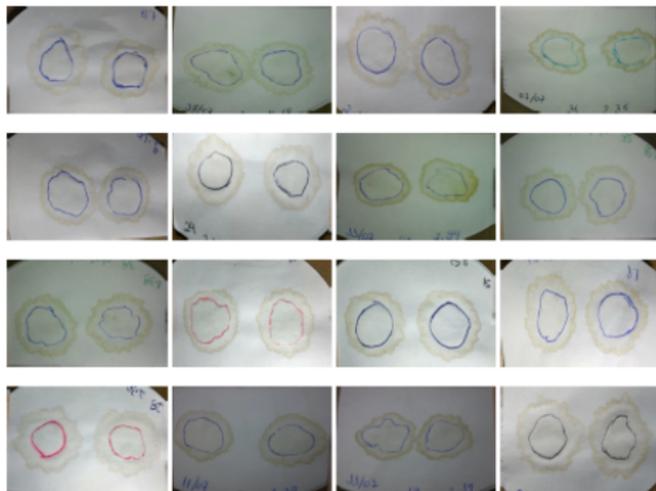
(b)

$$CRA = area_{int} / area_{ext} \quad (15)$$

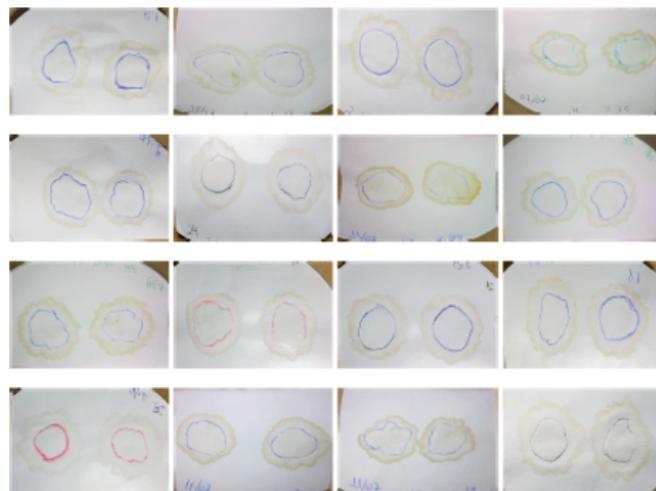
$$meCRA = (CRA_1 + CRA_2) / 2 \quad (16)$$

- **Resultados da preparação e correção da iluminação**

- Imagens do subconjunto
- Resultados satisfatórios



(a)



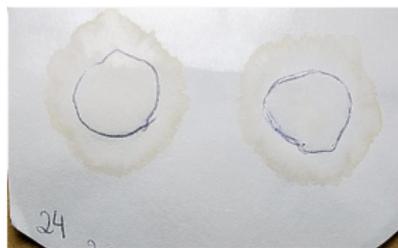
(b)

● Resultados da correção de iluminação

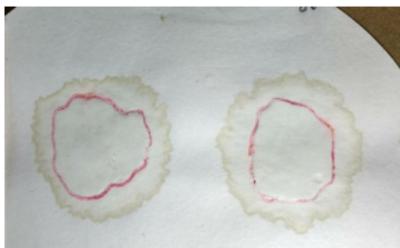
- Em alguns casos, algumas regiões da imagem já possuíam um elevado nível de brilho e não sofreram grandes alterações
- Essas irregularidades não afetaram a visualização das amostras



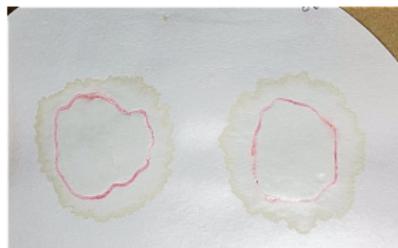
(a)



(b)



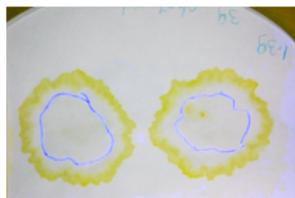
(c)



(d)

● Resultados da segmentação externa

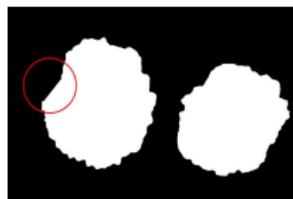
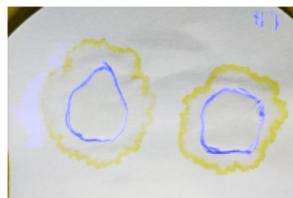
- As imagens do subconjunto foram segmentadas corretamente
- Considerando todo o conjunto, algumas poucas imagens não foram completamente identificadas



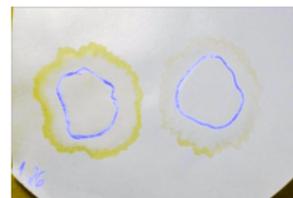
(a)



(b)



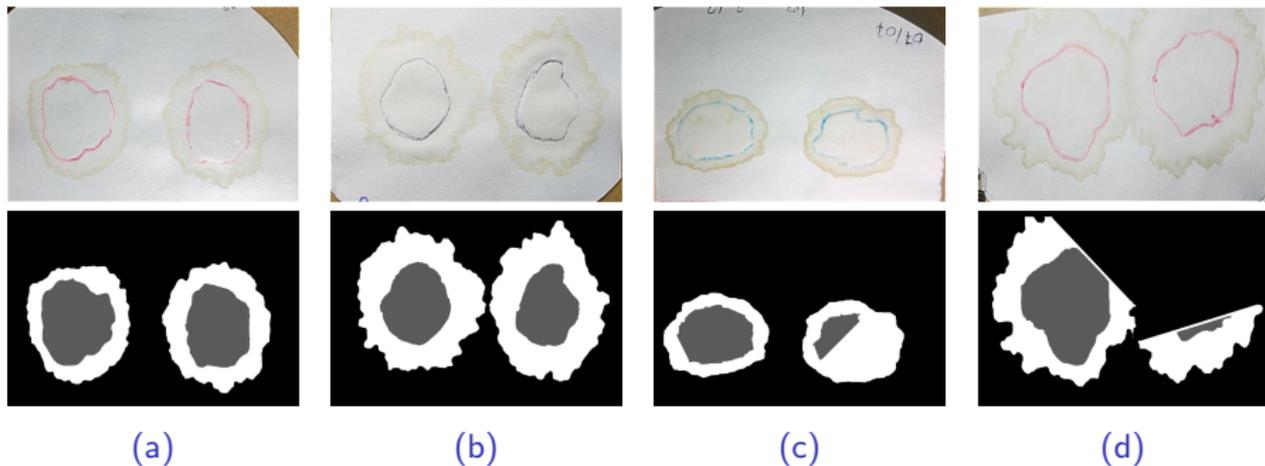
(c)



(d)

● Resultados da segmentação interna

- A maioria das imagens foi segmentada corretamente
- Além da similaridade entre a coloração da marcação e o papel, algumas falhas são causadas pelo resultado da segmentação externa



- A efetividade do método proposto foi avaliada a partir de dois estudos:
 - **Análise da Segmentação**
 - **Análise da CRA**

● Análise da Segmentação

- Análise comparativa visual nas 665 imagens
- O sucesso da segmentação é determinado pela semelhança visual entre a área segmentada e a original

Regiões	Total Amostras	Regiões Segmentadas Corretamente	Regiões Segmentadas Incorretamente	Porcentagem Acertos
externa	1330	1274	56	95.7%
interna	1330	1275	55	95.8%
externa e interna	1330	1241	89	93.3%

Avaliação dos Resultados

Experimentos e Análise dos Resultados

● Análise da CRA

- Apenas a análise da segmentação não é capaz de comprovar a efetividade do método proposto
- Comparação entre a segmentação manual e automática
- 8 imagens analisadas

Imagem	CRA A	CRA B	CRA Média
1	0,285	0,353	0,319
2	0,449	0,413	0,431
3	0,389	0,438	0,414
4	0,458	0,419	0,439
5	0,349	0,389	0,369
6	0,441	0,382	0,412
7	0,460	0,399	0,430
8	0,295	0,268	0,281

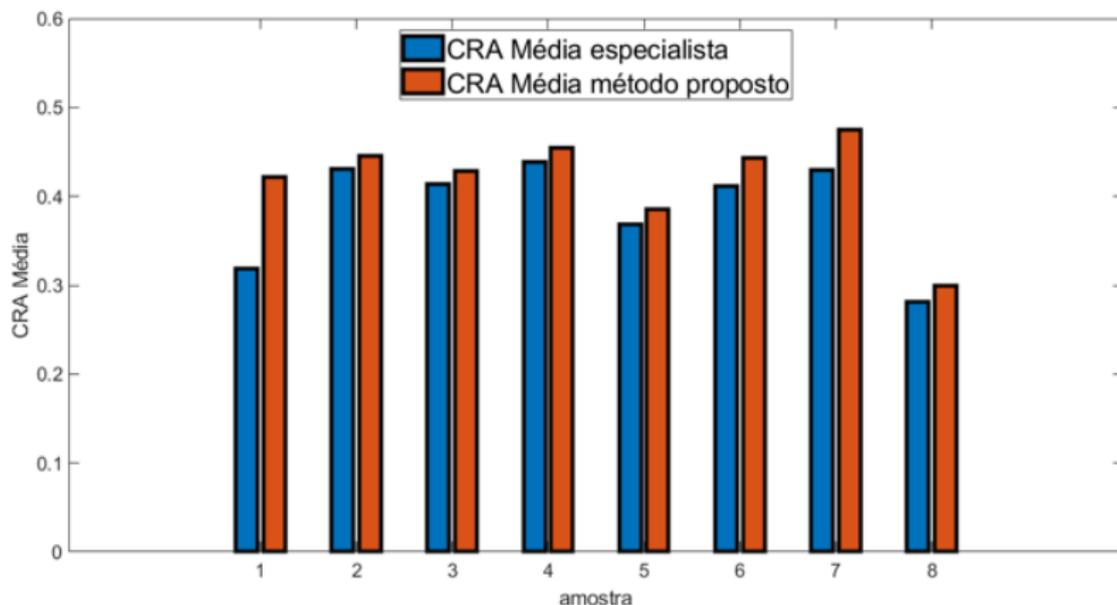
(a) Especialista

Imagem	CRA A	CRA B	CRA Média
1	0,382	0,462	0,422
2	0,473	0,420	0,446
3	0,403	0,453	0,428
4	0,481	0,430	0,455
5	0,365	0,405	0,385
6	0,480	0,406	0,443
7	0,509	0,442	0,475
8	0,314	0,285	0,300

(b) Método Proposto

• Análise da CRA

- Médias entre as CRAs das duas amostras de cada imagem.



- 1 Introdução
- 2 Fundamentação Teórica
- 3 Metodologia
- 4 Experimentos e Análise dos Resultados
- 5 Conclusão**

- O método proposto foi capaz de segmentar as regiões e calcular as CRAs de maneira satisfatória.
- Este trabalho poderá auxiliar os profissionais da área a realizar uma quantificação de CRA mais eficiente, prática e com menor custo.
- Grande dificuldade em reunir dados referentes às CRAs extraídas manualmente. Apenas os dados de uma pequena parte do conjunto puderam ser comparados.

- Realizar um novo experimento onde um número maior de amostras segmentadas por especialistas sejam comparadas com os resultados do método proposto.
- Comparar os resultados obtidos neste trabalho com uma segmentação automática que utilize algum algoritmo de aprendizado de máquina, como redes neurais convolucionais.
- Desenvolver um aplicativo contendo o método proposto para que o profissional responsável pela análise de CRA possa fotografar e quantificar as CRAs das amostras diretamente no local onde ele estiver.

- *Non-Uniform Illumination Correction Applied to Water Retention Capacity Images*, a ser submetido para uma conferência.
- *Automated Assessment of Water Holding Capacity in Digital Images*, submetido à revista científica *Expert Systems with Applications*.

- Este trabalho é apoiado pelo CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) (proc. 302416/2015-3 e 301715/2018-1), FAPEMIG (Fundação de Amparo à Pesquisa do Estado de Minas Gerais) (proc. APQ-03437-15) e CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior)(cód. 001).

-  [Agrointeligenta.](#)
Agrointeligenta, 2016.
-  [Indo-Canadian Swine Breeders.](#)
Boneless pork chop, 2019.
-  [Luana Ribeiro Alves.](#)
Qualidade de carne suína. 1. efeito do gene halotano sobre a decomposição de gordura intramuscular. 2 efeito da suplementação com minerais pré-abate.
[Master's thesis, Faculdade de Medicina Veterinária, Universidade Federal de Uberlândia, Uberlândia, MG, Brasil, 2011.](#)
-  [Marek Kultys.](#)
Visual alpha-beta-gamma: Rudiments of visual design for data explorers.
[Parsons Journal for Information Mapping, 2013.](#)