


SISTEMA DE INSPEÇÃO VISUAL DE OVOS

Objetivo

Desenvolver um módulo de **classificação** de ovos (**normais e com rachaduras**) usando **técnicas clássicas** de visão computacional e **redes neurais convolucionais**.



Aquisição de imagens




626 imagens
304 ovos normais
322 ovos com rachaduras

ABORDAGEM


Clássica

Filtragem e Pré-processamento



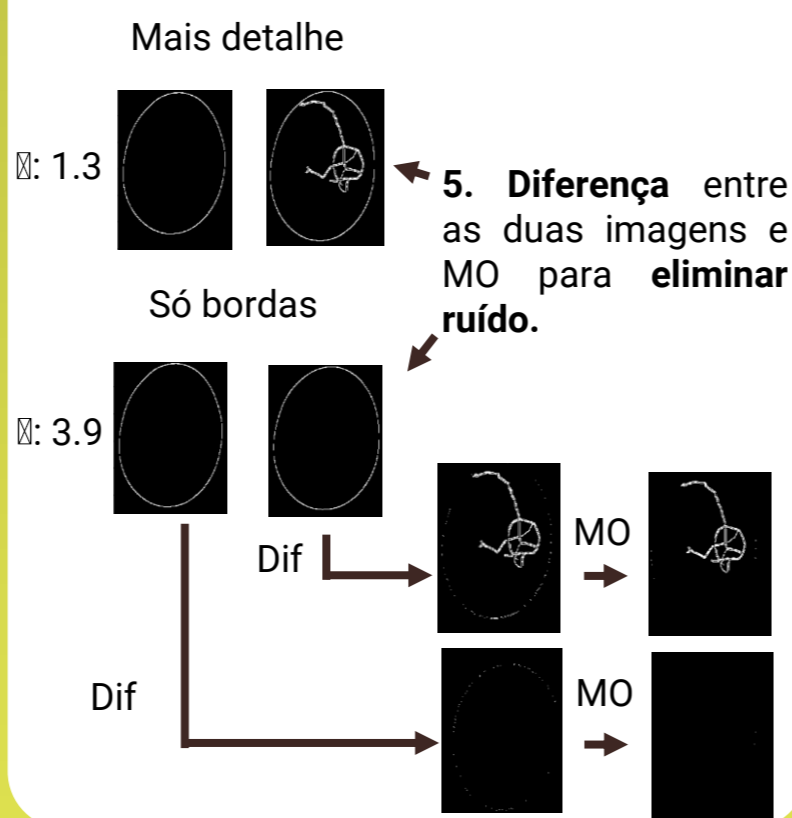
3. **Binarização** (*Threshold*) e operações morfológicas (MO) (abertura e fechamento).

A imagem binária foi aplicada como **máscara** para eliminar possíveis ruídos ao redor do ovo.




Condicionamento

4. **Filtragem** da imagem e aplicar método **Canny** para encontrar bordas empregando dois valores de sigma (σ).



Rotulação

6. Usar **componentes conectados** para encontrar a **área maior** e determinar o **número de componentes conectados (NCC)**.



7. Encontrar **alongamento (AL)** do maior componente.



Interpretação

Foram utilizados classificadores baseados em **aprendizado de máquina**.

As entradas de treinamento foram:

- Área,
- NCC
- AL

Como saída: 0 e 1, (ovos normais e ovos quebrados, respectivamente). Obtendo os resultados mostrados na Tabela 1.


Tabela 1. Resultados classificação

Classifier	Accuracy training set (%)	Accuracy test set (%)	FN	FP
Logistic regression	99	93	0	4
SGD	96	95	1	2
MLP	98	95	0	3
KNN	99	93	0	4

"Deep Learning"

1. "Transfer Learning"

- Adapta apenas as saídas da rede pré-treinada ao novo conjunto de dados




70 % Treinamento, 20 % validação, 10 % teste

(Resnet 34)

Esta abordagem exigiu menos tempo de implementação.

1.1 O treinamento foi realizado por 7 ciclos obtendo uma taxa de erro de 0.053.




2. "Fine Tuning"

- Adapta toda a rede ao novo conjunto de dados

2.1 **Learning rates:** Rastreia o relacionamento da taxa de aprendizado vs perda.

2.2 A rede foi descongelada e treinada por 5 ciclos com uma taxa de aprendizado entre (1e-04, 1e-03).



epoch	train_loss	valid_loss	error_rate	time
0	0.116410	0.278860	0.071429	00:20
1	0.148506	0.125358	0.035714	00:19
2	0.217948	0.126606	0.017857	00:19
3	0.170366	0.035858	0.017857	00:19
4	0.158097	0.001869	0.000000	00:19

Obtendo finalmente uma taxa de erro de **0.000**.
Acurácia: 100 %

RESULTADOS

A partir da técnica clássica foi selecionado o classificador **MLP** para ser comparado.

Matriz de confusão

Normal=0
Rachado=1

Ground truth	Predição	
	0	1
0	TP: 27	FP: 3
1	FN: 0	TN: 26

Clássica (MLP)

Ground truth	Predição	
	0	1
0	TP: 30	FP: 0
1	FN: 0	TN: 26

Deep Learning

Surgiram duas situações

Ovos normais classificados como rachados no abordagem clássica

Gera *Desperdício*

Nenhum ovo quebrado foi classificado como normal

Qualidade no produto

	MLP	DP
Acurácia	0,95	1
Recall	1	1
Precisão	0,9	1
Especificidade	0,89	1
Score F1	0,94	1

Como pode ver, a abordagem com **"Deep Learning"** obtém um melhor desempenho na classificação, uma vez que permite não só *preservar a qualidade do produto*, mas também *não causa desperdício de produto*; dois aspectos fundamentais neste tipo de processo.