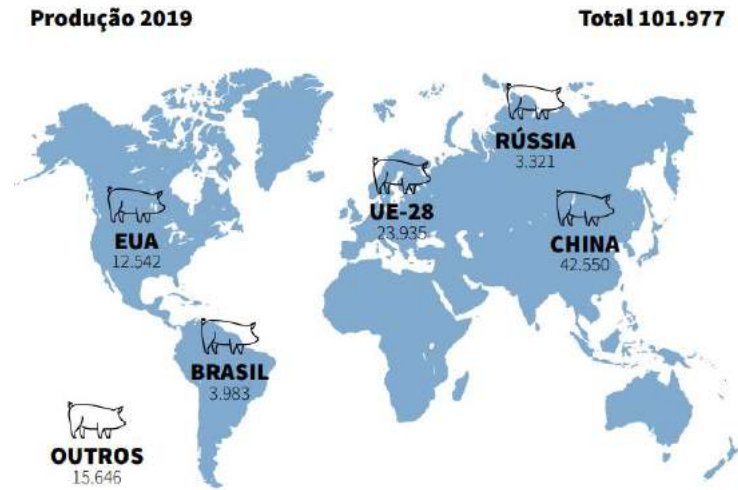


Aplicação de Redes Neurais Convolucionais na Classificação de Amostras de Carne Suína por Meio da Capacidade de Retenção de Água

Trabalho de conclusão de curso
Aluno: Vinícius Clemente de Sousa Reis
Orientador: André Ricardo Backes

Introdução

De acordo com a ABPA em 2019 o Brasil ocupava a 4ª posição mundial na produção de carne suína. (ABPA, 2020)



Fonte: Relatório ABPA 2020. Imagem retirada de (ABPA, 2020)

CRA

Para analisar a qualidade de carne Suínas podemos utilizar várias técnicas, entre elas podemos destacar a capacidade de retenção de água (CRA).

Normalmente, a CRA é estimada medindo o suco liberado após a compressão de amostras de carne. Entretanto, após gerar as marcações no filtro de papel, ainda é necessário a presença de profissional para analisar as amostras, esse trabalho sugere a utilização de redes neurais convolucionais para a segmentação automática das fotos dessas amostras.




Figura 7 – Etapas do método de compressão. Imagem retirada de (ALVES, 2011)

Objetivos

O principal objetivo deste trabalho é estudar e avaliar o desempenho de redes neurais convolucionais na segmentação de amostras de CRA de carne suína.

Objetivos específicos:

- Quantificar o desempenho de redes neurais convolucionais ***UNet***.
- Quantificar o desempenho de redes neurais convolucionais utilizando **diferentes tamanhos de imagens**.
- Quantificar o desempenho de redes neurais convolucionais utilizando **segmentação binária e multi classe**.
- **Concluir** a viabilidade da solução em comparação a outras técnicas.

Metodologia

Para implementar nossa abordagem utilizamos a linguagem Python na versão 3.7.10 e o framework Tensorflow na versão 2.4.0. Para a execução do código utilizamos uma máquina Intel i7 3770, 16GB de memória ram, Placa de video GTX 1650 4gb e um disco rígido de 1 Terabytes.

Unet

Neste trabalho iremos utilizar a arquitetura **Unet**.

Essa rede utiliza etapas de **compressão** e **descompressão**, para a realização da segmentação.

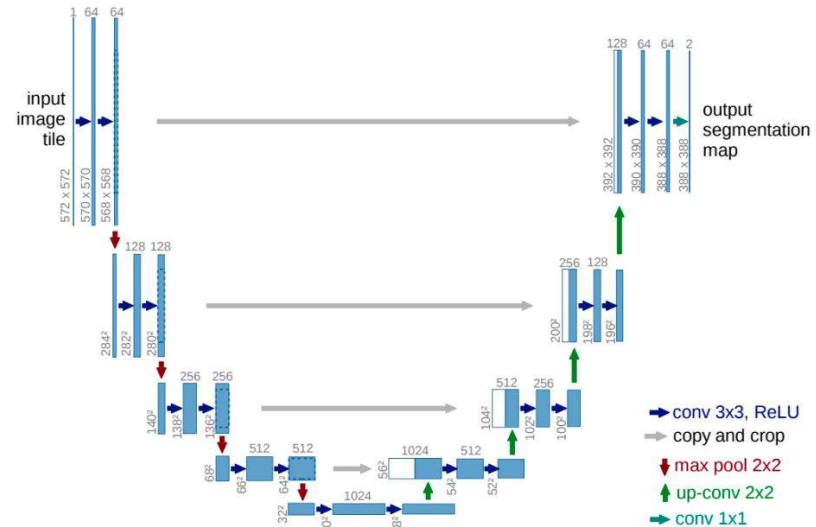


Figura 6 – Arquitetura da rede Unet. Figura retida de (RONNEBERGER; FISCHER; BROX, 2015)




Figura 6 – Arquitetura da rede U-net. Figura retida de (RONNEBERGER; FISCHER; BROX, 2015)

Hiperparâmetros

Na fase de treinamento da rede precisamos fornecer os hiperparâmetros. Esses parâmetros são parâmetros que controlam como a rede vai aprender e normalmente são definidos pelo programador.

- tamanho da imagem: 64 x 64 , 128 x 128 e 256 x 256
- número de épocas: 30
- tamanho do lote: 8 ou 4
- porcentagem de validação: 20%
- tamanho da rede: 64, 128 e 256

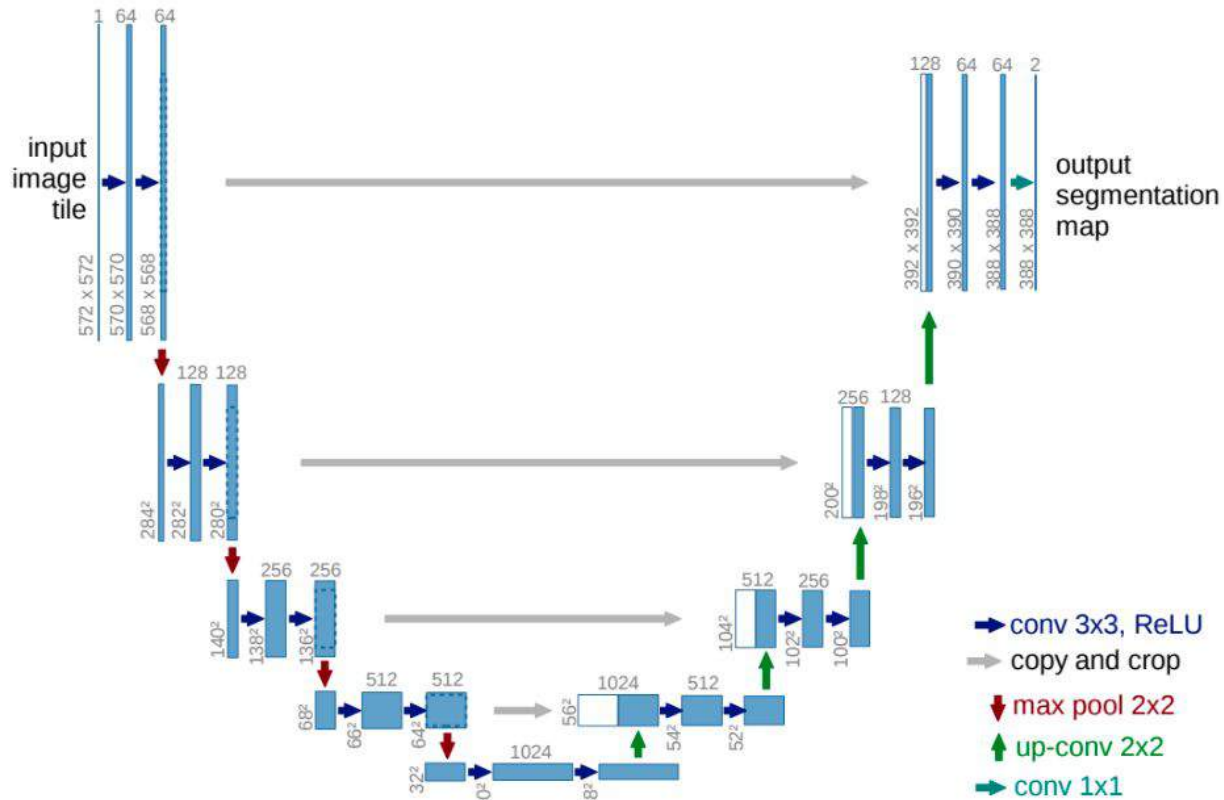


Figura 6 – Arquitetura da rede U-net. Figura retida de (RONNEBERGER; FISCHER; BROX, 2015)

Função de métrica e de ativação:

- função de métrica: *IoU (Intersection-Over-Union)*
- função de ativação: *Sigmoide* ou *Softmax*

$$IoU = \frac{true_positive}{true_positive + false_positive + false_negative}$$


Sigmoide: [0] ou [1]

Softmax: [1,0,0] ou [0,1,0] ou [0,0,1]

Dataset

Utilizamos um conjunto de dados composto por 659 imagens de CRA de tamanho variado. Cada imagem corresponde a um papel de filtro contendo duas amostras de carne do mesmo animal.

- Dataset de **treinamento**: 527 imagens;
- Dataset de **validação**: 132 imagens.




Resultados


- Segmentação binária da região externa:
 - Imagens 64 x 64;
 - Imagens 128 x 128;
 - Imagens 256 x 256;
- Segmentação binária da região interna:
 - Imagens 64 x 64;
 - Imagens 128 x 128;
 - Imagens 256 x 256;
- Segmentação multi classe de imagens:
 - Imagens 64 x 64;
 - Imagens 128 x 128;
 - Imagens 256 x 256;

Treinamento


Todas as redes conseguem evoluir rapidamente durante as primeiras 10 épocas. Porém, após esse período a evolução é mais lenta. Também é possível observar que as redes multi classe possuem uma tendência instável de aprendizagem.



(a) Segmentação binária da região interna.



(b) Segmentação binária da região externa.



(c) Segmentação multi classe.

Figura 10 – Acurácia por épocas obtida pelas redes utilizando imagens 256×256 .

Acurácia de todo o dataset.


- Redes especializadas na região **externa** tiveram mais dificuldade no aprendizado.
- Redes especializadas na região **interna** possuem uma média e mediana parecida com as redes multi classe.
- Redes **multi classes** apresentaram um resultado mais consistente.

Tabela 1 – Acurácia de todo o *dataset*.

Região	Tamanho	Média	Mediana	Mínimo	Máximo
externa	64 × 64	93,30%	94,22%	67,23%	96,97%
externa	128 × 128	95,47%	96,15%	73,81%	97,67%
externa	256 × 256	96,21%	96,76%	71,45%	98,20%
interna	64 × 64	96,32%	96,95%	75,19%	98,61%
interna	128 × 128	97,81%	98,10%	85,17%	99,03%
interna	256 × 256	98,62%	98,90%	85,34%	99,42%
multi classe	64 × 64	96,79%	96,90%	71,00%	98,37%
multi classe	128 × 128	97,54%	97,70%	90,37%	98,58%
multi classe	256 × 256	98,43%	98,51%	95,34%	99,15%

Região Externa


Um dos motivos para isso acontecer é que a **marcação** da região interna é feito **a caneta**, portanto é mais fácil identificar a suas bordas ao contrário da região externa.



(a) Entrada



(b) Resultado gerado



(c) Resultado esperado

Figura 11 – Exemplo da dificuldade em encontrar a região de área externa na rede de segmentação binária da região externa de imagens 256×256 .

Região Interna

Interna:
64-> -1,94%
128-> -1,49%
256-> -1,13%

A rede especializada na região interna apresenta um **overfitting** maior, isto é, o conhecimento aprendido durante o treino não é genérico o suficiente para obter o mesmo desempenho na validação.

Multi classe:
64-> -0,97%
128-> -0,26%
256-> -0,5%

Tabela 2 – Acurácia do *dataset* de treino.

Região	Tamanho	Média	Mediana	Mínimo	Máximo
externa	64 × 64	93,89%	94,56%	73,21%	96,97%
externa	128 × 128	95,99%	96,38%	76,19%	97,67%
externa	256 × 256	96,55%	96,91%	81,98%	98,20%
interna	64 × 64	96,88%	97,10%	93,40%	98,61%
interna	128 × 128	98,88%	98,28%	96,07%	99,03%
interna	256 × 256	98,88%	98,97%	96,74%	99,42%
multi classe	64 × 64	97,88%	97,13%	91,70%	98,37%
multi classe	128 × 128	97,88%	97,75%	92,96%	98,58%
multi classe	256 × 256	98,88%	98,61%	97,16%	99,15%

Tabela 3 – Acurácia do *dataset* de validação.


Região	Tamanho	Média	Mediana	Mínimo	Máximo
externa	64 × 64	90,92%	91,88%	67,23%	94,97%
externa	128 × 128	93,39%	94,18%	73,81%	96,36%
externa	256 × 256	94,83%	95,69%	71,45%	97,46%
interna	64 × 64	93,67%	95,16%	75,19%	98,29%
interna	128 × 128	96,18%	96,79%	85,17%	98,52%
interna	256 × 256	97,88%	97,84%	85,34%	99,14%
multi classe	64 × 64	95,88%	96,16%	71,00%	97,58%
multi classe	128 × 128	97,88%	97,49%	90,37%	98,23%
multi classe	256 × 256	97,88%	98,11%	95,34%	98,66%

Redes Multi Classes

É possível constatar que as redes multi classes tiveram a melhor média e mediana no conjunto de validação.

Tabela 3 – Acurácia do *dataset* de validação.

Região	Tamanho	Média	Mediana	Mínimo	Máximo
externa	64 × 64	90,92%	91,88%	67,23%	94,97%
externa	128 × 128	93,39%	94,18%	73,81%	96,36%
externa	256 × 256	94,83%	95,69%	71,45%	97,46%
interna	64 × 64	93,67%	95,16%	75,19%	98,29%
interna	128 × 128	96,19%	96,79%	85,17%	98,52%
interna	256 × 256	97,39%	97,84%	85,34%	99,14%
multi classe	64 × 64	95,62%	96,16%	71,00%	97,58%
multi classe	128 × 128	97,08%	97,49%	90,37%	98,23%
multi classe	256 × 256	97,92%	98,11%	95,34%	98,66%



Resultados considerando a saída transformada da rede

Para transformar as imagens para seu tamanho original foi utilizada a função *resize*, da biblioteca *OpenCV*, com o parâmetro *interpolation* com o valor *INTER_NEAREST*. Com isso ao transformar o tamanho da imagens não geramos novos tons de cor na imagem.

Tabela 1 – Acurácia de todo o *dataset*.

Região	Tamanho	Média	Mediana	Mínimo	Máximo
externa	64 × 64	93,30%	94,22%	67,23%	96,97%
externa	128 × 128	95,47%	96,15%	73,81%	97,67%
externa	256 × 256	96,21%	96,76%	71,45%	98,20%
interna	64 × 64	96,32%	96,95%	75,19%	98,61%
interna	128 × 128	97,81%	98,16%	85,17%	99,03%
interna	256 × 256	98,62%	98,90%	85,34%	99,42%
multi classe	64 × 64	96,79%	96,99%	71,00%	98,37%
multi classe	128 × 128	97,54%	97,70%	90,37%	98,58%
multi classe	256 × 256	98,43%	98,54%	95,34%	99,15%

Externa:

64 -> 93,30% - 90,63% = 2,67%

128 -> 95,47% - 94,35% = 1,12%

256 -> 96,21% - 95,51% = 0,70%

Interna:

64 -> 96,32% - 95,00% = 1,32%

128 -> 97,81% - 97,25% = 0,56%

256 -> 98,62% - 98,34% = 0,28%

Multi classe:

64 -> 96,79% - 95,61% = 1,18%

128 -> 97,54% - 97,14% = 0,40%

256 -> 98,43% - 98,24% = 0,19%

Tabela 4 – Acurácia de todo o *dataset* utilizando imagens em seu tamanho original.

Região	Tamanho	Média	Mediana	Mínimo	Máximo
externa	64 × 64	90,63%	91,52%	66,82%	94,21%
externa	128 × 128	94,35%	95,02%	73,95%	96,70%
externa	256 × 256	95,81%	96,36%	71,30%	97,78%
interna	64 × 64	95,00%	95,59%	75,02%	96,87%
interna	128 × 128	97,25%	97,57%	84,93%	98,33%
interna	256 × 256	98,34%	98,60%	85,11%	99,03%
multi classe	64 × 64	95,61%	95,76%	70,36%	97,47%
multi classe	128 × 128	97,14%	97,31%	90,17%	98,31%
multi classe	256 × 256	98,24%	98,33%	95,31%	98,99%

Tabela 2 – Acurácia do *dataset* de treino.

Região	Tamanho	Média	Mediana	Mínimo	Máximo
externa	64 × 64	93,89%	94,56%	73,21%	96,97%
externa	128 × 128	95,99%	96,38%	76,19%	97,67%
externa	256 × 256	96,55%	96,91%	81,98%	98,20%
interna	64 × 64	96,98%	97,10%	93,40%	98,61%
interna	128 × 128	98,22%	98,28%	96,07%	99,03%
interna	256 × 256	98,92%	98,97%	96,74%	99,42%
multi classe	64 × 64	97,08%	97,13%	91,70%	98,37%
multi classe	128 × 128	97,66%	97,75%	92,96%	98,58%
multi classe	256 × 256	98,56%	98,61%	97,16%	99,15%

Externa:

64 -> 93,89% - 91,02% = 2,87%

128 -> 95,99% - 94,76% = 1,23%

256 -> 96,55% - 96,12% = 0,43%

Interna:

64 -> 96,98% - 95,58% = 1,40%

128 -> 98,22% - 97,61% = 0,61%

256 -> 98,92% - 98,62% = 0,30%

Multi classe:

64 -> 97,08% - 95,84% = 1,24%

128 -> 97,66% - 97,25% = 0,41%

256 -> 98,56% - 98,36% = 0,20%

Tabela 5 – Acurácia do *dataset* de treino utilizando imagens em seu tamanho original.

Região	Tamanho	Média	Mediana	Mínimo	Máximo
externa	64 × 64	91,02%	91,86%	68,79%	94,21%
externa	128 × 128	94,76%	95,26%	74,53%	96,70%
externa	256 × 256	96,12%	96,53%	80,72%	97,78%
interna	64 × 64	95,58%	95,72%	92,88%	96,87%
interna	128 × 128	97,61%	97,66%	95,78%	98,33%
interna	256 × 256	98,62%	98,66%	96,46%	99,03%
multi classe	64 × 64	95,84%	95,88%	90,68%	97,47%
multi classe	128 × 128	97,25%	97,34%	92,72%	98,31%
multi classe	256 × 256	98,36%	98,40%	97,00%	98,99%

Tabela 3 – Acurácia do *dataset* de validação.

Região	Tamanho	Média	Mediana	Mínimo	Máximo
externa	64 × 64	90,92%	91,88%	67,23%	94,97%
externa	128 × 128	93,39%	94,18%	73,81%	96,36%
externa	256 × 256	94,83%	95,69%	71,45%	97,46%
interna	64 × 64	93,67%	95,16%	75,19%	98,29%
interna	128 × 128	96,19%	96,79%	85,17%	98,52%
interna	256 × 256	97,39%	97,84%	85,34%	99,14%
multi classe	64 × 64	95,62%	96,16%	71,00%	97,58%
multi classe	128 × 128	97,08%	97,49%	90,37%	98,23%
multi classe	256 × 256	97,92%	98,11%	95,34%	98,66%

Externa:

64 -> 90,92% - 89,08% = 1,84%

128 -> 93,39% - 92,73% = 0,66%

256 -> 94,83% - 94,56% = 0,27%

Interna:

64 -> 93,67% - 92,70% = 0,97%

128 -> 96,19% - 95,82% = 0,37%

256 -> 97,39% - 97,21% = 0,18%

Multi classe:

64 -> 95,62% - 94,71% = 0,91%

128 -> 97,08% - 96,73% = 0,35%

256 -> 97,92% - 97,78% = 0,14%

Tabela 6 – Acurácia do *dataset* de validação utilizando imagens em seu tamanho original.

Região	Tamanho	Média	Mediana	Mínimo	Máximo
externa	64 × 64	89,08%	89,95%	66,82%	93,03%
externa	128 × 128	92,73%	93,47%	73,95%	95,57%
externa	256 × 256	94,56%	95,48%	71,30%	97,23%
interna	64 × 64	92,70%	94,21%	75,02%	96,55%
interna	128 × 128	95,82%	96,45%	84,93%	97,91%
interna	256 × 256	97,21%	97,68%	85,11%	98,90%
multi classe	64 × 64	94,71%	95,23%	70,36%	96,54%
multi classe	128 × 128	96,73%	97,16%	90,17%	97,87%
multi classe	256 × 256	97,78%	97,96%	95,31%	98,48%




Figura 12 - Exemplo de resultado. a)Imagem Original b)Resultado esperado c)Segmentação binária da região interna de imagens 64×64 d)Segmentação binária da região interna de imagens 128×128 e)Segmentação binária da região interna de imagens 256×256 f)Segmentação binária da região externa de imagens 64×64 g)Segmentação binária da região externa de imagens 128×128 h)Segmentação binária da região externa de imagens 256×256 i)Segmentação multi classe de imagens de imagens 64×64 j)Segmentação multi classe de imagens de imagens 128×128 k)Segmentação multi classe de imagens 256×256

Conclusão

- Rede multi classes apresentou bons resultados;
 - Média de 97,78% e mediana de 97,96% após transformação para o tamanho original.
- Não foi necessário data augmentation;
- Placa de vídeos 4GB de memória;
- Não é necessário pre-processamento além da redução do tamanho da imagem
- Solução escalável que se beneficia com o aumento do dataset, mas mesmo com um dataset reduzido apresentou bons resultados.

Trabalho futuros

- Treinamento da rede com datasets de amostras de carnes de outros animais.
- Utilização de arquiteturas mais novas como LinkNet e PSPNet.

Referências

ABPA, A. B. de P. A. Produção Brasileira de Carne Suína (Mil Ton). 2020. Disponível em: <<http://abpa-br.org/mercados/>>.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. International Conference on Medical image computing and computer-assisted intervention. [S.l.], 2015. p. 234–241.

ALVES, L. R. Qualidade de carne suína. 1. efeito do gene halotano sobre a deposição de gordura intramuscular. 2. efeito da suplementação com minerais no pré-abate. 2011. Disponível em: <<https://repositorio.ufu.br/handle/123456789/13017>>.

Aplicação de Redes Neurais Convolucionais na Classificação de Amostras de Carne Suína por Meio da Capacidade de Retenção de Água

Trabalho de conclusão de curso
Aluno: Vinícius Clemente de Sousa Reis
Orientador: André Ricardo Backes