



Classificação Automática de Defeitos em Couro Bovino Utilizando Aprendizagem Profunda

Automatic Classification of Bovine Leather Defects Using Deep Learning

Luis Fernando da Rosa*, Thiago França Naves†, Arlete Teresinha Beuren‡

RESUMO

O processo de classificação de defeitos em couro bovino é realizado em curtumes por profissionais humanos, sendo este suscetível a um alto grau de subjetividade. Este artigo apresenta o desenvolvimento de um arquitetura de reconhecimento e classificação de defeitos em couro bovino utilizando Visão Computacional. O sistema utiliza a Rede Neural Convolutacional Resnet50 pré-treinada. A base de imagens possui 10 classes que são utilizadas e reorganizadas gerando uma segunda base de dados com 4 categorias, gerando um total de 18 treinamentos que alteram a estrutura de saída e o *batch size* da rede entre as bases de dados. Os resultados mostram uma acurácia de 74% e um erro de 0.27 na classificação de defeitos em couro bovino, indicando uma abordagem promissora que pode ser utilizada em curtumes e melhorada com a aquisição de mais imagens para a base de dados.

Palavras-chave: Visão Computacional. Aprendizado Profundo. Classificação de imagens. Couro bovino. Resnet50.

ABSTRACT

The process of classification of bovine leather defects is carried out in tanneries by human professionals, which is susceptible to a high degree of subjectivity. This article presents the development of an architecture of recognition and classification of defects in bovine leather using Computer Vision. The system uses the pre-trained Resnet50 Convolutional Neural Network. The image base has 10 classes that are used and reorganized generating a second database with 4 categories, generating a total of 18 trainings that change the output structure and the batch size of the network between the databases. The results show an accuracy of 74% and an error of 0.27 in the classification of bovine leather defects, indicating a promising approach that can be used in tanneries and improved with the acquisition of more images for the database.

Keywords: Computer Vision. Deep Learning. Image classification. Bovine leather. Resnet50.

1 INTRODUÇÃO

O Brasil possui um dos maiores rebanhos bovinos sendo responsável por 20,1% da produção mundial, sendo o couro um dos derivados de maior uso e exportação dentro da cadeia de bovinocultura de corte (XIMENES, 2020). Existem cerca de 700 empresas que trabalham com o couro bovino dentro do processo de tratamento e revenda do mesmo, onde estes curtumes empregam mais de 50 mil trabalhadores diretos movimentando uma quantia de US\$ 3,5 bilhões anualmente (NEHRING; FABRE, 2020). Para ser revendido e utilizado na fabricação

* Coordenação de Ciência de Computação; ✉ luis.fer.rosa@hotmail.com.

† Coordenação de Ciência de Computação; ✉ naves@utfpr.edu.br; <https://orcid.org/0000-0002-3152-1197>.

‡ Coordenação de Ciência de Computação; ✉ arletebeuren@utfpr.edu.br; <https://orcid.org/0000-0001-7565-6184>.

de produtos em diversos setores, como por exemplo o de vestuário, o couro é tratado através de processo químico industrial que o transforma no chamado *wet blue*, nome derivado da aparência azulada e da maleabilidade que facilita sua modelagem e uso.

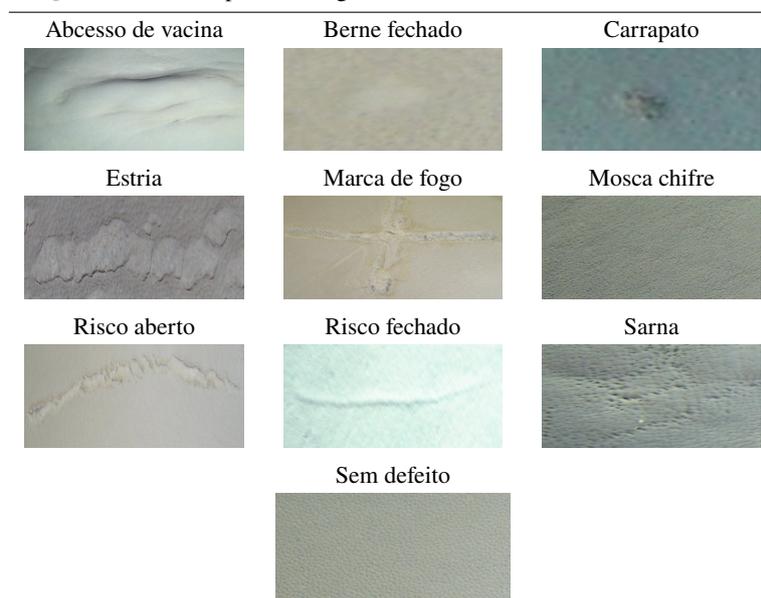
Ao final do processo de geração do couro *wet blue* é feita uma inspeção para identificar defeitos na peça gerada. Esses impactam na qualidade da peça e conseqüentemente no seu preço de venda pelo curtume (LIONG; GAN; HUANG; YUAN et al., 2019). Os defeitos presentes no couro bovino são decorrentes de acidentes ou doenças na pele do animal durante sua vida. Com isso, a identificação e classificação dos defeitos presentes em uma peça de couro torna-se uma atividade complexa, pois a superfície do couro *wet blue* produz pouca diferenciação com as marcas e defeitos devido a sua coloração e textura. Essa identificação geralmente é feita através de uma inspeção visual humana que está sujeita a um alto grau de subjetividade (LIONG; GAN; HUANG; LIU et al., 2019).

Este trabalho propõe utilizar Visão Computacional e modelos de Aprendizagem Profunda para identificar e classificar de forma automática diferentes tipos de defeitos presentes no couro bovino *wet blue*, com objetivo de reduzir a taxa de erro presente nessa tarefa e aumentar o aproveitamento das peças de couro gerada nos curtumes. Assim, será utilizada uma rede neural convolucional (CNN) Resnet50 (TARG; ALMEIDA; LYMAN, 2016) com redefinição de seus hiperparâmetros, junto a uma base de imagens de peças de couro *wet blue*. São classificados até 10 tipos diferentes de defeitos através da manipulação da rede neural e da base de dados, visando uma maior usabilidade para uso da solução dentro do ambiente de produção dos curtumes.

2 BASE DE DADOS COM COURO BOVINO

A base de dados utilizada neste trabalho foi retirada do repositório DTCOURO (VIANA et al., 2007), que consiste de imagens de peças de couro *wet blue* obtidas na região de Mato Grosso do Sul no Brasil. Foi realizado um filtro manual para a remoção de imagens com pouca qualidade para serem utilizadas para classificação. Assim, as imagens restantes foram redimensionadas para um tamanho 224x224, divididas entre 10 classes, sendo nove de defeitos e uma classe sem defeito como mostra o Quadro 1.

Quadro 1 – Exemplos de imagens e classes de defeitos da base de dados.



Fonte: (LIONG; GAN; HUANG; YUAN et al., 2019).



Para conseguir um treinamento de qualidade com o modelo da Resnet50, optou-se por gerar duas base de dados contendo as mesmas imagens. Contudo, a primeira base chamada de Não Categorizada contém as imagens separadas pelas 10 classes de defeitos originais mostradas no Quadro 1. A segunda base de dados chamada de Categorizada, contém as imagens separadas em 4 classes que agrupam as aquelas originais pela natureza do defeito, aumentando a representação das imagens da base. Assim, a base Categorizada possui as classes *Natural*, *Mecânico*, *Esfolamento* e *Sem defeitos*, como mostra a Tabela 1.

Tabela 1 – Classes de defeitos em couro da base de dados.

classe	tipo do defeito
Carrapato	Natural
Berne Fechado	Natural
Estria	Natural
Mosca chifre	Natural
Sarna	Natural
Abcesso de vacina	Mecânico
Marca de fogo	Mecânico
Risco Aberto	Esfolamento
Risco Fechado	Esfolamento
Sem defeito	Sem defeito

Fonte: Autoria própria (2021).

Na base de dados Categorizada a nova classe *Natural* engloba os defeitos de origem natural em relação ao animal, como doenças, ataque de animais e efeitos do tempo. Esses são encontrados em defeitos por Carrapato, Berne Fechado, Estria, Mosca Chifre e Sarna. Em *Mecânico* estão os defeitos normalmente de origem a parti da intervenção humana, tais como, Abcesso de Vacina e Marca de Fogo. Os erros de Risco Aberto e Risco Fechado foram categorizados como *Esfolamento*, uma vez que estes se dão por acidentes ou brigas entre os animais. Por fim, as imagens sem defeitos mantém o mesmo rótulo de classe original na nova base de dados.

3 ARQUITETURA DE CLASSIFICAÇÃO DE COURO BOVINO

Para a identificação dos defeitos em peças de couro bovino foi construída uma arquitetura de classificação de imagens, bem um protocolo de comunicação entre suas partes para automatizar a validação de diferentes configurações de hiperparâmetros da Resnet50 junto a base e dados. A Figura 1 mostra a arquitetura de classificação.

As Funções Base na Figura 1 são responsáveis pelos parâmetros gerais estabelecidos entre a base de dados e o modelo da Resnet50 durante seu treinamento. Os parâmetros definem os diferentes caminhos dentro da base de dados e caminhos para persistência de novos dados, que podem ser gerados a partir do pré-processamento das imagens da base, tal como o redimensionamento. O gerador de caminhos criar um *data frame* com todos os caminhos das imagens da base feitos anteriormente, sendo utilizado em conjunto com o gerador de imagens na próxima etapa da arquitetura. As funções de pré e pós-processamento podem ser facilmente trocadas apenas alterando a parte os parâmetros das Funções Base.

Os Geradores são a segunda etapa da arquitetura, com foco em facilitar a etapa de treinamento. O gerador de imagens carrega em memória as imagens utilizando os caminhos da etapa anterior e faz a aplicação da função de pré-processamento. Esse se comporta como uma lista para a Resnet50 gerando um *batch* (conjunto de dados para

Figura 1 – Arquitetura de classificação de defeitos em imagens de couro bovino.



Fonte: Autoria própria (2021).

uma interação do modelo) de imagens a cada vez que é chamado, economizando memória e sendo personalizável. As chamadas configurações compreendem os parâmetros para a execução dos testes e para persistência dos dados, que são obtidos de forma automática e configuram o modelo.

O modelo compilado obtido nos Geradores é uma função que utiliza as configurações na Resnet50 e retorna a mesma pré-treinada na base de dados Imagenet (FEI-FEI; DENG; LI, 2009). Assim, é possível executar transferência de aprendizado diminuindo drasticamente o tempo de treinamento. No modelo compilado as camadas treinadas são congeladas e apenas as quatro últimas terão seus pesos atualizados utilizando a base de dados de couro bovino deste trabalho.

A Execução dos Testes é a penúltima etapa da arquitetura, feita utilizando o método de *cross validation* (WESTERHUIS et al., 2008). No teste são feitas variações automáticas no tamanho do *batch size* da Resnet50 entre os valores 4, 8, 16, sendo possível explorar o tempo de conversão até o momento de generalização da rede. Para cada teste com um *batch size* específico são gerados diferentes modelos da Resnet50, sendo cada um destes gerado através de uma estrutura de parâmetros de *fining tuning* distintos. Cada modelo tem seu desempenho analisado, aumentando as chances de obter uma classificação com bons resultados e reduzindo a possibilidade de *overfitting* nestes. A Tabela 2 mostra as estruturas de *fining tuning* utilizadas.

Tabela 2 – Estruturas de Fining Tuning.

Estrutura	Base categorizada	Base não categorizada
Estrutura 1	N(128)-D(0.5)-N(64)-D(0.4)-N(4)	N(128)-D(0.5)-N(64)-D(0.4)-N(10)
Estrutura 2	N(256)-D(0.5)-N(64)-D(0.4)-N(4)	N(256)-D(0.5)-N(64)-D(0.4)-N(10)
Estrutura 3	D(0.5)-N(4)	D(0.5)-N(10)

Fonte: Autoria própria (2021).

Ainda na Tabela 2, o valor “N” representa uma camada e sua quantidade de neurônios e o “D” uma camada de *dropout*. Cada estrutura de *fining tuning* é treinada e testada na base categorizada e na base não categorizada. Com isso, a única diferença em uma estrutura em relação a base de dados é a quantidade de neurônios na última camada, uma vez que uma base contém 4 classes de defeitos e a outra 10 classes.

Por fim, a etapa final da arquitetura chamada do Pós Processamento e Persistência, é responsável por gerar *logs* e armazenar de forma estruturada os resultados das métricas de teste de cada um dos modelos da Resnet50 utilizados.



4 EXPERIMENTOS E ANÁLISE DOS RESULTADOS

O ambiente de testes utilizado foi o Google Colab¹ e no total foram 18 modelos da Resnet50 treinados, utilizando as 3 estruturas, os 3 *batch sizes* e as duas bases de dados nas variações entre estes. Os treinamentos duraram 30 épocas utilizando o erro *categorical cross-entropy*, com a taxa de validação a 20% com o *cross validation* com valor de 4. As Tabelas 3 e 4 apresentam os melhores resultados dos melhores modelos de cada uma das bases de dados, divididos pelos *batch sizes* utilizados.

Tabela 3 – Melhores acurácia e erro por batch size da base não categorizada.

Batch size	Acurácia de treino	Erro de treino	Acurácia de teste	Erro de teste
4	0.6417	0.3124	0.5470	0.3922
8	0.5180	0.4485	0.4058	0.5006
16	0.4352	0.5301	0.3624	0.5777

Fonte: Autoria própria (2021).

Tabela 4 – Melhores acurácias e erros por batch size da base categorizada.

Batch size	Acurácia de treino	Erro de treino	Acurácia de teste	Erro de teste
4	0.6340	0.3342	0.5208	0.4688
8	0.6616	0.2945	0.5934	0.4056
16	0.8761	0.1420	0.7473	0.2756

Fonte: Autoria própria (2021).

O melhor modelo geral foi obtido na base Categorizada com a utilização de um *batch* de tamanho 16. Devido ao maior número de imagens por categoria, e as características naturais semelhantes das classes que as compõem, a descrição dos defeitos nesse modelo foi feita com maior precisão. Já o melhor resultado encontrado na base Não Categorizada com uma acurácia de 0.5470 demonstra um aprendizado ineficiente destes modelos. Isso ocorre devido ao número reduzido de imagens na base por cada classe de defeito, pois com 10 classes alguns defeitos como abcesso de vacina ficaram com poucos exemplos, onde os modelos chegaram a acurácia de 0% neste.

O *batch size* afetou os resultados de diferentes maneiras em cada base de dados, sendo os melhores resultados para a Não Categorizada nos menores valores de *batch*, e aqueles da Categorizada nos maiores. A convergência mas rápida vista na Tabela 4 se dá pelo erro mais generalizado calculado a partir dos maiores *batch sizes*, direcionando a atualização dos pesos para o ponto desejável mais rapidamente do que em outros valores.

A melhor acurácia dos testes de 0.7473 foi obtida utilizando a Estrutura 3 da Tabela 2, sendo que nesta mesma base e *batch size* no valor de 16, as Estruturas 1 e 2 também tiveram um bom desempenho, ambas acima dos 0.60. Com isso, a Estrutura 3 se mostra mais propícia para a classificação de defeitos no couro bovino, devido ao seu menor número de neurônios que estão ligados diretamente com o vetor de características, sendo que os valores de saída possuem menos chances de serem confundidos por camadas que os precedem. Além disso, uma quantidade reduzida de classes de defeitos com maior amostragem de dados apresenta um caminho promissor para obter ainda melhores resultados.

¹ Plataforma construída com o apoio do Google Research que disponibiliza gratuitamente o uso de Graphic Process Units (GPUs) <https://colab.research.google.com/>



5 CONCLUSÕES

Este trabalho apresentou uma arquitetura de reconhecimento e classificação de defeitos em peças de couro bovino utilizando Visão Computacional e Aprendizado Profundo. A arquitetura utiliza a rede neural Resnet50 pré-treinada, com um protocolo de comunicação e configurações de etapas para aumentar a capacidade interação com a base de dados e treinamento com validação do modelo.

Nos experimentos, foi utilizada uma base de imagens de couro bovino que foi adaptada para classificar até 10 tipos de defeitos. Os resultados mostram que a arquitetura foi capaz de aprender as características dos defeitos, especialmente na base categorizada. Um dos modelos conseguiu acurácia e erro satisfatórios indicando a possibilidade de futuros testes práticos em curtumes na busca de automatizar o processo de inspeção de defeitos. Como trabalhos futuros espera-se aumentar o tamanho e robustez da base de imagens, além de trabalhar com novos modelos de redes neurais para melhoria da arquitetura desenvolvida.

AGRADECIMENTOS

Ao Laboratório de Aprendizado de Máquina e Imagens Aplicados a Indústria - LAMIA², por toda a orientação e suporte. A Universidade Tecnológica Federal do Paraná e a Fundação Araucária, pela concessão de bolsa de pesquisa.

REFERÊNCIAS

- FEI-FEI, Li; DENG, Jia; LI, Kai. ImageNet: Constructing a large-scale image database. **Journal of vision**, The Association for Research in Vision e Ophthalmology, v. 9, n. 8, p. 1037–1037, 2009.
- LIONG, Sze-Teng; GAN, Y. S.; HUANG, Yen-Chang; YUAN, Chang-Ann et al. **Automatic Defect Segmentation on Leather with Deep Learning**. [S.l.: s.n.], 2019. arXiv: 1903.12139 [cs.CV].
- LIONG, Sze-Teng; GAN, Yee Siang; HUANG, Yen-Chang; LIU, Kun-Hong et al. Integrated neural network and machine vision approach for leather defect classification. **arXiv preprint arXiv:1905.11731**, 2019.
- NEHRING, Cláudio; FABRE, Valkyrie. Modelagem da cadeia produtiva do couro onde a bovinocultura é leiteira. **Revista Brasileira de Tecnologia Agroindustrial**, v. 14, mar. 2020. DOI: 10.3895/rbta.v14n1.10115.
- TARG, Sasha; ALMEIDA, Diogo; LYMAN, Kevin. Resnet in resnet: Generalizing residual architectures. **arXiv preprint arXiv:1603.08029**, 2016.
- VIANA, Roberto et al. SVM with Stochastic Parameter Selection for Bovine Leather Defect Classification. In: MERY, Domingo; RUEDA, Luis (Ed.). **Advances in Image and Video Technology**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. P. 600–612. ISBN 978-3-540-77129-6.
- WESTERHUIS, Johan A et al. Assessment of PLSDA cross validation. **Metabolomics**, Springer, v. 4, n. 1, p. 81–89, 2008.
- XIMENES, Luciano Feijão. Segmento de carne bovina. **Caderno Setorial ETENE**, Banco do Nordeste do Brasil, v. 5, n. 116, 2020.

² <https://www.lamia.sh.utfpr.edu.br/>