



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL RURAL DA AMAZÔNIA
PROGRAMA DE PÓS-GRADUAÇÃO EM PRODUÇÃO ANIMAL NA AMAZÔNIA

ANDRÉ CASCALHO ANDRADE

**REDES NEURAIS CONVOLUCIONAIS APLICADAS A IMAGENS DE
ULTRASSONOGRAFIA DE OVÁRIO PARA IDENTIFICAR A GESTAÇÃO EM
VACAS NELORE**

PARAUPEBAS

2021

ANDRÉ CASCALHO ANDRADE

**REDES NEURAIS CONVOLUCIONAIS APLICADAS A IMAGENS DE
ULTRASSONOGRAFIA DE OVÁRIO PARA IDENTIFICAR A GESTAÇÃO EM
VACAS NELORE**

Dissertação apresentada à Banca Examinadora, como parte das exigências do Programa de Pós-Graduação em Produção Animal na Amazônia da Universidade Federal Rural da Amazônia, Campus de Parauapebas, para obtenção do título de Mestre.
Área de concentração: Tecnologia na produção animal

Orientador: Prof. Dr. João Paulo Pacheco Rodrigues
Coorientadores: Prof. Dr. Lucas Jacomini Abud e Dr. Tadeu Eder da Silva

PARAUAPEBAS

2021

Dados Internacionais de Catalogação na Publicação (CIP)
Bibliotecas da Universidade Federal Rural da Amazônia
Gerada automaticamente mediante os dados fornecidos pelo(a) autor(a)

A553r Andrade, André Cascalho

Redes neurais convolucionais aplicadas a imagens de ultrassonografia de ovário para identificar a gestação em vacas nelore / André Cascalho Andrade. - 2021.

43 f. : il. color.

Dissertação (Mestrado) - Programa de PÓS-GRADUAÇÃO em Produção Animal na AMAZÔNIA (PPGPAA), Campus Universitário de Parauapebas, Universidade Federal Rural Da Amazônia, Parauapebas, 2021.

Orientador: Prof. Dr. João Paulo Pacheco Rodrigues

Coorientador: Prof. Dr. Tadeu Eder da Silva.

1. Reprodução bovina. 2. Visão computacional. 3. Corpo lúteo. 4. Aprendizado profundo. 5. Ultrassonografia de ovário. I. Rodrigues, João Paulo Pacheco , orient. II. Título

CDD 006.32

ANDRÉ CASCALHO ANDRADE

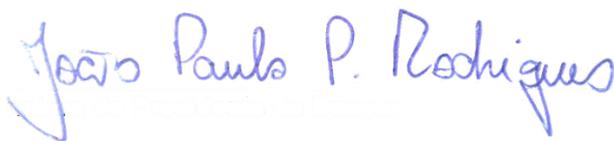
**REDES NEURAIIS CONVOLUCIONAIS APLICADAS A IMAGENS DE
ULTRASSONOGRRAFIA DE OVÁRIO PARA IDENTIFICAR A GESTAÇÃO EM
VACAS NELORE**

Dissertação apresentada à Banca Examinadora, como parte das exigências do Programa de Pós-graduação em Produção Animal na Amazônia da Universidade Federal Rural da Amazônia, como requisito para obtenção do título de Mestre em Produção Animal na Amazônia. Área de concentração: Tecnologia na Produção Animal

Orientador: Prof. Dr. João Paulo Pacheco Rodrigues
Coorientadores: Prof. Dr. Lucas Jacomini Abud e Dr. Tadeu Eder da Silva

Aprovada em 25 de agosto de 2021.

BANCA EXAMINADORA



Prof. Dr. João Paulo Pacheco Rodrigues - Orientador
Universidade Federal do Sul e Sudeste do Pará (Unifesspa)



Prof. Dr. Cleidson Manoel Gomes da Silva - 1º Examinador
Universidade Federal do Sul e Sudeste do Pará (Unifesspa)



Prof. Dr. Adam Dreyton Ferreira dos Santos - 2º Examinador
Universidade Federal do Sul e Sudeste do Pará (Unifesspa)



Prof. Dr. Diego de Azevedo Gomes - 3º Examinador
Universidade Federal do Sul e Sudeste do Pará (Unifesspa)

AGRADECIMENTOS

Inicialmente, **a Deus**, que mais uma vez me fortaleceu para conquistar esse desafio. Viver já é uma vitória digna de toda gratidão.

Aos meus pais, **Edison Andrade e Edna Cascalho**, pelo amor incondicional e exemplo de vida. Obrigado por me amar, me capacitar e me mostrar os caminhos da vida.

A minha amada esposa, **Jhulie Kessia**, pelo amor e companheirismo. Graças a você, construir nossa história, nas diferenças e nas boas ideias, faz minha vida ter sabor e me torno uma pessoa melhor.

Ao meu orientador, **Prof. Dr. João Paulo**, pela humildade intelectual ao estar aberto a sugestões e questionamentos e pela generosidade mental ao dividir comigo aquilo que sabe. Tornando-se para mim referência profissional e pessoal a ser seguida.

Aos meus coorientadores, **Dr. Tadeu da Silva**, pelas orientações e direcionamentos, grandiosamente significativos, na avaliação e escrita deste trabalho. E ao **Prof Dr. Lucas Abud**, pelo acompanhamento e apoio na execução do projeto.

Aos **Docentes e Colaboradores do Programa de Pós-Graduação em Produção Animal na Amazônia (PPGPAA)**, pela oportunidade de aprendizado.

Aos **amigos do PPGPAA** pela experiência compartilhada e auxílio em todas as tratativas relacionados ao Mestrado. Obrigado Hatus, Harry, Gilmara, James Luan, Vínicus, Gabriela, Alison, Dayana.

A equipe do **Laboratório de Computação Científica da Unifesspa**, pelo paciência e zelo nas avaliações dos dados. Em especial, aos colaboradores Luan e Victor.

A **Banca examinadora na etapa de qualificação e defesa** pelas relevantes contribuições para edição deste trabalho. Em especial ao Prof. Dr. Cleidison, Prof. Dr. Luís Rennan, Prof. Dr. Luis Gustavo, Prof Dr. Adam e Prof. Dr. Diego.

Ao **Prof. Dr. Eduardo Salgueiro**, pelo apoio e incentivo na realização desta Pós-Graduação.

Ao **Grupo Quagliato** pelo apoio na realização desta pesquisa. Em especial aos colaboradores Juliano, Lourenço e Hastaches, e também ao Beto Quagliato.

Aos alunos do **Grupo de Estudos em Bovinocultura (BovIETU) da Unifesspa** pelo auxílio e acompanhamento na coleta dos dados.

Toda essa rede de apoio me faz entender que: **“Se eu enxerguei mais longe, foi porque me apoiei sobre os ombros de gigantes (Isaac Newton, 1676) ”**. Este trabalho é fundamentalmente fruto de um empreendimento coletivo, com fatores dependentes do meu esforço e outros indiferentes ao meu mérito, apoiado em uma pirâmide de familiares, colaboradores, amigos e cientistas. Obrigado a todos!

RESUMO

A análise visual das estruturas ovarianas por ultrassom em vacas é uma relevante ferramenta de suporte para melhorar o desempenho reprodutivo em rebanhos. No entanto, pela análise visual humana a subjetividade é um fator limitante e as tecnologias de visão computacional são uma boa maneira de superá-la. Objetivamos avaliar o uso de redes neurais convolucionais (RNCs) para identificar a gestação em vacas por meio de imagens de ultrassom ovariano obtidas 30 dias após a inseminação artificial. Foi utilizado um conjunto de dados com 510 imagens individuais de ovários funcionais de 238 vacas Nelore gestantes e 272 não gestantes. Todas as imagens foram coletadas em uma mesma fazenda comercial. Para avaliar a dependência do desempenho das RNCs na qualidade da imagem, as imagens foram classificadas por dois veterinários, independentes, com experiência significativa em avaliação de ultrassom como: boas, regulares e ruins para a identificação visual de estruturas ovarianas. Cinco arquiteturas de RNCs foram avaliadas: ResNet50, ResNeXt50, InceptionResNetV2, DenseNet-121 e SimpleCNN. Todas as RNCs foram avaliadas usando o conjunto de dados completo (ALL; n = 510) e um subconjunto de imagens boas e regulares (GR; n = 462). Para cada combinação de arquitetura e conjunto de dados, dez avaliações foram realizadas. Em cada rodada de análise, os conjuntos de dados foram divididos aleatoriamente em 70% para treinamento e 30% para teste de acordo com o método de *holdout*. Foi utilizado um método baseado em regularização por *dropout*, *data augmentation* e uma taxa de aprendizagem dinâmica durante a fase de treinamento. O desempenho do modelo foi avaliado pela acurácia, precisão, sensibilidade e especificidade, que variou de 0.648 a 0.788, 0.344 a 0.800, 0.283 a 0.754 e 0.112 a 0.822, respectivamente. Os modelos ResNet50, DenseNet-121 e SimpleCNN tiveram melhor desempenho ao usar o conjunto de dados GR. A arquitetura DenseNet121 obteve melhor desempenho com base na acurácia, sensibilidade, especificidade e com menor variação entre os conjuntos de dados. A InceptionResNetV2 possui arquitetura mais precisa usando ALL, porém com desempenho inferior para subconjunto GR. Concluimos que as RNCs são capazes de identificar a presença de gestação de vacas a partir de imagens ovarianas coletadas 30 dias após a inseminação artificial. O efeito da qualidade da imagem no desempenho depende da arquitetura da RNCs.

Palavras-chave: Reprodução bovina. Visão computacional. Corpo lúteo. Aprendizado Profundo. Ultrassonografia de ovário.

ABSTRACT

Visual analysis of ovarian structures by ultrasound in cows are a relevant support tool for improving reproductive performance in livestock. However, by human visual analysis the subjectiveness is a limiting factor and computer vision technologies are a good way to overcome it. We aimed to evaluate the use of convolutional neural networks (CNNs) for identifying pregnancy in cows using ovarian ultrasound images obtained at 30 days after artificial insemination. A dataset with 510 images from individual functional ovaries of 238 pregnant and 272 non-pregnant Nellore cows was used. All images were collected in a same commercial farm. To evaluate dependency of CNNs performance on image quality, the images were classified by two independent veterinarians with significant experience in ultrasound evaluation as: good, regular, and bad for visual identification of ovarian structures. Five CNNs architectures were evaluated: ResNet50, ResNeXt50, InceptionResNetV2, DenseNet-121 and SimpleCNN. All CNNs were evaluated both using the complete dataset (ALL; n=510) and a subset of good and regular images (GR; n=462). For each architecture and dataset combination, ten evaluations were performed. In each run, the data sets were randomly divided into 70% for training and 30% for testing according to holdout method. A regularization-based method via dropout, data augmentation and a dynamic learning rate during the training phase was used. The model's performance was evaluated by accuracy, precision, sensitivity, and specificity, which ranged from 0.648 to 0.788, 0.344 to 0.800, 0.283 to 0.754, and 0.112 to 0.822, respectively. The models ResNet50, DenseNet-121 e SimpleCNN performed better when using the GR dataset. The DenseNet121 architecture performed better based on accuracy, sensitivity, specificity and with lower variation among datasets. The InceptionResNetV2 the more precise architecture using ALL, however with lower performance for GR dataset. We concluded that CNNs are capable to identify cow's pregnancy status in ovarian images collected at 30 days after artificial insemination. The effect of image quality on performance is dependent on CNNs architecture.

Keywords: Bovine reproduction. Computer vision. Corpus luteum. Deep Learning. Ovarian ultrasonography.

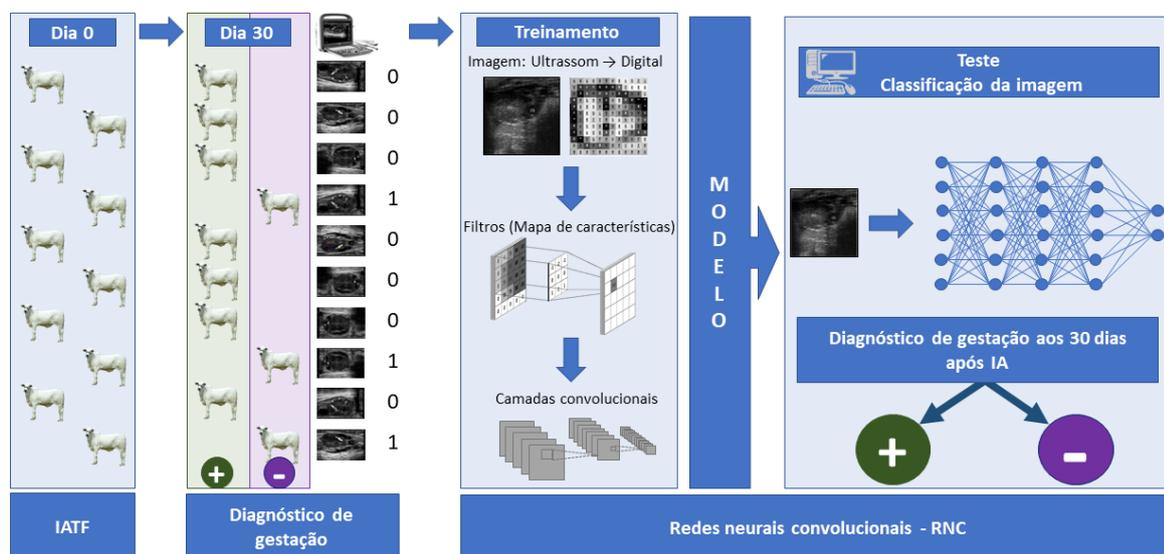
RESUMO INTERPRETATIVO E RESUMO GRÁFICO

TECNOLOGIAS DE COMPUTAÇÃO APLICADAS EM IMAGENS DE ULTRASSONOGRAFIA DE OVÁRIO PARA IDENTIFICAR A GESTAÇÃO EM VACAS NELORE

Elaborado por **André Cascalho Andrade** e orientado por **João Paulo Pacheco Rodrigues**, **Lucas Jacomini Abud** e **Tadeu Eder da Silva**.

No manejo reprodutivo das fêmeas bovinas, a imagem gerada pela ultrassonografia é uma importante ferramenta que auxilia no diagnóstico gestacional e na seleção de animais aptos à reprodução. No entanto, a análise dessas imagens depende da experiência profissional do avaliador. Nesse contexto, tecnologias computacionais têm sido avaliadas para a interpretação de imagens na ultrassonografia humana. Entretanto, ainda há poucas informações científicas aplicadas à ciência animal. Para avaliar o uso desses recursos, utilizou-se 510 imagens de ovários coletadas de vacas nelore aos 30 dias após a inseminação artificial. O processamento computacional das informações ultrassonográficas foi avaliado buscando identificar vacas gestantes e não gestantes. Para isso, 05 diferentes redes neurais convolucionais foram utilizadas. Na fase de treinamento essas redes aplicam filtros sobre a imagem para obter uma série de mapas com características que revelam padrões específicos da imagem. Posteriormente, o modelo treinado avalia imagens novas que são utilizadas para testar seu desempenho. Os resultados demonstraram que um dos modelos (DenseNet121) obteve 78,8% de acerto ao classificar as imagens. Observou-se que as redes neurais convolucionais apresentaram potencial de indicar a gestação por meio das imagens de ovário aos 30 dias após a inseminação artificial.

Figura 1. Fluxograma das etapas de avaliação do uso das redes neurais convolucionais para identificação de vacas gestantes e não gestantes por meio de imagens de ultrassonografia de ovário.



Fonte: Os Autores (2021)

LISTA DE ILUSTRAÇÕES

Figura 1. Fluxograma das etapas de avaliação do uso das redes neurais convolucionais para identificação de fêmeas gestantes e não gestantes por meio de imagens de ultrassonografia de ovário	04
Figura 2. Representação dos princípios físicos básicos para formação da imagem ultrassonográfica	12
Figura 3. Representação da estrutura de uma RNC	18
Figure 4. Images processing flowchart	30
Figure 5. Ultrasound image of bovine ovary showing compact corpus luteum (1) and follicle (2), before (A) and after (B) normalization.....	31

LISTA DE TABELAS

Table 1. Classification by pregnancy and subsets with different image quality of functional ovaries in Nellore cows at 30 days after timed artificial insemination.....	30
Table 2. Classification convolutional neural networks tested for pregnancy detection using ultrasound images of functional ovaries in Nellore cows at 30 days after artificial insemination	31
Table 3. Performance of different convolutional neural networks architectures for classifying ultrasound images of the functional ovary in cows at 30 days after artificial insemination.....	32

LISTA DE SIGLAS E ABREVIATURAS

RNCs - Redes neurais convolucionais

IA - Inseminação artificial

IATF - Inseminação artificial em tempo fixo

CL - Corpo lúteo

CNNs - Convolutional neural networks

RGB – Sistem de cores *red*, *green* e *blue*

US - Ultrassonografia

SUMÁRIO

1 CONTEXTUALIZAÇÃO	9
1.1 Revisão de literatura	11
1.1.1 Princípios físicos da formação de imagem ultrassonográfica.....	11
1.1.2 Ultrassonografia aplicada ao diagnóstico gestacional de bovinos	13
1.1.3 Atributos de imagens relacionados à avaliação ovariana.....	14
1.1.4 Análise computacional.....	16
1.1.5 <i>Deep learning</i> e redes neurais convolucionais	17
REFERÊNCIAS	21
2 IDENTIFYING PREGNANCY IN COWS USING OVARIAN ULTRASOUND IMAGES AND CONVOLUTIONAL NEURAL NETWORKS – A PROOF OF CONCEPT	27
2.1 Introduction	28
2.2 Material and methods	29
2.3 Results	32
2.4 Discusion	32
2.5 Conclusion	36
References	36

1 CONTEXTUALIZAÇÃO

A ultrassonografia (US) fornece um relevante suporte ao manejo reprodutivo de bovinos, aumentando a precisão na seleção de animais aptos a reprodução além de auxiliar o uso de biotecnologias. O diagnóstico de gestação aos 30 dias após a inseminação artificial em tempo fixo (IATF) é uma prática comum nas fazendas brasileiras. Normalmente, esse exame baseia-se somente na resposta classificatória quanto a gestação, sendo esta confirmada ou não (Kelley et al., 2017). No entanto, essa avaliação, ainda que de alta exatidão, é baseada em boa parte na subjetividade da análise humana, sendo esta dependente da experiência profissional do avaliador.

Para contornar a subjetividade, o uso de tecnologias computacionais que deêm suporte a interpretação de imagens estão em constante desenvolvimento em diversas áreas do conhecimento (Nebauer, 1998; Ting et al., 2019). Existem várias formas de se processar e avaliar imagens por computação, como a equalização em histograma, distribuições RGB e filtros convolucionais (Frey e Perciano, 2013). Além desses, diferentes métodos de aprendizado de máquina como floresta aleatória, regressão logística e análise linear discriminante são aprimorados constantemente (James et al., 2017). No entanto, as redes neurais convolucionais (RNCs) destacam-se pela capacidade de reconhecimento de objetos em análises de imagens, sendo esta metodologia atualizada continuamente (Ramasubramanian e Singh, 2017). Essa tecnologia possui menor dependência de *feature engineering*, e assim conseguem explorar características específicas que em outras técnicas de *machine learning* não é possível. Além disso, é possível aproveitar redes previamente treinadas, por *transfer learning*, devido à convolução como grande diferencial em relação a outras redes neurais artificiais.

Assim, em um contexto de alta representatividade de fazendas de cria para a atividade pecuária, a avaliação do uso de RNCs, com imagens coletadas em condições de campo, pode permitir o desenvolvimento de modelos preditivos computacionais aplicáveis à reprodução. Com isso, torna-se possível gerar ferramentas de suporte à tomada de decisão por profissionais envolvidos no diagnóstico de gestação de fêmeas bovinas, reduzindo a subjetividade e proporcionando maior acurácia aos exames realizados. Diante do potencial uso de aprendizado de máquina para a avaliação de imagens de ultrassonografia e a ampla utilização desses equipamentos por profissionais de campo, esse estudo apresenta-se como uma ponte de conexão entre o desenvolvimento tecnológico e as demandas da pecuária. Sendo uma integração entre

demandas regionais e internacionais para o desenvolvimento do estado da arte tanto da reprodução de bovinos quanto da zootecnia de precisão.

Apesar dos expressivos avanços no uso do *deep learning* em avaliações de imagens médicas, a literatura demonstra uma lacuna em estudos aplicados à ciência animal. Precisamente, sobre a ultrassonografia reprodutiva bovina até o presente momento sabe-se de apenas um estudo que avaliou a capacidade de redes neurais artificiais em identificar o estágio de desenvolvimento do corpo lúteo (Górna et al., 2017). Outros estudos, principalmente em humanos, demonstram a capacidade das redes neurais convolucionais em classificar planos padronizados na ultrassonografia materno-fetal com desempenho equivalente a profissionais técnicos que realizam a tarefa diariamente (Burgos-Artizzu et al., 2020).

Logo, hipotetiza-se que o uso de redes neurais convolucionais aplicadas às imagens de ultrassonografia de ovário tem potencial de diferenciar animais gestantes e não gestantes. Dessa forma, objetivou-se:

- (1) Obter imagens de ultrassom aos 30 dias após a IATF coletadas em condições de campo;
- (2) Mensurar a acurácia, precisão, sensibilidade e especificidade de diferentes arquiteturas de RNCs na identificação de vacas gestantes e não gestantes;
- (3) Verificar o desempenho das arquiteturas de RNCs sob diferentes níveis de qualidade das imagens.

1.1 Revisão de literatura

Esta revisão aborda aspectos relacionados aos princípios físicos da formação de imagem ultrassonográfica, bem como sua aplicação no diagnóstico gestacional de bovinos e na avaliação ovarina, destacando os atributos de imagens de corpo lúteo e folículos. Relata também os conceitos relacionados ao *deep learning*, os parâmetros das redes neurais convolucionais e sua aplicação em trabalhos com imagens de US. Ademais, no próximo capítulo apresentamos o artigo científico proposto para publicação.

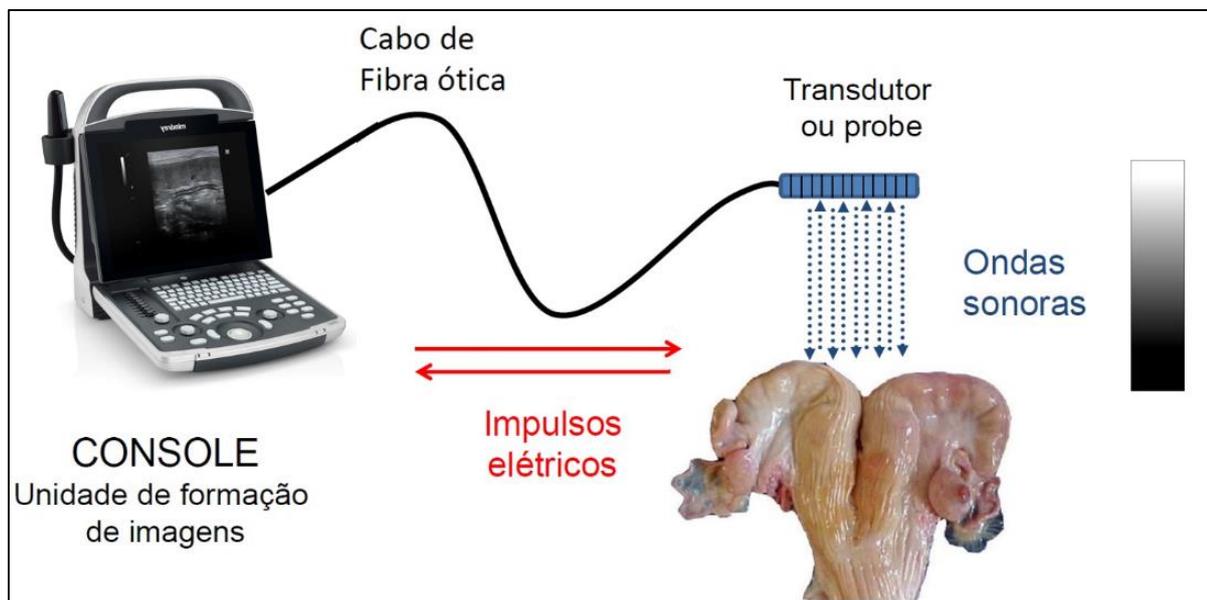
1.1.1 Princípios físicos da formação de imagem ultrassonográfica

O uso da ultrassonografia na reprodução de bovinos é uma prática consolidada, sendo aplicada tanto em fins científicos quanto rotineiramente no manejo reprodutivo de fazendas. É um método de avaliação ginecológica que permite a aquisição de imagens em tempo real, além de ser versátil e não invasivo, possibilita diferenciar tecidos e órgãos por meio de informações recebidas da arquitetura interna dessas estruturas. A utilização do equipamento de US, demanda do avaliador conhecimentos sobre a correta caracterização anatômica e morfológica do trato reprodutivo, para a obtenção e interpretação adequada das imagens. Outra parte importante, baseia-se na compreensão dos eventos físicos que ocorrem desde a produção dos feixes de ultrassons, suas interações com os tecidos e processamento dos ecos até a formação final da imagem. A otimização destes eventos tem valor fundamental tanto no manuseio do equipamento quanto na percepção de informações relevantes nas imagens.

A utilização do ultrassom para fins diagnósticos é uma interessante demonstração da aplicação dos princípios da física. Os sons emitidos pelo transdutor são ondas de energia mecânica que passam nos tecidos orgânicos com velocidade de propagação que pode variar de acordo com a composição e resistência acústica de cada estrutura (Rantanen e Ewing, 1981). Após interagirem com os tecidos (Pierson et al., 1988), os US refletidos retornam ao transdutor e são a base para a formação da imagem que representa um plano de corte da morfologia dos tecidos explorados (Chaffaux et al., 1988). No processamento dos sinais elétricos, estes são convertidos na tela do aparelho em um conjunto de pontos de brilho, com diferentes intensidades. No Modo B, a intensidade dos ecos é apresentada sob forma de pontos de diferentes tonalidades de cinza (Fish, 1990) que podem ser de 256 níveis e tem como limites o branco (intensidade máxima) e o preto (ausência de intensidade) (Feeney et al., 1991). A distância entre o transdutor e as interfaces acústicas é representada num eixo vertical, já o eixo horizontal representa o conjunto de feixes de US emitidos, obtendo-se assim uma imagem

bidimensional, correspondente a cortes tomográficos das estruturas avaliadas, conforme figura 3.

Figura 2. Representação dos princípios físicos básicos para formação da imagem ultrassonográfica



Fonte: Adaptado de Fernandes, C. A. C. (2021)

Os tecidos orgânicos oferecem diferentes resistências à propagação dos US, assim a impedância acústica é proporcional à densidade desses tecidos. São as diferenças de impedância acústica entre dois meios adjacentes que determinam a interface acústica, bem como os graus de intensidade da transmissão e da reflexão dos US (Rantanem e Ewing, 1981). Em tecidos ovarianos há pequenas diferenças acústicas, o que permite o retorno de ecos de intensidade variável, constituindo estas interfaces boas fontes de informação. Já a resolução acústica constitui-se na capacidade do US em diferenciar duas interfaces situadas próximas uma da outra. Quanto maior o poder de resolução do equipamento, melhor a qualidade da imagem (Moretti, 1982). Na resolução axial à diferenciação corresponde a duas interfaces dispostas no mesmo eixo de propagação dos US. Já a resolução lateral diferencia duas interfaces acústicas dispostas de forma paralela ao eixo de propagação (Nyland et al., 1995).

Os tecidos são constituídos por múltiplas interfaces acústicas e a capacidade de refletirem em maior ou menor intensidade os US denominam-se ecogenicidade. Dessa forma podem ser designados como tecidos hipoeicoico, quando a intensidade dos ecos é menor que a dos tecidos adjacentes; hipereicoicos quando maior e isoecoico com igual intensidade (Cartee et al., 1993), ou mesmo anecoico quando não há reflexão dos ecos. Uma vez que os pontos de brilho representam a ecogenicidade e o posicionamento relativo das interfaces acústicas, torna-se possível a avaliação das características dos tecidos explorados como tamanho, conformação,

posição e a ecotextura (Nyland et al., 1995). Enquanto as três primeiras podem ser avaliadas através da mensuração e do contorno dos limites dos tecidos, a avaliação da ecotextura é de natureza subjetiva. A sua avaliação depende da apreciação da homogeneidade, granulação ou irregularidade das interfaces acústicas, ou seja, do tamanho, espaçamento e regularidade dos pontos de brilho.

1.1.2 Ultrassonografia aplicada ao diagnóstico gestacional de bovinos

Para uma integração bem-sucedida em um sistema de manejo reprodutivo, um teste de diagnóstico de gestação precoce ideal dever ser: (1) sensível ao identificar corretamente fêmeas gestantes, (2) específico ao identificar corretamente fêmeas não gestantes, (3) baixo custo, (4) simples de conduta em condições de campo e (5) capaz de determinar o estado de gestação no momento em que o teste é realizado. Em bovinos, a US como método de diagnóstico gestacional baseia-se na localização do conceito-feto, na constatação de membranas e líquidos fetais e na identificação do CL (Jainudeen; Hafez, 2004). No entanto a acurácia ainda depende da experiência do técnico que é consistentemente maior a partir do 30º dia de gestação (Beal; Perry; Corah, 1992).

Na US uterina, antes do 28º dia de gestação pode não haver líquido suficiente para confirmar a gestação. Assim a visualização do embrião no líquido amniótico pode ser realizado entre 28º dia e 30º dia da gestação, pois o embrião pode ficar oculto durante o exame pelas dobras endometriais (Ball; Peters, 2004). Quando a US uterina foi realizada entre 21º e 25º dia pós-reprodução a sensibilidade e especificidade foram de 44,8% e 82,3%, respectivamente, mas aumentou para 97,7% e 87,7%, respectivamente, quando realizado entre 26º e 33º dia pós IA (Pieterse et al., 1990; Romano et al, 2006).

Em outro estudo, a US uterina no diagnóstico precoce de gestação, em vacas (24º-30º dia) e novilhas (21º-27º) pós-inseminação, demonstrou que nas vacas a sensibilidade do método aumentou gradual e significativamente do 24º dia (74,5%) ao 29º dia (100%). No mesmo intervalo, a especificidade aumentou de 86,9% para 97,4%, respectivamente. Em novilhas, aos 21 dias pós inseminação os valores para sensibilidade e especificidade, respectivamente, foram de 50,0% e 87,5%, passando a valores iguais a 100,0% e 96,7% no 26º dia. A sensibilidade foi significativamente maior em novilhas (96,8%) do que em vacas (89,2%) entre o 24º-27º dia pós-inseminação, sendo a máxima sensibilidade, assim como, o máximo valor preditivo

negativo obtidos três dias mais cedo nas novilhas (26° dia) do que nas vacas (29° dia) (Romano et al, 2006).

O diagnóstico impreciso de não gestante (falsos negativos) pode aumentar consequentemente a taxa de mortalidade embrionária iatrogênica quando a prostaglandina $F_{2\alpha}$ ou um de seus análogos é administrada para sincronizar a ovulação em manejo subsequente (Reese et al., 2020). Como a intervenção de manejo geralmente é implementada para animais não gestantes, é fundamental que um teste de gestação seja altamente específico e identifique com precisão as fêmeas não gestantes (Speckhart et al., 2018). Embora o diagnóstico impreciso de gestantes (falsos positivos) seja indesejável, suas consequências são menos graves em comparação com o diagnóstico impreciso de não gestação (Pohler et al., 2020). No entanto, uma alta taxa de resultados falsos positivos diminui a utilidade e o custo-benefício de um teste de gestação precoce ao diagnosticar incorretamente os animais como gestantes, deixando-os de retornar ao serviço de concepção e potencialmente aumentando o intervalo entre partos.

Aos 30 dias de gestação, as estruturas ovarianas são úteis e auxiliares na realização do diagnóstico de gestação. Pode acelerar o exame ao saber se um corpo lúteo (CL) está presente e, em caso afirmativo, de que lado pode estar o embrião. Uma gestação com o CL contralateral ao embrião ou feto pode apresentar risco para perda gestacional, assim como um CL pequeno ou de baixa qualidade pode indicar baixos níveis de progesterona que pode afetar a gestação. O diagnóstico precoce de vacas não gestantes é útil para a retomada de manejo nesses animais, no entanto vacas diagnosticadas gestantes antes dos 60 dias devem ser verificadas novamente após a placentação ser concluída, devido ao seu maior risco nos últimos tempos de morte embrionária e fetal precoce.

1.1.3 Atributos de imagens relacionados a avaliação ovariana

Devido as características dinâmicas das estruturas ovarianas, diversos estudos correlacionaram os atributos das imagens ultrassonográficas às variações morfológicas e fisiológicas no ciclo estral (Ludwick and Rader 1968; Pierson and Ginther 1984; Quirk et al., 1986; Pierson and Ginther 1986). Na fêmea cíclica, os ovários são identificados como estruturas acinzentadas em que podem ser observados folículos e corpo lúteo em diferentes fases do ciclo estral. A imagem ultrassonográfica dos folículos é caracterizada como áreas circulares com parede ecogênica bem definida e líquido anecoico no interior. É importante ressaltar que,

durante o escaneamento em tempo real, devem ser geradas imagens de toda a extensão dos folículos (início, meio e final), diferenciando-os de cortes transversais de vasos sanguíneos do pedículo ovariano. Com padrão anecoico, os folículos podem ser visualizados a partir de 2mm de diâmetro na tela do ultrassom, já os folículos pré-ovulatórios são identificados com diâmetro a partir de 10mm, em fêmeas zebuínas (Pierson and Ginther 1987).

O CL é observado como uma estrutura de coloração acinzentada escura, com ecogenicidade variável de acordo com o grau de luteinização e bordas marcantes e distintas. Sendo reconhecido pela sua forma e tamanho, além da ecogenicidade característica que possibilita diferenciá-lo do estroma ovariano após treinamento adequado. O CL pode apresentar-se com uma cavidade central anecoica e paredes espessas (CL cavitário), quando ocorre luteinização externa das células da teca e granulosa que não ocupam completamente o interior da estrutura. A cavidade não repercute em alterações significativas na função luteal.

Além disso, é difícil distinguir entre um CL recém-formado e um CL antigo estabelecido (Pieterse et al., 1990b) apenas pela observação visual. Também é um desafio determinar se um grande folículo no ovário está em crescimento ou em estágio de regressão de desenvolvimento. No entanto, com o advento de novas tecnologias de imagem e *doopler*, o fluxo sanguíneo e outras características das estruturas ovarianas podem ajudar a determinar o estado fisiológico dos folículos e corpos lúteos (Singh et al., 2003; Matsui e Miyamoto, 2009). Além disso, a viabilidade e o número de pixels coloridos foram significativamente correlacionados com as concentrações circulantes de progesterona (Herzog e Bollwein, 2007). A viabilidade de um folículo pode ser determinada por meio de ultrassonografia *doppler*; o fluxo sanguíneo aumentou após o desvio folicular e diminuiu quando o folículo entrou em atresia (Matsui e Miyamoto, 2009). A ultrassonografia *doppler* também pode ser usada para determinar o estado da gestação precoce; como o fluxo sanguíneo diminuiu para um CL em regressão, o fluxo sanguíneo elevado contínuo para um CL após o dia 19 do ciclo estral é indicativo de uma gestação precoce (Matsui e Miyamoto, 2009). Com as melhorias tecnológicas, também aumenta a necessidade de habilitação do técnico para obter consistentemente a varredura de estruturas ovarianas.

1.1.4 Análise computacional

O processamento computacional de imagens pode revelar informações e recursos com finalidade científica, principalmente devido à capacidade dos algoritmos de computador em quantificar variáveis e estabelecer medidas numéricas. Em contraste, a análise visual por humanos é baseada na comparação entre imagens. Nesse sentido, a visão humana tem dificuldade em julgar a cor ou o brilho das formas e características e requer escalas de medição ou tamanho relativo, ângulo e posição de vários objetos para identificar suas características. A segmentação e a análise de textura permitem a avaliação automática de variáveis importantes do contexto matemático e físico das imagens, que a visão humana não consegue identificar.

A observação visual é limitada à subjetiva diferenciação de ecotexturas, pois o olho humano somente é capaz de distinguir entre 18 e 20 tonalidades de cinza (Pierson; Adams, 1995). Por sua vez, a imagem digital, como representação de uma cena natural, pode ser convertida em uma matriz numérica de pixels com até 256 níveis de cinza. Dessa forma, o processamento computacional de informações ultrassonográficas pode revelar padrões específicos devido à capacidade dos algoritmos em quantificar variáveis e estabelecer medidas numéricas (Xu and Vaziri-Pashkam, 2021).

Alguns estudos demonstram que a análise quantitativa em imagens de ovários forneceu boa predição da fase do CL (Thijssen et al., 2011; Herzog et al., 2008), já a heterogeneidade do pixel demonstrou potencial de indicar a funcionalidade e capacidade esteroidogênica da glândula lútea (Siqueira et al., 2009). Além do CL, mudanças nos atributos de imagem do antro folicular (central e periférico), parede folicular e estroma ovariano perifolicular indicaram potenciais diferenças morfológicas e funcionais entre os folículos antrais emergentes em diferentes estágios em vacas (Pierson; Adams 1999; Toosi and Rawlings, 2009; Warren, 2014) e em ovelhas (Wu et al., 2009). Esses resultados corroboram com técnicas de reconhecimento de padrões estatísticos (tamanho, densidade e ecotextura) sobre a diferenciação entre os diferentes estágios do ciclo estral em vacas apresentados por Singh, Pierson and Adams; 1997; Tom et al., 1998a e Tom et al., 1998b. No entanto, os valores dos parâmetros de ecotextura dependeram do tipo e das configurações da máquina de ultrassom e carecem de consenso sobre a metodologia adotada para processamento e valores de referência.

As melhorias no processamento das imagens e na qualidade dos equipamentos, bem como a introdução da tecnologia *doppler* indicam uma tendência de aprimoramento na avaliação ginecológica (Palhão et al., 2019). Assim, o desenvolvimento de tecnologias

computacionais e eletrônicas estimulam novas abordagens de estudo da estrutura e função ovariana (Singh; Adams; Pierson, 2003) e da ecotextura uterina (Scully et al., 2014; Akblut; Çelik, 2021; Gengiz et al., 2017). Em aplicações de diagnóstico gestacional, a avaliação do ovário por meio da US associada as CNNs poderia identificar a gestação de forma precoce, objetiva e com precisão. Esse adiantamento do diagnóstico de gestação, pode levar a um encurtamento da estação de monta, favorecendo a eficiência reprodutiva, e consequentemente a sustentabilidade e a lucratividade das operações pecuárias.

No exame ultrassonográfico, o técnico simultaneamente opera o equipamento para gerar as imagens e interpreta as informações expressas no monitor. A sincronia dessas ações exige habilidade e experiência do avaliador. Melhorias futuras que podem auxiliar esse processo ao incluir software de imagem melhor e recursos de diagnóstico aprimorados da máquina (ou seja, software que será capaz de usar densidade de pixels para categorizar ovários). Imagens digitais de alta resolução são mais sensíveis do que o olho humano na determinação de detalhes em imagens em tons de cinza, e algoritmos de computador podem ser especialmente projetados para avaliar imagens de ultrassom (Singh et al., 2003). Estudos recentes usaram o software analítico ImageProPlus® disponível comercialmente (MediaCybernetics, Rockville, MD) para calcular um valor de pixel numérico e relataram correlações positivas significativas entre o número de folículos primordiais, intermediários e primários com valores de pixels numéricos médios em imagens ultrassonográficas ovarianas em bovinos (Warren et al., 2015). Assim, à medida que a tecnologia continua a se desenvolver, o uso da ultrassonografia provavelmente aumentará, bem como a capacidade da máquina de analisar as imagens e tomar decisões de gerenciamento.

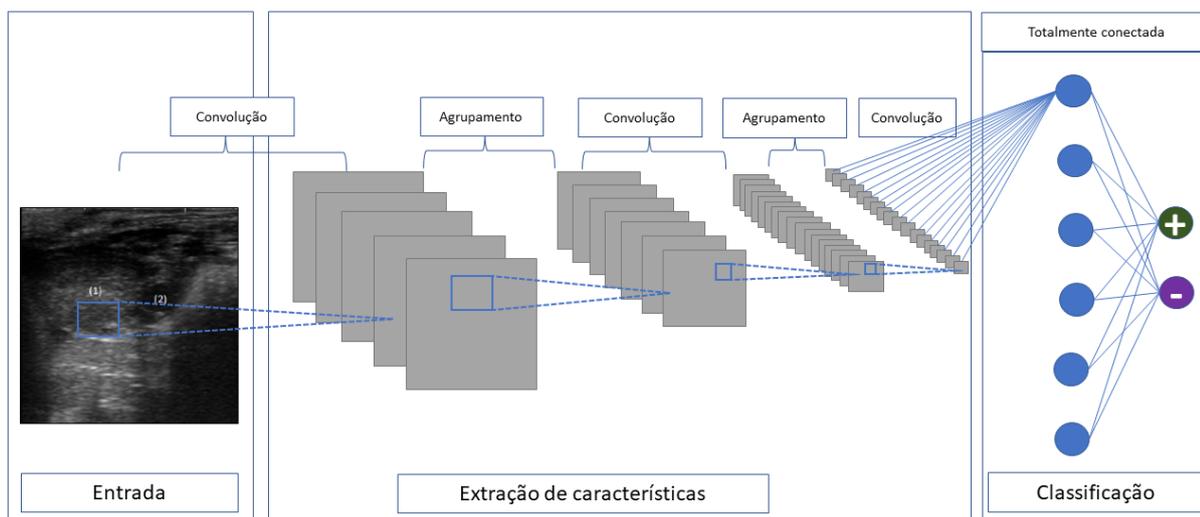
1.1.5 Aprendizagem profunda e redes neurais convolucionais

Nesse contexto, o *deep learning* é um conjunto de técnicas de *machine learning* que se baseia nas interações entre neurônios do cérebro humano, podendo simular em certas condições o intelecto e resolver problemas que por nós exigimos treinamento intensivo e intuição. Abordagens de *deep learning* permitem que um modelo computacional aprenda automaticamente recursos abstratos proveniente de dados e adquira experiência e ajustes aos resultados que precisa alcançar.

A utilização apropriada de dados visuais é o componente habilitador em muitas tarefas automatizadas. A introdução da visão de máquina nos processos industriais é motivada pelo desejo de aumentar a eficiência (e, portanto, a produtividade), reduzir erros (e assim melhorar a qualidade) ou coletar dados. Os avanços tecnológicos possibilitaram a realização prática de compreensão de imagem, ou mais especificamente, técnicas de visão de computacional, para ajudar a resolver problemas industriais práticos que envolvem um componente visual significativo.

As RNCs são arquiteturas inspiradas na rede neural biológica, capazes de serem treinadas e aprender, bem como generalizar representações invariantes de escala, translação, rotação e transformações relacionada (Liu et al., 2007). São as arquiteturas de aprendizagem profundas mais populares e com bom desempenho em várias tarefas de classificação de imagem, detecção de objeto e segmentação de alvo (Arel et al., 2010). A aplicação de um modelo de RNC envolve aprender com os dados brutos (por exemplo, imagens de US) a fim de gerar representações abstratas hierárquicas, seguidas por um classificador que pode ser usado para produzir uma ou mais probabilidades ou rótulos de classe. Nesse caso, anotações ou rótulos de imagem são necessários para realizar a tarefa. Este é o chamado aprendizado supervisionado. Essa ação permite criar um modelo pré-treinado de detecção de características que seja capaz de representar e detectar padrões nos dados de entrada.

Figura 3: Representação da estrutura de uma RNC



Fonte: Autor (2021)

Semelhante aos processos tradicionais de visão computacional, uma RNC é capaz de aplicar filtros a dados não estruturados, enquanto mantém a relação de vizinhança entre os pixels da imagem em todo o processamento da rede. Normalmente, três tipos de camadas são

usados para construir uma RNC: camadas convolucionais, de agrupamento e totalmente conectadas. As camadas convolucionais aplicam vários filtros sobre a imagem para obter uma série de mapas de recursos, um para cada filtro. Por sua vez, as camadas de agrupamento resumem esses mapas de recursos destacando os recursos mais relevantes. A tarefa de classificação é realizada pela camada totalmente conectada (Mousser e Ouadfel, 2019).

A camada principal dessas redes é a camada de convolução, e sua função é aplicar máscaras às imagens de entrada, com base em uma vizinhança de pixels. A saída nesta operação são os filtros de convolução (matrizes) que armazenam os pesos das conexões entre os neurônios (Mousser e Ouadfel, 2019). A convolução é representada por um operador linear entre duas funções que produz uma terceira função. O último representa as áreas sobrepostas das máscaras que são aplicadas à imagem (Parkhi et al., 2015). A distinção dos padrões de dados com esta operação é dada por campos receptores locais (pequenas porções espaciais de pixels), que são representados por estruturas de neurônios conectados localmente (Shi e He, 2011).

Os pesos de compartilhamento na camada de convolução garantem que os filtros sejam aplicados em diferentes posições na imagem, significativamente diminuindo o número de dados a serem aprendidos. A ativação é uma estrutura muito importante na camada de convolução, fazendo um ajuste entre um conjunto de neurônios, com uma função de ativação sobre uma convolução. Isso produz mapas de características que armazenam as informações aprendidas pelos filtros. Outra camada que também é crucial nas RNCs é a camada de pooling. Reduz a dimensionalidade dos mapas de recursos diminuindo largura e altura. A operação de agrupamento permite uma invariância espacial.

As próximas camadas de RNCs desempenham o papel de regressão das ativações. Em uma dada rede, após a camada de agrupamento, é necessária pelo menos uma camada totalmente conectada, servindo para criar caminhos de decisão a partir dos filtros obtidos na camada anterior. A última camada de RNCs também está totalmente conectada e pode classificar os dados. Nesta situação, uma função de ativação determina a identificação das saídas nas classes. A ativação mais comumente usada é a função Softmax para problemas multiclasse e sigmoid para problemas binários.

O treinamento de uma RNC é realizado, na maioria dos casos, por meio do algoritmo de retropropagação, que ajusta os pesos dos neurônios propagando e corrigindo erros relacionados à classificação de dados, apoiados pela otimização fornecida pelo gradiente

descendente (Dainez e Dainez, 2015). As arquiteturas RNCs são projetadas para se ajustarem em uma variedade de imagens e classes, fornecendo reconhecimento de padrões mais robusto. Vários estudos investigam o tamanho dessas arquiteturas e sua eficácia. Nesse sentido, o ImageNet Large Scale Visual Recognition Challenge (ILSVRC) avalia abordagens de identificação e classificação que aplicam redes neurais profundas (Santos et al., 2017).

A partir da AlexNet, uma RNC que venceu o Desafio de Reconhecimento Visual de Grande Escala da ImageNet (ILSVRC) em 2012, o aprendizado profundo começou a atrair a atenção no campo do aprendizado de máquina em vários domínios de pesquisa e, particularmente, em análise de imagens em geral, incluindo análise de imagens naturais e médicas, e visão computacional.

A aplicação de aprendizagem profunda foi avaliada intensamente em imagens de ultrassom relacionadas à saúde humana (Liu et al., 2019), incluindo tarefas de classificação (Christiansen et al., 2020; Nii et al., 2018; Srivastava et al., 2020), segmentação (Wanderley et al., 2019; Eliyani et al., 2019; Li et al., 2020), detecção e medições biométricas (Meiburger et al., 2018; Springer et al., 2016; Springer et al., 2013). Na ciência animal, a aprendizagem profunda associada a sistemas de visão computacional tem sido utilizado em condições experimentais com algumas execuções desenvolvidas em fazendas comerciais (Li et al., 2021; Fernandes et al., 2020). As aplicações podem variar desde identificação de animais (Barbedo et al., 2019), observação do comportamento para detecção de estro (Cairo et al., 2020), classificação automatizada de escore de condição corporal e até classificação de blastocisto bovino em fertilização in vitro (Rocha et al., 2017a; Rocha et al., 2017b).

Com base nesses resultados observa-se a potencial capacidade das RNCs em extrair de características de ecotextura em modelos pré-treinados e classificar automaticamente imagens de ovários através de janelas de pixels. A revisão de literatura sobre o estado atual do conhecimento mostra que foram realizadas poucas pesquisas semelhantes utilizando a ultrassonografia ovariana bovina (Górna et al., 2017). No entanto, avanços significativos têm sido observados na ultrassonografia em humanos, que também são espécies monovulares, tanto em trabalhos aplicados à detecção de patologias ovarianas (Al-Karawi et al., 2021) quanto para técnicas de reprodução assistida (Maraci et al., 2017). Assim, a análise dos atributos da imagem ovariana por meio das RNCs pode tornar-se uma extensão natural dos avanços tecnológicos na ultrassonografia de fêmeas bovinas.

REFERÊNCIAS

BURGOS-ARTIZZU, X. P; CORONADO-GUTIÉRREZ, D; VALENZUELA-ALCARAZ, B; BONET-CARNE, E; EIXARCH, E; CRISPI, F; GRATACÓS, E. 2020. Evaluation of deep convolutional neural networks for automatic classification of common maternal fetal ultrasound planes. *Sci. Rep.* 10, 10200. <https://doi.org/10.1038/s41598-020-67076-5>

AREL, I; ROSE D. C; KARNOWSKI T. P. Deep machine learning-a new frontier in artificial intelligence research. *IEEE computational intelligence magazine*, vol. 5, no. 4, pp. 13–18, 2010.

BALL, P. J. H e PETERS, A. R. (2004). **Reproduction in cattle**. (3ª edição). Editora - Blackwell Pub. Disponível em: <<https://onlinelibrary.wiley.com/doi/book/10.1002/9780470751091>>

BEAL W. E; PERRY R. C; CORAH L. R. The use of ultrasound in monitoring reproductive physiology of beef cattle. *J Anim Sci.* 1992 Mar;70(3):924-9. doi: 10.2527/1992.703924x.

CHAFFAUX, S.T; BIANCHI, M; BHAT, P; HEDGE, G.V., REDDY, G.N.J. e THIBIER, M., 1988. L'échographie en temps réel par voie transrectale. Intérêt pour diagnostic de gestation chez la vache. *Recueil de Médecine Vétérinaire* 164 (2): 101-108.

CARTEE, R.E.; HUDSON, J.A. e FIN-BORNER, S., 1993. Ultrasonography. *Veterinary Clinics of North America (Small Animal Practice)* 23 (2): 345-377.

FEENEY, D.A.; FLETCHER, T.F.; e HARDY, R.M., 1991. Atlas of correlative imaging anatomy of the normal dog – Ultrasound and computed tomography. W.B. Saunders Company, Philadelphia, pp. 353-366.

FREY, A. C.; PERCIANO, T. **Introduction to Image Processing Using R**. 1. ed. London, UK: Springer, 2013.

FISH, P., 1990. Physics and instrumentation of diagnostic medical ultrasound. John Wiley & sons Ltd. P.O. 19, 1VD, Baffins Lane, Chichester, West Sussex, pp. 1-26.

K. HE, X. ZHANG, S. REN AND J. SUN. “Deep residual learning for image recognition”. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778, 2016.

HERZOG K. & BOLLWEIN H. 2007. Application of Doppler ultrasonography in cattle reproduction. *Reprod. Dom. Anim.* 42(Suppl. 2):51-58. <<http://dx.doi.org/10.1111/j.1439-0531.2007.00903.x>> <PMid:17688602>

HERZOG K., BROCKHAN-LÜDEMANN M., KASKE M., BEINDORFF N., PAUL V., NIEMANN H. & BOLLWEIN H. 2010. Luteal blood flow is a more appropriate indicator for luteal function during the bovine estrous cycle than luteal size. *Theriogenology* 73(5):691-697.

GAO, Z.; ZHANG, Y.; LI, Y. Extracting features from infrared images using convolutional neural networks and transfer learning. ***Infrared Physics & Technology***, v. 105, p. 103237, mar. 2020. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1350449519307431>>.

K. GÓRNA, B. M. JAŚKOWSKI, P. OKOŃ, M. CZECHLOWSKI, K. KOSZELA, M. ZABOROWICZ, P. IDZIASZEK, "Neural analysis of bovine ovaries ultrasound images in the identification process of the corpus luteum," *Proc. SPIE 10420*, Ninth International Conference on Digital Image Processing (ICDIP 2017), 104204H (21 July 2017); doi: 10.1117/12.2281723

HAMYLTON, S. M.; MORRIS, R. H.; CARVALHO, R. C.; RODER, N.; BARLOW, P.; MILLS, K.; WANG, L. Evaluating techniques for mapping island vegetation from unmanned aerial vehicle (UAV) images: Pixel classification, visual interpretation and machine learning approaches. ***International Journal of Applied Earth Observation and Geoinformation***, v. 89, p. 102085, jul. 2020. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0303243419310293>>.

JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. ***An Introduction to Statistical Learning with Applications in R***. 8. ed. New York: Springer London, 2017.

JAINUDEEN & HAFEZ. 2004. Gestação Fisiologia pré-natal e parto. In: Hafez E.S.E. e Hafez B. *Reprodução Animal*. Editora Manole. 7a Ed

KETKAR, Nikhil, *Introduction to keras. Deep Learning with Python*, 2017.

LIU, S., WANG, Y., YANG, X., LEI, B., LIU, L., LI, S.X., NI, D., WANG, T., 2019. Deep Learning in Medical Ultrasound Analysis: A Review. *Engineering* 5, 261–275. <https://doi.org/10.1016/j.eng.2018.11.020>

T. LIU, C. ROSENBERG AND H. A. ROWLEY. “Clustering billions of images with large scale nearest neighbor search”. In 2007 IEEE Workshop on Applications of Computer Vision (WACV’07), pp. 28–28. IEEE, 2007.

W. MOUSSER AND S. OUADFEL. “Deep Feature Extraction for Pap-Smear Image Classification: A Comparative Study”. In Proceedings of the 2019 5th International Conference on Computer and Technology Applications, pp. 6–10. ACM, 2019.

MARTÍN A.; BARHAM P.; CHEN J.; CHEN Z.; DAVIS A.; DEAN J.; DEVIN M.; GHEMAWAT S.; IRVING G.; ISARD M.; KUDLUR M.; LEVENBERG J.; MONGA R.; MOORE S.; MURRAY D. G.; STEINER B.; TUCKER P.; VASUDEVAN V.; WARDEN P.; WICKE M.; YU Y.; XIAOQIANG ZHENG. TensorFlow: A System for Large-Scale Machine Learning. 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16), 2016

KECELI, A. S.; CATAL, C.; KAYA, A.; TEKINERDOGAN, B. Development of a recurrent neural networks-based calving prediction model using activity and behavioral data. **Computers and Electronics in Agriculture**, v. 170, p. 105285, mar. 2020. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0168169919312220>>.

KELLEY, D. E.; GALVÃO, K. N.; MORTENSEN, C. J.; RISCO, C. A.; EALY, A. D. Using Doppler ultrasonography on day 34 of pregnancy to predict pregnancy loss in lactating dairy cattle. **Journal of Dairy Science**, v. 100, n. 4, p. 3266–3271, abr. 2017. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0022030217301273>>.

LAMB, G. C.; MERCADANTE, V. R. G. Synchronization and Artificial Insemination Strategies in Beef Cattle. **Veterinary Clinics of North America: Food Animal Practice**, v. 32, n. 2, p. 335–347, jul. 2016. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0749072016000074>>.

LOPEZ-GARNIER, S.; SHEEN, P.; ZIMIC, M. Automatic diagnostics of tuberculosis using convolutional neural networks analysis of MODS digital images. **PLOS ONE**, v. 14, n. 2, p. e0212094, 27 fev. 2019. Disponível em: <<http://dx.plos.org/10.1371/journal.pone.0212094>>.

LUDWICK, T. M.; RADER E.R. Diagnosis of early pregnancy in cattle by ovarian analysis. *J Dairy Sci.* 1968 Jan;51(1):74-7. doi: 10.3168/jds.S0022-0302(68)86923-1. PMID: 5640019.

MATSUI M, MIYAMOTO A. Evaluation of ovarian blood flow by colour Doppler ultrasound: practical use for reproductive management in the cow. *Vet J.* 2009 Sep;181(3):232-40. doi: 10.1016/j.tvjl.2008.02.027. Epub 2008 Aug 6. PMID: 18693121.

QUIRK, S.M., HICKEY, G.J., FORTUNE, J.E. (1986) 'Growth and regression of ovarian follicles during the follicular phase of the oestrous cycle in heifers undergoing spontaneous and PGF25.-induced luteolysis', *Journal of Reproduction and Fertility*, 77, 211–219.

O. M. PARKHI, A. VEDALDI, A. ZISSERMAN. "Deep face recognition." In *bmvc*, volume 1, p. 6, 2015.

PIERSON, R.A.; GINTHER, O.J. Ultrasonography for detection of pregnancy and study of embryonic development in heifers, ***Theriogenology***, Volume 22, Issue 2, 1984, Pages 225-233, ISSN 0093-691X, [https://doi.org/10.1016/0093-691X\(84\)90435-7](https://doi.org/10.1016/0093-691X(84)90435-7).

MORETTI, J.L., 1982. Eléments de physique ultrasonore. Echographie. *Bull. Acad. Vét. de France* 55: 159-176.

NEBAUER, C. Evaluation of convolutional neural networks for visual recognition. ***IEEE Transactions on Neural Networks***, v. 9, n. 4, p. 685–696, jul. 1998. Disponível em: <<http://ieeexplore.ieee.org/document/701181/>>.

NYLAND, T.G., MATTOON, J.S. e WISNER, E.R., 1995. Physical Principles, Instrumentation, and Safety of diagnostic Ultrasound. In *Veterinary diagnostic Ultrasound*. W.B. Saunders Company, Philadelphia, pp. 3-18.

GRIFFIN, P.G.; GINTHER, O.J. Research applications of ultrasonic imaging in reproductive biology, ***Journal of Animal Science***, Volume 70, Issue 3, March 1992, Pages 953–972, <https://doi.org/10.2527/1992.703953x>

PIERSON, R.A.; GINTHER, O.J. Ovarian follicular populations during early pregnancy in heifers. *Theriogenology*. 1986 Nov;26(5):649-59. doi: 10.1016/0093-691x(86)90173-1. PMID: 16726232.

PIERSON, R.A.; ADAMS, G.P. (1995) Computer-Assisted Image Analysis, Diagnostic Ultrasonography and Ovulation Induction: Strange Bedfellows. *Theriogenology*, 43, 105-112. [https://doi.org/10.1016/0093-691X\(94\)00014-L](https://doi.org/10.1016/0093-691X(94)00014-L)

PIERSON, R.A.; GINTHER, O.J., Reliability of diagnostic ultrasonography for identification and measurement of follicles and detecting the corpus luteum in heifers, ***Theriogenology***, Volume 28, Issue 6, 1987, Pages 929-936, ISSN 0093-691X, [https://doi.org/10.1016/0093-691X\(87\)90043-4](https://doi.org/10.1016/0093-691X(87)90043-4).

PIETERSE, M.C.; SZENCI O.; WILLEMSE, A.H.; BAJCSY, C.S.A.; DIELEMAN, S.J.; TAVERNE, M.A.M. Early pregnancy diagnosis in cattle by means of linear-array real-time ultrasound scanning of the uterus and a qualitative and quantitative milk progesterone test, **Theriogenology**, Volume 33, Issue 3, 1990, Pages 697-707, ISSN 0093-691X, [https://doi.org/10.1016/0093-691X\(90\)90547-7](https://doi.org/10.1016/0093-691X(90)90547-7).

RANTANEN, N.W. e EWING, R.L., 1981. Principles of ultrasound application in animals. *Veterinary Radiology* 22 (5): 196-203.

RAMASUBRAMANIAN, K.; SINGH, A. **Machine Learning Using R**. Berkeley, CA: Apress, 2017.

ROMANO, J.E.; THOMPSON, J.A.; FORREST, D.W.; WESTHUSIN, M.E.; TOMASZWESKI, M.A.; KRAEMER, D.C., 2006. Early pregnancy diagnosis by transrectal ultrasonography in dairy cattle. **Theriogenology** 66, 1034–1041.

POHLER, K. G.; REESE, S. T.; FRANCO, G. A.; OLIVEIRA FILHO, R. V.; PAIVA, R.; FERNANDEZ, L. (2020). New approaches to diagnose and target reproductive failure in cattle. *Anim. Reprod.* 17:e20200057. doi: 10.1590/1984-3143-ar2020-0057

PIETERSE, M.C.; SZENCI, O.; WILLEMSE, A.H. Early pregnancy diagnosis in cattle by means of Linear-Array Real-Time ultrasound scanning of the uterus and a quantitative and qualitative milk progesterone test. **Theriogenology**, v. 33, n. 3, p. 697-707, 1990.

PIERSON, R.A.; KASTELIC, J.P. and GINTHER, O.J., 1988. Basic principles and techniques for transrectal ultrasonography in cattle and horses. **Theriogenology** 29: 3-20.

REESE S.T.; FRANCO G.A.; POOLE R.K.; HOOD R.; FERNADEZ M. L.; OLIVEIRA RV FO, COOKE R.F.; POHLER K.G. Pregnancy loss in beef cattle: a meta-analysis. *Anim Reprod Sci.* 2020;212:106251.
Disponível em: < <http://dx.doi.org/10.1016/j.anireprosci.2019.106251>>

Z. SHI and L. HE. “Current status and future potential of neural networks used for medical image processing”. *Journal of multimedia*, vol. 6, no. 3, pp. 244, 2011.

SANTOS A.; AIRES K.; VERAS R.; UCHOA V. e SANTOS L. “Uma Abordagem de Classificação de Imagens Dermatoscópicas Utilizando Aprendizado Profundo com Redes Neurais Convolucionais”. In *Anais do XVII Workshop de Informática Médica*. SBC, 2017.

SIMARD, P. Y., STEINKRAUS, D., AND PLATT, J. C. (2003). Best practices for convolutional neural networks applied to visual document analysis. In *Proceedings of the*

Seventh International Conference on Document Analysis and Recognition - Volume 2, ICDAR '03, pages 958–, Washington, DC, USA. IEEE Computer Society

SRIVASTAVA, S., KUMAR, P., CHAUDHRY, V., SINGH, A., 2020. Detection of Ovarian Cyst in Ultrasound Images Using Fine-Tuned VGG-16 Deep Learning Network. *SN Comput. Sci.* 1, 81. <https://doi.org/10.1007/s42979-020-0109-6>

SINGH, J.; PIERSON, R.A.; ADAMS, G.P. Ultrasound image attributes of the bovine corpus luteum: structural and functional correlates. *Journal of Reproduction and Fertility*, v.109, p.35-44, 1997.

SIQUEIRA L.G, TORRES CA, AMORIM LS, SOUZA ED, CAMARGO LS, FERNANDES CA, VIANA JH. Interrelationships among morphology, echotexture, and function of the bovine corpus luteum during the estrous cycle. *Anim Reprod Sci.* 2009 Oct;115(1-4):18-28. doi: 10.1016/j.anireprosci.2008.11.009. Epub 2008 Nov 20. PMID: 19117703..

TING, F. F.; TAN, Y. J.; SIM, K. S. Convolutional neural network improvement for breast cancer classification. **Expert Systems with Applications**, v. 120, p. 103–115, abr. 2019. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0957417418307280>>.

JOHAN M. THIJSSSEN, KATHRIN HERZOG, GERT WEIJERS, MAREN BROCKHAN-LUEDEMANN, ALEXANDER STARKE, HEINER NIEMANN, HEINRICH BOLLWEIN, CHRIS L. DE KORTE, Ultrasound image analysis offers the opportunity to predict plasma progesterone concentrations in the estrous cycle in cows: A feasibility study, *Animal Reproduction Science*, Volume 127, Issues 1–2, 2011, Pages 7-15, ISSN 0378-4320, <https://doi.org/10.1016/j.anireprosci.2011.07.006>.

VOLPATO, G. **Ciência: Da Filosofia À Publicação**. 6. ed. São Paulo, SP: Cultura Acadêmica, 2013.

2 IDENTIFYING PREGNANCY IN COWS USING OVARIAN ULTRASOUND IMAGES AND CONVOLUTIONAL NEURAL NETWORKS: A PROOF-OF-CONCEPT STUDY

ABSTRACT: Visual analysis of ovarian structures by ultrasound in cows are a relevant support tool for improving reproductive performance in livestock. However, by human visual analysis the subjectiveness is a limiting factor and computer vision technologies are a good way to overcome it. We aimed to evaluate the use of convolutional neural networks (CNNs) for identifying pregnancy in cows using ovarian ultrasound images obtained at 30 days after artificial insemination. A dataset with 510 images from individual independent functional ovaries of 238 pregnant and 272 non-pregnant Nellore cows was used. All images were collected in a same commercial farm. To evaluate dependency of CNNs performance on image quality, the images were classified by two independent veterinarians with significant experience in ultrasound evaluation as: good, regular, and bad for visual identification of ovarian structures. Five CNNs architectures were evaluated: ResNet50, ResNeXt50, InceptionResNetV2, DenseNet-121 and SimpleCNN. All CNNs were evaluated both using the complete dataset (ALL; n=510) and a subset of good and regular images (GR; n=462). For each architecture and dataset combination, ten evaluations were performed. In each run, the data sets were randomly divided into 70% for training and 30% for testing according to holdout method. A regularization-based method via dropout, data augmentation and a dynamic learning rate during the training phase was used. The model's performance was evaluated by accuracy, precision, sensitivity, and specificity, which ranged from 0.648 to 0.788, 0.344 to 0.800, 0.283 to 0.754, and 0.112 to 0.822, respectively. The models ResNet50, DenseNet-121 e SimpleCNN performed better when using the GR dataset. The DenseNet121 architecture performed better based on accuracy, sensitivity, specificity and with lower variation among datasets. The InceptionResNetV2 the more precise architecture using ALL, however with lower performance for GR dataset. We concluded that CNNs are capable to identify cow's pregnancy status in ovarian images collected at 30 days after artificial insemination. The effect of image quality on performance is dependent on CNNs architecture.

Keywords: bovine reproduction, computer vision, corpus luteum, deep learning, ovary ultrasonography.

Highlights:

- We used 510 images from individual cows at 30 days after insemination
- Five CNNs architectures were evaluated with two datasets varying in for image quality
- Best performed architecture had 78.8% of accuracy
- Performance of some CNNs architectures was more affected by image quality
- CNNs can be a future support tool for pregnancy diagnosis in cows

2.1 Introduction

In bovine reproduction, the grayscale ultrasound image (Mode B) was initially used in the 1980s as a research support tool (Pierson e Ginther, 1984). With the popularization of transrectal ultrasound, the gynecological evaluation of female cattle has become more accurate in several livestock farms. In this sense, the early diagnosis of pregnancy allows to increase the reproductive efficiency of the herd and contributes to subsequent management decisions. Usually, this evaluation is performed 30 days after timed artificial insemination and the identification between pregnant and non-pregnant cows is depending on the technician's skill and experience in analyzing imaging of the uterus. Thus, the subjectivity of the human image evaluation is evident.

The use of computational technologies associated with machine learning techniques that support this interpretation such as convolutional neural networks (CNNs) are constantly developing in several areas of knowledge (Ting et al., 2019). It is a way for overcoming subjectivity in visual image analysis. The application of deep learning has been intensively evaluated in ultrasound images related to human health (Liu et al., 2019), including classification tasks (Christiansen et al., 2020; Srivastava et al., 2020), segmentation (Li et al., 2020), detection and biometric measurements (Meiburger et al., 2018). In animal science, the deep learning associated with computer vision systems has been used both in experimental

conditions and commercial farms (Li et al., 2021). Reported applications range from the identification of animal behavior (Barbedo et al., 2019), automated estrus detection (Cairo et al., 2020), automated classification of body condition score and even classification of bovine blastocyst in *in vitro* fertilization (Rocha et al., 2017).

However, development and application of CNNs as support in reproductive evaluation of cows still lack. Precisely, on bovine reproductive ultrasound, only one study is known to date that evaluated the ability of artificial neural networks to identify the developmental stage of the corpus luteum (Górna et al., 2017). Other studies, mainly in humans, demonstrate the ability of convolutional neural networks to classify standardized plans in maternal-fetal ultrasound with performance equivalent to technical professionals who perform the task on a daily basis (Burgos-Artizzu et al., 2020). Evaluation CNNs performance in farm conditions may allow the development of computational models to support decision-making by professionals involved in the reproductive management of cows.

We aimed to evaluate the applicability of CNNs for identifying pregnancy in cows using ovary ultrasonography images collected at 30 days after timed artificial insemination.

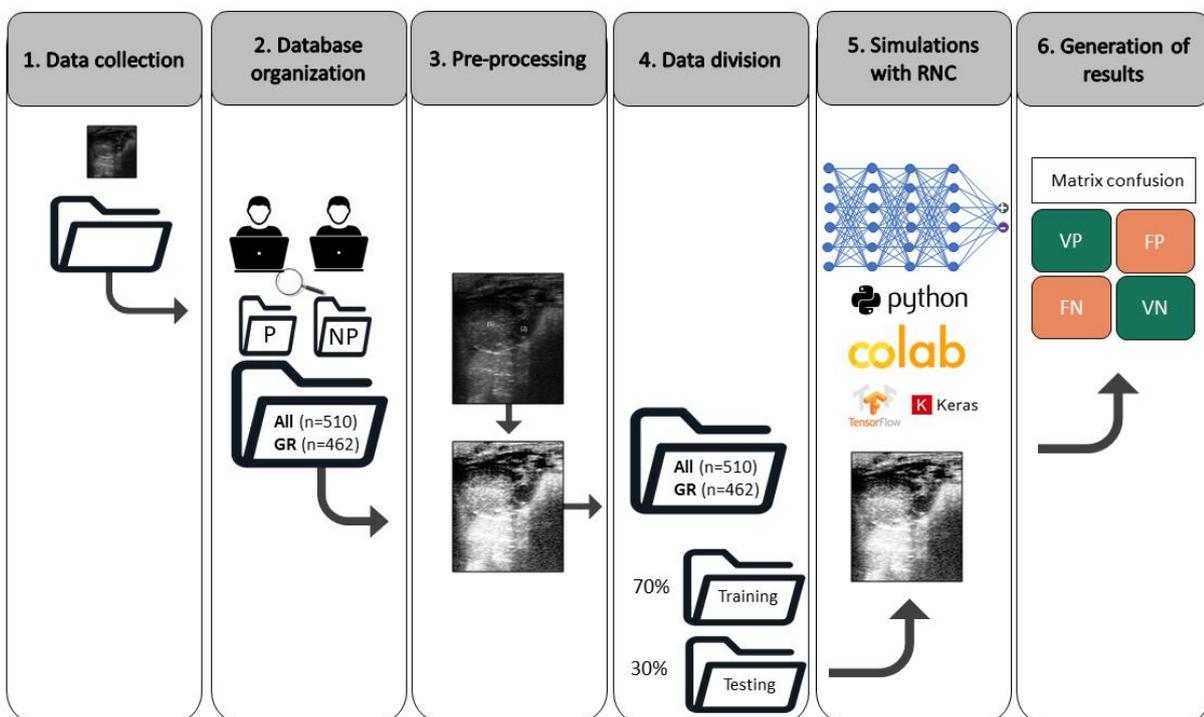
2.2 Material and methods

A dataset with 510 ultrasound images of functional ovaries from individual primiparous Nellore cows was obtained in a commercial farm (Fazenda Santa Rosa Xinguara, Pará, Brazil; 6°58'10.8"S 50°08'02.7"W). All cows were submitted to timed artificial insemination and the images and pregnancy diagnosis data were obtained at 30 days after insemination, according to the farm management. All farm management followed the recommendations of good practices and welfare for production and economic interests' animals (MAPA, 2008).

The images were obtained by transrectal ultrasonography (DP-Vet 2200; Shenzhen Mindray Bio-Medical Electronics Co., China) using linear transducer 7.5 MHz (Model 75L50EAV; Mindray). The images were obtained in B mode (shine; grey scale) and were saved

in JPEG (Joint Photographic Experts Group) format. Pregnancy was confirmed by the presence of anechoic liquid in the uterine horn, finding of gestational vesicle and embryo. Previously to the image sampling the functional ovary of each cow was selected by presence of corpus luteum. All images collection and pregnancy diagnosis were performed by the same veterinarian, with solid experience in monitoring reproduction and gynecological evaluation (i.e., around 250.000 cows). Beside this, all positive diagnostics were confirmed by ultrasonography at 150 days after artificial insemination. After obtaining the database, the images went through different processing steps, as shown in figure 4.

Figure 4: Images processing flowchart



Source: Authors (2021)

To verify if the model's performance is dependent on image quality, two independent veterinarians classified the images regarding to clarity of visualizing ovarian structures. The images were classified independently as good, regular, or bad quality and those without similar classification for both classifiers were reclassified with them together. Two subsets were

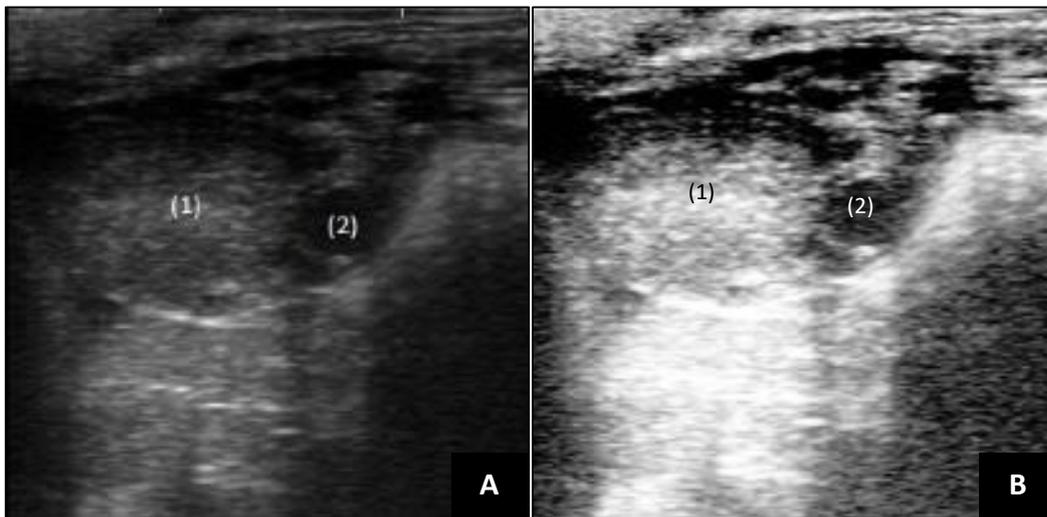
evaluated: all images (ALL; n = 510) with 238 pregnant cows and 272 non-pregnant; good and regular (GR; n = 462) with 211 pregnant and 251 non-pregnant cows (Table 3). The complete classified dataset can be accessed in Andrade et al. (2021).

Table 3. Classification by pregnancy and subsets with different image quality of functional ovaries in Nellore cows at 30 days after timed artificial insemination.

Class	Quality			Total
	Good	Regular	Bad	
Pregnant	123	88	27	238
Not pregnant	105	146	21	272
Subset				
Good and regular (GR)	228	234	-	462
All images (ALL)	228	234	48	510

The images denote the longitudinal section of the ovary. They were cropped equally into 280×280 pixels with the functional part for interpretation and then normalized using the GIMP software version 2.10.18 (Figure 5).

Figure 5. Ultrasound image of bovine ovary showing compact corpus luteum (1) and follicle (2), before (A) and after (B) normalization.



Source: Authors (2021)

The CNNs models were trained and evaluated using the open source Keras API libraries version 2.0 and TensorFlow version 2.0 in the Python software (version 3.6.9, python.org). This

research presents five CNN implementations with different paradigms, in relation to its architecture, for extracting features from images. The original architecture of each CNNs was maintained (**Table 2**). Google Colab was used as a processing unit with 12 GB of RAM and a Tesla K80 GPU.

Table 4. Classification convolutional neural networks tested for pregnancy detection using ultrasound images of functional ovaries in Nellore cows at 30 days after artificial insemination.

Architecture	Params	Layers	Reference
ResNet50	25.636.712	177	He et al., 2015
ResNeXt50	25.097.128	179	Xie et al., 2017
InceptionResNetV2	55.873.736	164	Szegedy et al., 2016
DenseNet-121	8.062.504	428	Huang et al., 2016
SimpleCNN	30.471	7	LCC/Unifesspa, 2021

Previously to start all training and testing processes, the data set was randomly splitted into 70% for training and 30% for testing, according to holdout method (James et al., 2013). To avoid overfitting a regularization-based methodology via dropout, data augmentation and a dynamic learning rate was used during the training phase. The parameters established for evaluations were standard input image size 75×75 pixels, ReLU and Sigmoid as an activation function for hidden and output layers, respectively, batch size of 8, binary cross entropy as function of cost, Adam's optimizer, 200 seasons and a 0.5 dropout. The initial learning rate was 10^{-3} , 10^{-1} 10^{-2} 10^{-3} and 0.5×10^{-3} for seasons 1, 81, 121, 161 and 181, respectively. After the implementation of the trained models the performance of the architectures was compared between the 5 CNNs in both ALL and GR subsets. To evaluate the overall performance of each CNN, all following metrics were calculated as the average value of ten simulations: accuracy, precision, sensitivity, specificity (Ramasubramanian and Singh, 2017).

2.3 Results

From all evaluated architectures the DenseNet121 combined higher accuracy, sensitivity, and specificity (Table 3). For precision, the InceptionResNetV2 performed better

using GR dataset, however with low performance for all other metrics. The proposed SimpleCNN performed close to DenseNet121, with consistency for all metrics.

Table 3. Performance of different convolutional neural networks architectures for classifying ultrasound images of the functional ovary in cows at 30 days after artificial insemination.

Architecture	Accuracy		Precision		Sensitivity		Specificity	
	GR ¹	ALL ²	GR	ALL	GR	ALL	GR	ALL
ResNet50	0.699	0.611	0.522	0.393	0.507	0.286	0.732	0.629
ResNeXt50	0.648	0.682	0.344	0.588	0.283	0.568	0.683	0.702
InceptionResNetV2	0.465	0.711	0.800	0.684	0.353	0.706	0.112	0.718
SimpleCNN	0.746	0.666	0.715	0.612	0.712	0.666	0.775	0.667
DenseNet121	0.788	0.736	0.776	0.690	0.754	0.745	0.822	0.732

¹GR= Images selected as good and regular for clarity of ovarian structures.

²ALL= complete dataset of images.

The subsets provided different performances in all metrics, with greater differences for sensitivity for ResNet50, sensitivity for ResNeXt50, and sensitivity and specificity for InceptionResNetV2 (Table 3). Both SimpleCNN and DenseNet121 performed better in all metrics in GR than in ALL, however, with lower magnitude than other architectures.

2.4 Discussion

As a proof-of-concept study, we aimed to ensure the potential applicability of CNNs in cows' reproductive management in farm conditions and for future research aiming to improve its use for decision making in commercial farms. It is worth to emphasize that our objective is not to replace the veterinarian regarding checking cow's pregnancy status. Obviously, many steps are needed before direct application of CNN models for classifying ovarian images in farms. However our results are a significant evidence that it is possible at 30 days after artificial insemination. We evaluated a limited number of architectures with a relatively low number of images and even so values of accuracy of 78.8% were obtained. This result opens relevant perspectives for future studies and some directions are discussed below.

In pregnancy diagnosis the ovarian structures are relevant features to define the reproductive status of the cow. With an anechoic pattern, follicles can usually be seen from

2mm in diameter on the ultrasound screen, whereas dominant or preovulatory follicles are identified from 10mm, which when absent in the ovary they are indicators of pregnant cows. (Pierson and Ginther 1987). As a main marker of pregnancy at around 30 days after insemination, the corpus luteum is observed as a grayish-colored structure with strong edges and variable echogenicity according to the degree of luteinization, being recognized by its shape and size. Furthermore, the luteal tissue appears with a characteristic echogenic pattern that makes it possible to visually differentiate it from the ovarian stroma after adequate training. Even so, the accuracy of ovarian evaluations in cattle is directly related to the skill and experience of the examiner on identifying those previously described components (Quirk et al., 1986). Beside this, human visual analysis is limited and subjective to interpret ecotextures, due to the limito distinguishing about 20 shades of gray (Pierson and Adams, 1995). On the other hand, a standar digital image has 256 shades of gray. Thus, the computational processing of ultrasound images can detect changes in image patterns which are not noticeable to the human vision (Xu and Vaziri-Pashkam, 2021).

Corpus luteum stage can be accurately predicted by image analysis (Herzog et al., 2008; Thijssen et al., 2011). Moreover, the pixel's heterogeneity also demonstrated potential to identify the functionality and steroidogenesis capacity of the luteal gland (Siqueira et al., 2009). Probably the best performed CNNs in our study were more efficient on identifying these and other features associated to pregnancy. In addition to the corpus luteum, changes in the imaging attributes of the follicular antrum and wall, and perifollicular ovarian stroma indicated potential morphological and functional differences between the antral follicles at different stages in cows (Warren, 2014). These results corroborate with statistical pattern recognition techniques (size, density and ecotexture) on the differentiation between the different stages of the estrous cycle in cows (Tom et al., 1998a e Tom et al., 1998b). However, the values of the echotexture parameters depend on the type and configurations of the ultrasound equipment and lack

consensus on the methodology adopted for processing and reference values. We utilized a linear transducer 7.5 MHz and B mode images, which may limit the number of clear features in the images, but even so accuracy value of 78.8% was observed. Probably in future studies with higher resolution equipments and integrating technologies such as doppler, greater performance of CNNs can be achieved.

Pregnancy diagnosis by ultrasound is conventionally based on locating the conceptus, finding of fetal fluids and membranes and identification of corpus luteum. This procedure is more accurate after 30 days of pregnancy (Beal et al., 1992). When uterine ultrasound was performed between the 21st and 25th day post-reproduction, the sensitivity and specificity were 44.8% and 82.3%, respectively, but increased to 97.7% and 87.7%, respectively, when performed between the 26th and 33rd day after AI (Pieterse et al., 1990; Romano et al, 2006). With the support of appropriate CNNs models with a numerical value of probability of pregnancy, the pregnancy diagnosis can be a relevant support for the farms. The development of models to detect pregnancy in times shorter than 30 days can support farms to reduce breeding season time. However, in some farms the early diagnosis is not used to minimize the handling of the uterus at a stage of greater sensitivity of the embryo. Maybe with the development of models at earlier pregnancy time the uterus handling can be replaced by the exclusive access to the ovaries and the application of CNN models.

From all evaluated architectures, DenseNet121 had the higher accuracy, indicating best performance for classifying both pregnant and non-pregnant cows. This architecture also performed satisfactory with 0.929 of accuracy when classifying maternal-fetal stages in human pregnancy (Burgos-Artizzu et al., 2020). This performance is probably a consequence of its operating principle in relation to the other CNNs evaluated. In Densenets, each layer takes additional input from all previous layers and passes its own resource maps to all subsequent layers, making them fully connected. These networks have skip-connection structures that

concatenate the resource maps and include the advantage of reducing the disappearance gradient problem, reducing the number of parameters to make the network faster to be trained. This improves resource reuse and encourages models to learn the finer details (coming from layers near the input) and more general details (coming from layers near the output) of images. Besides accuracy, DenseNet121 also had higher sensitivity and specificity, which deals specifically with the classification for pregnant and non-pregnant cows, respectively. Is not adequate a recommendation of a specific architecture for future models in this study; however, dense nets can be highlighted as a relevant option to be evaluated. Studies screening a greater number of architectures and including images from several kinds of ultrasound types and different origins still needed.

Noisy and artifacts are commonly visualized in ultrasound images of reproductive structures in cows, and they are mostly related to equipment quality, probe characteristics and experience of the handling professional (Hoskins et al., 2019). When comparing ALL and GR datasets we aimed to check how the presence of artifacts would affect CNNs performance. The architectures ResNet50, SimpleCNN e DenseNet-121 performed better when using GR dataset, whereas ResNeXt50 and InceptionResNetV2 performance were more affected by image quality. InceptionResNetV2 was the most affected by image datasets, mainly for sensitivity and specificity. This difference between architectures dependency on image quality support studies for carefully select CNNs architecture to keep robustness models that support APIs applied by different professionals in several farm conditions in the future.

2.5 Conclusion

This proof-of-concept study demonstrated that convolutional neural networks are capable to identify cow's pregnancy using ultrasound imagens from functional ovaries at 30 days after timed artificial insemination. The effect of image quality on performance is dependent on CNNs architecture. It opens perspectives for studies incrementing images features such as RGB using

doppler and for evaluating acquisition of images at times lower than 30 days after insemination. With the support of CNNs, the human subjectivity can be reduced and using an appropriate model with adequate robustness to deal with lack of image quality, all professionals involved in reproductive evaluation of cows by ultrasonography can be benefited in the future.

Declaration of Competing Interest

We declare no conflict of interest.

Acknowledgements

We are grateful to Grupo Quagliato and Fazenda Santa Rosa (Xinguara, Pará, Brazil) staff for providing the images and information. We thank the Scientific Computing Lab (LCC/UNIFESSPA) for the support in analysis.

References

- Andrade, A. C., 2021 (Será submetido em um banco de repositório; Mendeley data)
- Barbedo, J.G.A., Koenigkan, L.V., Santos, T.T., Santos, P.M., 2019. A Study on the Detection of Cattle in UAV Images Using Deep Learning. *Sensors* 19, 5436. <https://doi.org/10.3390/s19245436>
- Beal, W.E., Perry, R.C., Corah, L.R., 1992. The use of ultrasound in monitoring reproductive physiology of beef cattle. *J. Anim. Sci.* 70, 924–929. <https://doi.org/10.2527/1992.703924x>
- Burgos-Artizzu, X.P., Coronado-Gutiérrez, D., Valenzuela-Alcaraz, B., Bonet-Carne, E., Eixarch, E., Crispi, F., Gratacós, E., 2020. Evaluation of deep convolutional neural networks for automatic classification of common maternal fetal ultrasound planes. *Sci. Rep.* 10, 10200. <https://doi.org/10.1038/s41598-020-67076-5>
- Cairo, F.C., Pereira, L.G.R., Campos, M.M., Tomich, T.R., Coelho, S.G., Lage, C.F.A., Fonseca, A.P., Borges, A.M., Alves, B.R.C., Dorea, J.R.R., 2020. Applying machine learning techniques on feeding behavior data for early estrus detection in dairy heifers. *Comput. Electron. Agric.* 179, 105855. <https://doi.org/10.1016/j.compag.2020.105855>
- Christiansen, F., Epstein, E.L., Smedberg, E., Åkerlund, M., Smith, K., Epstein, E., 2021. Ultrasound image analysis using deep neural networks for discriminating between benign and malignant ovarian tumors: comparison with expert subjective assessment. *Ultrasound Obstet. Gynecol.* 57, 155–163. <https://doi.org/10.1002/uog.23530>
- He, K., Zhang, X., Ren, S., Sun, J., 2015. Deep Residual Learning for Image Recognition. <https://doi.org/https://arxiv.org/abs/1512.03385>
- Herzog, K., Kiossis, E., Bollwein, H., 2008. Examination of cyclic changes in bovine luteal echotexture using computer-assisted statistical pattern recognition techniques. *Anim. Reprod. Sci.* 106, 289–297. <https://doi.org/10.1016/j.anireprosci.2007.05.004>

- Hoskins, P.R., Martin, K., Thrush, A., 2019. *Diagnostic Ultrasound*, 3rd editio. ed. CRC Press, Boca Raton, FL.
- Huang, G., Liu, Z., van der Maaten, L., Weinberger, K.Q., 2016. *Densely Connected Convolutional Networks*.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning: with applications in R* (1st ed.) [PDF]. Springer.
- Li, G., Huang, Y., Chen, Z., Chesser, G.D., Purswell, J.L., Linhoss, J., Zhao, Y., 2021. Practices and Applications of Convolutional Neural Network-Based Computer Vision Systems in Animal Farming: A Review. *Sensors* 21, 1492. <https://doi.org/10.3390/s21041492>
- Li, H., Fang, J., Liu, S., Liang, X., Yang, X., Mai, Z., Van, M.T., Wang, T., Chen, Z., Ni, D., 2020. CR-Unet: A Composite Network for Ovary and Follicle Segmentation in Ultrasound Images. *IEEE J. Biomed. Heal. Informatics* 24, 974–983. <https://doi.org/10.1109/JBHI.2019.2946092>
- Liu, S., Wang, Y., Yang, X., Lei, B., Liu, L., Li, S.X., Ni, D., Wang, T., 2019. Deep Learning in Medical Ultrasound Analysis: A Review. *Engineering* 5, 261–275. <https://doi.org/10.1016/j.eng.2018.11.020>
- MAPA, 2008. Instrução normativa nº 56 de 6 de novembro de 2008. Ministério da Agricultura, Pecuária e Abastecimento. <https://www.gov.br/agricultura/pt-br/assuntos/sustentabilidade/bem-estar-animal/arquivos/arquivos-legislacao/in-56-de-2008.pdf>
- Meiburger, K.M., Acharya, U.R., Molinari, F., 2018. Automated localization and segmentation techniques for B-mode ultrasound images: A review. *Comput. Biol. Med.* 92, 210–235. <https://doi.org/10.1016/j.compbimed.2017.11.018>
- Pierson, R.A., Ginther, O.J., 1984. Ultrasonography of the bovine ovary. *Theriogenology* 21, 495–504. [https://doi.org/10.1016/0093-691X\(84\)90411-4](https://doi.org/10.1016/0093-691X(84)90411-4)
- Pierson, R.A., Ginther, O.J., 1987. Reliability of diagnostic ultrasonography for identification and measurement of follicles and detecting the corpus luteum in heifers. *Theriogenology* 28, 929–936. [https://doi.org/10.1016/0093-691X\(87\)90043-4](https://doi.org/10.1016/0093-691X(87)90043-4)
- Pierson, R.A., Adams, G.P., 1995. Computer-assisted image analysis, diagnostic ultrasonography, and ovulation induction: strange bedfellows. *Theriogenology* 43, 105–112. [https://doi.org/10.1016/0093-691X\(94\)00014-L](https://doi.org/10.1016/0093-691X(94)00014-L)
- Pieterse, M.C., Szenci, O., Willemse, A.H., Bajcsy, C.S.A., Dieleman, S.J., Taverne, M.A.M., 1990. Early pregnancy diagnosis in cattle by means of linear-array real-time ultrasound scanning of the uterus and a qualitative and quantitative milk progesterone test. *Theriogenology* 33, 697–707. [https://doi.org/10.1016/0093-691X\(90\)90547-7](https://doi.org/10.1016/0093-691X(90)90547-7)
- Quirk, S.M., Hickey, G.J., Fortune, J.E., 1986. Growth and regression of ovarian follicles during the follicular phase of the oestrous cycle in heifers undergoing spontaneous and PGF-2_α-induced luteolysis. *Reproduction* 77, 211–219. <https://doi.org/10.1530/jrf.0.0770211>
- Ramasubramanian, K., Singh, A., 2017. *Machine Learning Using R*. Apress, Berkeley, CA. <https://doi.org/10.1007/978-1-4842-2334-5>
- Rocha, J.C., Passalia, F.J., Matos, F.D., Takahashi, M.B., Maserati Jr, M.P., Alves, M.F., de Almeida, T.G., Cardoso, B.L., Basso, A.C., Nogueira, M.F.G., 2017. Automatized image processing of bovine blastocysts produced in vitro for quantitative variable determination. *Sci. Data* 4, 170192. <https://doi.org/10.1038/sdata.2017.192>
- Romano, J.E., Thompson, J.A., Forrest, D.W., Westhusin, M.E., Tomaszewski, M.A., Kraemer, D.C., 2006. Early pregnancy diagnosis by transrectal ultrasonography in dairy cattle. *Theriogenology* 66, 1034–1041. <https://doi.org/10.1016/j.theriogenology.2006.02.044>

- Singh, J., Pierson, R.A., Adams, G.P., 1997. Ultrasound image attributes of the bovine corpus luteum: structural and functional correlates. *Reproduction* 109, 35–44. <https://doi.org/10.1530/jrf.0.1090035>
- Siqueira, L.G.B., Torres, C.A.A., Amorim, L.S., Souza, E.D., Camargo, L.S.A., Fernandes, C.A.C., Viana, J.H.M., 2009. Interrelationships among morphology, echotexture, and function of the bovine corpus luteum during the estrous cycle. *Anim. Reprod. Sci.* 115, 18–28. <https://doi.org/10.1016/j.anireprosci.2008.11.009>
- Srivastava, S., Kumar, P., Chaudhry, V., Singh, A., 2020. Detection of Ovarian Cyst in Ultrasound Images Using Fine-Tuned VGG-16 Deep Learning Network. *SN Comput. Sci.* 1, 81. <https://doi.org/10.1007/s42979-020-0109-6>
- Szegedy, C., Ioffe, S., Vanhoucke, V., Alemi, A., 2016. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning.
- Thijssen, J.M., Herzog, K., Weijers, G., Brockhan-Luedemann, M., Starke, A., Niemann, H., Bollwein, H., de Korte, C.L., 2011. Ultrasound image analysis offers the opportunity to predict plasma progesterone concentrations in the estrous cycle in cows: A feasibility study. *Anim. Reprod. Sci.* 127, 7–15. <https://doi.org/10.1016/j.anireprosci.2011.07.006>
- Ting, F.F., Tan, Y.J., Sim, K.S., 2019. Convolutional neural network improvement for breast cancer classification. *Expert Syst. Appl.* 120, 103–115. <https://doi.org/10.1016/j.eswa.2018.11.008>
- Tom, J.W., Pierson, R.A., Adams, G.P., 1998a. Quantitative echotexture analysis of bovine corpora lutea. *Theriogenology* 49, 1345–1352. [https://doi.org/10.1016/S0093-691X\(98\)00081-8](https://doi.org/10.1016/S0093-691X(98)00081-8)
- Tom, J.W., Pierson, R.A., Adams, G.P., 1998b. Quantitative echotexture analysis of bovine ovarian follicles. *Theriogenology* 50, 339–346. [https://doi.org/10.1016/S0093-691X\(98\)00143-5](https://doi.org/10.1016/S0093-691X(98)00143-5)
- Toosi, B.M., Seekallu, S.V., Pierson, R.A., Rawlings, N.C., 2009. Evaluation of the ultrasound image attributes of developing ovarian follicles in the four follicular waves of the interovulatory interval in ewes. *Theriogenology* 72, 902–909. <https://doi.org/10.1016/j.theriogenology.2009.06.006>
- Warren, L., Murawski, M., Wilk, K., Zieba, D.A., Bartlewski, P.M., 2015. Suitability of antral follicle counts and computer-assisted analysis of ultrasonographic and magnetic resonance images for estimating follicular reserve in porcine, ovine and bovine ovaries ex situ. *Exp. Biol. Med.* 240, 576–584. <https://doi.org/10.1177/1535370214560971>
- Wu, D., Barrett, D.M.W., Rawlings, N.C., Giffin, J.L., Bartlewski, P.M., 2009. Relationships of changes in ultrasonographic image attributes to ovulatory and steroidogenic capacity of large antral follicles in sheep. *Anim. Reprod. Sci.* 116, 73–84. <https://doi.org/10.1016/j.anireprosci.2009.01.011>
- Xie, S., Girshick, R., Dollár, P., Tu, Z., He, K., 2016. Aggregated Residual Transformations for Deep Neural Networks.
- Xu, Y., Vaziri-Pashkam, M., 2021. Limits to visual representational correspondence between convolutional neural networks and the human brain. *Nat. Commun.* 12, 2065. <https://doi.org/10.1038/s41467-021-22244-7>