

UNIVERSIDADE FEDERAL DE MINAS
Instituto de Ciências Agrárias
Programa de Pós-graduação em Produção Animal

Brenda Marques de Paula

**MODELO DE APRENDIZADO PARA CLASSIFICAÇÃO DE ESCORE DE COCHO
EM CONFINAMENTOS DE BOVINOS DE CORTE COM BASE EM IMAGENS**

Montes Claros

2023

Brenda Marques de Paula

**MODELO DE APRENDIZADO PARA CLASSIFICAÇÃO DE ESCORE DE COCHO
EM CONFINAMENTOS DE BOVINOS DE CORTE COM BASE EM IMAGENS**

Dissertação apresentada ao Programa de Pós-graduação em Produção Animal da Universidade Federal de Minas Gerais, como requisito parcial para a obtenção do título de Mestre (a) em Produção Animal.

Orientador: Dra. Amália Saturnino
Chaves

Coorientadores:

Dr. Alcinei Místico
Azevedo

Dr. Luiz Maurílio da
Silva Maciel

Montes Claros
2023

Paula, Brenda Marques de.

P324m
2023 Modelo de aprendizado para classificação de escore de cocho em confinamentos de bovinos de corte com base em imagens [manuscrito] / Brenda Marques de Paula. Montes Claros, 2023.
75f. : il.

Dissertação (mestrado) - Área de concentração em Produção Animal. Universidade Federal de Minas Gerais / Instituto de Ciências Agrárias.

Orientadora: Amália Saturnino Chaves

Banca examinadora: Amália Saturnino Chaves, Luiz Maurílio da Silva Maciel, Lívia Vieira de Barros, Luiz Gustavo Ribeiro Pereira.

Inclui referências: f.36-42

1. Bovino -- Uso eficiente de rações -- Teses. 2. Bovino de corte -- Alimentação e rações -- Teses. 3. Redes neurais (Computação) -- Teses. 4. Aprendizado do computador -- Teses. I. Chaves, Amália Saturnino. II. Universidade Federal de Minas Gerais. Instituto de Ciências Agrárias. III. Título.

CDU: 636.2.033



Universidade Federal de Minas Gerais
Instituto de Ciências Agrárias
Colegiado de Pós-Graduação em Produção Animal

ATA DE DEFESA DE DISSERTAÇÃO

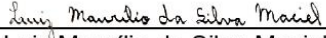
Aos 18 dias do mês de abril de 2023 às 14:00 horas, sob a Presidência da Professora Amália Saturnino Chaves, D. Sc. (Orientadora – UFJF) e com a participação dos Professores Luiz Maurílio da Silva Maciel, D. Sc. (Coorientador - UFJF), Lívia Vieira de Barros, D. Sc. (UFMG/ICA) e do Pesquisador Luiz Gustavo Ribeiro Pereira, D. Sc. (Embrapa – Gado de leite), reuniu-se, por videoconferência, a Banca de defesa de dissertação de **Brenda Marques de Paula**, aluna do Curso de Mestrado em Produção Animal. O resultado da defesa de dissertação intitulada **“Modelos de aprendizado para classificação de escore de cocho em confinamentos de bovinos de corte com base em imagens”**, sendo a aluna considerada (aprovado(a)/reprovado(a)) **aprovada**. E, para constar, eu, Professora Amália Saturnino Chaves, Presidente da Banca, lavrei a presente Ata que depois de lida e aprovada, será assinada por mim e pelos demais membros da Banca examinadora.

OBS.: A aluna somente receberá o título após cumprir as exigências do ARTIGO 53 do regulamento e da resolução 05/2016 do Curso de Mestrado em Produção Animal.


Montes Claros, 18 de abril de 2023.



Amália Saturnino Chaves
Orientador



Luiz Maurílio da Silva Maciel
Coorientador



Lívia Vieira de Barros
Membro



Luiz Gustavo Ribeiro Pereira
Membro

À Deus, meus pais e irmão, dedico.

“Conservar a certeza do que ensina, mas estudar sempre, a fim de ouvir com equilíbrio, ver com segurança, analisar com proveito e servir mais”

Emmanuel (Espírito) – Francisco Cândido Xavier

RESUMO

A avaliação de escore de cocho permite a avaliação das sobras de alimento no cocho usando-se notas ou escore, permitindo ajustar a quantidade de alimento fornecida por dia com objetivo de otimizar o desempenho dos animais e diminuir o desperdício de alimentos. O objetivo deste trabalho foi desenvolver uma tecnologia móvel capaz de auxiliar na leitura do escore de cocho em confinamentos de bovinos de corte por meio de imagens. Para o desenvolvimento da plataforma, inicialmente foram incluídas informações de composição da dieta e imagens de escore de cocho para criação de bases diferentes de acordo com escore. Simultaneamente foi realizado estudo de identificação de imagens coletadas baseadas em aspectos cromáticos e visão computacional. Essas informações demonstraram que na maioria dos confinamentos foram utilizados sorgo, silagem, cevada, caroço de algodão e fubá para compor a dieta dos animais. Além disso, os cochos de cimento e plástico em formato J e quadrado, foram os mais utilizados. Ademais, a rede neural convolucional proposta por este trabalho demonstrou que as imagens em tamanho 108 x 108 obtiveram maior precisão (85,45%) na classificação por escores além de apresentarem tamanho do modelo (59 MB) que seria possível embarcá-lo em dispositivo móvel. Com isso, o modelo apresentou desempenho promissor tanto para a tarefa de classificação baseada em escores quanto aquela baseada nos ajustes da quantidade de alimento.

Palavras-chave: avaliação visual; comportamento alimentar; machine learning; manejo nutricional; pecuária 5.0; nutrição de precisão

ABSTRACT

The evaluation of feed bunk score is a fundamental technique for evaluating the leftover food in the feed bunk using notes or scores, which allows adjusting the amount of food supplied per day to optimize animal performance and reduce food waste. Therefore, the objective of this work was to develop a mobile technology capable of assisting in reading the feed bunk score in beef cattle feedlots by using digital images. To develop the platform, we initially included information on diet composition and feed bunk score images to create different bases according to the score. Concurrently, a study was conducted to identify the collected images based on chromatic aspects and computer vision. This information showed that in most feedlots sorghum, silage, barley, cottonseed, and cornmeal were used to compose the animals' diet. In addition, the most used bunks were cement and plastic, and H-bunk and J-bunk formats. Furthermore, the convolutional neural network proposed by this work showed that images in size 108 x 108 obtained higher accuracy (85.45%) in the classification by scores besides presenting a model size (59 M.B.) that would be possible embedded in an application. Thus, the model showed promising performance for both the score-based classification task and the one based on adjustments of the amount of food.

Key words: application visual assessment; food behavior; machine learning; livestock 4.0; precision nutrition

LISTA DE ILUSTRAÇÕES

Figura 1 – Leitura de escore de cocho.....	23
Figura 2 - Callan Broadbent Feeding System.....	30
Figura 3 – Vytelle Sense.....	31
Figura 4 - Examples of feed bunks score images	46
Figura 5 - Proposed convolutional neural network mode	61
Figura 6 - Confusion matrix of the best input size (108 x 108) on the best stratified cross-validation for the score classification	66
Figura 7 - Confusion matrix of the best stratified cross validation for adjustment classification	67

LISTA DE TABELAS

Tabela 1- Sistema de classificação de escore de cocho SDSU (South Dakota State University).....	24
Tabela 2- Sistema de pontuação de cocho.....	25
Tabela 3- Leitura de cocho do Southeast Colorado Research Center e sistema de pontuação.....	26
Tabela 4- Especification table.....	43
Tabela 5- Feed bunk scoring SDSU (South Dakota State University)	45
Tabela 6- Distribution of the dataset samples, by score.....	46
Tabela 7- Annotations in the XML file	47
Tabela 8- Data acquisitions steps.....	49
Tabela 9- Feed bunk scoring SDSU (South Dakota State University)	54
Tabela 10- Distribution of the dataset samples, by score	59
Tabela 11- Average of overall and class accuracies of the 6 stratified cross-validations. The best input size, according to the highest overall accuracy, the highest accuracies per class, and the smallest standard deviation (SD) among classes, prediction time and model size were highlighted.....	64
Tabela 12- Average overall and class accuracies of the 6 stratified cross-validation. The best input size obtained in the score classification task (108 x 108) was used.....	65
Tabela 13- Average overall accuracy of the validation and test set for both classification tasks.....	68

LISTA DE ABREVIATURAS E SIGLAS

CMS	Consumo de matéria seca
GPD	Ganho de peso diário
IA	Inteligência artificial
MAE	Erro absoluto da média
MS	Matéria seca
TIC	Tecnologia da informação e comunicação
RGB image	Imagens em cores vermelho, verde, azul
RMSEP	Erro de predição da média
COT	Custo Operacional Total
GMD	Ganho médio diário
GPT	Ganho de peso total
GMC	Ganho médio de carcaça em arrobas
RNAs	Redes neurais artificiais

SUMÁRIO

1	INTRODUÇÃO	13
2	OBJETIVOS	15
2.1	Objetivo Geral.....	15
2.2	Objetivos Específicos.....	15
3	REVISÃO DE LITERATURA	16
3.1	Confinamento de bovinos.....	16
3.2	Manejo alimentar em sistemas confinados.....	19
3.3	Manejo de cocho.....	22
3.4	Aplicações de inteligência artificial na pecuária.....	27
3.5	Referências.....	35
4	ARTIGO(S)	42
4.1	Artigo 1 – Dataset of feed bunk score images of cattle feedlot.....	43
4.2	Artigo 2 – Classification of feed bunk score images using convolutional neural networks.....	52
5	CONSIDERAÇÕES FINAIS	73
	ANEXOS	74
	Anexo A – Certificado de Registro de Programa de Computador.....	74

1 INTRODUÇÃO

O desempenho dos animais está intimamente ligado à correta ingestão, em quantidade e qualidade, da dieta formulada. Entretanto, há diferentes sistemas de manejo alimentar, o que pode interferir no resultado. Dessa forma, é importante o uso de alternativas que permitam monitorar a eficiência desse manejo (LUZ et al., 2019). A classificação de escore de cocho é uma avaliação visual e, portanto, subjetiva, que consiste em analisar a quantidade de sobras deixadas nos cochos durante as últimas 24 horas. Esta avaliação é feita diariamente, antes do primeiro trato do dia. O volume das sobras é correlacionado a escores que sugerem ajustes na quantidade ofertada conforme a necessidade em cada lote de animais (LOY et al., 2016). Assim, é possível melhorar o atendimento às exigências nutricionais e minimizar o desperdício e deterioração dos alimentos (LUZ et al., 2019).

Buscando alternativas para otimização do trabalho no campo, o emprego de tecnologias tem sido importante para produtores rurais de todo o país. Técnicas de processamento de imagens (GONZALEZ e WOODS, 2000; HOSHIRO e GOLDSCHIMIDT, 2008) e visão computacional (SZELISKI, 2010) vêm sendo aplicadas com sucesso para solução de problemas em diversas áreas. É possível observar que, nos dias atuais tem ganhado destaque em visão computacional os termos aprendizado de máquina (*machine learning*) e aprendizado profundo (*deep learning*) (LECUN et al., 2015), que estão associados a solução de problemas de aprendizado a partir de bases de imagens e vídeos. Logo, o uso de tecnologia da informação e comunicação (TIC) pode automatizar a captura e interpretação das imagens de quantidade de sobras; minimizar o tempo gasto para realizar a avaliação; reduzir a necessidade de pessoa treinada e conseqüentemente a subjetividade da avaliação, haja vista que, baseado no contexto econômico a que este projeto se refere, é notável a

necessidade de usar estratégias baseada em dados para otimizar o manejo alimentar de bovinos confinados.

Dessa forma, buscou-se a utilização de técnicas de processamento de imagens e visão computacional para o aprendizado e determinação do escore de cocho a partir de uma base de imagens. A tecnologia proposta é de uso simples uma vez que há somente a necessidade de uma câmera de smartphone para capturar as imagens. Além disso, é promissor o desempenho de classificação além da rapidez de resposta da rede neural convolucional. Aliado a isso, é uma tecnologia com potencial de ser embeccada para o desenvolvimento de aplicativos que poderão direcionar a tomada de decisão no manejo alimentar de bovinos confinados. Ademais, é de baixo custo, o que permite auxiliar maior número de confinadores.

2 OBJETIVOS

2.1 Objetivo Geral

Desenvolver modelo preditivo de escore de cocho com base em imagens RGB para aplicação em confinamentos de bovinos de corte.

2.2 Objetivos Específicos

- Gerar banco de dados de imagens obtidas com diferentes dispositivos, em diferentes condições de fazenda, em distintas estruturas físicas de cocho e contemplando os diferentes escores de cocho;
- Desenvolvimento e validação de um protótipo de modelo preditivo funcional utilizando linguagem de programação orientada a objetos com o objetivo de prever o escore de cocho;
- Disponibilizar algoritmo de tomada de decisão com base em dados para ajustes na quantidade de dieta a ser mantida, reduzida ou aumentada.

3 REVISÃO DE LITERATURA

3.1 CONFINAMENTO DE BOVINOS

O sistema de produção de bovinos a pasto, predominante no Brasil, contribui para o saldo positivo do comércio desses animais no país, no entanto seu maior tempo de ciclo produtivo delonga o resultado financeiro final (MOREIRA et al., 2015). Além disso, a diminuição de áreas destinadas à bovinocultura devido à expansão das lavouras como soja e milho, cujos lucros são mais significativos, fez com que o sistema de terminação em confinamentos se tornasse, cada vez mais, uma alternativa frente ao sistema de pastejo (MEDEIROS, 2013).

Portanto, ao longo dos anos a estrutura produtiva de confinamentos tem sido utilizada para reduzir, significativamente, o tempo necessário para o abate e conseqüentemente aumentar a produtividade (NICHELE et al., 2015). O confinamento é uma prática de manejo habitualmente utilizada na fase de terminação dos animais, entretanto, pode ser utilizada também na fase de recria, de forma a intensificar os ganhos encurtando o ciclo produtivo. O tempo de confinamento pode variar entre 80 e 120 dias dependendo do objetivo do pecuarista (OLIVEIRA e MILLEN 2014).

Esse manejo consiste em separar os animais em lotes com área delimitada em metros quadrados dimensionados por animal, e o fornecimento da alimentação é determinada e acondicionada em cochos, além disso há fornecimento de água *ad libitum* em bebedouros (MEDEIROS et al., 2015). É recomendado que as baias do confinamento tenham 10 m² por animal de área de cocho considerando 0,55 a 0,70 m lineares por animal. Os bebedouros devem ser dimensionados a fim de atender o consumo de água de cerca de 8 a 10% do peso vivo mantendo-se o bem estar dos animais (DIAS FILHO, 2011;

GUIMARÃES, JUNIOR, OLIVEIRA, 2017).

Além disso, outra recomendação para o confinamento é a homegeneidade dos lotes visto que a dieta é calculada com base no peso corporal inicial, na idade fisiológica, sexo, padrão racial e grau de acabamento em que será estimado um ganho médio diário (GMD) a ser alcançado alterando-se a ingestão de matéria seca (MS) conforme o objetivo do confinador (OLIVEIRA e MILLEN, 2014). Em bovinos confinados é utilizado teor mínimo de cerca de 20% de fibra fisicamente efetiva visando o adequado funcionamento ruminal, estímulo da mastigação, produção de saliva e consequente tamponamento ruminal (NRC, 2001; ZEBELI et al., 2012).

Apesar do confinamento ter se tornado uma ferramenta estratégica para a pecuária, é importante que haja planejamento antes e durante a sua implantação, haja vista que este sistema é oneroso. Dentre os principais custos do confinamento pode-se destacar a aquisição de animais e insumos referentes à alimentação. Estes são os principais fatores a serem analisados quanto a viabilidade e rentabilidade do confinamento (SILVA et al., 2018). Os custos com a alimentação podem chegar até 27,56% dos custos operacionais totais (COT); contudo, ao desconsiderar os custos de aquisição dos animais sua representação passa a ser, em média, 94,15%. As diferenças nos preços dos insumos, na proporção de volumoso e concentrado da dieta assim como o peso corporal dos animais podem explicar a variação percentual da alimentação no COT (MOREIRA et al., 2015). Porém, em estudo que avaliou em totalidade a viabilidade do confinamento, Lopes et al (2013) apontam que os itens em propriedade lucrativa e com potencial de expansão mais representativos nos custos totais foram, em ordem decrescente: aquisição de animais; alimentação; despesas diversas, como aluguel de máquinas, principalmente e depreciação.

Além disso, para atingir os objetivos do confinamento, a eficiência nutricional e econômica dos animais nesta fase tem sido influenciada, entre outros fatores, pelo peso corporal dos bovinos no início do confinamento, pelo consumo de matéria seca (CMS) e pelo desempenho dos mesmos (NICHELE et al., 2015).

Ao avaliarem o desempenho produtivo e econômico de três grupos genéticos (Guzonel, Guzolando e Tricross) recriados a pasto e terminados em confinamento, Moreira et al. (2015) observaram que todos os animais demonstraram desempenho satisfatório haja vista que não houve ($P > 0,05$) diferença entre os valores de GMD (755 g), ganho de peso total (GPT) (893 @) e ganho médio de carcaça em arrobas (GMC) (9,52 @). Além disso, o valor da diária do confinamento foi semelhante entre os tratamentos, cuja média foi de R\$ 6,25.

Este índice é frequentemente utilizado entre os confinadores para mensurar os custos diários – como alimentação, mão de obra, combustível, despesas gerais, dentre outros – por boi no confinamento, não incluindo o custo com aquisição dos animais. Ademais, os animais do grupo genético Tricross mostraram-se mais eficiente pois apresentaram menor ($P < 0,05$) COT por arroba produzida (R\$ 91,48) e foram mais eficiente na produção de carcaça (79,79 kg) quando comparados aos demais grupos genéticos. Logo, esses resultados demonstram a importância da estimativa dos custos de produção haja vista que há a necessidade de adequado planejamento.

3.2 MANEJO ALIMENTAR EM SISTEMAS CONFINADOS

O manejo alimentar dentro de sistemas confinados, objetiva assegurar a disponibilidade de alimento, sem que haja desperdício e

deterioração, atender as exigências nutricionais e reduzir a variação de consumo (LUZ et al., 2019). A flutuação do CMS que pode ser observada nos confinamentos é associada à fatores como: animal, os alimentos, o ambiente e manejo, tempo de acesso ao alimento, frequência de alimentação, e comportamento ingestivo (VAN SOEST, 1994). Ademais, o controle do consumo alimentar de animais confinados é considerado mais simples quando comparado àqueles em sistema de pastejo, haja vista, que todo o alimento é fornecido no cocho, o que facilita a coleta das informações (MEDEIROS et al., 2014).

Com isso, sabe-se que a nutrição exerce influência sobre o desempenho zootécnico, tendo em vista que conforme a dieta, há alterações na população e proporção de microrganismos ruminais, na taxa de passagem dos alimentos no trato gastrointestinal, motilidade e velocidade de absorção dos nutrientes (ARCURI; LOPES; CARNEIRO, 2006). Dessa forma, no manejo alimentar pode-se citar várias estratégias como o período de adaptação à nova dieta, frequência de fornecimento da dieta, horário de oferta da dieta e manejo de cocho.

Com o objetivo de conhecer as práticas de manejo nutricional adotadas em confinamentos brasileiros, Pinto e Millen (2018) entrevistaram 33 nutricionistas, responsáveis por 4.228.254 animais. Os autores observaram que 57,6% dos entrevistados recomendam a adaptação dos bovinos em programa de *step up*. O estudo mostrou que em média são usados 3,2 tipos de dietas durante esse período no qual são necessários aproximadamente 6,3 dias de fornecimento para cada formulação. Com isso, são dispendidos 16,2 dias para realizar a adaptação dos animais, diferente do que sugerem Millen et al. (2009) e Oliveira e Millen (2014), os quais indicam 17,1 e 18,6 dias, respectivamente. Estes estudos demonstram a

capacidade dos confinamentos brasileiros em atingir 14 dias de adaptação cujos animais apresentam melhor desempenho e menor ocorrência de rumenite e lesões hepáticas (PERDIGÃO et al., 2017).

Período de adaptação mais curto pode ser atrativo para os pecuaristas uma vez que a produção de carne em sistema intensivo é onerosa. Touros Nelore podem ser adaptados por 14 dias em protocolos de dietas “*step-up*”, cuja estratégia é aumentar gradativamente o teor de carboidratos na dieta, ou por restrição da ingestão da formulação de terminação, uma vez que o período adaptativo mais curto não comprometeu ($P > 0,05$) o desempenho enquanto resultou em maior ($P < 0,05$) peso de carcaça quente (PARRA et al.; 2019).

Além das estratégias de adaptação à dieta, é reportado na literatura o efeito da frequência de alimentação sobre o desempenho de animais confinados. Schutz et al. (2011) avaliaram o efeito de um, dois e três arraçoamentos no dia sobre a performance e características de carcaças de novilhos. O estudo demonstrou que animais alimentados três vezes ao dia apresentaram maior ($P < 0,05$) peso ao final do período experimental (604 kg) quando comparados àqueles alimentados uma (593 kg) e duas vezes (593 kg) ao dia. Além disso, o ganho médio diário ($P < 0,03$) aumentou linearmente a medida em que se aumentou a frequência de alimentação e atingiu médias de 1,63; 1,64; e 1.71 kg de GPD para os tratamentos 1x, 2x, e 3x, respectivamente. Entretanto, a eficiência alimentar foi semelhante ($P > 0,05$) entre os tratamentos. Para as características de carcaça, os autores observaram que o peso da carcaça quente obteve aumento linear ($P < 0,01$) e quadrático ($P < 0,05$) apresentando médias de 362 kg; 360 kg; e 370 kg, para os tratamentos 1X, 2X e 3X respectivamente. Logo, os autores sugerem que fracionar a alimentação em 3 vezes ao dia melhora a performance e peso

da carcaça quente. Entretanto, sugerem a avaliação dessas operações sobre os custos e rentabilidade do confinamento.

Em relação ao horário de fornecimento da dieta, durante os meses de verão, as horas de maior incidência de calor acontecem entre 12:00 e 14:00 horas, e quando ocorre pico de alimentação neste momento, os animais sofrem por estresse térmico. Além do calor do ambiente, o incremento calórico necessário ao processo de digestão, potencializa o desconforto. Neste caso, arraçoamentos que ocorrem ao final da tarde ou início da noite podem ser vantajosos uma vez que o calor gerado pela alimentação e consequente digestão ocorre durante as horas mais amenas do dia, em que o animal possui maior capacidade de dissipar o calor (HOLT, 2011). Estudo realizado por Reinhardt e Brandt (1994) reforçam a ideia ao avaliar novilhos Holstein, recebendo dietas semelhantes, alimentados às 8:00 e às 20:00 horas. Esses animais apresentaram aumento ($P < 0,05$) de 18% no ganho de peso diário ao se alimentarem no período noturno.


Os estudos reforçam o consenso acerca da importância do manejo alimentar no confinamento, haja vista que, são diversos os fatores que influenciam o desempenho dos animais (PERDIGÃO et al., 2017; PINTO e MILLEN, 2018). Sendo assim, estratégias de adaptação à dieta e horários de arraçoamento podem ser usados conforme as especificidades de cada confinamento.

3.3 MANEJO DE COCHO

A leitura e classificação do escore ou manejo de cocho é uma avaliação visual e consiste em analisar a quantidade de sobras de alimento deixadas no cocho durante as últimas 24 horas. Para cada volume de sobras, são atribuídas pontuações específicas que sugerem ajustes na quantidade

de alimento a ser fornecido durante o dia, de acordo com as necessidades dos animais de cada lote (Figura 1) (LOY et al., 2016). Independente da abordagem adotada é comum que o colaborador da fazenda avalie cada cocho diariamente, antes do primeiro trato do dia, embora em algumas propriedades também seja feita a leitura entre um trato e outro. Neste momento não há necessidade de certo nível de detalhamento pois o objetivo é analisar a sobra ou falta de alimento entre os períodos de arraçoamento.

Figura 1- Leitura de escore de cocho



Legenda: A) escore 0; B) escore $\frac{1}{2}$; C) escore 1; D) escore 2; E) escore 3 e F) escore 4

Fonte: Da autora (2022)

O manejo de cocho objetiva minimizar a variação na ingestão de matéria seca e os distúrbios digestivos ocorridos devido a uma dieta de alta densidade energética, típica no sistema de confinamento. Além disso, procura relacionar, de forma positiva, a quantidade de dieta fornecida e a quantidade de alimento em que o animal é capaz de ingerir. Dessa forma, o arraçoamento consistente permite a manutenção do padrão fermentativo ruminal e conseqüentemente há adequado aproveitamento dos alimentos ingeridos (PRITCHARD e BRUNS, 2003).

O sistema de alimentação em confinamentos pode ser feito de duas formas: *ad libitum* (à vontade) ou por manejo do escore de cocho. No primeiro sistema não há sobras e geralmente observa-se maior variação de consumo e provável desperdício de alimento. Entretanto, no sistema de manejo de cocho é considerada certa quantidade de sobra e os animais recebem de 92 a 96% da quantidade que consumiriam se estivessem recebendo ração *ad libitum*. Cada propriedade pode adotar diferentes métodos para o monitorar o consumo alimentar com base no objetivo do seu sistema (LOY et al., 2016). A metodologia proposta por Pritchard e Bruns (2003) e desenvolvida na South Dakota State University (SDSU) é amplamente utilizada em pesquisas. Neste sistema, os escores variam de 0 a 4 e, os ajustes estão sujeitos ao aumento ou diminuição de 1kg da MS da dieta ou, a manutenção da quantidade fornecida no dia anterior (Tabela 1).

Tabela 1 – Sistema de classificação de escore de cocho SDSU (South Dakota State University)

Escore	Característica	Ajuste
---------------	-----------------------	---------------

0	Cocho limpo (sem sobras)	Aumento de 1kg de MS na dieta ou 5%
1/2	Alimento disperso – 5% de sobra. Maior parte do fundo do cocho exposta	Aumento de 1kg de MS da dieta ou 5%
1	Camada fina (< 5 cm) – 5 a 10% de sobra	Mantém a quantidade fornecida
2	Camada média (5 a 8 cm) – 25% de sobra	Diminui 1 kg de MS da dieta ou 5%
3	Camada grossa (> 8 cm) – 50% de sobra	Diminui 1kg de MS da dieta ou 5% - observar outros problemas
4	Alimento intacto	Diminui 1kg de MS da dieta ou 5% - observar outros problemas

Fonte: Adaptado de PRITCHARD e BRUNS (2003)

Esta metodologia foi modificada e adaptada para avaliar o efeito dos manejos *ad libitum* e *slick-bunk*, conhecido popularmente como bica corrida, e a densidade aparente do milho floculado sobre o desempenho e saúde de novilhos confinados. Nesta abordagem os escores passam a ser: 0, 1/2, 1, 1 1/2, 2, 3 e 4 e as características que os definem são diferentes do sistema SDSU (Tabela 2). No sistema modificado, o aumento do número de escores possibilitou aos autores determinar diferenças mais sutis entre os escores. Outra diferença entre os sistemas diz respeito aos ajustes sugeridos no qual o sistema SDSU atribui à cada pontuação um ajuste. Entretanto, na metodologia modificada há diminuição do arraçoamento caso o escore seja igual ou maior que 2, enquanto o aumento do fornecimento de ração se dá quando o escore é menor ou igual a 1 (SMOCK et al., 2021).

Tabela 2- Sistema de pontuação de cocho

Escore	Descrição
0	Nenhum alimento no cocho
$\frac{1}{2}$	De 1 a 2% de sobra
1	Até 5% de sobra
1 1/2	De 5 a 15% de sobra
2	De 15 a 50% de sobra
3	Mais de 50% de sobra
4	Alimento intacto

Fonte: Adaptado de SMOCK et al (2021)

Assim como a metodologia supracitada, aquela proposta por Schutz et al (2011) também se destinou aos manejos *ad libitum* e *slick-bunk*. Entretanto, este sistema se difere dos demais devido ao número de escores, a quantidades a serem ajustadas e o momento em que são feitas as mudanças na quantidade de alimento fornecido (Tabela 3). Nesta metodologia os animais do tratamento *slick-bunk*, manejo de cocho e *ad libitum* requerem os escores 0, $\frac{1}{2}$ e 1 respectivamente. Entretanto, o ajuste no arraçoamento ocorre após três leituras consecutivas de um mesmo escore. Além disso, cochos com escore 1 ou 2 durante três leituras consecutivas ou escore 3 em uma única leitura exigem amostragem, pesagem e análise de matéria seca (MS) da sobra.

Tabela 3- Leitura de cocho do Southeast Colorado Research Center e sistema de pontuação de escore de cocho

Escore	Sobras (kg)	Ajuste
0	Nenhuma sobra no cocho	Aumento de 0,23 kg/animal

½	Até 2,26 kg de sobra/animal	Mantém a quantidade fornecida
1	De 2,27 a 9,05 kg de sobra/animal	Diminuir 0,91 kg/animal
2	De 9,06 a 18,8 kg/animal	Diminuir 1,82 kg/animal
3	Mais de 18,9 kg/animal	Diminuir 2,27 kg/animal

Fonte: Adaptado de SCHUTZ et al (2011)

Embora as metodologias citadas estabeleçam os critérios de classificação, de pontuação e seus respectivos ajustes, ainda há subjetividade em visualizar as sobras e atribuí-las uma nota, haja vista que as conclusões podem variar entre avaliadores. Além disso, é dependente de experiência e bom senso do avaliador. Portanto, a utilização de TIC pode ajudar, de forma objetiva, na padronização, automação e homogeneidade da interpretação (CORREA BERNARDES et al., 2015).

3.4 APLICAÇÕES DE INTELIGÊNCIA ARTIFICIAL NA PECUÁRIA

A inteligência artificial (IA) pode ser definida, de forma generalizada, como o campo da ciência da computação que se ocupa de tornar o comportamento humano, de ser inteligente, em habilidade computacional automática (LUGER, 2007) ou que estuda formas de simular o comportamento inteligente usando métodos computacionais. Devida sua abrangência e complexidade, a IA pode ser dividida em subcampos: Processamento de Linguagem Natural, Robótica, Aprendizagem de Máquina (*machine learning*), Redes Neurais Artificiais, e Visão Computacional.

O processamento de linguagem natural é responsável por conceber a compreensão e geração da linguagem natural humana por parte de sistemas computacionais. A robótica ocupa-se com os estudos e evolução dos robôs como agentes que executam tarefas através da manipulação do

ambiente físico. *Machine learning* é responsável pelo estudo da capacidade de aprendizagem por meio do reconhecimento de padrões através do treinamento de algoritmos, ou seja, a máquina aprende ao observar as análises feitas e posteriormente guarda essas informações. Isso permite que elas sejam capazes de tomar decisões.

Os algoritmos de *machine learning* usam três técnicas de estudos: supervisionado, não supervisionado e por reforço (RUSSELL e NORVIG, 2013). Um exemplo de aplicação desta ferramenta é a recomendação de conteúdos na internet baseado no histórico de navegação do usuário. Para a resolução de problemas mais difíceis, é utilizado o *deep learning* cujo aprendizado é mais complexo quando comparado ao machine learning, pois utiliza-se de redes neurais artificiais (RNAs) que são abstrações do modelo biológico do sistema nervoso humano que permitem representar os neurônios como unidades simplistas de computação, e são utilizadas com o objetivo de solucionar problemas de reconhecimento de imagens (CHAMOSO et al. 2014; GUEDES, 2017).

A visão computacional é o subcampo da Inteligência Artificial que permite às máquinas perceber e interpretar imagens simulando a visão humana. Assim é possível criar sistemas que captam imagens por meio de sensores e posteriormente são capazes de analisá-las e processá-las para suas devidas finalidades (RUSSELL e NORVIG, 2013).

O crescente movimento pela agropecuária sustentável e a preocupação com a vulnerabilidade da produção frente às mudanças climáticas, formaram o contexto de inserção da tecnologia da informação no agronegócio. O conceito de Zootecnia de Precisão surgiu como “a integração de conhecimento de áreas relacionadas à automação (mecânica, eletrônica, informática e mecatrônica) com a zootecnia” (NAAS, 2000, p. 43), além de

relacionar-se com a redução de perdas durante o processo de produção através da tecnologia da informação e da comunicação (TIC), por exemplo.

A TIC tem contribuído para a sinergia de diversas áreas do conhecimento permitindo armazenar e processar grandes quantidades de dados e automatizar processos manuais. O seu potencial está na agregação de valor e benefícios para áreas de negócios, mercado, agricultura e meio ambiente (MASSRUHÁ; LEITE; MOURA, 2014). Dentre as suas aplicações destacam-se, por exemplo: sensoriamento remoto; sistema de irrigação inteligente; predição de bem estar animal; manejo e gerenciamento de cochos em confinamentos, e monitoramento do consumo de alimentos (HOMBURGER et al., 2014; MASSRUHÁ; LEITE; MOURA, 2014; MEDEIROS; CUNHA; WANDER, 2015).

Um dos sistemas de alimentação individual utilizados há mais tempo foi criado pela empresa American Calan Gates, o Calan Feeding System (CFS) (COLE; GALYAEN; BROWN, 2006). Os sistemas desenvolvidos pela empresa são destinados a pesquisas de monitoramento de consumo alimentar de bovinos leiteiros e de corte, porém, foram adaptados para cabras, ovelhas e suínos. Estas ferramentas, possibilitam ao pesquisador formular a dieta, controlar e documentar a ingestão alimentar de cada animal em curral coletivo. A atual versão do sistema, o *Calan Broadbent Feeding System*, consiste no reconhecimento eletrônico individual através da ativação das cancelas feitas pelos transponders acoplados no pescoço de cada animal (Figura 2). O sistema funciona para alimentos secos ou úmidos, forragens, concentrados ou misturas podendo ser fornecidos *ad libitum* ou com restrições. O gerenciamento dos padrões de alimentação e dos dados são registrados de forma completa e individual através do *Data Ranger*, máquina equipada com computador capaz de formular, pesar, misturar e distribuir a

ração em cada cocho (AMERICAN CALAN, 1997).

Figura 2- Calan Broadbent Feeding System



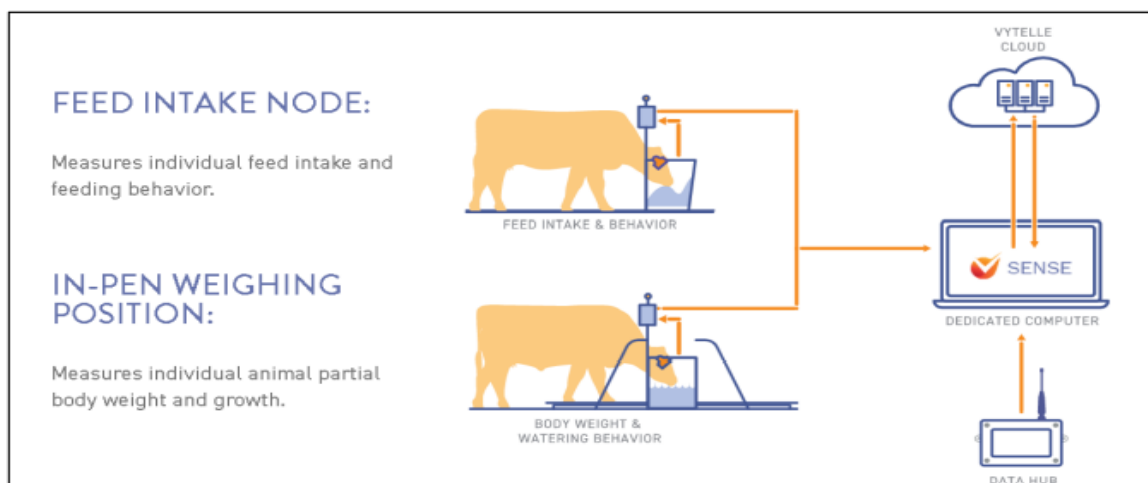
Fonte: AMERICAN CALAN, 1997

O *GrowSafe Beef*, desenvolvido pela empresa *GrowSafe System*, inicialmente foi desenvolvido com a tecnologia *Radio Frequency Identification* (RFID) convencional. Entretanto, identificou-se que metais do ambiente causavam interferências, propagações indesejadas e *carrier phase*, haja vista que, a leitura é automática e dependente da orientação dos brincos. A tecnologia usada atualmente, o *Half Duplex*, permitiu melhorias no sistema possibilitando mensurar a ingestão de matéria seca continuamente a cada segundo, com precisão de cerca de 10 g, utilizando algoritmo de peso “precedente/subsequente”. Devido ao tempo de medição do sistema, não há necessidade de restringir o acesso ao cocho para realizar o fornecimento do

alimento. Os dados obtidos são armazenados em disco rígido e há outro sistema, interativo, para a filtragem de ruídos. Dessa forma, é possível, pelo computador, distinguir o real consumo dos animais visto que cada um é representado graficamente por uma cor (MEDEIROS et al., 2014).

A Vytelle Sense™, plataforma de tecnologia integrada, é parte das soluções tecnológicas da GrowSafe Systems®. O objetivo da plataforma é registrar o consumo de ração e mensurar o ganho de peso dos animais para identificar aqueles com melhor desempenho, ou seja, que apresentam características econômicas importantes. Os dispositivos são considerados de baixo contato e coletam dados de desempenho sem que haja comprometimento no comportamento dos animais, e assim os comunica automaticamente com o *Vytelle Cloud* para que ocorra o processamento e integração dessas com outras informações (Figura 3) (VYTELLE, 2021).

Figura 3- Vytelle Sense™



Fonte: VYTELLE, 2021.

A revolução dos dados em diversos setores da indústria provocou mudanças significativas na ciência, tecnologia e educação. Além disso, o aumento do tamanho dos rebanhos observado nos últimos anos desencadeou dificuldades nas operações pecuárias, principalmente no

monitoramento da saúde e nutrição dos animais (OLIVEIRA et al, 2021). Dessa forma, diversas tecnologias digitais baseadas em visão computacional (WEBER et al., 2020), espectrometria infravermelho (BRESOLIN e DOREA, 2020) e ordenha automática (RODENBURG, 2017) tem sido incorporada ao dia a dia das fazendas, utilizando-as para a predição de peso corporal, fenotipagem de alto desempenho, robotização do processo de ordenha, dentre outras finalidades.

A visão computacional é o subcampo da Inteligência Artificial (IA) que permite às máquinas perceberem e interpretar imagens simulando a visão humana. Assim é possível criar sistemas que captam imagens por meio de sensores ou câmeras que são capazes de analisá-las e processá-las para suas devidas finalidades (RUSSELL e NORVIG, 2013). De acordo com Oliveira et al (2021), 48% dos trabalhos científicos publicado entre 2015 e 2020, que utilizaram *deep learning* para aplicações na pecuária, implementaram algoritmos para realizar classificação de imagens. Além disso, 82% (36 artigos) do total utilizaram Imagens baseadas nas cores primárias aditivas vermelho, verde e azul (imagens RGB).

Dentre as aplicações de *deep learning* é possível destacar a predição de peso corporal de bovinos confinados por meio da medição da área dorsal dos animais em imagens 2D. Para tanto, Weber et. al. (2020) usaram Modelos de Contorno Ativo e algoritmo *Bagging*, no qual alcançou erro absoluto médio (MAE) de 13,44 quilos e erro de predição (RMSEP) de 3,6%. Estes resultados se aproximam daqueles encontrados por LeColzer et al (2019^a) cujo RMSEP foi de 2,72% para imagens 3D. O uso de imagens 2D pode ser justificado pelo baixo custo de aquisição, a redução do processamento do cálculo para a estimativa, além de permitir que esses softwares possam ser embarcados em hardwares menos robustos (WEBER

et al., 2020).

Além disso, a técnica de fotogrametria utilizada no *PhotoModeler Scanner*, possibilita monitorar o consumo de matéria seca em vacas leiteiras. A proposta do sistema consiste no posicionamento de câmeras em diferentes posições do cocho no qual o objetivo é acompanhar a vaca antes e depois de serem alimentadas. A estimativa do volume consumido é realizada de 20 a 30 minutos. Apesar da redução dos custos e do tempo gasto para estimar a ingestão individual de ração, os autores afirmam ser difícil a implementação do sistema. Ademais, os melhores resultados foram obtidos sob condições laboratoriais controladas (BLOCH; LEVIT; HALACHMI, 2019).

Além do monitoramento do consumo de alimentos de animais leiteiros é possível fazer o mesmo com aqueles confinados. O *Feed Quantity Prediction* é um software capaz de indicar ajustes na dieta de bovinos confinados através das sobras encontradas no cocho e assim obter o histórico de ingestão de ração desses animais. Este sistema é fruto da base de dados elaborada com informações sobre a dieta, estimativas de peso dos animais, e avaliação das sobras nos cochos realizadas diariamente (DYCK et al., 2007).

Diante do exposto, os métodos não invasivos de coleta de dados são úteis por não interferir diretamente no organismo que é detentor dessa informação. Assim, o bem-estar dos animais é mantido (ABREU; HERRA; TEIXEIRA, 2006). Além disso, uma plataforma de uso simplificado e de baixo custo torna-se viável, haja vista que, os sistemas de avaliação de consumo disponíveis no mercado são onerosos. Embora a visão computacional tenha ganhado bastante espaço nas operações pecuárias, nenhum trabalho reportou o uso de classificação de imagens destinadas à avaliação de escore de cocho.

3.5 REFERÊNCIAS

ABREU, A. de; HERRERA, V. E; TEIXEIRA, M. A. Mercado mundial de carne

bovina: participação brasileira e barreiras às exportações. In: **CONGRESSO DA SOCIEDADE BRASILEIRA DE ECONOMIA E SOCIOLOGIA RURAL**, 44., 2006, Fortaleza. Anais... Fortaleza: SOBER, 2006

Calan Broadbernt Feeding System. American Calan. Disponível em: <<https://americancalan.com/>> Acesso em: 10 janeiro 2023

ARCURI, P. B.; LOPES, F. C. F.; CARNEIRO, J. C. Microbiologia do rúmen. In: BERCHIELLI, T. T.; PIRES, A. V.; OLIVEIRA, S. G (ed.). **Nutrição de Ruminantes**. Jaboticabal: FUNEP, 2006, p. 111-140

BLOCH, V.; LEVIT, H.; HALACHMI, I. Assessing the potential of photogrammetry to monitor feed intake of dairy cows. **Journal of Dairy Research**, v. 86, n. 1, p. 34-39, 2019. <https://doi.org/10.1017/S0022029918000882>

BRESOLIN, T.; DÓREA, J. R. R. Infrared spectrometry as a high-throughput phenotyping technology to predict complex traits in livestock systems. **Frontiers in Genetics**, v. 11, p. 923, 2020. <https://doi.org/10.3389/fgene.2020.00923>

BERNARDES, J. C., VIEIRA, S. C., BONFIM, E. B., SANT'ANA, R. C. G. (2015). O uso das tecnologias de informação e comunicação na agricultura familiar: um caminho para a sustentabilidade. **Periódico Eletrônico Fórum Ambiental Da Alta Paulista**, 11(9). <https://doi.org/10.17271/1980082711920151175>

DYCK, N. D. TG; CROWE, J. J.; MCKINNON, H. R. I. Feed Prediction and

Management Software for Beef Feedlots. **Canadian Biosystems Engineering**. n. 49, v. 1, 2007

GUIMARÃES, L. A.; JUNIOR, G. N.; OLIVEIRA, P. A. Análise e viabilidade econômica em um sistema de confinamento para a terminação de gado de corte anelorado. **Tekhne e Logos**, v. 8, n. 1, 2017. Disponível em: <<http://revista.fatecbt.edu.br/index.php/tl/article/view/459>>. Acesso em: 15 de fevereiro de 2023.

GONZALEZ, R. C.; WOODS, R. E. Processamento de imagens digitais. São Paulo: Blucher, 2000. 509 p. ISBN 8521202644

HOSHIRO, H. S.; GOLDSCHIMIDT, R. R. Processamento de Imagens. Rio de Janeiro: **Instituto Militar de Engenharia**, 2008. Disponível em: <http://www.comp.ime.eb.br/techreports/repositorio/2008_05.pdf>.

LE COZLER, Y. et al. Volume and surface area of Holstein dairy cows calculated from complete 3D shapes acquired using a high-precision scanning system: Interest for body weight estimation. **Computers and Electronics in Agriculture**, v. 165, p. 104977, 2019. <https://doi.org/10.1016/j.compag.2019.104977>

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444, 2015

LOPES, M. A., RIBEIRO, A. D. B., NOGUEIRA, T. M., DEMEU, A. A., BARBOSA, F. A. Análise econômica da terminação de bovinos de corte em confinamentos no estado de Minas Gerais: estudo de caso. **Revista Ceres**, v. 60, n. 4, 2013.

<https://doi.org/10.1590/S0034-737X2013000400004>

LUGER, G. F. Inteligência artificial: estruturas e estratégias para a solução de problemas complexos. 4ª ed. Porto Alegre: Bookman, 2004.

LOY, DD et al. Iowa beef center. **Iowa State University Animal Industry Report**. 13 (2016), doi: https://doi.org/10.31274/ans_air-180814-547

LUZ, G. B.; DE MATOS, R. F.; CARDOSO, J. B.; BRAUNER, C. C. Exigências nutricionais, cálculos de dieta e mensuração de sobras no manejo nutricional de vacas leiteiras. **Pesquisa Agropecuária Gaúcha**, v. 25, n. 12, p. 16-31, 1 jul. 2019. <https://doi.org/10.36812/pag.2019251/216-31>

MASSRUHÁ, S. M. F. S.; LEITE, M. A. DE A.; MOURA, M. F. Os novos desafios e oportunidades das tecnologias da informação e da comunicação na agricultura (AgroTIC). (Ed). Brasília, DF: Embrapa, v. 1, n. 9, 2014.

MEDEIROS, S. R. de; GOMES, R. da C.; BARIONI, L. G. Ferramentas de pecuária de precisão aplicada à bovinocultura de corte. In: **Simpósio Brasileiro de Pecuária de Precisão Aplicada à Bovinocultura de Corte**, 1., 2014, Campo Grande, Anais... Campo Grande: Embrapa Gado de Corte, 2014. 22 p.

MEDEIROS, J. A. V.; CUNHA, C. A.; WANDER, A. E. Viabilidade econômica de sistema de confinamento de bovinos de corte em goiás. In: **Congresso da sociedade brasileira de economia, administração e sociologia rural**, 53., 2015,

João Pessoa. Agropecuária, meio ambiente e desenvolvimento: anais. João Pessoa: Sober, 2015.

MEDEIROS, J. A. V. Análise da viabilidade econômica de Sistema de confinamento de bovinos de corte em goiás: aplicação da Teoria de opções reais. Universidade Federal de Goiás - Escola de Agronomia e Engenharia de Alimentos. Goiânia - GO, p. 58. 2013. (Dissertação de Mestrado em Agronegócio)

MILLEN, DD, PACHECO, RDL, ARRIGONI, MDB, GALYEAN, ML, VASCONCELOS, JT A snapshot of management practices and nutritional recommendations used by feedlot nutritionists in Brazil, **Journal of Animal Science**, v. 87, p. 3427-3439, 2009, <https://doi.org/10.2527/jas.2009-1880>

NAAS, I. A. Agricultura de Precisão: Zootecnia de Precisão. In: BORÉM, A.; DEL GUIDICE, M. P.; QUEIROZ, D. M.; MANTOVANI, E. C.; FERREIRA, L. R. (Orgs.). **Agricultura de Precisão**. Viçosa: Editora da Universidade Federal de Viçosa, 2000. v. 1, p. 43-63.

NRC. (2001). Nutrient Requirements of Dairy Cattle. 7th rev. ed. Natl. Acad. Sci., Washington, DC.

OLIVEIRA, C. A.; MILLEN, D. D. Survey of the nutritional recommendations and management practices adopted by feedlot cattle nutritionists in Brazil. **Animal Feed Science and Technology**, v. 197, p. 64-75, 2014. <https://doi.org/10.1016/j.anifeedsci.2014.08.010>

OLIVEIRA, D. A. B., PEREIRA, L. G. R., BRESOLIN, T., FERREIRA, R. R. P.,

DOREA, J. R. R. A review of deep learning algorithms for computer vision systems in livestock, **Livestock Science**, v. 253, p. 104700, 2021. <https://doi.org/10.1016/j.livsci.2021.104700>

PARRA F. S. et al. Nellore bulls in Brazilian feedlots can be safely adapted to high-concentrate diets using 14-day restriction and step-up protocols. **Animal Production Science**. n. 59, p. 1858-1867, 2019. <https://doi.org/10.1071/AN18207>

PERDIGÃO, A et al. Effects of restricted vs. step up dietary adaptation for 6 or 9 days on feedlot performance, feeding behaviour, ruminal and blood variables of Nellore cattle, **Journal of Animal Physiology and Animal Nutrition**, v. 102, p. 224-234, 2017, <https://doi.org/10.1111/jpn.12681>

PINTO, A. C. J.; MILLEN, D. D. Nutritional recommendations and management practices adopted by feedlot cattle nutritionists: the 2016 Brazilian survey, **Canadian Journal of Animal Science**, v. 99, n. 2, p. 392-407, 2018, <https://doi.org/10.1139/cjas-2018-0031>

RODENBURG, J. Robotic milking: Technology, farm design, and effects on workflow. **Journal of Dairy Science**, v. 100, n. 9, p. 7729-7738, 2017. <https://doi.org/10.3168/jds.2016-11715>

SCHUTZ, J. S., WAGNER, J. J., NEUHOLD, K. L., ARCHIBEQUE, S. L., ENGLE, T. E. Effect of feed bunk management on feedlot steer intake. **The Professional Animal Scientist**, v. 27, n. 5, p. 395-401, 2011. [https://doi.org/10.15232/S1080-7446\(15\)30511-8](https://doi.org/10.15232/S1080-7446(15)30511-8)

SILVA, G. P.; CONTIN, T. L. M. SANTOS, A. C. R. Custos de confinamento de bovinos de corte no município de Colômbia, SP. **Revista iPecege** v. 4, n. 4, p.7-15, 2018. Colômbia/SP. Disponível em: . Acesso em: 20 mar. 2021. Doi: 10.22167/r.ipecege.2018.4.7

SMOCK, T. M., et al. Effects of feedlot bunk management and bulk density of steam-flaked corn on growth performance, carcass characteristics, and liver score of finishing beef steers fed high-concentrate diets without by-products or tylosin phosphate. **Applied Animal Science**, v. 37, n. 6, p. 722-732, 2021 <https://doi.org/10.15232/aas.2021-02206>

SZELISKI, Richard. Computer vision: algorithms and applications. **Springer Science & Business Media**, 2010

VAN SOEST, P. J. Nutritional ecology of the ruminant. 2. Ed. Ithaca: Cornell University, p. 466, 1994.

WEBER, V. A. M. et al. Cattle weight estimation using active contour models and regression trees Bagging. **Computers and Electronics in Agriculture**, v. 179, p. 105804, 2020. <https://doi.org/10.1016/j.compag.2020.105804>

ZEBELI, Q., et al. Invited review: Role of physically effective fiber and estimation of dietary fiber adequacy in high-producing dairy cattle. **Journal of dairy science**, v. 95, n.3, p.1041-1056, 2012. <https://doi.org/10.3168/jds.2011-4421>

1
2
3
4
5
6

4 ARTIGOS

4.1 Artigo 1- Dataset of feed bunk score images of cattle feedlot

Este artigo foi elaborado conforme normas da Data in Brief.

7 Abstract

8 Bunk management is an important technique to minimize the variations in consumption in
 9 feedlot cattle and can be performed according to the South Dakota State University
 10 classification system. The use of information and communication technology (I.C.T.) can
 11 help, in an objective way, in the interpretation of these measurements. We created a
 12 dataset with the objective of developing an automatic classification method of feed bunk
 13 score. In May, September, and October 2021 and September 2022 we captured 1511 bunk
 14 images in the morning on the farms, in natural lighting conditions with different angles and
 15 backgrounds, and at the height of about 1.5 m from the bunk. After the acquisition of data,
 16 each image was classified according to its score classification.
 17 Additionally, we resized the images to 500x500 pixels, generated annotations files, and
 18 organized the dataset in folders. The images in this dataset were set to be used to train
 19 and validate a machine-learning model to classify feed bunk images. This model can be
 20 used to develop an application to support bunk management.

21

Specifications table

Subject	Applied Machine Learning, Animal Science, Animal Nutrition, Computer Vision and Pattern Recognition
Specific subject area	Feed Bunk Management, Image Classification
Type of data	Feed bunk score images
How the data were acquired	The data were acquired using a high-resolution rear camera of iPhone 11 (Apple) and a digital camera Cyber-shot DSC-H300 (Sony). The images were captured between 6 am and 10 am on different days.
Data format	Raw: .jpg imagens Annotations: .xml and .csv Distribution: .csv
Description of data collection	The dataset is composed of images of leftover rations on feed bunks in feedlot cattle and represents diet composition according to farms. The main ingredients were silage, citrus pulp and concentrate feed. In this dataset, the feed bunks differ in terms of their material and model. Most feed bunks are made of cement, but some are made of wood with the background covered in rubber or plastic material.
Data source location	The images were collected directly from the feedlot in nine different farms in the state of Minas Gerais, Brazil.
Data accessibility	Repository name: Feed Bunk Score Images - FBSI Data identification number: 10.17632/p9cr67s6jp.1 Direct URL to data: https://data.mendeley.com/datasets/p9cr67s6jp

22

23 Value of the data

24 • This dataset can be helpful to develop deep learning algorithms to classify feed
25 images concerning the amount of leftovers, composition, and feed bunk attributes.

26 • The set of images of leftover feed in bunk can contribute to developing research on
27 new methods of managing feedlots for confined cattle.

28 • The methods developed, and technological tools obtained through this data can
29 enable farmers and bunk readers to support the management of animal nutrition and thus
30 optimize the farms' profits.

31 • This dataset can be used to explore the potentialities of computer vision applications
32 in livestock farming operations.

33 • This dataset has the potential to develop new tools capable of assisting in balancing
34 rations, in the recognition by images of the ingredients used, in the observations of the
35 animals' preference for some food and reduce costs with cattle feeding.

36

37 Objective

38 This dataset was created to develop an automatic classification method of feed bunk score.

39 The images could be used to train and validate a machine learning model. This model could
40 be embedded in an application, for mobile devices. In this application the feeder would
41 capture the images using the camera and the application would suggest the adjustments.

42

43 Data description

44 The Feed Bunk Score Images - FBSI dataset is a set of images of leftover rations on feed
45 bunks in feedlot cattle. These images are used for reading and classification of the bunk
46 score. This technique is a visual assessment and consists of analyzing the amount of feed
47 left in the bunk over the last 24 hours. For each volume of leftovers, specific scores are
48 assigned. Such scores can be used to drive adjustments in the amount of feed to be

49 provided during the day, according to the needs of the animals in each herd [1-2]. In this
 50 system, the animals' residual feed is classified into six bunk scores according to the South
 51 Dakota State University (SDSU) score system. For scores 0 and 1/2, an increment
 52 adjustment is recommended. For score 1 a maintenance adjustment, and for scores 2, 3
 53 and 4 a decrement adjustment, according to Table 1 [3]. This visual assessment avoids
 54 wasting feed. Since among the operational expenses of the feedlot, feed costs can reach
 55 60% to 80% of the total, avoiding wasting feed is essential for the producers [4].

56

57 **Table 1**

58 Feed bunk scoring SDSU (South Dakota State University).

Score	Features	Adjustment
0	There is no feed in the feed bunk	Increase 1 kg of DM in the diet or 5%
1/2	Spread food – 5% leftover	Increase 1 kg of DM in the diet or 5%
1	Thin layer (< 5 cm) – 5 to 10% leftover	Keep quantity provided
2	Medium layer (5 to 8 cm) – 25% leftover	Decrease 1 kg of DM in the diet or 5%
3	Thick layer (> 8% cm) – 50% leftover	Decrease 1 kg of DM in the diet or 5% – note other problems
4	Intact food	Decrease 1 kg of DM in the diet or 5% – note other problems

59

60 The dataset is composed of 1511 images of 6 different scores, distributed according to
 61 Table 2. These images represent different diet compositions adopted on the farms.
 62 Furthermore, in this dataset, the feed bunks differ in their material and model. Most feed
 63 bunks are made of cement, but some are made of wood with the background covered in
 64 rubber or plastic material. Figure 1 shows a sample of each score image.

65

66 **Table 2**

67 Distribution of the dataset samples, by score.

Score	Amount of samples	Proportion (%)
0	85	5.63
1/2	266	17.6
1	265	17.54
2	118	7.81
3	270	17.87

68
69

A) Score 0

C) Score 1/2

B) Score 1

70
71
72
73

F) Score 2

E) Score

D) Score 4

74
75
76
77

Fig. 1. Examples of feed bunks score images.

78
79
80
81

Because of the high similarity between classes and high intra-class variability, distinguishing some classes can be a complex task. For these reasons, the images labeling in our dataset was performed by specialists in the animal nutrition field, where:

- 84 • Score: represents the score according to Feed Bunk Scoring SDSU system (South
- 85 Dakota State University).
- 86 • Number: represents the image number on the dataset.
- 87 • jpg: image format.

88 We also provide an XML file for each image containing some annotations. Table 3 presents

89 a description and samples of the annotated attributes. For some farms, we could not collect

90 the diet composition data. We indicated this field as “MD” (Missing Data) for these images.

91 Since score 0 represents empty feed bunk, we defined the composition diet field in images

92 of score 0 as “NApp” (Not Applicable). Additionally, we provide a CSV file named
93 “annotations.csv” containing the annotation of all images.

94 To standardize the comparison between classification methods and mitigate possible
95 biases we suggest a 5-5-fold stratified cross-validation distribution for our dataset. For each
96 distribution and each fold, we provide CSV files containing the list of train, test and
97 validation images.

98 We do not provide a bounding box for each image. This is a pre-processing step, which
99 can be performed or not according to the pipeline designed by everyone who will explore
100 the dataset.

101 **Table 3**
102 Annotations in the XML file.

Attribute	Description	Type	Example
Name ID	Image identification	Text	score-0_0
Farm	Location where the images were captured	Int	0, 1, 2, etc
Diet composition	Description of the ingredients which the diet is composed	Text	Cornmeal, sorghum, cottonseed, barley
Feed bunk background	Material that composes the feed bunk background	Text	Cement, cement-ceramic, plastic
Format	Geometric form of the feed bunk	Text	H-bunk, J-bunk, feed curb
Adjustment	Suggestion for adjusting the amount of feed supplied to the animals during the day	Text	Increase, maintenance, decrease
Score	Feed bunk scoring according to the leftover feed in the bunk	Real	0, 0.5, 1, 2, 3 and 4

103

104 **Experimental design, materials and methods**

105 The feed bunk images were acquired using a high-resolution rear camera of iPhone 11
106 (Apple) and a digital camera Cyber-shot DSC-H300 (Sony). We also recorded some videos
107 and extracted the frames through Python scripts. To ensure variability, we sampled the
108 videos every 30 frames. The images were collected on different days, between 6 am and
109 10 am, from eight farms in the state of Minas Gerais, Brazil. We performed the collections
110 in May, September, and October 2021, and September 2022.

111 The original images had six different spatial resolutions (5152 x 3864, 4608 x 3456, 4032

112 x 3024, 1280 x 958, 1920 x 1080, and 960 x 1280 pixels) and sRGB color space. We
 113 reduced the images to 500x500 pixels, which is a suitable resolution for extraction of
 114 predictive visual features. Considering the state-of-the-art, several deep convolutional
 115 neural networks have an input size of 224 x 224 pixels [5-7]. Another aspect to downscaling
 116 image resolutions is the dataset storage scalability, which can become a limitation if dataset
 117 updates with additions of new images occur.

118 To account for variations in environmental conditions, we manually captured the images in
 119 natural lighting conditions with different angles and backgrounds and at the height of about
 120 1.5 meters from the bunk. In each bunk visited, the photos were captured across the entire
 121 length. We did not use a static camera that always pointed to the bunker, but the capture
 122 device stood in the hand of the person responsible for the capture, which pointed to the
 123 bunker. We collected the images during the daily routine of each farm. Therefore, they are
 124 representations of different bunk management and diet composition and animals of
 125 different breeds whose feed consumption is not the same. Thus, this dataset is unbalanced
 126 since some scores are more commonly encountered than others. After acquiring data, we
 127 classified the images according to feed bunk scoring SDSU [4] and organized them into
 128 their folders. Table 4 summarizes the steps of data acquisition.

129

130 **Table 4**
 131 Data acquisition steps.

No	Steps	Time	Activity
1	Data collecting	May, September and October 2021, and September 2022	The images were captured in the morning, in natural lighting conditions with different angles and background and at a height of about 1.5 m from the bunk
2	Images classification	May, September and October, and September 2022	After acquisition data each image was classified according to its score classification
3	Images processing and dataset organization	October and November 2022	Images were resized to 500x500 pixels, XML and CSV files were generated and dataset organized in folders

132

133 **Ethics statements**

134 There is no conflict of interest. The data is available in the public domain.

135

136 **CRedit author statement**

137

138 **Brenda Marques de Paula:** Conceptualization, Data collection, Data curation, Writing –
139 original draft reviewing and editing. **Gabriel Rezende da Silva:** Data curation, Writing –
140 reviewing and editing – Validation. **Brian Luís Coimbra Maia:** Data curation, Writing –
141 reviewing and editing – Validation. **Valdo Martins Soares Júnior:** Data collection, Writing
142 – reviewing and editing. **Sabrina Evelin Ferreira:** Data curation, Writing – reviewing and
143 editing. **Mathews Edwirds Gomes Almeida:** Data curation, Writing – reviewing and editing
144 – Validation. **Amália Saturnino Chaves:** Data curation, Methodology, Supervision,
145 Funding acquisition, Writing – reviewing and editing. **Luiz Maurílio da Silva Maciel:** Data
146 curation, Methodology, Supervision, Funding acquisition, Writing – reviewing and editing.

147

148 **Acknowledgments**

149 The authors would like to thank the Coordenação de Aperfeiçoamento de Pessoal de
150 Nível Superior - Brazil (CAPES) and Programa de Apoio à Pós-Graduação (PROAP) at the
151 Universidade Federal de Minas Gerais.

152

153 **Declaration of interests**

154 The authors declare that they have no known competing financial interests or personal
155 relationships that could have appeared to influence the work reported in this paper.

156

157 **References**

158 [1] D.D. Loy, P.J. Gunn, B.E. Doran, R.M. Euken, D.L. Schwab, C.A. Clark, J. Sellers, P.B.
159 Wall, G.R. Dahlke, S.Hoyer, E. L. Lundy, L. L. Schulz, G. A. Dewell, Iowa beef center. Iowa

- 160 State University Animal Industry Report. 13 (2016), doi: https://doi.org/10.31274/ans_air-
161 180814-547
162
- 163 [2] G. B. Luz, R. F. de Matos, J. B. Cardoso, C.C. Brauner, Exigências nutricionais, cálculos
164 de dieta e mensuração de sobras no manejo nutricional de vacas leiteiras. Pesquisa
165 Agropecuária Gaúcha 25 (2019) 16–31, doi: <https://doi.org/10.36812/pag.2019251/216-31>
166
- 167 [3] DD. Uyeh, R. Mallipeddi, T. Pamulapati, T. Park, J. Kim, S. Woo, Y. Ha. Interactive
168 livestock feed ration optimization using evolutionary algorithms. Computers and Electronics
169 in Agriculture 155 (2018) 1–11, doi: <https://doi.org/10.1016/j.compag.2018.08.031>
170
- 171 [4] R. H. Pritchard, K. W. Bruns, Controlling variation in feed intake through bunk
172 management. Journal of Animal Science, v. 81, n. 14, suppl.2 p. 133 - 138, doi:
173 https://doi.org/10.2527/2003.8114_suppl_2E133x
174
- 175 [5] S. Karen, A. Zisserman, Very deep convolutional networks for large-scale image
176 recognition. arXiv preprint arXiv:1409.1556, 2014
177
- 178 [6] H. Kaiming, X. Zhang, S. Ren, J. Sun, Deep residual learning for image recognition, in:
179 Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR),
180 2016, pp. 770-778
181
- 182 [7] G. Huang, Z. Liu, L. van der Maaten, K. Q. Weinberger, Densely connected
183 convolutional networks, in: Proceedings of the IEEE Conference on Computer Vision and
184 Pattern Recognition (CVPR), 2017, pp. 4700-47008

1

2 4.2 ARTIGO 2- Classification of feed bunk score images using convolutional neural
3 networks

4

5 Este artigo foi elaborado conforme normas da Revista Computers and Eletronics
6 in Agriculture

7 **Abstract**

8 Feed management is a critical factor in livestock production. An inappropriate formulation
9 and bunk management can harm the animal's health and production. For years the feed
10 bunk management was conducted subjectively and inconsistently through manual and
11 visual methods of classification. The present paper proposes a computational model
12 capable of analyzing images of feedlot cattle's leftover diets and classifying these images
13 in scores. The continuous improvement of artificial neural networks and deep learning have
14 contributed positively to solve problems in several fields with the use of computer vision
15 techniques. Thus, we developed one of these networks, more specifically a Convolutional
16 Neural Network, to classify feed bunk score images, achieving 85.45% of accuracy. To train
17 our model, a dataset of images captured specifically for this problem was built, which will
18 be available to be explored in future research in the area. In addition, the final model
19 achieved computational performance metrics favorable for a low cost and a real time
20 application for producers.

21

22 **Introduction**

23 The feedlot of cattle allows higher stocking rates, if compared to the pasture system, and
24 allows the use of pastures for other stages of animal breeding [13]. Moreover, it reduces
25 the age at slaughter, produces higher quality meat and allows for greater profit. Among the
26 operational expenses of the feedlot, it is important to highlight the representativeness of
27 the feed costs, which can reach 60-80% of the overall expenses [22]. In addition, animal
28 performance is linked to the correct quantity and quality intake of the formulated diet.
29 However, there are different feed management systems, which can interfere with the final
30 result. In this context, it is important to plan the proper feed bunk management [15] since
31 inconsistent total mixed ration formulation and poor bunk management can cause digestive
32 disorders that result in erratic intake patterns, reduce dry matter (D.M.) intake and animal
33 daily gain [14, 15].

34 Bunk management can be an important technique to minimize the variations in

35 consumption and can be performed according to the South Dakota State University
 36 classification system (Table 1). The method consists of daily evaluation before the first feed
 37 supply and should be made by the same person daily. It allows to analyze possible
 38 adjustments in the diet feeding provided during the day [15]. Since it is a visual assessment,
 39 bunk scoring is considered subjective and not standardized. The use of information and
 40 communication technology (I.C.T.) can help, in an objective way, in the interpretation of
 41 these measurements [2].

42

43 **Table 1**

44 Feed bunk scoring SDSU (South Dakota State University) [18].

Score	Features	Adjustment
0	There is no food in the feed bunk	Increase 1 kg of in the diet or 5%
½	Spread food – 5% leftover	Increase 1 kg of DM in the diet or 5%
1	Thin layer (< 5 cm) – 5 to 10% leftover	Keep quantity provided
2	Medium layer (5 to 8 cm) – 25% leftover	Decrease 1 kg of DM in the diet or 5%
3	Thick layer (> 8 cm) – 50% leftover	Decrease 1 kg of DM in the diet or 5% – note other problems
4	Intact food	Decrease 1 kg of M.S. in the diet or 5% – note other problems

45

46 The adoption of technologies in beef cattle feedlot and genetic evolution can improve the
 47 growth of quality of animal products. Thus, producers have invested in these tools in
 48 production systems [1].

49 In the last years, various studies on the use of technology in livestock operations have been

50 developed. Dick et al. [5] used a network of portable computers in a beef feedlot to develop
51 a software capable of recording feed intake history and predicting feed adjustments based
52 on feed management rules. They evaluated the performance by comparing the predictions
53 made by the software and the feedlot staff. Researchers at Iowa State University carried
54 out a similar work, creating a confinement feed monitoring software [14].

55 Bloch et al. [4] presented a technique to measure the individual feed intake of dairy cows
56 through photogrammetry. The proposed system included the use of several cameras of
57 different resolutions around the feed pile before and after the cow is fed. The feed mass
58 was estimated through its volume, which can be calculated with the photogrammetry
59 method, using *PhotoModeler* Scanner software. The volume estimation takes 20 to 30
60 minutes. Despite reducing the costs and time spent for estimating individual feed intake,
61 the technique is challenging to implement, and the best results were achieved under
62 controlled laboratory conditions.

63 Convolutional Neural Networks (CNNs) are deep learning models that have been widely
64 used in several applications, such as medical diagnosis [12], weather analysis [7], and
65 remote sensing [16]. These networks are inspired by the neural structure used by intelligent
66 organisms to process and learn visual data. Hubel and Wiesel [9] built the basis for creating
67 these networks. Based on kittens' experiments, they discovered that some neurons are
68 activated together when exposed to different figures and formats, resulting in visual
69 recognition. This is essentially the main concept of a CNN: filtering lines, curves, and edges
70 to extract the most relevant features according to the problem approached.

71 Some recent works have applied CNNs to solve problems in animal production systems.
72 Yao et al. [24] used CNNs in a cow facial recognition framework that combines face
73 detection and individual identification. Bezen et al. [3] presented a work based on CNNs
74 models to identify cows and monitor individual feed intake. They used a low-cost RGB-D
75 camera to measure the size of the feed piles. The feed intake is obtained by the difference
76 between the data obtained before and after the cow goes to the feeding lane. For this, it is

77 necessary to train a CNN regression model that calculates the feed weight and makes
78 predictions based on the results. It is important to note that they used a specific acquisition
79 system through RGB-D cameras.

80 We propose and evaluate a CNN architecture to achieve feed bunk score classification
81 based on RGB images in the present work. We expect that this model can be embedded
82 in a mobile technology application as an auxiliary tool in the management of commercial
83 feedlots. The idea of this technology is to perform, in a simple and standardized way, the
84 classification of bunk scores from an RGB image captured by a smartphone. This will allow
85 cattle more efficient feed management, minimizing losses and optimizing profits on farms.
86 Therefore, the main contributions of this work are: 1) A CNN architecture capable of
87 classifying RGB images of feed bunk scores; 2) The organization of a dataset labeled
88 according to feed bunk score classification and other relevant attributes, which will be
89 publicly available in future for other research; 3) Evaluation of the proposed CNN
90 architecture on the constructed image dataset through computational performance metrics,
91 aiming to incorporate the developed model into a real-time application.

92

93 **Materials and methods**

94 **Bunk score images**

95 The reading and classification of the bunk score is a visual assessment and consists of
96 analyzing the amount of feed left in the bunk over the last 24 hours. For each volume of
97 leftovers, specific scores are assigned suggesting adjustments in the amount of feed to be
98 provided during the day, according to the needs of the animals in each flock [14]. Feed
99 bunk management aims to minimize the variation in dry matter intake and the digestive
100 disorders that occur due to a high energy density diet, typical of feedlots. In addition, this
101 technique relates, in a positive way, the amount of diet supplied and the amount of food
102 that the animal can ingest. Furthermore, consistent feeding allows the maintenance of the
103 rumen fermentative pattern and consequently there is adequate utilization of the food

104 ingested. The animals residual feed is classified in six bunk scores [18]. The scores and
105 their respective adjustments are described in Table 1.

106 Among computer vision applications, image classification is one of the most popular tasks
107 and its main goal is to classify an image by assigning it a specific class. This task can be
108 expanded to a multiclass problem, where more than two classes could be used [17]. In this
109 case, a deep learning algorithm could be applied to classify, for example, what bunk score
110 is present in an image according to the SDSU system.

111 To solve this problem we propose, train, and evaluate a convolutional neural network. To
112 train this network, we constructed a dataset of feed bunk score images that were obtained
113 using a digital camera. The procedures used to obtain the images are described in
114 Subsection 2.3.

115

116 **Convolutional Neural Network (CNN)**

117 A CNN is a variation of the Multilayer Perceptron (MLP) and was developed to require
118 minimal data preprocessing [19]. Usually, the network is composed of convolution layers
119 followed by an activation function, pooling layers and fully connected layers. The
120 convolution layers aim to extract different features from the input. The lower-layers extract
121 low level features, such as edges, while the higher-layers extract more abstract features,
122 including patterns and shapes.

123 After the convolution layer, an activation function is commonly applied. It is responsible for
124 deciding whether a given neuron should be activated and whether the information extracted
125 from the previous layer will be interpreted or ignored. Generally, functions with some degree
126 of non-linearity are used for neural networks, such as sigmoidal logistics (sigmoid) and
127 hyperbolic tangent (tanh). However, the rectified linear unit (ReLU) is the most designated
128 for convolutional neural networks because it is computationally more efficient without large
129 accuracy differences [6].

130 The pooling layer is commonly applied after convolution and activation. In general, this

131 layer simplifies the information of the previous one, reducing the data dimensionality in the
132 network. This simplification can be done in several ways, but the most used method is max
133 pooling, in which only the largest value is passed to the output [23]. Some advantages of
134 this data reduction are speeding up training and avoiding overfitting [8].

135 In classification tasks, at least one fully-connected layer is added, which acts as a
136 feedforward multilayer neural network [6]. It is responsible for the interpretation of the
137 feature extracted in the previous layers. In association with this structure, a classification
138 function, such as SoftMax, can be applied. Due to its simplicity and good results, this
139 function improves the speed of training without loss of quality [23]. Another technique that
140 is usually used in CNNs is the dropout, which deactivates a neuron with a previously
141 defined probability [20], in order to avoid overfitting training data [6].

142 Inspired by classical artificial neural networks [11, 10, 21], we adapted our own model to
143 solve the feed bunk scoring classification problem.

144

145

146 **Dataset**

147 The dataset is composed by 1001 images of 6 different scores, distributed according to
148 Table 2. The images have eight different spatial resolutions (5152 x 3864, 4608 x 3456,
149 4032 x 3024, 3024 x 4032, 2268 x 4032, 1280 x 958, 1280 x 956 and 960 x 1280 pixels),
150 and sRGB color space. Figure 1 shows a sample of each class image. We collected the
151 images on different days, between 6 am and 10 am, from eight farms in Minas Gerais,
152 Brazil. To account for variations in environmental conditions, we captured images of
153 different diet compositions, and feed bunk structures. Furthermore, we took images across
154 the feeding bunk at different angles and at the height of about 1.5 m. from the bunk.

155

156

Table 2

157

Distribution of the dataset samples, by score

Score	Amount of samples	Proportion (%)
0	83	8.29
½	137	13.69
1	193	19.28
2	112	11.19
3	164	16.38
4	312	31.17

158

159 In addition, we used the Penn State Particle Separator (PSPS) to determine the particle
160 size of the total mixed rations (TMR), since the particle size of the feed has an impact on
161 how much feed should be delivered. We observed that the most used feeds on farms were
162 silage (sugar cane, sorghum or corn), citrus pulp and concentrate feed (corn meal, soybean
163 meal??????). In our dataset, the feed bunks differ in their material and model. There are
164 fence line feeding bunks, which are mostly made of concrete, and others made of plastic
165 material. For our study, we considered only the images where the entire feeding and the
166 bunk edges were visible.

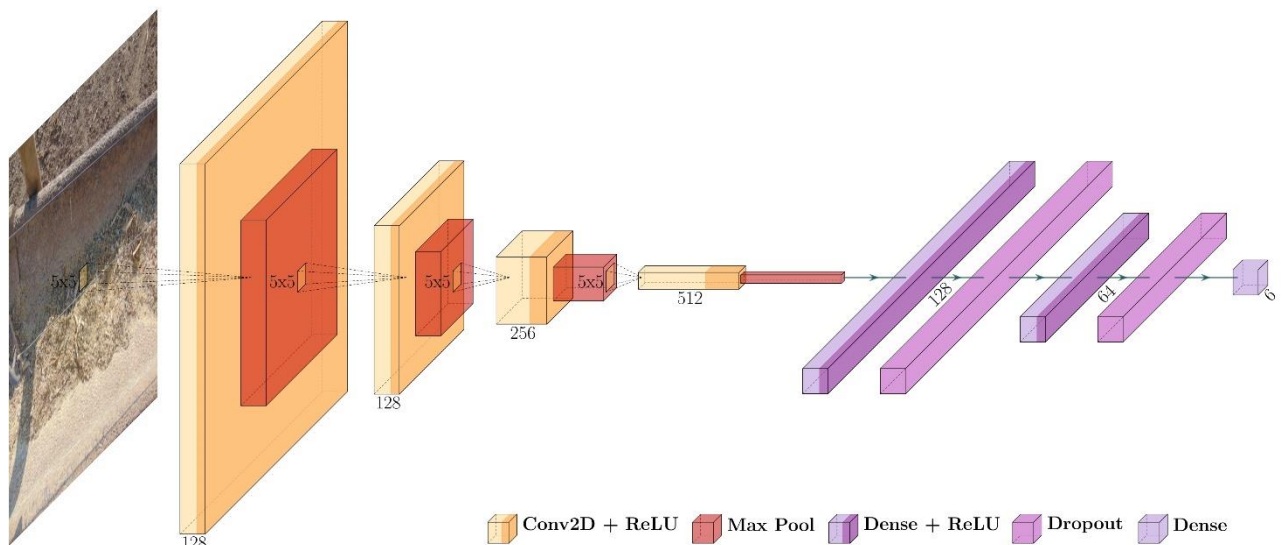
167 There are three underrepresented scores in the dataset (scores 0, 1/2 and 2), two
168 overrepresented (scores 1 and 4), and one close to the ideal sample number (score 3). An
169 important characteristic of the bunk score problem is the diet adjust, according to Table 1.
170 For scores 0 and 1/2 it is recommended an increment adjustment, for score 1 a
171 maintenance adjustment, and for scores 2, 3, 4 a decrement adjustment. Therefore, it is
172 possible to address another classification task with 3 classes (increment, maintenance and
173 decrement). Reducing the number of classes is an advantage of this approach. However,
174 it intensifies the imbalance between classes (increment - 22.38%, maintenance - 19.28%,
175 decrement - 58.74%). We highlight the importance of score 1 in both tasks, because only
176 this class is responsible for a unique type of recommendation.

177

178 Proposed Architecture

179 Figure 2 shows our proposed architecture (illustration elaborated using PlotNeuralNet1).
 180 The network consists of 4 convolutional layers (2 x 128, 256, and 512 features) with a
 181 kernel size of 5x5 and ReLU activation function. There is a max-pooling layer with a pooling
 182 size of 2x2 after each convolutional layer. A fully connected layer with 128 units and a ReLU
 183 activation function receives the output of the convolution block, followed by a dropout rate
 184 of 0.2. Next, we have another fully connected layer with 64 units and dropout at the same
 185 rate. We also added L2 regularization with a factor of 0.001 in the fully connected layers.
 186 Both dropout and L2 regularization are techniques to avoid overfitting, and their rates were
 187 found experimentally. The third fully connected layer is for classification (6 units, one per
 188 class).

189



190

191

Figure 2: Proposed convolutional neural network model

192

193

Separation of training and test sets

194 For the evaluation of model performance, 6 stratified 3-fold cross-validations were
 195 executed, with about 2/3 of the samples for the training set and 1/3 for the test set. The
 196 validation set was defined as 1/5 of the training set. Thus, the model performed on 18
 197 different data distributions.

198

199 **Hardware**

200 For our experiments, we used a computer architecture with Processor i7-8550U 1.80 GHz,
201 8 GB of RAM and GPU NVIDIA GeForce MX150. Furthermore, we develop and train our
202 model with Python 3.8.8 and TensorFlow 2.3.

203

204 **Experiments**

205 **Experimental Setup**

206 We run all experiments for 300 epochs, with a batch size of 8, optimizing the sparse
207 categorical cross-entropy loss. For optimization, we used the Adam optimizer. The
208 exponential decay rate for the first moment estimates, β_1 , was set to 0.98, and the constant
209 for numerical stability, ϵ , was fixed in 0.1. These parameter values were obtained
210 experimentally.

211 We applied some data augmentation techniques in training data to consider the problem
212 variability in field conditions and avoid overfitting. These techniques consist of increasing
213 the diversity of the training set by applying transformations to its samples. In this work,
214 these transformations were applied during training - without creating new samples
215 (oversampling) - and included horizontal flip with a probability of 50%, rotation by a random
216 angle in range ± 4 , zoom out by a factor of 25% and contrast adjust by a random factor
217 between 0.75 and 1.25.

218 We proposed two experiments: first, we varied the input image size on the classification of
219 scores, in order to determine the best correlation between accuracy and model size. Since
220 we intend to embed the model in a mobile application, it is important to find the smallest
221 trained model that ensures an accurate and fast prediction. Finally, we trained on the
222 classification of the recommended adjustments. We used accuracy as a measure of the
223 models' performance. We also measured the prediction time, corresponding to the sum of
224 the prediction times of all samples in the data set. The average of the 6 stratified cross-
225 validations was taken for accuracy and prediction time. We included the resulting model

226 sizes for each input size evaluated. Both prediction time and model size are important
227 metrics to analyze the applicability of the model.

228

229 **Score classification**

230 The results of the input size variation on the score classification is presented in Table 3.

231 The metric used in the evaluation was accuracy, which considers the number of samples
232 correctly predicted over the total number of samples in the dataset. We note that increasing
233 input image size does not necessarily improve the accuracy. The input size of 108 x 108
234 achieved a better performance (85.45%) than the bigger inputs. This input size results in a
235 model size of 59 MB, which is 2 times smaller than the resulting of the largest input of 220
236 x 220 (127 MB). Thus, for a mobile application, it is possible to choose a smaller model
237 without a significant loss of accuracy. Furthermore, the prediction time is relatively low
238 independently of the input size, qualifying the model for a real-time application.

239 Another desired characteristic in classification tasks is a low standard deviation between
240 classes. This means that the model has not prioritized learning one or more classes over
241 others. The lowest standard deviation was obtained with an input size of 108 x 108 (4.25%).
242 This value is most affected by the accuracies of scores 3 and 4, the lowest and highest
243 accuracy per class, respectively.

244

245

246

247

248

249

Table 3

Average of overall and class accuracies of the 6 stratified cross-validations. The best input size, according to the highest overall accuracy, the highest accuracies per class, and the smallest standard deviation (SD) among classes, prediction time and model size were highlighted

Input size	Score accuracies (%)							Overall (%)	Pred. Time (s)	Model size (MB)
	0	1/2	1	2	3	4	S. D			
76 x 76	85.14	84.97	81.63	84.67	75.10	90.60	4.66	84.63	4.60	53
92 x 92	84.94	84.20	83.94	84.97	74.19	91.40	5.05	84.92	5.59	55
108 x 108	83.94	84.63	85.04	85.27	76.63	91.24	4.25	85.45	6.66	59
124 x 124	85.34	82.47	85.16	87.95	76.83	90.22	4.25	85.18	7.61	64
140 x 140	84.14	83.94	85.89	85.12	75.81	90.44	4.34	85.05	10.34	71
156 x 156	84.54	84.80	84.91	85.27	73.88	90.28	4.92	84.77	11.56	80
172 x 172	81.33	82.73	82.48	83.18	73.27	92.04	5.45	83.98	12.54	89
188 x 188	81.33	82.12	85.28	84.38	73.88	90.01	4.88	83.85	15.68	100
204 x 204	82.93	84.02	83.94	86.01	74.49	89.58	4.57	84.32	17.40	112
220 x 220	85.14	82.47	83.58	86.01	73.27	89.74	5.06	84.00	21.11	127

Adjustment classification

The results of the adjustment classification are presented in Table 4. Two points highlighted in Subsection 2.3 about the advantages and disadvantages of this task were observed in these results: the decrease in the number of classes (6 to 3) and the consequent increase of the overall accuracy (90.34%), and the intensification of the dataset imbalance, reflected by the increase of the standard deviation between classes (7.28%). The “decrease” class obtained a higher accuracy. However, the “increase” and “maintenance” classes performed worst compared to their respective scores. We will discuss these results with more detail in the Subsection 3.4.

Table 4

Average of overall and class accuracies of the 6 stratified crossvalidations. The best input size obtained in the score classification task (108 x 108) was used

Adjustment accuracies (%)				Overall (%)
Increase	Maintenance	Decrease	SD.	
80.92	81.75	96.77	7.28	90.34

Detailed results

Figure 3 presents the confusion matrix of the best-stratified cross-validation for the score classification, considering the best input size (108 x 108). We notice a specific behavior for score 4. All classes have samples that were confused with score 4, except for score 1. A possible explanation is the proportion of this score, which corresponds to 31.17% of the dataset. It is interesting to highlight that despite the smaller proportion of samples (8.29%), score 0 obtained the second-best result, above the overall accuracy. Since this class is characterized by having no diet leftovers at the feed bunk, it is visually more distinguishable from the high scores (2, 3, and 4). On the other hand, it is more likely to be confused with the close scores, which present less leftovers (scores ½ and 1).

	Score 0	Score 1/2	Score 1	Score 2	Score 3	Score 4
Score 0	89.16% 74	2.41% 2	4.82% 4	0.00% 0	2.41% 2	1.20% 1
Score 1/2	0.00% 0	83.94% 162	7.77% 15	2.07% 4	1.55% 3	4.66% 9
Score 1	1.46% 2	12.41% 17	84.67% 116	0.73% 1	0.73% 1	0.00% 0
Score 2	0.00% 0	2.68% 3	0.89% 1	87.50% 98	2.68% 3	6.25% 7
Score 3	0.61% 1	1.83% 3	1.83% 3	1.22% 2	79.88% 131	14.63% 24
Score 4	0.32% 1	2.24% 7	0.64% 2	0.32% 1	1.92% 6	94.55% 295

Figure 3: Confusion matrix of the best input size (108 x 108) on the best-stratified cross-validation for the score classification

Two other confusions that can be highlighted are between scores 1/2 and 1 and between scores 3 and 4. Both are visually close and, therefore, more likely to be confused. However, from an application point of view, the first one is less desirable since their respective adjustment recommendations are different. In contrast, confusion between scores 3 and 4 does not affect the diet adjustment recommendation since a decrease in the diet is recommended for both.

Figure 4 shows the confusion matrix of the best-stratified cross-validation for the adjustment classification. A similar behavior identified for score 4 was perceived for the decreasing adjustment. However, the adjustment with the smallest number of samples (maintenance) was less affected than the increase adjustment, which corresponds to the opposite adjustment. The confusion between increase and decrease adjustments is the highest observed for both absolute (35) and relative (12.68%) values. To balance the number of samples in each class could reduce this confusion.

	Increase	Maintenance	Decrease
Increase	80.43% 222	6.88% 19	12.68% 35
Maintenance	7.30% 10	90.51% 124	2.19% 3
Decrease	1.87% 11	0.85% 5	97.28% 572

Figure 4: Confusion matrix of the best stratified cross validation for adjustment classification

Table 5 presents the average overall accuracy of the validation and test sets of the 6 stratified cross-validations for both classifications. We observe that, for both classifications, the validation accuracies are not excessively higher than the test accuracies, which evidences the -non-occurrence of overfitting. This is an important result that indicates the generalization potential of the model. This is extremely important since other samples with different characteristics will probably be faced in an actual application.

Table 5

Average overall accuracy of the validation and test sets for both classification tasks.

Set	Classification task accuracy (%)	
	Score	Adjustment

Validation	90.31	94.83
Test	85.45	90.34

Conclusion

Objective management of the bovine diets leftovers is essential to ensure the nutritional management efficiency of farms. Based on this necessity, we developed a convolutional neural network to classify images of feed bunk scores. A dataset of images captured for this problem was built to train this network. We intend to make this dataset available, contributing to research in the area. The results of the experiments demonstrated that the proposed model achieves a promising performance on all image classes for both classification tasks addressed (score and adjustment). Furthermore, our model presents a reduced size and satisfactory prediction time. Thus, we expected it could be applied on a wider range of platforms, especially in mobile applications. Furthermore, the results did not indicate overfitting, presenting a significant potential for generalization.

In future works, it is essential to expand and balance the image dataset to improve the model. We intend to incorporate the developed model into a mobile application, as well implement new functionalities such as volume and particle size calculation. Thus, based on real-time predictions, the tool will support the producer in more precisely and quickly recomposing the animal's diet.

References

- [1] Abreu, A.D., Herrra, V.E., Teixeira, M.A., 2006. Mercado mundial de carne bovina: participação brasileira e barreiras à exportação. Technical Report.
- [2] Bernardes, J .C., Vieira, S. C., Bonfim, E. B., Sant'Ana, R. C. G., 2015. O uso das tecnologias de informação e comunicação na agricultura familiar: um caminho para a sustentabilidade. Periódico Eletrônico Fórum Ambiental da Alta Paulista 11.
- [3] Bezen, R., Edan, Y., Halachmim, I., 2020. Computer vision system for measuring individual cow feed intake using rgb-d camera and deep learning algorithms. Computers and Eletronics in Agriculture 172, 105345.
- [4] Bloch, V., Levit, H., Halachmim, I., 2019. Assessing the potential of photogrammetry to monito feed intake of dairy cows. Journal of Dairy Research 86, 34-39.
- [5] Dyck N., Crowe, T., McKinnin, J., Ingleby, H., 2007. Feed prediction and management software for beef feedlots. Canadian Biosystems Engineering 49, 7.
- [6] Ebermam, E., Kroling, R., 2018. Uma introdução compreensiva às redes neurais convolucionais: Um estudo de caso para reconhecimento de caracteres alfabéticos. Revista de Sistemas de Informação da FSMA 22, 49-59.
- [7] Elhoseiny, M., Huang, S., Elgammal, A., 2015. Weather classification with deep convolutional neural networks, in: 2015 IEEE International Conference on Image Processing (ICIP), IEEE. pp. 3349-3353.
- [8] Hawkins, D. M., 2004. The problem of overfitting. Journal of chemical information and

computer sciences 44, 1-12.

[9] Hubel, D. H., Wiesel, T. N., 1964. Effects of monocular deprivation in kittens. *Naunyn-Schmiedebergs Archiv für Experimentelle Pathologie und Pharmakologie* 248, 492-497.

[10] Krizhevsky, A., Sutskever, I., Hinton, G. E., 2012. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems* 25, 1097-1105.

[11] LeCun, Y., Bottou, L., Bengio, Y., Haffner, P., 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE* 86, 2278-2324.

[12] Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D., Chen, M., 2014. Medical image classification with convolutional neural networks, in: 2014 13th international conference on control automations robotic & vision (ICARCV), IEEE. pp. 844-848.

[13] Lopes. M A., Magalhães, G. P., 2005. Análise da rentabilidade da terminação de bovinos de corte em condições de confinamento: um estudo de caso. *Arquivo Brasileiro de Medicina Veterinária e Zootecnia* 57, 374-379.

[14] Loy, D. D., Gunn, P.J., Doran, B. E. Euken, R. M., Shwab, D. L., Clark, C. A., Seller, J., Wall, P. B., Dahlke, G. R., Hoyer, S., et al, 2016. Iowa beef center. Iowa State University Animal Industry Report 13.

[15] Luz, G. B., de Matos, R. F., Cardoso, J. B., Brauner, C. C., 2019. Exigências nutricionais, cálculos de dieta e mensuração de sobras no manejo nutricional de vacas leiteiras. *Pesquisa Agropecuária Gaúcha* 25, 16-31.

- [16] Maggiori, E., Tarabalka, Y., Charpiat, G., Alliez, P, 2016. Fully convolutional neural networks for remote sensing image classification, in: 2016 IEEE international geoscience and remote sensing symposium (IGARSS), IEEE. pp. 5071-5074.
- [17] Oliveira, D. A. B., Pereira, L. G. R., Bresolin, T., Ferreira, R. E P., Dorea, J. R. R., 2021. A review of deep learning algorithms for computer vision systems in livestock. *Livestock Science* 253, 104700.
- [18] R. H. Pritchard, K. W. Bruns, Controlling variation in feed intake through bunk management. *Journal of Animal Science*, v. 81, n. 14, suppl.2 pç. 133 - 138, doi: https://doi.org/10.2527/2003.8114_suppl_2E133x
- [19] Raju, A., Thirunavukkarasu, S., 2020. Convolutional neural network demystified for a comprehensive learning with industrial application, in: *Dynamic Data Assimilations Beating the Uncertainties*. IntechOpen.
- [20] Righetto, G., 2016. O uso da rede neural convolucional como extrator de características aplicado ao problema de identificação de escritores. B. S. thesis. Universidade Tecnológica Federal do Paraná.
- [21] Simonyan, K., Zisserman, A., 2014. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- [22] Uyeh, D. D., Mallipeddi, R., Pamulapati, T., Park, T., Kim, J., Woo, S., Ha, Y., 2018. Interactive livestock feed ration optimization using evolutionary algorithms. *Computers and Electronics in Agriculture* 155, 1-11.

[23] Vargas, A. C. G., Paes, A., Vasconcelos, C. N., 2016. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres, in: Proceedings of the xxix conference on graphics, patterns and images, sn.

[24] Yao, L., Hu, Z., Liu, C., Liu, H., Kuang, Y., Gao, Y., 2019. Cows face detection and recognition based on automatic feature extraction algorithm, in: Proceedings of the A.C.M. Turing Celebration Conference – China, pp. 1-5.

5 CONSIDERAÇÕES FINAIS

A partir dos resultados deste estudo, observa-se que a leitura e classificação de escore de cocho pode tornar-se homogênea e padronizada através do uso da rede neural convolucional proposta. Dessa forma, pode ser usada em qualquer propriedade, eximindo-a do viés subjetivo da avaliação visual. A superioridade da acurácia de classificação baseada em ajuste de quantidade de dieta possibilita a execução de novos estudos afim de disponibilizar uma solução cada vez mais assertiva. Além disso, a ferramenta possui baixo custo e portanto, tem potencial de auxiliar maior número de pecuaristas. Ademais, a tecnologia proposta tem potencial para novas pesquisas visando maior integração dos maquinários agrícolas com o objetivo de maximizar as soluções em manejo alimentar e assegurar o sucesso financeiro do confinamento.

ANEXO(S)**ANEXO A- Certificado de Registro de Programa de Computador**

REPÚBLICA FEDERATIVA DO BRASIL
MINISTÉRIO DA ECONOMIA
INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL
DIRETORIA DE PATENTES, PROGRAMAS DE COMPUTADOR E TOPOGRAFIAS DE CIRCUITOS INTEGRADOS

Certificado de Registro de Programa de Computador

Processo Nº: **BR512022003061-6**

O Instituto Nacional da Propriedade Industrial expede o presente certificado de registro de programa de computador, válido por 50 anos a partir de 1º de janeiro subsequente à data de 01/08/2021, em conformidade com o §2º, art. 2º da Lei 9.609, de 19 de Fevereiro de 1998.

Título: Click Cocho

Data de criação: 01/08/2021

Titular(es): UNIVERSIDADE FEDERAL DE JUIZ DE FORA - UFJF

Autor(es): AMÁLIA SATURNINO CHAVES; LUIZ MAURÍLIO DA SILVA MACIEL; SABRINA EVELIN FERREIRA; GABRIEL REZENDE DA SILVA; BRENDA MARQUES DE PAULA; BRIAN LUIS COIMBRA MAIA; MMATHEWS EDWIRDS GOMES ALMEIDA

Linguagem: JAVA

Campo de aplicação: AG-10

Tipo de programa: AP-01

Algoritmo hash: SHA-512

Resumo digital hash:

91c2425f6c473ae5c592e5dfd87ad027fe45fed8588939ec49621bca8879e4b27358ac6e60ccf3e601c48a11471f5e743ac2ff1279464730b4f7db5e001421f1

Expedido em: 16/11/2022

Aprovado por:

Carlos Alexandre Fernandes Silva
Chefe da DIPTO