

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
Faculdade de Ciências Agrárias e Tecnológicas
UNESP - Câmpus de Dracena

USO DE MÉTODOS DE INTELIGÊNCIA ARTIFICIAL NA AVALIAÇÃO ANIMAL

Discente: Jorge Adrian Velasco Avila
Orientador: Rafael Simões Tomaz

Trabalho de Conclusão de Curso
apresentado à Faculdade de Ciências
Agrárias e Tecnológicas do Câmpus de
Dracena - UNESP, como parte das
exigências para graduação em Zootecnia.

Dracena – SP
2022

UNIVERSIDADE ESTADUAL PAULISTA
"JULIO DE MESQUITA FILHO"
FACULDADE DE CIÊNCIAS AGRÁRIAS E TECNOLÓGICAS
UNESP – CÂMPUS DE DRACENA

CERTIFICADO DE APROVAÇÃO

Título: USO DE MÉTODOS DE INTELIGÊNCIA ARTIFICIAL NA AVALIAÇÃO ANIMAL.

Modalidade: **Trabalho de PESQUISA**


Autor: JORGE ADRIAN VELASCO AVILA


Orientador (a): RAFAEL SIMÕES TOMAZ

Co-orientador(es):

Número de Créditos: 15

Data da aprovação e correção de acordo com as sugestões da Banca: 24/06/2022


Rafael Simões Tomaz


Étienne Groot


Cristiana Andrighetto

OFERECIMENTOS/DEDICATÓRIA

À Deus que sempre esteve comigo nos tempos mais difíceis desses últimos 5 anos.

Aos meus pais por todo o apoio que me deram em todo momento.

À minha família Kbarete que me acolheram, ajudaram e fizeram com que todo esse tempo que passamos juntos seja inesquecível.

Ao meu orientador, o professor Rafael Simões Tomaz, que me ensinou durante a faculdade e ajudou a desenvolver meu trabalho de conclusão de curso.

SUMÁRIO

Sumário

1- RESUMO	4
2- ABSTRACT.....	5
3-. INTRODUÇÃO	6
4-. OBJETIVO DA PESQUISA	7
5-. REVISÃO DE LITERATURA E DISCUSSÃO.....	8
5.1-. “BIG DATA”	8
5.2-. INTERNET DAS COISAS	9
5.3-. APRENDIZAGEM DE MÁQUINA.....	10
5.4-. REDE NEURAL ARTIFICIAL (RNA)	13
5.5-. APLICAÇÕES NA ZOOTECNIA.....	16
6-. REFLEXÃO	23
7-. REFERÊNCIAS BIBLIOGRÁFICAS.....	24

1- RESUMO

Os avanços tecnológicos, como o advento dos algoritmos de Inteligência Artificial, têm causado grande impacto na área da produção animal, sendo, em algumas áreas, imprescindíveis para otimização do tempo, de recursos e na diminuição do estresse dos animais. A inteligência artificial e o “*Machine Learning*” são as técnicas que estão crescendo mais por causa da precisão que demonstram no processo produtivo, além da capacidade de “aprendizado”, que é inerente à tecnologia. Neste trabalho, é apresentado uma revisão bibliográfica, a partir do qual são apresentados conceitos atuais relativos ao tema de inteligência artificial, “Big data”, internet das coisas, e sua aplicabilidade no processo de produção animal. São apresentados, por fim, exemplos de utilização de tais tecnologias, derivados de artigos, em diferentes áreas da produção animal, sendo que muitas destas tem sido de grande importância no processo de avaliação de parâmetros zootécnicos, considerando que tais tecnologias apresentam melhor acurácia que os métodos tradicionalmente utilizados. Faz-se necessário ressaltar, que por se tratar de uma tecnologia “nova”, muitos estudos precisam ser feitos com o intuito de proporcionar uma melhor aplicabilidade de tais métodos nas mais diversas áreas da produção animal.

Palavras-chave: *Machine learning*, rede neural artificial, avaliação animal.

2- ABSTRACT

Technological advances, such as the advent of Artificial Intelligence algorithms, have caused great impact in animal production, and in some areas, are essential for the optimization of time, resources and in the reduction of animal stress. Artificial Intelligence and Machine Learning are the techniques that are growing because of the precision they have shown in the production process, besides the "learning" capacity, which is inherent to the technology. In this work, a bibliographic review is presented, from which current concepts related to the subject of artificial intelligence, "Big data", internet of things, and their applicability in the animal production process are presented. Finally, examples of the use of such technologies, derived from articles, in different areas of animal production are presented, and many of these have been of great importance in the process of evaluation of zootechnical parameters, considering that such technologies have better accuracy than the methods traditionally used. It is necessary to emphasize that because it is a "new" technology, many studies need to be done in order to provide a better applicability of such methods in various areas of animal production.

Keywords: Machine learning, artificial neural network, animal evaluation.

3-. INTRODUÇÃO

Os avanços na área das ciências computacionais vêm crescendo muito rápido e com isso levando a produção de sistemas inteligentes, softwares e tecnologias que vêm ajudando a facilitar o trabalho que antigamente era realizado apenas por seres humanos. As grandes bases de dados, e tecnologias de inteligência de máquina que conseguem aprender com a experiência, vem auxiliando a área de produção animal à medida que facilita o manejo, dentre outros procedimentos. Com isto muitas empresas que trabalham na área também vêm investindo muitos recursos no desenvolvimento de softwares, sendo que hoje em dia precisa se muito da interação entre a área da informática e a área do agro para conseguir fazer bons produtos.

As avaliações animais vêm sendo realizadas faz muitos anos e tem um grande papel na produção animal. Procedimentos como detecção de doenças que podem prejudicar na produção animal, até procedimentos relacionados com o aprimoramento do manejo em diversas etapas do processo produtivo. A junção da chamada “Internet Of Things” (IoT) e da Inteligência Artificial (IA) vem auxiliando os profissionais que buscam desenvolver máquinas com o intuito de auxiliar na avaliação otimizada diferentes parâmetros na produção animal (Koketsu e Lida, 2020).

A tecnologia destas avaliações vem melhorado muito nos últimos anos, porém muitas destas avaliações ainda causam dúvidas aos produtores por causa da complexidade, e devido ao desconhecimento das bases dessa nova tecnologia que tem sido aplicada nas mais diversas áreas da ciência. O funcionamento destas novas tecnologias não resulta fácil de explicar para muitos produtores, além do desconhecimento que o agro teve nessa área durante muito tempo, sendo que hoje em dia muitos desenvolvedores de produtos precisam ter um conhecimento técnico e pratico de como as maquinas funcionam para otimizar a produção de maquinas com inteligência artificial.

O trabalho visa fazer um levantamento do funcionamento e a aplicabilidade das diferentes tecnologias relacionadas à inteligência Artificial, que vem sendo usada na avaliação animal; e como diferentes pesquisas avaliaram a aplicabilidade destas “novas” tecnologias.

4-. OBJETIVO DA PESQUISA

Esse trabalho constitui uma revisão de literatura, e tem o objetivo de apresentar temas relevantes associados ao assunto Inteligência Artificial. Sendo de grande ajuda para o entendimento da tecnologia, e exemplos nos quais elas tem sido utilizadas, especificamente, no contexto da produção animal.

5-. REVISÃO DE LITERATURA E DISCUSSÃO

5.1-. “BIG DATA”

Para conhecer o que o “*Big Data*” faz, é muito importante entender que o termo “data”, ou dados, se refere às quantidades, caracteres ou símbolos que são usados para avaliar diferentes características, que podem ser armazenadas ou utilizadas no processo de tomada de decisão.

O termo “*Big Data*” diz respeito todo o conjunto de dados em quantidades gigantes, que se incrementam com o passar do tempo. O “*Big Data*” é uma ferramenta tão grande que as bases de dados tradicionais têm dificuldade de armazená-lo de forma eficientemente, a maioria destas “*big datas*” são usadas para controlar dados, sensores e muitos outros caracteres e levá-los para lugar onde estes dados possam ser analisados (LANEY, 2012).

Existem diversos exemplos que são usados, hoje em dia, referentes ao “*Big Data*”, sendo um deles o “*New York Stock Exchange*”. Essa base de dados gera mais ou menos um terabyte de dados diariamente, sendo um bom exemplo gradeza que essa ferramenta pode chegar a ser, se os melhores processadores de dados são utilizados. O “*Big Data*” também é usado nas redes sociais, sem o “*Big Data*” muitas dessas redes sociais teriam um funcionamento pouco eficiente e não chegariam ao máximo potencial de cada uma. Isto se deve a que quanto maior seja uma base de dados, mais esforço o processador precisa para achar o que você precisa com esses dados, sendo por isso muito importante os processadores e os neurônios artificiais para o bom uso desta ferramenta. Segundo as estatísticas, Facebook chega a ter mais de 500 terabytes de dados por dia, os quais contemplam, desde mensagens e comentários, até fotos e vídeos. Com as bases de dados aumentando todos os anos, faz-se necessário métodos específicos para o armazenamento e funcionamento destes (DASH *et al.*, 2019, ADAM, 2014).

Basicamente, existem 3 tipos de “*Big Data*”: O estruturado, o não estruturado e o semiestruturado. O “*Big Data*” estruturado armazena qualquer tipo de dados, que são processados na forma de um formato fixo. Com o passar do tempo, profissionais da informática conseguiram desenvolver esse tipo de armazenamento aplicado ao “*Big Data*”, obtendo resultados interessantes. O “*Big Data*” não estruturado é denominado assim quando os dados tem uma estrutura desconhecida. Essa

categoria de dados tem sido utilizada de forma até mesmo mais ostensiva do que o dado do tipo estruturado. Faz-se exemplo deste tipo de dado, a ferramenta de pesquisa do google, que nem sempre “busca” o que está sendo procurado exatamente. Já o “*Big Data*” semiestruturado pode conter os dois tipos de dados, sendo o utilizado, por exemplo, nos arquivos XML (STANDER, 2015).

Além disso, “*Big Data*” tem as seguintes características: Volume, variedade, velocidade e variabilidade. O nome do termo, por si só, tem sido caracterizado pela quantidade de dados. A variedade é outra característica importante, que diz respeito a natureza dos dados e a quantidade de variáveis e heterogeneidade nos caracteres, de onde se originam. Antigamente, só havia bases de dados anotados, registrados em cadernos, atas ou livros; hoje em dia, eles têm muito mais fontes de origem, podendo ser desde e-mails, vídeos ou fotos, até aparelhos ou sensores, que monitorizam atividades de diversas naturezas. O termo velocidade, refere-se ao quão rápido os dados são gerados. A variabilidade refere-se à velocidade inconsistente na qual a informação é gerada e carregada no banco de dados, em resumo a á velocidade que um resultado é obtido desses dados (RISTEVSKI e CHEN, 2018).

Existem diversas características relevantes com respeito ao uso dessa ferramenta, e uma delas, diz respeito à necessidade de uso de Inteligência Artificial. Ambas as ferramentas, o “*Big Data*” e a Inteligência Artificial, tem um grande potencial de utilização, para produtores em empresas das áreas da agricultura e da pecuária precisa, como ferramenta preditiva, de forma a resolver os diferentes problemas e desafios que essas áreas enfrentam (WOLFERT, 2017)

5.2-. INTERNET DAS COISAS

A internet das coisas ou “*Internet of things*” (IoT) diz respeito ao sistema que conecta sistemas informatizados, máquinas digitais e mecânicas, objetos, animais ou pessoas, que tem a habilidade de transferir dados em uma rede de internet sem requerer interação humana. Uma “coisa” no IoT, pode ser um marcapasso, que controla um coração, uma fazenda com o uso de chips, um trator, que foi construído com sensores para avisar quando um pneu está com a pressão baixa, ou qualquer

equipamento que possa ser ligado a um endereçamento de protocolo de internet (IP) de forma a transferir dados à uma rede.

Um ecossistema de IoT consiste em aparelhos inteligentes ligados à internet que usam sistemas incorporados como processadores, sensores e hardwares de comunicação para coletar, enviar e atuar com dados que foram adquiridos em aqueles ambientes. Os aparelhos com Internet das coisas enviam os dados coletados à uma entrada que recebe dados dos IoT ou qualquer outro aparelho que envie dados à nuvem para ser analisado local ou externamente. Os aparelhos IoT simulam muitas das ações que os humanos realizam, sendo possível ainda a ajuda ou a mudança de algumas decisões se os humanos quiserem, sendo os humanos que decidem as instruções para dar para esses IoTs (Yang, 2020).

A IoT vem crescendo a cada vez mais, e hoje em dia é usada por muitas indústrias com o intuito de aumentar a eficiência e a velocidade dos processos, além de melhorar o processo de tomada de decisão. A IoT apresenta grande perspectiva no aprimoramento da automação na agricultura e na pecuária, tendo sido bastante utilizado nessas áreas (Matta e Pant, 2019), embora tenha sido um desafio aplicar o uso da Inteligência Artificial em tais situações com o intuito de tornar mais dinâmico o processo de tomada de decisão baseado nos dados, sem a interferência humana.

5.3- APRENDIZAGEM DE MÁQUINA

“*Machine learning*” (ML) ou como é falado em português “Aprendizado da máquina” é uma ramificação da inteligência artificial e da ciência informática que está focada no uso de dados e algoritmos para imitar a forma na quais os humanos aprendem e melhoram. O avanço desse tipo de tecnologia tem gerado grandes avanços na pecuária de precisão. Permitem analisar diferentes dados para gerar diferentes informações, que ajudem na hora da precisão da produção de carne e de leite (HOSSAIN, 2019).

O termo “*Machine Learning*” foi concebido por Arthur Samuel, que desenvolveu uma máquina capaz de vencer o melhor jogador da história em damas, na época. Isso hoje em dia é pouco comparado com o que as máquinas são capazes de fazer, mas foi naqueles tempos uma grande notícia para a época (1962) e para a inteligência artificial em geral. Com o passar do tempo, os avanços

tecnológicos na área de armazenamento e de processadores tornaram possíveis muitos produtos de inovação que conhecemos e utilizamos hoje em dia, como os tratores que dirigem sozinhos para plantar diferentes culturas, e carros inteligentes, que desviam de obstáculos. Estes modelos computacionais representam um mapeamento baseado em informações conhecidas de um conjunto de entradas para um conjunto de saídas (BROWN-BRANDL; JONES; WOLDT, 2005).

O ML constitui um componente muito importante no crescimento da ciência de dados. Mediante o uso de métodos estatísticos, os neurônios são treinados para prever diferentes resultados. A modelagem realizada por tais máquinas permitem com que o ser humano, o operador, identifique aspectos a serem melhorados, e realize tais aprimoramentos no sistema sob análise. Dessa forma, o ML tem sido utilizado para análise e interpretação do “*Big Data*” (MOROTA *et al.*, 2018), de forma a permitir com que tais informações sejam inteligíveis e úteis no processo de tomada de decisão.

Existem três tipos de *ML* que são aplicados no processo de mineração de dados: a aprendizagem supervisionada, aprendizagem não supervisionada e a aprendizagem por reforço (Figura 1). A aprendizagem supervisionada está ligada à previsão de uma variável dependente a partir de variáveis independentes, para que o modelo computacional possa aprender a partir dos dados. Esses dados, por sua vez, vêm acompanhados das respostas reais (variáveis dependentes), como pares de entrada e saída. A aprendizagem não supervisionada, é utilizada quando não é possível obter os pares de variáveis dependentes e independentes. A estratégia implementada neste caso, é que o modelo computacional encontre uma associação entre os dados de entrada disponíveis e desenvolva um padrão para a previsão das respostas, simplificando a obtenção de resultados. O último tipo de aprendizagem é a denominada aprendizagem por reforço em que a máquina toma decisões com os dados de entrada disponíveis e recebe recompensas positivas ou negativas da saída que a auxiliam a construir o melhor modelo (MOROTA *et al.*, 2018).

Esses tipos de aprendizagem têm sido utilizados e referenciados por diversos autores, em áreas específicas das ciências agronômicas. Na pecuária de precisão a aprendizagem supervisionada vem sendo usada com mais frequência para predição de características físicas, fisiológicas e comportamentais, para assim acessar de

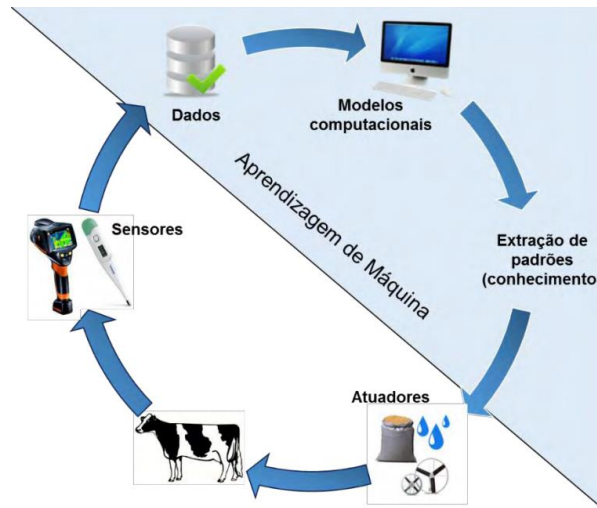
forma antecipada ao estado de saúde e a performance dos animais. Na pecuária leiteira, existem algoritmos que conseguem prever de forma precoce problemas de saúde como a laminitite (JABBAR *et al.*, 2017). Além disso, são relatados aplicação de algoritmos de ML na predição da condição corporal dos animais (ALVAREZ *et al.*, 2018), a previsão do parto (BORCHERS *et al.*, 2017) e detecção do nível de bem-estar animal (KRUG *et al.*, 2015).

As Redes Neurais Artificiais (RNA) constituem exemplos de ferramentas de aprendizagem supervisionada, e são utilizadas no desenvolvimento de modelos computacionais não lineares, aplicados no processo de classificação ou de predição. Elas são capazes de mapear grandes quantidades de uma diversa gama de categorias de dados, com o intuito de proporcionar resultados que contribuem para o entendimento a respeito do conjunto de dados (PACHECO, V. M., 2019). Na Figura 2 é apresentado um exemplo de aplicação de tais modelos.

Figura 1. Esquema representando os três tipos de Aprendizagem de Máquina, supervisionada, não supervisionada e por reforço.



Figura 2: Exemplo de aplicação do ML em um sistema aplicado de avaliação animal.



5.4- REDE NEURAL ARTIFICIAL (RNA)

As RNAs são sistemas computacionais lineares baseados de unidades básicas de processamento chamados neurônios artificiais ou unidades de processamento simples. Nesse sistema, os neurônios artificiais estão conectados entre si e realizam atividades simples, por meio da execução funções matemáticas lineares ou não-lineares (BINOTI *et al.*, 2013), em algoritmos. O funcionamento destas redes é inspirado na estrutura física de organismos inteligentes, no qual o neurônio biológico (Figura 3A) constitui elemento básico, e cuja função receber, processar, e repassar a informação. A RNA, por sua vez, constitui uma tentativa de replicar de forma simplificada o funcionamento do cérebro humano em computadores (FLECK *et al.*, 2016), sendo composto por um conjunto de neurônios artificiais interconectados.

As RNAs, podem ser constituídas por uma ou várias camadas de neurônios, sendo que a quantidade de neurônios pode variar. Os neurônios que, por sua vez, estão interconectados, são capazes de criar múltiplas conexões unidirecionais até um neurônio de saída, que proporciona um resultado. Cada neurônio artificial integrado na rede, armazena e processa as informações recebidas ponderadas por pesos sinápticos (MACHADO; FONSECA JUNIOR, 2013).


O neurônio biológico (Figura 3A) é constituído por dendritos, corpo celular e axônio. Os dendritos são os responsáveis de receber sinais de outros neurônios, conduzindo-os até o corpo da célula, o qual irá somar todos os sinais de entrada recebidos. Após a somatória dos sinais de entrada atingir um limiar, o sinal

produzido viaja através do axônio visando propagar a informação para outros neurônios e continuar com esse funcionamento para chegar a uma reação do corpo (MASSUCATTO, 2018).


Os neurônios artificiais (Figura 3B) funcionam de maneira similar, mas tem algumas diferenças, segundo VENDRUSCOLO *et al.* (2015). Um conjunto de neurônios artificiais conectados, compõem uma RNA (Figura 3C). A camada de entrada recebe somente os valores das variáveis fornecidas, sejam elas quantitativas ou qualitativas, e as transmite para a camada intermediária e de saída. A camada intermediária (ou camada oculta) e a camada de saída identificam e processam as informações por meio de neurônios, também chamados de nós de computação. Um nó de computação recebe os sinais de entrada e pondera-os com pesos; uma soma é obtida por adição das entradas multiplicado por seus respectivos pesos e adicionando um sinal preconizado. O resultado dessa soma atua através de uma função de ativação e fornece a saída do neurônio.

Figura 3. (A) Modelo de neurônio biológico. (B) Modelo de neurônio artificial. Parâmetros – $x_1, 2, \dots, m$: valores de entrada; w_{k1}, k_2, \dots, k_m : pesos sinápticos; b_k : bias ou erro; Σ : função somatória; $\phi(v)$: função de ativação; y_k – valor de saída. Adaptado de HAYKIN (2009). (C) Modelo de uma RNA. Adaptado de MASSUCATO (2018).

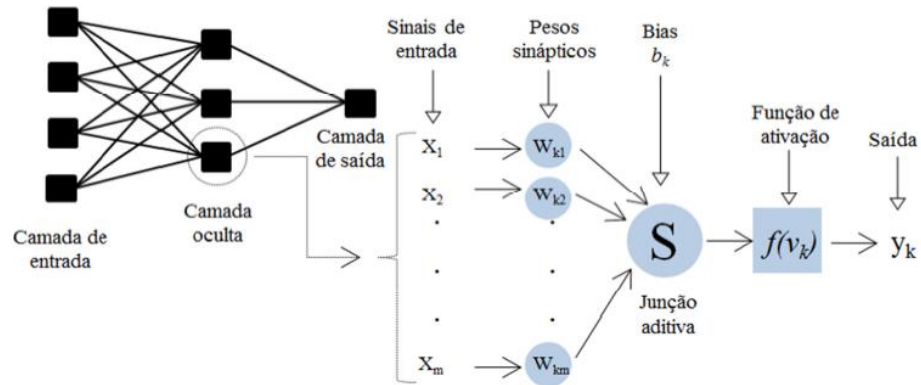
(A)



(B)



(C)



O processo de treinamento de uma RNA inicia-se pela introdução de variáveis de entrada e de saída em conjunto com valores aleatórios adicionado aos pesos por meio de uma arquitetura pré-estabelecida. Isto é feito para que o RNA aprenda a base destes valores por meio de um treinamento, para que seja mais acurado na hora de utilizar os outros valores(SOARES *et al.*, 2015). Baseado nos valores dos pesos, a saída inicial é comparada com o respectivo valor real da primeira observação, sendo assim realizada a diferença entre elas (FLECK *et al.*, 2016). O produto dessa rede gera um sinal de erro que calibra o ajuste de pesos, possibilitando um novo ciclo de análises objetivando-se a aproximação dos valores estimados pela rede e o valor real, diminuindo a probabilidade de erro (VENDRUSCOLO *et al.*, 2015).

Os sistemas sob análise podem ser demasiadamente complexos, dependendo do problema sob estudo, significando que um maior número de neurônios será necessário para modelagem. De qualquer forma, espera-se que um modelo baseado em RNA seja capaz de aprender com os dados, e extrapolar o conhecimento para prever respostas em um conjunto de dados cuja variável resposta seja desconhecida (DING *et al.*, 2013; SVOZIL; KVASNICKA; POSPICHAL, 1997). Por fim, o tipo de RNA, a arquitetura da rede, a quantidade de neurônios na camada escondida, a função de ativação e as regras de treinamento (algoritmos de aprendizagem) são configurações determinantes para o desempenho da RNA (SHEELA; DEEPA, 2013).

5.5-. APLICAÇÕES NA ZOOTECNIA

Na bovinocultura, são relatadas diversas aplicações que fazem uso das tecnologias baseadas em inteligência artificial, e que tem auxiliado na melhoria dos métodos de produção.

Na área de Bovinocultura de leite, tem sido relatado o uso de análises de estresse térmico por meio de raios infravermelhos. As vacas de leite sofrem muito com o calor excessivo, uma vez que eles destinam parte da energia para manter a homeotermia, afetando tanto o sistema de produção de leite como a reprodução destes animais (ALLEN *et al.*, 2015). Em tais sistemas, é de grande importância o monitoramento da alimentação, que por sua vez está associado com o aumento do calor metabólico produzido (PACHECO, V.M., 2019). O estresse térmico em vacas de leite tem sido estudado como um caminho para melhorar a eficiência produtiva e o bem-estar animal. Diversos autores têm verificado o potencial da termografia de infravermelho como ferramenta não-invasiva para monitorar a temperatura de superfície dos animais. Da mesma forma, modelos computacionais têm sido estudados na área animal, com o intuito de auxiliar o manejo.

Pacheco (2019) realizou um estudo avaliando pela temperatura infravermelha, para monitorar a temperatura da superfície dos animais. Os resultados apresentaram que a fronte e a área ocular tendem a ter maior correlação com os dados de frequência respiratória e temperatura retal. Com estes dados uma rede neural conseguiu determinar quais vacas estavam em estresse calórico durante todo o experimento, diminuindo o risco de perdas e melhorando o bem-estar do animal.

Borchers e Bewley (2015) citam que a maioria dos produtores que usa estes softwares baseados em Inteligência Artificial, tendem a não entender todos os dados que os RNAs fornecem, e acabam dando atenção somente aos parâmetros que lhes são familiares. Apesar de as informações fornecidas pelas redes conduzirem a conclusões mais robustas a respeito da avaliação animal, os produtores tendem a rejeitar a maioria destas informações, primeiramente, por falta de familiaridade, e segundo, com o intuito de não se confundirem na execução da tarefa ou resolução do problema. Borchers and Bewley (2015) também afirmam que tais produtores tem o costume de olhar o animal como forma de atestar o resultado dos cálculos

realizados por tais sistemas; o que reforça a necessidade de reformulação da maneira de se apresentar o resultado das avaliações realizadas por máquinas inteligentes, de forma que tais resultados sejam mais inteligíveis e de mais simples entendimento por técnicos e produtores.

Eckelamp e Bowley (2020) realizaram uma pesquisa com diferentes produtores que compraram máquinas de precisão para gado de leite. Estas máquinas, por meio de “*machine learning*” conseguem identificar se um animal está com uma doença como uma mastite, dependendo do seu comportamento. Com essas máquinas os produtores conseguem resolver o problema antes que se agrave ou não tenha volta.

A OMS, Organização Mundial da Saúde, tem se preocupado muito com os diferentes adulterantes que vem sendo usado na produção de leite no mundo inteiro (SHARIFAN, 2019; Barros, 2020). Por isso diferentes softwares e máquinas inteligentes vêm sendo desenvolvidas, com o intuito de avaliar a presença de adulterantes no leite, com um resultado muito produtivo para as indústrias por causa da velocidade e da efetividade destas novas tecnologias.

Lal *et al.* (2022) indicou que o uso de novas tecnologias baseadas em inteligência artificial tem se desenvolvido muito rápido e que no futuro será muito prático a utilização de bases de dados atuar na pecuária leiteira. Em seu trabalho, os autores discutem a respeito do uso de tecnologias baseadas em lógica fuzzy (um método de inteligência artificial), visando a classificação de leites de acordo com seus atributos, e na detecção de adulterantes no leite. Para que avanços importantes sejam feitos precisa se de mais pesquisas e de máquinas que consigam ter uma maior acurácia e que os vendedores consigam ter certeza de qual tipo de leite eles estão comprando.

Na pecuária de corte os avanços estão mais atrasados comparados com as outras áreas de avaliação animal, e muito disso se deve a que os parâmetros de avaliação antigos para esta área são muito estressantes para os animais por causa do contato humano-animal que se tem na hora da avaliação. Sendo que as avaliações precisam se fazer individualmente e com o contato dos animais. Isto não representaria um problema para animais acostumados com o contato com o homem, só que a maioria da bovinocultura de corte é extensiva e os animais tendem a ser

ariscos e agressivos. É por isso que muitos pesquisadores e grandes empresas já desenvolveram e estão desenvolvendo mais inovações com o intuito de diminuir o estresse no processo de avaliação do ganho de peso, sanidade, dentre outros. O uso de sistemas de visão computacional tem sido de grande avanço para auxiliar na medição das diferentes partes no animal a fim de proporcionar mensurações biométricas de forma rápida, e sem causar estresse excessivo nos animais (Gomes *et al.*, 2016; Kashiha *et al.*, 2014; Wang *et al.*, 2008). Tais mensurações são gravadas automaticamente em uma base de dados que permite o cálculo do peso desses animais, diminuindo o estresse do animal (GOMES *et al.*, 2016; KASHIHA *et al.*, 2014; WANG *et al.*, 2008).

A cada ano que vem sendo desenvolvidos mais equipamentos com tecnologias baseadas em “*Machine Learning*”, as quais proporcionam mensurações com menos erro embutido (GIANOLA *et al.*, 2011). Medições realizadas por meio de tecnologias baseadas em RNAs, são atualmente, as mais precisas, mas os autores ressaltam a necessidade de mais estudos, visando sua aplicabilidade em diferentes raças de forma com que a ferramenta proporcione uma maior acurácia (Cominotte *et al.*, 2020). Os avanços da Inteligência Artificial na pecuária vêm aumentando muito e diferentes estudos vem demonstrando que sua utilização culmina por diminuir a probabilidade de erro no processo de avaliação animal. Estudos envolvem pecuária de precisão, produção e manejo de pastagens, bem-estar animal, etc.

Na agricultura os avanços na hora do plantio são muito maiores, sendo assim que facilita muito o cálculo de produção e produtividade da pastagem que teu campo tem. Com isso diferentes cálculos podem ser feitos para diminuir a quantidade de suplemento que os animais vão precisar para ganhar o peso previsto. Outro motivo pelo qual é muito relevante ter uma base de dados é para saber quando fazer diferentes procedimentos e como fazer eles em diferentes áreas (ARIAS, 2004)


Fazendas avançadas tecnologicamente já utilizam sistemas de gerenciamento capaz de estimar o impacto que determinadas ações de manejo no processo produtivo. Tais tecnologias são capazes de integrar smartphones e tablets, que são utilizados no processo de coleta de dados de por exemplo, altura de capim, condições de pasto, leitura de cocho, consumo de suplementação e condições

sanitárias, de forma que tais atributos sejam considerados no processo de tomada de decisão. A junção tecnologias baseadas em Internet das Coisas (IoT), colares inteligentes e balança de passagem são cada vez mais usados de forma integrada para monitorar indicadores de produtividade, ambientais e de bem-estar animal, com isso, e auxiliar no desenvolvimento de tecnologias baseadas em modelos de Inteligência Artificial, para uso dos próprios pecuaristas.

Brenneke (2007), usou uma rede neural para prever a quantidade de proteína bruta e suas frações, usando uma base de dados que incluiu as variáveis como tamanho, cor das folhas, média da altura do pré-pastejo, latitude e longitude, perfilho novos, perfilho remanescentes e mais variáveis. O resultado deste trabalho mostrou que a RNA conseguiu estabelecer uma relação entre as variáveis que foram fornecidas à base de dados, o que proporcionou um cálculo de proteína bruta acurado e com uma velocidade maior do que seria feito em laboratório.

Ghotbaldini, *et al.* (2019) indicam que poucas pesquisas foram realizadas nessa área, aplicada a pequenos ruminantes. Em seu trabalho, os autores avaliaram o uso de Redes Neurais Artificiais em ovelhas de 6 meses, visando seleção para peso corporal, e conseguiram ajustar modelos satisfatórios para característica de produtividade. No experimento, foram considerado as diversas características visando a predição do valor genético dos animais (Figura 4). Os autores concluíram que os métodos predição normalmente utilizados já são bastante satisfatórios, mas aqueles ajustados com método de Inteligência Artificial proporcionam um erro bem menor do que aqueles baseados nos métodos tradicionais.

Figura 4. Rede neural simples ajustada para predição de valor genético em progênie de ovinos (GHOTBALDINI, *et al.*, 2019).



As redes neurais artificiais têm sido aplicadas também na avicultura com o intuito de auxiliar na determinação de planos de ação no processo de manejo, com maior acurácia. As diferentes RNAs têm sido utilizada na interpretação de dados derivados de sensores e dados de clima, (RIBEIRO, *et al.* 2019). Tais informações auxiliam no processo de cálculo mistura da ração diária que os animais devem ingerir para chegar ao peso ideal para o abate. Tal processo auxilia na tomada de decisão pelos produtores, proporcionando ainda mais acurácia ao processo (RICO-CONTRERAS, *et al.* 2017).

Na área da suinocultura, muitos trabalhos são descritos visando otimizar o uso de bases de dados de forma a proporcionar avaliar diferentes parâmetros associar / correlacionar dados de diferentes avaliações. Com o uso da Inteligência Artificial e das bases de dados, consegue-se inferir a respeito da saúde de suínos para diferentes fases de crescimento, além de associar tais informações com a produção dos animais (VAN KLOMPENBURG, 2022).

Ma *et al.* (2019), desenvolveram um aparato que realiza a mistura de ração e o arraçamento, de forma automatizada e inteligente, além de uma plataforma de serviços online que auxilia a otimizar o manejo de suínos e sua alimentação. Ma *et al.* (2019) realizaram seus estudos utilizando bases de dados de diferentes experimentos, considerando o uso de sensores e unidades de monitoramento avançada, que com o uso da aprendizagem da máquina conseguiram proporcionar

resultados satisfatórios, considerando o atual nível de avanço tecnológico da suinocultura.

A alimentação na piscicultura tem apresentado avanços notáveis, sendo uma das áreas da zootecnia que tem se aproveitado da tecnologia de inteligência Artificial. Os produtores de peixes têm um grande problema relacionado às sobras da alimentação, o que acarreta um prejuízo significativo, quando computado o gasto anual. Mendes Junior e Moura (2021), modelaram uma rede neural que avaliou o som e as vibrações na água, que os peixes fazem antes, durante e depois do arraçoamento. Com o auxílio do modelo ajustado, os autores conseguiram prever quando o peixe está com fome, e utilizaram tal informação de forma a otimizar os horários que os produtores ou as máquinas precisam fornecer a ração para os animais. Dessa forma, conseguiram otimizar o processo de dispensa da ração e diminuir a quantidade de sobras. Com estes dados, o método de “*Machine Learning*” conseguiram obter uma acurácia de 88% na detecção da fome dos animais.

A genética de peixes também tem se beneficiado dos avanços da Inteligência Artificial. Os diferentes métodos de avaliação genômica utilizando métodos de IA, aplicado a piscicultura, também tem mostrado resultados mais promissores do que os métodos tradicionais de cálculo baseados modelos lineares (PALAIOKOSTAS, 2021). Em seu trabalho, tais autores, com a ajuda do “*Machine Learning*” conseguiram identificar SNP associados a resistência a doenças, e prever o valor genético dos animais, para tal característica. Dessa forma, pode-se selecionar animais genitores, melhorando a genética da população, com o intuito de diminuir as perdas por morte ou doença, e melhorar o retorno financeiro dos produtores rurais.

A nutrição animal constitui uma das áreas da Zootecnia que também tendem a se beneficiar bastante com os avanços da inteligência artificial. Suparwito *et al.* (2020), conseguiram ajustar um modelo de machine learning visando a predição de consumo de energia metabolizável em ovelhas. Os animais foram monitorados em campo, por meio de sensores, acoplados com GPS (Figura 5), mensurados seus respectivos pesos corporais e seu gasto energético; e tais informações foram associadas com seus respectivos comportamentos de pastoreio em campo. O objetivo do trabalho foi realizar essa associação de forma a prever a ingestão energética de cada animal, a partir dos dados dos sensores. De acordo com os

autores, os resultados obtidos foram satisfatórios e permitiram demonstrar que com o auxílio da tecnologia de sensores, conseguiram quantificar o consumo de energia dos animais durante o pastoreio.

Figura 5. Imagem de ovino com sensor, visando monitorar o comportamento de pastoreio dos animais.



6-. REFLEXÃO

As avaliações nos animais por métodos de inteligência artificial já são uma realidade e a perspectiva é de serem utilizadas cada vez mais, no futuro.

Os pesquisadores começaram a se dedicar no uso destas tecnologias com o intuito de aprimorar o manejo, considerando a capacidade preditiva de tais tecnologias, as quais apresentam maior acurácia que os métodos tradicionais.

Cada vez mais, faz-se necessário, profissionais e pesquisadores que auxiliem e participem no desenvolvimento de novos softwares e máquinas inteligentes, visando uma melhor aplicabilidade da tecnologia.

7-. REFERÊNCIAS BIBLIOGRÁFICAS

ADAM, K., ADAM, M., FAKHARALDIEN, I., MOHAMAD ZAIN, J. and MAJID, M. "Big Data Management and Analysis," 2014.

ALLEN, J. D. *et al.* Effect of core body temperature, time of day, and climate conditions on behavioral patterns of lactating dairy cows experiencing mild to moderate heat stress. **Journal of dairy science**, v. 98, n. 1, p. 118-127, 2015.

ALVAREZ, J. R. *et al.* Body condition estimation on cows from depth images using Convolutional Neural Networks. **Computers and electronics in agriculture**, v. 155, p. 12-22, 2018.

ARIAS, N.A.; MOLINA, M.L.; GUALDRON, O. Estimate of the weight in bovine livestock using digital image processing and neural network. **Proc. SPIE**, v.562, p.224, 2004

BARROS, C. P. *et al.* Paraprobiotics and postbiotics: concepts and potential applications in dairy products. **Current Opinion in Food Science**, v. 32, p. 1-8, 2020.

BINOTI, M. L. M. da S.; BINOTI, D. H. B.; LEITE, H. G. **Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto**. Revista Árvore, Viçosa, v. 37, n. 4, p. 639-645, 2013b.

BORCHERS, M. R. *et al.* Machine-learning-based calving prediction from activity, lying, and ruminating behaviors in dairy cattle. **Journal of dairy science**, v. 100, n. 7, p. 5664-5674, 2017.

BORCHERS, M. R.; BEWLEY, J. M. An assessment of producer precision dairy farming technology use, prepurchase considerations, and usefulness. **Journal of dairy science**, v. 98, n. 6, p. 4198-4205, 2015.

BRENNECKE, K.. **Fracionamento de carboidratos e proteínas e a predição da proteína bruta e suas frações e das fibras em detergentes neutro e ácido de *Brachiaria brizantha* cv. Marandu por uma rede neural artificial**. 2007. Tese de Doutorado. Universidade de São Paulo.

BROWN-BRANDL, T. M.; JONES, D. D.; WOLDT, W. E. Evaluating modelling techniques for cattle heat stress prediction. **Biosystems Engineering**, v. 91, n. 4, p. 513-524, 2005.

COMINOTTE, A. *et al.* Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases. **Livestock Science**, v. 232, p. 103904, 2020.

COSTA, J. P. O.; ORTOLAN, Lucas Dissenha. **Classificação de imagens de sensoriamento remoto utilizando redes neurais artificiais**. 2014. 80 f. Trabalho de Conclusão de Curso (Graduação) - Curso Superior de Bacharelado em Sistemas de In-formação, Universidade Tecnológica Federal do Paraná, Curitiba, 2014.

DASH, S. *et al.* Big data in healthcare: management, analysis and future prospects. **Journal of Big Data**, v. 6, n. 1, p. 1-25, 2019.

DING, S. *et al.* Evolutionary artificial neural networks: a review. **Artificial Intelligence Review**, v. 39, n. 3, p. 251-260, 2013.

ECKELKAMP, E.A., BEWLEY J.M. On-farm use of disease alerts generated by precision dairy technology, **Journal of Dairy Science**, Volume 103, Issue 2, 2020, Pages 1566-1582.

ERDMANN, A. C. **Reconhecimento de espécies florestais por meio de imagens de folhas**. 2016. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.

FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. Cristina; ANDRADE, M. A. M. REDES NEURAIIS ARTIFICIAIS: PRINCÍPIOS BÁSICOS. **Revista Eletrônica Científica Inovação e Tecnologia**, Medianeira, v. 1, n. 13, p. 47-57, jun. 2016.

GHOTBALDINI, H. *et al.* Predicting breeding value of body weight at 6-month age using Artificial Neural Networks in Kermani sheep breed. **Acta Scientiarum. Animal Sciences**, v. 41, 2019.

GIANOLA, D. *et al.* Predicting complex quantitative traits with Bayesian neural networks: a case study with Jersey cows and wheat. **BMC genetics**, v. 12, n. 1, p. 1-14, 2011.

GOMES, R. A. *et al.* Estimating body weight and body composition of beef cattle trough digital image analysis. **Journal of Animal Science**, v. 94, n. 12, p. 5414-5422, 2016.

HAYKIN, S.. **Neural networks and learning machines, 3/E**. Pearson Education India, 2009.

HESS, A. F. *et al.* Aplicação dos modelos lineares generalizados para estimativa do crescimento em altura. **Pesquisa Florestal Brasileira**, v. 35, n. 84, p. 427-433, 2015.

HOSSAIN, E. *et al.*, “Application of Big Data and Machine Learning in Smart Grid, and Associated Security Concerns: **A Review**,” **IEEE Access**, vol. 7, pp. 13960-13988, 2019.

JABBAR, K. A. *et al.* Early and non-intrusive lameness detection in dairy cows using 3-dimensional video. **Biosystems engineering**, v. 153, p. 63-69, 2017.

KASHIHA, M. *et al.* Automatic weight estimation of individual pigs using image analysis. **Computers and Electronics in Agriculture**, v. 107, p. 38-44, 2014.

KOKETSU, Y.; IIDA, Ryosuke. Farm data analysis for lifetime performance components of sows and their predictors in breeding herds. **Porcine Health Management**, v. 6, n. 1, p. 1-12, 2020.

KRUG, C. Creating a model to detect dairy cattle farms with poor welfare using a national database. **Preventive Veterinary Medicine**, v. 122, n. 3, p. 280-286, 2015.

LAL, P. P. IoT integrated fuzzy classification analysis for detecting adulterants in cow milk. **Sensing and Bio-Sensing Research**, v. 36, p. 100486, 2022.

LANEY. Deja VVVu: others claiming Gartner’s construct for big data Gart. Blog. Jan., 14 (2012), p. 1

MA, W. The realization of pig intelligent feeding equipment and network service platform. In: **International Conference on Computer and Computing Technologies in Agriculture**. Springer, Cham, 2017. p. 473-484.

MACHADO, W. C.; FONSECA JUNIOR, E. S. Redes neurais artificiais aplicadas na previsão do VTEC no Brasil. **Boletim de Ciências Geodésicas**, v. 19, p. 227-246, 2013.

MASSUCATTO, J. D. P. **Aplicação de conceitos de redes neurais convolucionais na classificação de imagens de folhas**. 2018. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.

MATTA, P.; PANT, B. Internet of things: Genesis, challenges and applications. **Journal of Engineering Science and Technology**, v. 14, n. 3, p. 1717-1750, 2019.

MENDES JUNIOR, J.N.N; MOURA, R.S.T. ALIMENTAÇÃO AUTOMATIZADA NA PISCICULTURA COM USO DE INTELIGÊNCIA ARTIFICIAL. **9a Edição do Aquaciencia digital**, Universidade Federal Do Maranhão, 2021.

MOROTA, G. Machine learning and data mining advance predictive big data analysis in precision animal agriculture. **Journal of Animal Science**, 2018.

PACHECO, V. M. **Desenvolvimento de classificador de conforto térmico para bovinos de leite utilizando modelagem computacional e termografia de infravermelho**. 2019. Tese de Doutorado. Universidade de São Paulo.

PALAIOKOSTAS, C. Predicting for disease resistance in aquaculture species using machine learning models. **Aquaculture Reports**, v. 20, p. 100660, 2021.

RIBEIRO, R. Generating action plans for poultry management using artificial neural networks. **Computers and Electronics in Agriculture**, v. 161, p. 131-140, 2019.

RICO-CONTRERAS, J. O. Moisture content prediction in poultry litter using artificial intelligence techniques and Monte Carlo simulation to determine the economic yield from energy use. **Journal of Environmental Management**, v. 202, p. 254-267, 2017.

RISTEVSKI, B.; CHEN, M. Big data analytics in medicine and healthcare. **Journal of integrative bioinformatics**, v. 15, n. 3, 2018.

SHARIFAN, P. Effect of low-fat dairy products fortified with 1500IU nano encapsulated vitamin D3 on cardiometabolic indicators in adults with abdominal obesity: A total blinded randomized controlled trial. **Current Medical Research and Opinion**, v. 37, n. 4, p. 579-588, 2021.

SHEELA, K. G.; DEEPA, S. N. Review on methods to fix number of hidden neurons in neural networks. **Mathematical problems in engineering**, v. 2013, 2013.

SILVA, R.B.; SIMÕES, D.; SILVA, M.R. Qualidade de mudas clonais de *E. urophylla* x *E. grandis* em função do substrato. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 297-302. 2012.

SOARES, F. C., ROBAINA, A. D., PEITER, M. X., & RUSSI, J. L. Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, v. 45, n. 11, p. 1987-1993, 2015.

SOUSA, R. M. de. **Avaliação da Predição de Algoritmos de Treinamento Supervisionado de Redes Neurais Artificiais Aplicado a Qualidade de Biodiesel**. 2015. 82 f. Dissertação (Doutorado) - Curso de Engenharia de Eletricidade, Centro de Ciências Exatas e Tecnologia, Universidade Federal do Maranhão, São Luís, 2015.

STANDER, J. B. The modern asset: Big Data and Information Valuation. **Thesis presented in partial fulfilment of the requirements for the degree of Master of Science in Engineering Management in the Faculty of Engineering at Stellenbosch University**, 2015.

SUPARWITO, H. The use of animal sensor data for predicting sheep metabolisable energy intake using machine learning. **Information Processing in Agriculture**, v. 8, n. 4, p. 494-504, 2021.

SVOZIL, D.; KVASNICKA, V.; POSPICHAL, J. Introduction to multi-layer feed-forward neural networks. **Chemometrics and intelligent laboratory systems**, v. 39, n. 1, p. 43-62, 1997.

VAN KLOMPENBURG, T. A.; KASSAHUN, A. Data-driven decision making in pig farming: a review of the literature. **Livestock Science**, p. 104961, 2022.

VENDRUSCOLO, D. G. S.; DRESCHER, R.; SOUZA, H. S.; MOURA, J. P. V. M.; MAMORÉ, F. M. D.; SIQUEIRA, T. A. S.. ESTIMATIVA DA ALTURA DE EUCALIPTO POR MEIO DE REGRESSÃO NÃO LINEAR E REDES NEURAIIS ARTIFICIAIS. **Revista Brasileira de Biometria**, Cuiabá, v. 33, n. 4, p. 556-569, 2015.

WANG, Y., YANG, W., WINTER, P., WALKER, L., 2008. Walk-through weighing of pigs using machine vision and an artificial neural network. **Biosyst. Eng.** 100, 117–125

WOLFERT, S., GE, L., VERDOUW, C., & BOGAARDT, M. J. (2017). Big Data in Smart Farming. **A review. Agricultural Systems**, 153, 69–80.

YANG, L.B., Application of artificial intelligence in electrical automation control Procedia Comput. Sci., **Proceedings of the 3rd International Conference on Mechatronics and Intelligent Robotics** (ICMIR-2019), 166 (2020), pp. 292-295.

Autorização de arquivamento da versão final do Trabalho de Conclusão de Curso (TCC)

Eu, Prof. Dr. Rafael Simões Tomaz, venho por meio desta **AUTORIZAR** o arquivamento no Repositório Institucional Unesp da versão final do trabalho de conclusão de curso intitulado "Uso de métodos de Inteligência Artificial na avaliação animal", do aluno Jorge Adrian Velasco Avila, regularmente matriculada no Curso de Graduação em Zootecnia, período integral da Faculdade de Ciências Agrárias e Tecnológicas (FCAT) do Câmpus de Dracena da Unesp.

Informo que o arquivo em PDF do TCC está tecnicamente adequado em sua forma e estrutura e contém os devidos agradecimentos aos órgãos de fomento à pesquisa (no caso de recebimento de bolsa e/ou financiamento).

AUTORIZO ainda, a disponibilização online em acesso aberto do TCC no Repositório Institucional Unesp.

NÃO AUTORIZO a disponibilização online em acesso aberto do TCC no Repositório Institucional Unesp.

Justificativa:

Dracena, 27 de julho de 2022.

Dr. Rafael Simões Tomaz
ORIENTADOR

Rafael Simões Tomaz
Prof. Assistente Doutor
FCAT UNESP - Câmpus de Dracena