

UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DE ESTRESSE EM OVELHAS PRENHAS

Wildson Antonio de Oliveira Bezerra
Universidade Anhanguera UNIDERP
victordamage@gmail.com

Celso Correia de Souza
Universidade Anhanguera UNIDERP
celso.correia@anhanguera.com

Marcos Barbosa Pereira
Universidade Anhanguera UNIDERP
marcos.barbosa@uniderp.com.br

José Francisco dos Reis Neto
Universidade Anhanguera UNIDERP
jfrn@terra.com.br

Diogo Cesar Gomes Silva
Universidade Anhanguera UNIDERP
diogocgsilva@hotmail.com

RESUMO

Este trabalho teve como objetivo avaliar o estresse térmico na fase de gestação e maternidade na ovinocultura com o uso de RNA, com base em variáveis térmicas ambientais e fisiológicas de ovelhas gestantes. A pesquisa foi realizada no Centro Tecnológico de Ovinos (CTO) da Universidade Anhanguera UNIDERP utilizando 30 matrizes alojadas em um piquete comum durante as fases de pré e pós gestação, onde foram classificados três indicadores de estresse em função da frequência respiratória (Leve, Moderado e Alto). Para tanto, foi implementada uma RNA *Multilayer Perceptron* com uma camada de entrada, uma oculta (com sete neurônios) e uma camada de saída, com função de ativação tangente hiperbólica e softmax. A temperatura ambiente do ar, a umidade relativa, e as temperaturas da pele, do corpo, da lã, da cabeça, a retal e a frequência respiratória foram consideradas variáveis de entrada. Como variável de saída foi considerada o estresse animal. Os resultados podem ser considerados satisfatórios, visto que a RNA apresentou erro de entropia cruzada de 2,337 e predições incorretas de 1,1% em prever o nível de estresse térmico das ovelhas.

Palavras-chave: Sistemas inteligentes; Centro tecnológico de ovino (CTO); Variáveis ambientais; RNA_MLP; Treinamento de RNA

1 INTRODUÇÃO

Para a melhoria do cenário da carne de ovino no Brasil, relativa à qualidade da carne ovina ofertada ao consumidor, necessário se faz melhorar a estrutura da cadeia produtiva da

ovinocultura, incluindo nessa o bem-estar animal, com o acompanhamento técnico especializado do ovino desde o nascimento até o abate. A produção de indicadores ambientais e zootécnicos para o controle da qualidade do bem-estar animal, além da melhoria de plantas de abatedouros que devem ser implantados nas proximidades das propriedades rurais, dentre outras.

Um dos fatores de maior impacto nos sistemas produtivos de animais são os fatores ambientais, em especial, o efeito direto do clima sobre os animais, que ocorre principalmente devido a influência da temperatura do ar, radiação solar e pela umidade relativa do ar quando associada à temperatura (TITTO *et al.*, 1998). Desse modo, a avaliação do ambiente e do microclima de cada região em que os animais são submetidos, bem como, o estudo das respostas fisiológicas e comportamentais é imprescindível para compreender seus mecanismos adaptativos e índices de conforto e melhor performance produtiva.

Regiões com elevadas temperaturas, ou variações de temperatura ambiente com acréscimo de ganho calórico, produzem consequentes alterações no sistema termo regulatório e, portanto, estresse calórico. Alterações fisiológicas podem ser observadas nesses cenários, como o aumento na liberação de cortisol, alterando o metabolismo, o comportamento e o bem-estar animal (SILANIKOVE, 2000; STARLING *et al.*, 2005). Há, ainda, os relatos com os prejuízos em relação à ingestão e metabolização de alimentos, capazes de afetar negativamente o desempenho e o rendimento da função reprodutiva (COSTA *et al.*, 1992; HOPKINS *et al.*, 1980).

As principais vantagens de utilização de RNA na predição de índices de estresse são sua aplicação em tempo real e, a rápida resolução de problemas práticos, sem a necessidade de definição de lista de regras ou de modelos precisos, como acontece com modelos de regressões lineares múltiplas. As RNA utilizam programas de instruções sequenciais, utilizando regras de aprendizagem obtida através de exemplos, que permitem adquirir poder de generalização suficiente para reconhecer padrões e predizer cenários.

Os modelos de RNA têm potencial de aplicação na agropecuária em situações que requeiram classificação de padrões, identificação e associação de padrões, aproximação de funções e aprendizado em áreas em que é difícil criar modelos precisos da realidade e com frequentes mudanças de ambiente (HAYKIN, 2001).

A aplicabilidade das RNA é crescente e a redução no custo de implantação é constante à medida que se popularizam ferramentas computacionais que permitem a inserção de novas

técnicas para solução de problemas complexos, como a predição de dados não-lineares e padrões de comportamento. A entrada e saída de dados dos sistemas produtivos são preditas nas análises múltiplas e paralelas das redes (MURASE, 2000).

As RNA são modelos de processamento serial ou distribuídos paralelamente, procurando alcançar bom desempenho via interconexão de elementos computacionais simples. Os modelos exploram simultaneamente muitas hipóteses utilizando regras de aprendizagem que permitem adquirir poder de generalização suficiente para reconhecer padrões e prever cenários (HAYKIN, 2001; FREEMAN e SKAPURA, 2002). Os modelos de redes neurais têm potencial de aplicação na produção animal quando é necessário um banco de dados que permita a compreensão das relações entre o ambiente e a exploração agropecuária (FERNANDEZ *et al.*, 2006; VIEIRA *et al.*, 2010). Desse modo, o objetivo deste estudo foi o de avaliar o estresse térmico na fase de gestação e maternidade na ovinocultura com o uso de RNA, com base em variáveis térmicas ambientais e fisiológicas de ovelhas gestantes.

2 REVISÃO DA LITERATURA

2.1 REDES NEURAIS ARTIFICIAIS (RNA)

As RNA são modelos computacionais, inspirados nos neurônios biológicos do sistema nervoso de seres vivos, e que possuem a capacidade de aprendizagem e manutenção do conhecimento do conhecimento adquirido, baseado em informações recebidas, na forma de exemplos do fenômeno em tela. As RNA são compostas por neurônios artificiais que são interligados por um grande número de interconexões afetadas de pesos sinápticos (FREEMAN E SKAPURA, 1991; HAYKIN, 2001; KOVACS, 2006).

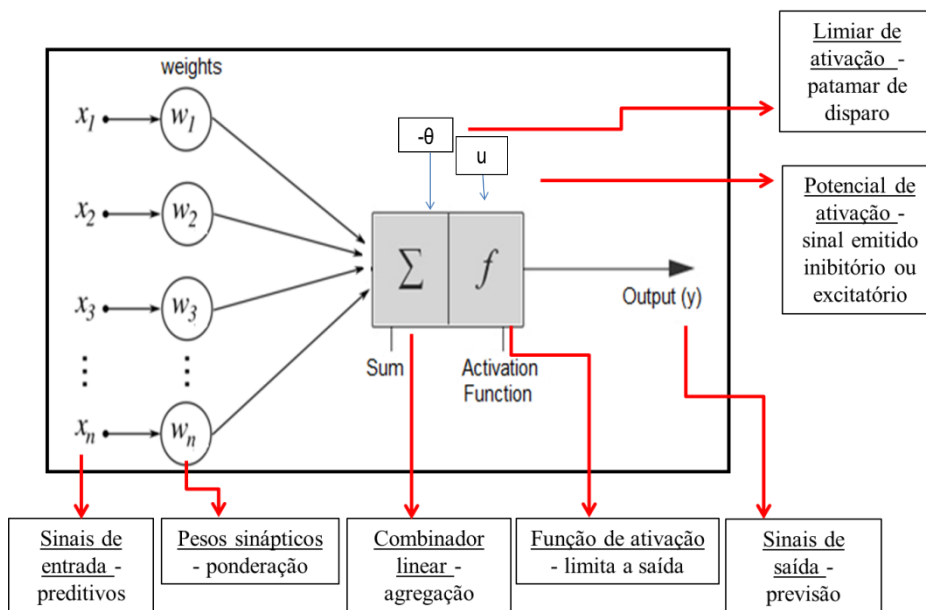
De acordo com Braga *et al.* (2014), as principais características das RNA são: i) organização de dados; ii) adaptação do modelo por experiência; iii) capacidade de aprendizado; iv) armazenamento distribuído; v) tolerância a falhas; vi) habilidade de generalização; vii) controle e otimização de sistemas; viii) processamento de sinais e predição. Essas características das RNA conduzem à busca por processos que possam realizar a predição de fenômenos biológicos como a dos índices zootécnicos, que geram dados satisfatórios próximos dos valores reais.

O processo de funcionamento das RNA é composto basicamente pelo tripé: uma arquitetura, uma topologia e um treinamento. A arquitetura define a forma como os neurônios estão dispostos, a topologia define as diferentes formas de composições estruturais assumidas

pela rede e o treinamento está associado ao algoritmo de aprendizagem, ou seja, consiste no conjunto de passos ordenados visando os ajustes dos pesos, sintonizando as respostas de saída da rede próximas dos valores desejados (BRAGA, 2014).

Segundo HAYKIN (2001), em 1950 foi criado o primeiro modelo de RNA, que consistia em uma rede de múltiplos neurônios artificiais distribuídos em três camadas, denominado *perceptron* ou discriminador linear. Os *perceptrons* eram dispostos em camadas de entrada e de saída, com os pesos das ligações adaptados para alcançar a eficácia sináptica. Um *perceptron* pode aprender conceitos através de exemplos e responder quando um novo exemplo é apresentado, com 1, se é verdade, ou com 0 se ele é falso, com base nos exemplos apresentados inicialmente. A figura 1 mostra a estrutura de uma RNA *perceptron*.

Figura 1. Arquitetura de uma RNA *perceptron*.



Fonte: Adaptado de SILVA *et al.* (2013).

Uma RNA de uma camada intermediária pode implementar qualquer função contínua. O uso de duas camadas ocultas permite a abordagem de diversas funções. O caminho para chegar com o *perceptron* em camadas é chamado *multilayer perceptron* (MLP). O MLP foi concebido para resolver problemas mais complexos, que não poderiam ser resolvidas pelo modelo de rede utilizando apenas um neurônio.

As RNAs do tipo MLP pertencem à classe de arquitetura *feedforward* (alimentação à frente), e são constituídas de uma camada de entrada de neurônios, uma ou mais camadas

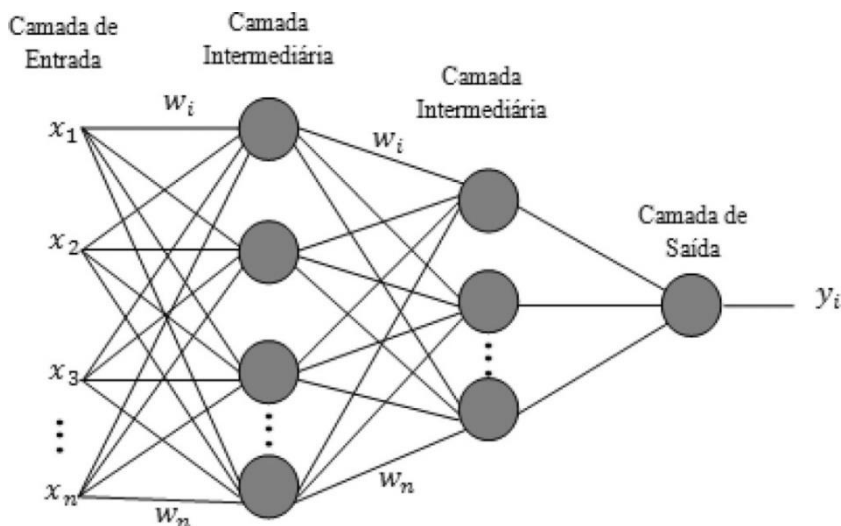
ocultas (ou intermediárias) e uma camada de saída. O algoritmo de aprendizado utilizado no treinamento supervisionado da rede MLP é o *backpropagation* ou algoritmo de retro propagação de erros, baseado na regra Delta generalizada (GOMES ET AL., 2010).

As redes MLP são caracterizadas por conter pelo menos uma camada intermediária de neurônios, pelas elevadas possibilidades de aplicação e são consideradas versáteis pela abrangência no potencial de aproximação universal de funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais e otimização de sistemas (MEHDAWI e AHMAD, 2012).

A RNA MLP possui uma estrutura composta basicamente por três camadas ou mais camadas, sendo respectivamente de uma camada de entrada, uma ou mais camadas intermediárias ou ocultas e uma camada de saída. Na camada de entrada são inseridos os parâmetros das variáveis que serão preditoras no processo, ou seja, as variáveis independentes, na camada intermediária ocorrem o processamento dos neurônios e ajustes das funções e pesos sinápticos e na camada de saída estão os parâmetros a serem previstos, dados como variáveis dependentes.

Cada um dos neurônios da camada de entrada se conecta a todos os outros neurônios da camada intermediária e estes por sua vez aos neurônios da camada de saída e dependendo da estimulação gerada pela soma ponderada do produto dos neurônios de entrada por seus pesos sinápticos, a função de transferência e emissão dos sinais de saída, serão diferentes (HAIR *et al.*, 2005; KOVÁCS, 2006; BRAGA *et al.*, 2014). A figura 2 mostra a estrutura de uma RNA MLP.

Figura 2. Arquitetura da Rede Neural Artificial MLP.



Fonte: Adaptado de SILVA *et al.* (2013).

Os sinais de entrada $\{x_1, x_2, \dots, x_n\}$ são os sinais inseridos para as variáveis da aplicação específica. Esses sinais são normalizados na rede visando incrementar a eficiência computacional dos algoritmos de aprendizagem; Pesos sinápticos $\{w_1, w_2, \dots, w_n\}$, que são os valores que servem para a ponderação de cada variável x_i de entrada da rede ($w_i \times x_i$), e que permite quantificar a relevância em relação à funcionalidade de cada neurônio.

Dependendo do estímulo gerado pela soma ponderada das entradas pelos pesos, os neurônios ativam a função de transferência, que emite uma resposta para a próxima camada. A camada de saída, dada por y_i , recebe os estímulos da camada intermediária e gera um padrão de resposta. Portanto, as camadas intermediárias funcionam como extratoras de características dos padrões de entrada, codificadas pelos pesos e permitem que a rede represente o problema com os sinais de saída mais detalhados (HAYKIN, 2001).

Estruturada a RNA para uma determinada aplicação, ela está pronta para ser da. Para iniciar esse processo, os pesos iniciais são escolhidos aleatoriamente; em seguida inicia-se o treinamento ou aprendizagem. Existem duas abordagens de treinamento principais: supervisionado e não supervisionado. O treinamento supervisionado exige o fornecimento da saída desejada para a rede, seja por modo manual de “classificação” do desempenho da rede, seja fornecendo os resultados desejados com as entradas.

Para que a RNA apresente resultados de saída é necessário aplicar o processo de aprendizagem da rede, cuja resposta é resultado do processo obtido do treinamento dessa rede através de um algoritmo. O algoritmo de aprendizagem adotado para a RNA MLP foi o de retropropagação de erros, ou também denominado de *backpropagation*, que trata de uma técnica de treinamento supervisionada e realiza o ajuste dos pesos através do cálculo da diferença entre o valor previsto e o valor observado (SAFI e BOUROUMI, 2011; BRAGA *et al.*, 2014).

O algoritmo *backpropagation* é um algoritmo supervisionado que utiliza pares (entradas, saída desejada) para, por meio de um mecanismo de correção de erros, ajustar os pesos da rede. O treinamento ocorre em duas fases, em que cada fase percorre a rede em um sentido. Estas duas fases são chamadas de *fase forward* e *fase backward*. A *fase forward* é utilizada para definir a saída da rede para um dado padrão de entradas, ao mesmo tempo em que, atualiza os pesos de suas conexões.

Um conjunto de elementos da amostra de treinamento são inseridos nas entradas e propagados camada a camada até a reprodução das respectivas saídas, os pesos sinápticos e

limiares dos neurônios permanecem inalterados durante a execução desse processo. A fase *backward* é baseada na propagação reversa em que os ajustes dos pesos sinápticos e limiares de todos os neurônios ocorrem no decorrer da fase (BRAGA *et al.*, 2010).

Após a obtenção dos pesos ideais para a rede, que deve ser testado utilizando os problemas cujas soluções são conhecidas, mas não têm sido utilizados no processo de formação de rede e deve-se verificar se os dados de entrada para estes problemas atingem a solução esperada. Se o teste for bem-sucedido, então pode se usar a rede treinada para resolver o problema em tela.

2.2 ESTRESSE EM OVINOS

Em sistemas de criação extensivo, os ovinos possuem a possibilidade de manifestar em maior frequência, seus comportamentos (MUNOZ *et al.*, 2018), no entanto, isso não implica, necessariamente que o bem-estar seja elevado, e, de fato, algumas situações adversas podem afetar este aspecto, como por exemplo o manejo, transporte e instalações inadequados (FAZIO *et al.*, 2018), privação de espaço (CAROPRESE, 2008), desbalanço ou déficit nutricional (PEREIRA *et al.*, 2018), e adversidades climáticas (MARAI *et al.*, 2007).

Tais condições apresentadas se tornam ainda mais importantes no período gestacional, em especial, no terço final da gestação. Sobre este aspecto, Henrique *et al.* (2017) demonstraram que alterações fisiológicas como o aumento da concentração sanguínea de cortisol e temperatura retal foram em ovelhas no período final da gestação possuem consequências negativas no desenvolvimento de seus cordeiros após o nascimento.

Jensen *et al.* (2002), após submeterem ovelhas no terço final de gestação a estresse crônico, por meio da infusão de hidrocortisona, constataram redução no crescimento fetal e alterações nas funções cardiovasculares, endócrinas e metabólicas dos fetos, com consequências negativas no desenvolvimento ponderal das crias.

A ambiência é outro aspecto a ser considerado durante o período gestacional e em países de clima tropical, o estresse térmico promove mudanças metabólicas, fisiológicas e endócrinas que comprometem a produção e reprodução de ovinos (SILVA *et al.*, 2013; MARAI *et al.*, 2007). Desta forma, para manter a homeotermia, as ovelhas reduzem a ingestão de matéria seca, aumentam o consumo de água, elevam a frequência respiratória e a temperatura retal.

Silva *et al.* (2017) relata que em ovinos, a raça é um fator importante para a adaptabilidade térmica, sendo que as raças nativas de países tropicais apresentam maior adaptabilidade ao

calor, sendo mais tolerantes a altas temperaturas (SILVA *et al.*, 2017). Em termos de mecanismos fisiológicos visando a homeostase, a termólise em fêmeas gestantes pode ser atribuída à polipneia térmica e aumento da frequência cardíaca (YAQUB *et al.*, 2017), com consequências na diminuição do desempenho produtivo (SEJIAN *et al.*, 2010) e do bem-estar animal (MAURYA *et al.*, 2016).

Em relação a frequência respiratória como indicador de estresse em ovinos, podemos citar Santos *et al.* (2011), que relatam que os parâmetros fisiológicos como temperatura retal e frequência respiratória têm sido muito utilizados para identificar animais mais adaptados ao clima tropical. Segundo os autores citados, a frequência respiratória normal em ovinos é menor do que 40 movimentos por minuto (mov/min), e a elevação desta variável é um dos primeiros sinais visíveis de estresse térmico e, em termos de resposta, é a terceira na sequência dos mecanismos de termorregulação, sendo precedido pela vasodilatação periférica e o aumento da sudorese (SANTOS *et al.*, 2011).

As frequências respiratória e cardíaca são descritas por Broom e Jhonson (2000) como indicadores importantes de estresse de curto prazo, com grande relevância para o monitoramento do bem-estar animal. Além de suas implicações em estresse térmico, Broom e Jhonson destacam sua relevância para outros fatores ambientais e fisiológicos como isolamento espacial, introdução de novos animais ao grupo, transporte, manejo e respostas emocionais.

Desta forma, diante da facilidade na mensuração da frequência respiratória, de modo pouco invasivo e sem a necessidade de utilização de instrumentos de coleta de dados, objetivou-se construir uma Rede Neural Artificial e prever esta variável a partir de um conjunto de dados climáticos e fisiológicos de ovelhas no período final da gestação e pós parto.

3 PROCEDIMENTOS METODOLÓGICOS

A presente pesquisa foi desenvolvida no Centro Tecnológico de Ovino (CTO) da Universidade Anhanguera - UNIDERP, localizada na Fazenda Três Barras, no município de Campo Grande, estado de Mato Grosso do Sul. O clima da região é caracterizado como mesotérmico Cwa (tropical de altitude), com temperatura do mês mais frio entre 15 e 25 °C, inverno seco e temperatura do mês mais quente maior que 30 °C, segundo classificação Köppen (PEREIRA *et al.*, 2013).

As variáveis utilizadas neste estudo foram: temperatura ambiente (°C), a umidade relativa do ar (%), as temperaturas do corpo (°C), da cabeça (°C), da pele (°C), da lã (°C), retal

($^{\circ}\text{C}$) e a frequência respiratória (mpm).

Foram selecionadas trinta ovelhas pantaneiras, sendo estas acompanhadas desde o início da prenhez até o parto. As trinta ovelhas prenhas foram separadas em um piquete de 2 hectares com pastagem de *Brachiária decumbens*, e acesso a suplementação alimentar e água.

A coleta de dados no Centro Tecnológico de Ovinos (CTO) ocorreu no período de dezembro de 2019 a abril de 2020, sendo as amostragens padronizadas em horários (período da manhã, com início às 07h:00min) em dias pré-determinados, com duas coletas semanais.

As variáveis climáticas foram obtidas por meio de estação meteorológica do Instituto Nacional de Meteorologia (INMET), utilizando-se o valor médio (período da manhã) de cada data de coleta. Para avaliar a temperatura retal, utilizou-se um termômetro clínico veterinário digital, marca Incoterm, tendo como especificações técnicas: dimensões 190x11x35mm, peso bruto 195g, peso líquido 55g, plástico, com escala de 32 a 44 $^{\circ}\text{C}$, mantido no reto do animal até que emissão do sinal sonoro indicasse a temperatura estabilizada. As temperaturas da pele, corpo, cabeça e lã foram avaliadas com auxílio de termômetro infravermelho digital, de marca Incoterm, com faixa de medição: -50 $^{\circ}\text{C}$ a 330 $^{\circ}\text{C}$, resolução: 0,1 $^{\circ}\text{C}$, exatidão: -50 $^{\circ}\text{C}$ ~ 0 $^{\circ}\text{C}$: \pm 4 $^{\circ}\text{C}$ 0 $^{\circ}\text{C}$ ~ 330 $^{\circ}\text{C}$: 2% \pm 2 $^{\circ}\text{C}$, sensor: temperatura infravermelho, resposta espectral: 8~14 μm , diodo laser: saída < 1mV, 630~670nm, classe 2, tempo de resposta: < 1s, alimentação: 1 bateria de 9V e dimensões de 134 x 88.5 x 36 mm, apontados para regiões pré-determinadas. A frequência respiratória foi avaliada pela contagem de movimentos do flanco e costado dos animais durante 15 segundos. Os animais foram avaliados somente uma vez, a cada dia de coleta.

Para a aplicação do algoritmo da figura 3 foi utilizado o software IBM-SPSS na seguinte configuração: RNA do tipo multilayer perceptron; uma camada oculta intermediária com n neurônios e função de ativação tangente hiperbólica; algoritmo de aprendizagem *backpropagation*; redimensionamento de todas as variáveis (entrada e saída normalizadas) para minimizar o coeficiente de variação (decorrente das diferentes unidades físicas utilizadas); e a camada de saída, com função identidade como ativação. A saída do *software* fornece os valores observados e previstos, com o ajuste e os erros dados pelo erro de entropia cruzada e previsões incorretas.

A classificação do estresse térmico das ovelhas foi realizada por meio de entropia cruzada, que pode ser usada como uma medida de erro quando as saídas de uma rede podem ser pensadas como representando hipóteses independentes e as ativações podem ser entendidas

como representando a probabilidade (ou a confiança) que cada uma das hipóteses pode ser verdadeira. Nesse caso, o vetor de saída representou uma distribuição de probabilidade, e a medida de erro (entropia cruzada) indica a distância entre o que a rede acredita que essa distribuição deve ser e o que realmente deveria ser, conforme equação (1).

$$H(p, q) = - \sum_x p(x) \log(q(x)) \quad (1)$$

Onde $H(p, q)$ representa a entropia em termos probabilístico de eventos (p e q) e x representa o vetor de variáveis de entrada.

Para nossa adequada modelagem e diante do conjunto de dados utilizados, a função tangente hiperbólica (\tanh) foi utilizada na camada de entrada diante de seu formato sigmoide característico, variando de -1 a 1, se aproximando mais da função identidade.

Já, a função softmax, segundo Barber *et al.* (2012), que também apresentam um caráter sigmoide, mas ao contrário de outras funções exponenciais, essa é mais indicada quando se está diante de um conjunto de dados de classificação. Tendo em vista que no presente estudo utilizou-se três classificações de estresse (leve, moderado e elevado), a função softmax foi a função utilizada, pois, é mais adequada quando existem mais de duas classes de classificação. Essa função transforma as saídas, para cada classe, em valores entre 0 e 1, dando a probabilidade de a entrada estar em uma determinada classe.

4 DISCUSSÃO E ANÁLISE DOS DADOS

As estatísticas descritivas dos dados climáticos e fisiológicos das trinta ovelhas pantaneiras, referentes ao período de 12/2019 a 04/2020, estão na tabela 1.

Tabela 1. Estatísticas Descritivas das variáveis climáticas e fisiológicas de ovelhas pantaneiras do CTO, no período de 12/2019 a 04/2020

Variáveis	Média	Desvio Padrão	CV (%)	Mínimo	Máximo
Temperatura retal	38,91	0,83	2,13	28,76	41,20
Temperatura do corpo	37,41	1,44	3,85	32,11	39,56
Temperatura da cabeça	36,55	1,51	4,13	23,70	42,00
Temperatura da lã	33,69	3,45	10,24	22,00	40,00
Temperatura da pele	36,17	2,85	7,88	26,00	71,70
Frequência respiratória	71,31	13,12	18,40	24,00	120,00
Temperatura do ar	26,47	1,77	6,69	22,32	29,55
Umidade relativa do ar	70,08	8,33	11,89	54,58	84,00

Legenda: CV: Coeficiente de variação; Temperatura (°C); Umidade relativa do ar (%); Frequência respiratória (mpm).

Fonte: Elaborado pelos autores

Em relação aos parâmetros fisiológicos do presente estudo, a temperatura retal média também é considerada normal (tabela 1). De acordo com os resultados de Silva Sobrinho (2001), a temperatura retal normal de ovinos adultos situa-se entre 38,5 °C e 40 °C e Costa et al. (2015) afirmaram que esta temperatura nos ovinos da raça Santa Inês varia entre 38,6 °C e 39,5 °C quando criados em ambiente sem sombra e entre 38,4 °C e 38,9 °C quando criados em ambientes com acesso livre a sombra.

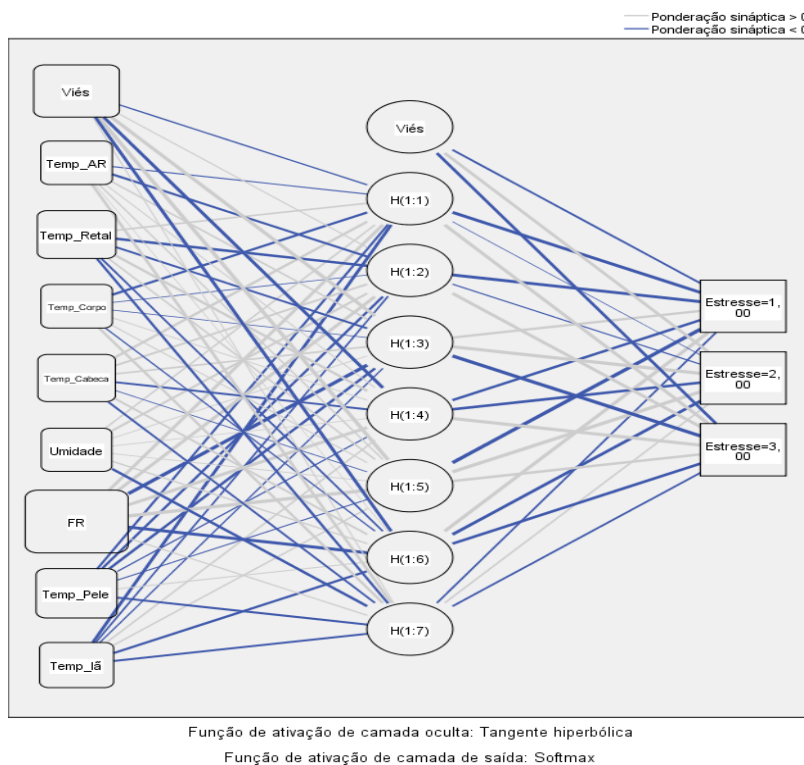
Em relação a frequência respiratória, a média de 71,31 mpm (tabela 1) representa valores acima do fisiológico que segundo Santos et. al. (2001) é < 40mpm. Tal resultado presente na tabela 1 pode refletir tanto a condição gestacional das fêmeas (maior produção de calor endógeno), como a respostas a agentes estressores ambientais diversos.

Conforme demonstrado por Trunkfiled *et. al.* (1991), distúrbios no ambiente dos animais podem alterar a variação da temperatura corporal, por meio de uma maior ativação do córtex adrenal e conseqüentemente aumento da temperatura corporal. As variações na concentração dos hormônios da tireoide e das adrenais é de extrema importância quando se relaciona estresse térmico e metabolismo (ALNAIMY et al.,1992; DICKSON, 1996).

Observando a coluna dos coeficientes de variação CV (%) da tabela 1, nota-se valores abaixo de 15%, demonstrando uma certa homogeneidade dos dados coletados. Destaca-se, o coeficiente de variação da frequência respiratória, que atingiu 18,40%, um valor alto, destoando dos demais. Em uma análise mais minuciosa, percebe-se que a amplitude total das frequências respiratórias é muito grande, de 96 mpm, com o valor mínimo de 24 e valor máximo de 120 mpm.

A modelagem da RNA MLP mais adequada para o modelo preditivo foi a de uma rede com uma camada de entrada, com oito neurônios, correspondentes às variáveis predictoras: temperatura do ar (Temp_Ar), temperatura retal (Temp_Retal), temperatura do corpo (Temp_Corpo), temperatura da cabeça (Temp_Cabeça), umidade relativa do ar (Umidade), frequência respiratória (FR), temperatura da pele (Temp_Pele) e temperatura da lã (Tem_Lã), uma camada oculta (com sete neurônios), e função de ativação do tipo tangente hiperbólica e uma camada de saída, correspondentes às variáveis do estresse térmico: leve (Estresse_1), moderado (Estresse_2) e elevado (Estresse_3), com função de ativação do tipo softmax. O layout da RNA mostrado na figura 1, apresenta as ponderações sinápticas e funções de ativação.

Figura 1. Layout da RNA e ponderadores de sinapse para a predição de estresse térmico de ovelhas pantaneiras nas fases de gestação e maternidade, em abril de 2020.



Fonte: Adaptado de IBM_SPSS (2020).

A arquitetura da RNA da figura 1 é chamada arquitetura *feedforward* porque as conexões de rede fluem unidimensionalmente da camada de entrada para a camada de saída sem *loops* de *feedback*. A camada de entrada contém os preditores, a camada oculta contém nós (ou unidades) não observáveis. O valor de cada unidade oculta é uma função dos preditores; a forma exata da função depende, por um lado, do tipo de rede e, por outro lado, das especificações controláveis pelo usuário. A camada de saída contém as respostas estresse térmico: leve, estresse moderado e elevado. As linhas representam as ponderações sinápticas, ou seja, os ponderadores utilizados pelas funções de ativação das camadas ocultas e saída. Valores >0 são representadas por linhas mais proeminentes, o que indicam uma maior ponderação ou “grau de importância” da variável no modelo.

Em relação ao desempenho de predição da RNA, a tabela 2, apresenta o resultado da variável dependente classe de estresse em relação ao percentual correto após treinamento.

Tabela 2. Porcentagem global correta da predição da variável estresse das amostras de treinamento e teste da RNA para a predição de estresse térmico de ovelhas pantaneiras nas fases de gestação e maternidade, em abril de 2020

Amostra	Observado	Predito em mpm			
		Estresse baixo (40-60)	Estresse médio (60-80)	Estresse alto (80-120)	(%) Correta
Treinamento	Estresse baixo (40-60)	43	0	0	100
	Estresse médio (60-80)	0	142	0	100
	Estresse alto (80-120)	0	0	30	100
	(%) Acerto Global	20,0%	66,0%	14,0%	100
Testes	Estresse baixo (40-60)	18	0	0	100
	Estresse médio (60-80)	1	62	0	98,4
	Estresse alto (80-120)	0	0	10	100
	(%) Acerto Global	20,9%	68,1%	11,0%	98,9

Variável Dependente: estresse térmico.

Fonte: Elaborado pelos autores

Pode-se observar na tabela 2, que a taxa de erro global foi de 1,1% nos Testes da rede, um resultado satisfatório para a predição de classes de estresse em ovelhas pantaneiras a partir das variáveis climáticas e fisiológicas utilizadas. Na construção da arquitetura da rede, utilizou-se de 30% do conjunto de dados para treinamento, o que significa durante o treinamento, o algoritmo da rede opera em uma sequência passos. Primeiro, identifica um padrão e o apresenta à camada de entrada da rede. Tal resposta resultante “passa” através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. Em um segundo momento, a saída obtida é comparada à saída desejada (variável dependente). Se o valor for distinto, então o erro é calculado, e este erro é propagado a partir da camada de saída até a camada de entrada, e os ponderadores das camadas internas vão sendo modificados conforme o erro é retro propagado.

Desta forma, quando se avalia um erro global na fase de teste de 1,1%, admite-se uma satisfatória predição diante de dados biológicos, demonstrando a eficiência do algoritmo da rede para identificar o padrão do conjunto de dados. A importância de cada variável independente para a predição da classificação de estresse pode ser observada na tabela 3.

Tabela 3. Importância e importância normalizada das variáveis independentes da RNA para a

predição de estresse térmico de ovelhas pantaneiras nas fases de gestação e maternidade

Variável	Importância	Importância normalizada (%)
Temperatura do ar	0,036	8,3
Temperatura retal	0,125	28,7
Temperatura do corpo	0,036	8,3
Temperatura da cabeça	0,113	25,9
Umidade relativa do ar	0,027	6,1
Frequência respiratória	0,437	100,0
Temperatura da pele	0,156	35,7
Temperatura da lã	0,069	15,7

Legenda: Temp. (Temperatura, °C), Umidade (Umidade Relativa do Ar, %); FR (Frequência Respiratória, movimento por minuto – mpm).

Fonte: Elaborado pelos autores

Desta forma, pode-se observar na tabela 3 que a utilização dos indicadores climáticos locais e das variáveis fisiológicas dos animais foram eficazes na construção de um modelo preditivo de estresse térmico, sendo a frequência respiratória, a temperatura retal e a temperatura da pele e cabeça, as mais relevantes para o modelo.

5 CONCLUSÕES

A modelagem da RNA para predição de classes de estresse térmico em ovelhas pantaneiras foi adequada, com erros de predição de 1,1% a partir de variáveis climáticas (temperatura do ar e umidade relativa do ar) e parâmetros fisiológicos (temperaturas do corpo, pele, cabeça, lã e retal) e frequência respiratória. A utilização da RNA permitiu construir um modelo com capacidade de predição de níveis de estresse calórico, identificando as variáveis com potenciais de causarem os maiores estresses em ovelhas pantaneiras nas fases de gestação e maternidade.

AGRADECIMENTOS:

Agradecimentos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação Nacional de Desenvolvimento do Ensino Superior (FUNADESP), pelos apoios financeiros das bolsas de iniciação científica.

REFERÊNCIAS

BARBER, D.; SOLLICH, P.; SAAD, D. Finite Size Effects in on-line learning of multi-layer Neural Network. In: ELLACOTT, S. W.; MASON, J. C.; ANDERSON, I. J. **Mathematics of Neural Networks: Models, Algorithms and Applications**. Manchester: SPRINGER SCIENCE, 2012. p. 84-88.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2ed. Rio de Janeiro: LTC, 2014. 228p.

FERNANDEZ, C. Neural networks for animal science applications: Two case studies. **Expert Systems with Applications**, v.31, n.2, p.444-450, 2006.

FREEMAN, J. A.; SKAPURA, D. M. **Neural Networks: Algorithms, Applications, and Programming Techniques**. 2ed. California: CNS, 1991. 414p.

HAIR, J. F.; TAHAM, R. L.; ANDERSON, R. E.; BLACK, W. C. **Análise Multivariada de dados**. 5ed. Porto Alegre: Artmed Editora S.A., 2005. 583p.

HAYKIN, S. **Redes Neurais Princípios e Prática**. 2ed. Porto Alegre: Artmed Editora S.A., 2001. 780p.

KOVÁCS, Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações**. 4ed. São Paulo: Livraria da Física, 2006. 169p.

PEREIRA, A. A.; BARROS, D. A.; JUNIOR, F. W. A.; PEREIRA, J. A. A.; REIS, A. A. Análise da distribuição espacial de áreas queimadas através da função K de Ripley. **Scientia Forestalis**, Piracicaba, v. 41, n. 100, p. 445-455, 2013.

SAFI, Y.; BOUROUMI, A. *A Neural Network Approach for Predicting Forest Fires*. In: **IEEE SENSORS**, Morocco, 2011. **Conference IEEE Sensors**. Morocco: IEEE, 2011, p. 1-5.

SANTOS, M. M., AZEVEDO, M., COSTA, L. A. B., SILVA FILHO, F. P., MODESTO, E. C. & LANA, Â. M. Q. Comportamento de ovinos da raça Santa Inês, de diferentes pelagens, em pastejo. **Acta Scientiarum. Animal Sciences**, v. 33, p. 287-294, 2011.

SILANIKOVE, N. Effects of heat stress on the welfare of extensively managed domestic ruminants, **Livestock Production Science**, v.67, p.1 – 18, 2000.

SILVA; M. H. S.; PASSOS, M. M.; SAKAMOTO, A. Y. As lagoas Salitradas do Pantanal da Nhecolândia: um estudo da paisagem baseado no modelo GTP – Geossistema, Território e Paisagem. **Confins. Revue franco-brésilienne de géographie/Revista franco-brasileira de geografia**, Paris, n. 19, 2013. Disponível em:

<<http://confins.revues.org/8614>>. Acesso em: 24 abr. 2015.

VIEIRA, F.M.C.; SILVA, I.J.O.; BARBOSA FILHO, J.A.D. et al. Productive losses on broiler preslaughter operations: effects of the distance from farms to abattoirs and of lairage time in a climatized holding area. **Revista Brasileira de Zootecnia**, v.39, p.2471-2476, 2010