

**UNIVERSIDADE FEDERAL DO MATO GROSSO DO
SUL**

**FACOM – FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA**

**PREDIÇÃO DE PARTO DE GADO HOLANDÊS COM O
USO DE REDES NEURAS ARTIFICIAIS**

MARCEL JOSÉ SOLEIRA GRASSI

**ORIENTADORA: PROF^a. DRA. ANDREA TERESA RICCIO BARBOSA
CO-ORIENTADOR: PROF^o. ME. QUINTINO IZIDIO DOS SANTOS NETO**

Campo Grande - MS
Agosto/2017

**UNIVERSIDADE FEDERAL DO MATO GROSSO DO
SUL**

FACOM – FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA

**PREDIÇÃO DE PARTO DE GADO HOLANDÊS COM O
USO DE REDES NEURAIAS ARTIFICIAIS**

MARCEL JOSÉ SOLEIRA GRASSI

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação Aplicada da Faculdade de Computação/FACOM pela Universidade Federal do Mato Grosso do Sul/UFMS, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação Aplicada.

Campo Grande - MS
Agosto/2017

AGRADECIMENTOS

O Deus, fonte de luz e esperança.

A professora Andrea Teresa Riccio Barbosa, pela sua orientação no desenvolvimento da dissertação e pela sua amizade e convívio. E também ao professor Fábio Iaione, por abrir as portas de sua casa e ceder sua esposa, Andrea, para as reuniões de sábados.

A todos os professores e colegas do Instituto Federal do Mato Grosso do Sul campus Corumbá.

A todos os amigos do Departamento de Engenharia Elétrica e Faculdade de Computação da Universidade Federal do Mato Grosso do Sul.

Aos meus pais e irmãos, Edson, Sandra, Marcio e Murilo, pelo apoio, incentivo e amor sempre.

A minha companheira, Evelyn da Silva Campos Grassi, pelo seu apoio e carinho afetuoso, principalmente em momentos de irritação que ocorrem durante o desenvolvimento de uma dissertação.

A toda minha família.

RESUMO

No período de parto, criadores e técnicos da raça Holandesa têm uma preocupação crescente com o aumento nas incidências de distocia e de natimortos em seus rebanhos. A distocia é definida como uma situação de nascimento difícil, onde há necessidade de um auxílio para que o parto ocorra. Os natimortos são bezerros que nascem mortos ou que morrem poucos minutos após o nascimento. Sabe-se que a incidência de natimortos é particularmente alta em partos distócicos. Assim, a meta mundialmente almejada pelos produtores é limitar esta proporção de natimortos em até 4%, pois para os criadores é importante minimizar o problema de partos distócicos na propriedade para evitar prejuízos financeiros. Logo, o uso da tecnologia pode ajudar a evitar este problema e maximizar a eficiência do sistema produtivo. Diante desse contexto, este trabalho volta-se para a problemática da aplicação de técnicas computacionais na predição do momento do parto. Em particular, buscou-se explorar e implantar o modelo *Perceptron* de Múltiplas Camadas (MLP ou PMC) para predição do parto em gado Holandês. Com isso, o trabalho visa o monitoramento dos animais, permitindo assim uma análise do produtor para a definição do momento de parto do animal. Para a simulação da rede MLP foi utilizado o pacote de *software* Weka (*Waikato Environment for Knowledge Analysis*). Assim, várias simulações foram realizadas com o Weka. As simulações cuja rede teve como saída a hora restante para o parto, não apresentou bons resultados. Não sendo, portanto a mais indicada para a automatização do processo de predição. Outros testes, tendo com saída da rede MLP, o momento de parto e não-parto ou momento de parto, pré-parto e não-parto, foram os que obtiveram os melhores resultados. Em alguns desses testes a rede chega a atingir 100% de taxa de acerto. Portanto, sendo a arquitetura e parâmetros da rede a mais indicada para a automatização do processo de predição do parto em gado da raça Holandesa.

Palavras-chave: Predição, Redes Neurais Artificiais, Gado Holandês.

ABSTRACT

During the calving period, breeders and technicians of the Dutch breed are increasingly concerned about the increased incidences of dystocia and stillbirths in their herds. Dystocia is defined as a difficult birth situation, where there is a need for help in giving birth. Stillbirths are calves that are born dead or die within a few minutes of birth. It is known that the incidence of stillbirths is particularly high in dystocic births. Thus, the goal is to limit this proportion of stillbirths by as much as 4%, since it is important for breeders to minimize the problem of dystocic births on the property in order to avoid financial losses. Therefore, the use of technology can help to avoid this problem and maximize the efficiency of the productive system. Given this context, this work turns to the problem of the application of computational techniques in the prediction of the moment of delivery. In particular, we sought to explore and implant the Multi-Layer Perceptron model (MLP or PMC) to predict delivery in Dutch cattle. With this, the work aims at the monitoring of the animals, thus allowing an analysis of the producer for the definition of the moment of delivery of the animal. For the simulation of the MLP network we used the Weka software package (Waikato Environment for Knowledge Analysis). Thus, several simulations were performed with Weka. The simulations whose network had as output the remaining hour for delivery, did not present good results. Therefore it is not the most suitable for the automation of the prediction process. Other tests, starting with the MLP network, the time of delivery and non-delivery or time of delivery, pre-delivery and non-delivery were the ones that obtained the best results. In some of these tests the network reaches a 100% hit rate. Therefore, the architecture and parameters of the network being the most suitable for the automation of the process of prediction of calving in Holstein cattle.

Keywords: Prediction, Artificial neural networks, Dutch cattle.

.

LISTA DE FIGURAS

Figura 1: Neurônio Biológico [BRAGA et al., 2014].	21
Figura 2. Neurônio Artificial [SILVA et al., 2010].	22
Figura 3. Redes feedforward de camada única [SILVA et al., 2010].	23
Figura 4. Redes <i>feedforward</i> de camadas múltiplas [SILVA et al., 2010].	24
Figura 5. Configuração dos dados de treinamento da rede.....	26
Figura 6. Fase de Treinamento [SILVA et al., 2010].	29
Figura 7. Fase de Operação [SILVA et al., 2010].....	30
Figura 8. Sistema de telemetria por rádio frequência [COSTA JUNIOR, 2014].	37
Figura 9. Esquema de coleta de dados da Trr pelo sistema de telemetria por rádio frequência [COSTA JUNIOR, 2014].....	37
Figura 10.Gráfico contendo a variação de temperatura de um animal.....	39
Figura 11. Gráfico contendo a variação de temperatura de cinco animais.	40
Figura 12. Janela de Configurações para RNA MLP do software Weka.	41
Figura 13. Sistema de janelamento aumentando de uma em uma hora.....	43
Figura 14. Sistema de janelamento aumentando de 12 em 12 horas.	43
Figura 15. Arquivo com valores fictícios para verificar comportamento do <i>software</i> Weka e da rede MLP.....	49
Figura 16. Parte da janela de configurações, com os destaques para as normalizações de entrada e saída.	52
Figura 17. RNA gerada pelo Weka para os dados brutos.	54
Figura 18. Arquivo de Dados do Segundo Teste com Um Animal.	65
Figura 19. Rede gerada pelo Simulador para testes com temperaturas reais.	66
Figura 20. Arquivo de Dados do teste com dois Animais.....	68
Figura 21. Trecho do arquivo com as Trr e saída horas antes do parto.....	76
Figura 22. Trecho do arquivo com o conjunto de exemplos.	78
Figura 23. Rede gerada pelo simulador Weka para saída com parto, pré-parto e não-parto. ..	79
Figura 24. Dados de Trr sem ajustes e sem filtro.	82
Figura 25. Dados de Trr com ajustes, mas sem filtro.	82
Figura 26. Dados de Trr com ajuste e com filtro de média móvel.	83

Figura 27. Resultado de desempenho obtido por Costa Junior [2014] para predição dentro de 24 ou 12 horas para vacas Holandesas.	92
--	----

LISTA DE TABELAS

Tabela 1. Valores de saída da rede do teste inicial.	50
Tabela 2. Valores de saída, do teste inicial, com a os dados de entrada normalizados.	51
Tabela 3. Tabela com dados estatísticos do Teste Inicial.	51
Tabela 4. Valores de saída da rede do segundo teste inicial.....	52
Tabela 5. Tabela com dados estatísticos do segundo Teste Inicial.....	53
Tabela 6. Resultado do teste bruto.....	55
Tabela 7. Resultado variando o valor de <i>Momentum</i> para 0.5.....	55
Tabela 8. Resultado variando o valor de <i>momentum</i> para 0.3.	56
Tabela 9. Resultado variando o valor da taxa de aprendizagem para 0.3.	57
Tabela 10. Tabela Comparativa dos Resultados dos Teste com Valores Brutos.....	58
Tabela 11. Resultado da alteração das Trr menores do que 37,7 °C	60
Tabela 12. Resultado da alteração das Trr menores do que 37,7 °C com valor de <i>momentum</i> em 0.5.....	61
Tabela 13. Resultado da alteração das Trr menores do que 37,7 °C com valor de <i>momentum</i> em 0.3.....	62
Tabela 14. Resultado da alteração das Trr menores do que 37,7 °C com a taxa de aprendizagem em 0.3.....	62
Tabela 15. Resultado da alteração das Trr menores do que 37,7 °C com a taxa de aprendizagem em 0.6.....	63
Tabela 16. Tabela Comparativa dos Resultados dos Teste com ajustes na Trr.	64
Tabela 17. Saída do Primeiro Teste com Temperaturas Reais.....	67
Tabela 18. Dados estatísticos do Teste 1 com uma vaca.	67
Tabela 19. Resultado do teste com dois animais.	69
Tabela 20. Dados estatísticos do Teste 1 com duas vacas.....	70
Tabela 21. Resultados do Teste com Cinco Animais. Os valores destacados referem-se aos valores cuja a predição da rede não condiz com a saída desejada.....	71
Tabela 22. Dados estatísticos do Teste 1 com cinco vaca.....	71
Tabela 23. Resultados do Teste com Dez Animais. Os valores destacados referem-se aos valores cuja a predição da rede não condiz com a saída desejada.....	73
Tabela 24. Dados estatísticos do Teste 1 com dez vacas.	73

Tabela 25. Resultados do Teste com 51 Animais. Os valores destacados referem-se aos valores cuja a predição da rede não condiz com a saída desejada.....	75
Tabela 26. Dados estatísticos do Teste 1 com 51 vaca.....	75
Tabela 27. Resultado do teste com 51 vacas e saída com horas antes do parto.....	77
Tabela 28. Resultado do teste de parto, pré-parto e não-parto.....	80
Tabela 29. Tabela de contagem de acerto e erros.....	80
Tabela 30. Resposta da rede com Trr sobre filtro média móvel.....	84
Tabela 31. Tabela de contagem de acerto e erros Trr sobre filtro de média móvel.....	84
Tabela 32. Tabela de Comparação dos Resultados.....	87
Tabela 33. Tabela comparativa entre os resultados obtidos por Costa Junior [2014] e os resultados com a utilização de Redes Neurais Artificiais (RNA).....	93

LISTA DE ABREVIATURAS E SIGLAS

RNA – *Rede Neural Artificial*

RNAs – *Redes Neurais Artificiais*

Trr – *Temperatura retículo-ruminal*

MLP – *Multilayer Perceptron*

PMC – *Perceptron de Múltiplas Camadas*

FSH – *Hormônio Folicular Estimulante*

LH – *Hormônio Luteinizante*

g – *grama*

m – *metro*

SUMÁRIO

INTRODUÇÃO	14
1.1 Contexto.....	14
1.2 Justificativa.....	16
1.3 Objetivo	17
1.4 Objetivos Específicos.....	17
1.5 Organização do Trabalho.....	18
REDES NEURAIIS	19
2.1 Considerações Iniciais.....	19
2.1.1 Redes Neurais Biológicas.....	20
2.2 Redes Neurais Artificiais.....	21
2.2.1 Neurônio Artificial	21
2.2.2 Arquiteturas de Redes Neurais Artificiais.....	22
2.2.3 Aspectos de Aprendizado e Processo de Treinamento	24
2.2.4 Treinamento Supervisionado	26
2.2.5 Redes <i>Perceptron</i> de Múltiplas Camadas	27
2.2.6 Princípio de Funcionamento da Rede MLP	27
2.2.7 Aspectos de Implementação de Redes <i>Perceptron</i> Multicamadas	28
TRABALHOS RELACIONADOS.....	32
METODOLOGIA	36
4.1 Características de Implementação da Rede MLP	44
4.2 Medida de Desempenho de um Classificador.....	46
RESULTADOS E DISCUSSÕES.....	48
5.1 Teste Inicial com Valores Fictícios	48
5.2 Teste com valores brutos	53
5.2.1 Variando configuração da rede: <i>momentum</i>	55
5.2.2 Variando configuração da rede: Taxa de Aprendizagem	57
5.3 Testes com ajustes nas Trr	59
5.3.1 Ajuste da Trr e variando o valor de <i>momentum</i>	60

5.3.2 Ajuste da Trr e variando a taxa de aprendizagem	62
5.4 Teste 1 com saída parto e não-parto	64
5.4.1 Teste com Um Animal	65
5.4.2 Teste com Dois Animais	68
5.4.3 Teste com Cinco Animais	70
5.4.4 Teste com Dez animais	72
5.4.5 Teste com 51 animais	74
5.5 Teste com 51 animais com a saída em horas	76
5.6 Teste com saídas de parto, pré-parto e não-parto	78
5.7 Teste com filtro de média móvel	81
5.8 Discussões	85
CONCLUSÃO	94
6.1 Conclusão.....	94
6.2 Trabalhos Futuros.....	95
REFERÊNCIAS.....	96
TABELAS COMPLETAS	98
A.1 Teste Inicial com Valores Fictícios	98
A.1.1 Teste Inicial com Valores Fictícios Normalizados	99
A.1.2 Segundo Teste Inicial com Valores Fictícios Normalizados.....	100
A.2 Teste com Um Animal	102
A.3 Teste com Dois Animais.....	103
A.4 Teste com Cinco Animais	105
A.5 Teste com Dez animais.....	106
A.6 Teste com 51 animais.....	109
A.7 Teste com 51 animais com a saída em horas	115
A.8 Teste com saídas de parto, pré-parto e não-parto	118
A.9 Teste com filtro de média móvel.....	121

Capítulo 1

INTRODUÇÃO

1.1 Contexto

Atualmente, o Brasil encontra-se entre os maiores produtores mundiais de leite, ocupando a quinta colocação. Essa grande produção leiteira está relacionada ao tamanho territorial do país, ao quantitativo populacional e também com as práticas de melhoramentos genéticos, cruzamentos e melhorias nas técnicas de manejo e de produção do gado. Além do uso cada vez maior de técnicas e tecnologias de precisão na produção animal [IBGE, 2015].

Nesse contexto, observa-se que a produção de leite no Brasil em 1960 era de 5 bilhões de litros/ano passando para 35 bilhões de litros/ano em 2014, representando um aumento de 30 bilhões de litros em 54 anos. Acredita-se que nos próximos anos a produção poderá alcançar 40 bilhões de litros e essa expansão pode ser impulsionada pelo aumento do consumo interno e pela exportação de seus produtos derivados [FERREIRA e MIRANDA, 2007].

Com relação às raças produtivas, existem inúmeras com aptidão leiteira, entretanto, a raça Holandesa se destaca mundialmente pela sua alta produção de leite. Desta forma, é muito utilizada em diversas partes do mundo, inclusive no Brasil, com mais de dois milhões de animais registrados. Isto ocorre porque apresenta, como característica favorável, um longo período de lactação, que vai resultar para o produtor um maior retorno financeiro.

Com relação à reprodução destes animais, observa-se que a primeira cobertura pode ser realizada entre 16 e 18 meses de idade e com aproximadamente dois anos de idade (25 e 27 meses) ocorre, geralmente, o primeiro parto. O intervalo entre os partos é de 15 a 17 meses e o período de gestação tem duração média de 280 dias, podendo ter variação deste intervalo,

conforme a época de parição, onde no inverno as gestações são mais longas. Geralmente as vacas leiteiras apresentam período de gestação maior que as de corte e a gestação de machos têm em média 1,5 dias a mais que a gestação de fêmeas, respectivamente, 290 e 291 dias.

No período de parto, criadores e técnicos da raça Holandesa tem uma preocupação crescente com o aumento nas incidências de distocia e de natimortos em seus rebanhos. Os partos distócicos podem ser divididos como de origem fetal e/ou materna. A distocia é definida como uma situação de nascimento difícil, onde há necessidade de um auxílio para que o parto ocorra [CARNEIRO, 2013]. Os natimortos são bezerros que nascem mortos ou que morrem poucos minutos após o nascimento.

Nota-se que estes problemas acarretam grandes prejuízos financeiros ao produtor devido à perda da vaca e do bezerro, a diminuição da produção e aos gastos com a saúde animal. A ocorrência de distocia em rebanhos leiteiros pode variar de 3 a 25% e o índice de mortalidade de bezerros pode alcançar os 50%. Há relatos de sua ocorrência em atendimento clínico representar entre 15% a 20%, do caso de bovinos atendidos, e que 50% dos casos de distocias os animais são submetidos à cesariana [AFONSO, 2009].

Nos partos extremamente difíceis, a mortalidade das vacas aumenta em 4 a 5% e de bezerros 53%. Casos severos de dificuldade de parto, além da redução da fertilidade da vaca, com maior incidência de desordens reprodutivas no pós-parto, freqüentemente causam a morte do bezerro e ocasionalmente da vaca [CARNEIRO, 2013].

A meta é limitar esta proporção de natimortos em 4%. Sabe-se que a incidência de natimortos é particularmente alta em partos distócicos e em novilhas de primeira cria, que não receberam a devida atenção no período pré-parto, tendo sido associada com boa parte do descarte involuntário de vacas, no início do período de lactação [TENHAGEN et al., 2007].

Para os produtores é importante, portanto, minimizar o problema de partos distócicos na propriedade, e conseqüentemente, evitar prejuízos financeiros. Sendo assim, o uso de tecnologia de informação pode ajudar a evitar estes problemas e maximizar a eficiência do sistema produtivo, automatizando a coleta de dados e fornecendo informações para o adequado controle.

Observa-se que na tecnologia da informação, o uso de Redes Neurais Artificiais (RNAs) vem aumentando cada vez mais, possibilitando que essa ferramenta computacional realize predição de informações e padrões de comportamentais [PANDORFI et al, 2011]. As RNAs são sistemas distribuídos compostos por unidades de processamento, que a maioria delas, propõe conexões associadas a pesos, os quais armazenam o conhecimento adquirido e

servem para tomar decisões, com base em cálculos de funções matemáticas [BRAGA et al., 2014].

A capacidade de aprender e de generalizar as informações são as principais características das RNAs. Logo, a vantagem de utilizar uma RNA é a tolerância a falhas, a aplicação em tempo real, à capacidade de auto-organização e a rápida solução em fornecer respostas.

Na agropecuária, as aplicações das RNAs destacam-se no controle de índices zootécnicos com resposta ao comportamento animal, ao consumo de energia metabólico, ao manejo com base nas variáveis fisiológicas, ao aspecto nutricional e produtivo, a sanidade do rebanho, sem a utilização de práticas invasivas e ao melhoramento genético e as práticas de pré-abate, em determinar a qualidade do produto final.

Diante desse contexto, este trabalho volta-se para a problemática da aplicação de técnicas computacionais na predição do momento do parto. Em particular, busca-se explorar e implantar o modelo *Perceptron* de Múltiplas Camadas (MLP ou PMC) para predição do parto em gado Holandês. Espera-se, como resultado, a validação do sistema de predição de parto para bovinos da raça Holandesa.

1.2 Justificativa

A maioria dos produtores de leite no Brasil ainda são considerados pequenos e médios, sendo muitos de base familiar com uma produção diária inferior a 200 litros. Significando 80% dos produtores com sistemas de produção a pasto, os quais indicam o conservadorismo. Para que a atividade leiteira consiga ser mais econômica e competitiva é necessário um aumento na produtividade da terra e dos animais, o que irá exigir uma reestruturação nas etapas de planejamento, organização, execução e principalmente no controle zootécnico [FERREIRA e MIRANDA, 2007].

Segundo Costa Júnior [2014], nos últimos 25 anos, os países como EUA e União Europeia, vêm diminuindo o número de propriedades leiteiras e aumentando o número de animais por unidade produtiva. Esta mudança ocorre devido à passagem de um sistema de produção dependente de mão de obra, que está cada vez mais onerosa, para um sistema com maior inovação tecnológica, permitindo redução de custos e aumento dos resultados da produção.

Observa-se que à redução de mão de obra ocasionou, em consequência, uma diminuição do tempo de monitoramento por animal. Impedindo, desta forma, o produtor prever futuros eventos fisiológicos do animal. Tem-se como exemplo o parto, onde houve um aumento da distocia nos animais devido ao não acompanhamento em tempo apropriado, levando algumas vezes a morte da mãe e do bezerro.

Ainda de acordo com Costa Junior [2014], 50% dos casos de distocia poderiam ser evitados com o uso de tecnologias que monitorassem os animais, alertando o produtor do início do parto, além do conhecimento das relações entre os estágios do parto e relações maternas e fetais.

Com isso, esse trabalho visa o monitoramento dos animais, permitindo assim uma análise do produtor para a definição do momento de parto do animal.

Por fim, esse trabalho tem uma enorme importância para a pecuária de precisão, pois não há relatos na literatura de outros trabalhos para a predição do momento de parto.

1.3 Objetivo

O objetivo deste trabalho é realizar a predição do momento do parto das vacas Holandesas, utilizando Redes Neurais Artificiais.

1.4 Objetivos Específicos

Os objetivos específicos são:

- Pesquisar um simulador de Redes Neurais Artificiais;
- Processar os dados de temperatura retícoluruminal (Trr) obtidos como preditor para o parto em novilhas e vacas da raça Holandesa;
- Efetuar testes no simulador com as Trr;
- Avaliar os resultados dos testes obtidos pelo simulador;
- Validar este sistema com dados obtidos em Costa Junior [2014].

1.5 Organização do Trabalho

A estrutura da proposta apresenta-se da seguinte forma: o Capítulo 2 detalha assuntos envolvidos no contexto das Redes Neurais, apresentando detalhes específicos da Rede Neural Biológica e Artificial, sendo um tema pertinente ao trabalho. No Capítulo 3, apresenta-se o assunto de trabalhos relacionados, onde é descrito o uso de Redes Neurais Artificiais na área de zootecnia. No Capítulo 4, apresenta-se a metodologia considerando, tarefas e métodos utilizados. No Capítulo 5 mostra os resultados e discussões da Rede Neural Artificial para o momento do parto. Ao final, no Capítulo 6, apresentam-se os trabalhos futuros e as considerações finais do trabalho.

Capítulo 2

REDES NEURAIAS

2.1 Considerações Iniciais

As Redes Neurais Artificiais (RNAs) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência, sendo conhecidas como sistemas concorrentes ou paralelos. As RNAs apresentam uma enorme capacidade de aprendizagem, baseando-se em dados que são processados em unidades de processamento, que são chamados de neurônios artificiais [BRAGA et al., 2014].

As principais características para aplicação de Redes Neurais Artificiais são:

- Aprendizagem por experiência, na qual se apresentam exemplos relacionados ao objetivo da rede, o que permite a rede aprender por experimentação;
- Capacidade de aprender por treinamento, em que a rede obtém informações das variáveis que fazem parte da aplicação;
- Possibilidade de generalizar o conhecimento aprendido após o treinamento da rede, tornando possível prover uma solução que até o momento era desconhecida;
- Capacidade de melhor tolerância a falhas, devido a sua arquitetura, ou seja, as várias interconexões entre os neurônios artificiais que a compõe;
- Facilidade de implementação em *hardware* ou *software*, pois após o seu treinamento os seus resultados são formados por operações matemáticas.

Sendo assim, as RNAs podem ser utilizadas em diversas áreas permitindo a sua interdisciplinaridade [SILVA et al., 2010]. As principais aplicações de uma RNA são:

- Aproximação de funções: consiste em mapear relacionamento funcional entre variáveis de um sistema a partir de valores conhecidos;

- Controle de processos: consiste em classificar as ações de controle que geram qualidade, eficiência e segurança do processo. As principais aplicações estão na área de robótica, aeronaves, elevadores, eletrodomésticos, satélites, entre outros;
- Reconhecimento de padrões: o objetivo é encontrar padrões de classes previamente definidas, como o reconhecimento de imagens, voz, escrita, entre outros;
- Agrupamento de informações: consiste em encontrar similaridades e particularidades entre padrões de entrada que possam ser agrupados como, por exemplo, mineração de dados;
- Previsão de informações: o objetivo é informar valores futuros adquiridos de várias informações observados no processo. Podendo ser aplicações como, previsão meteorológica, previsão do mercado financeiro, entre outros;
- Otimização de sistemas: consiste em encontrar valores mínimos ou máximos para funções de custo, de acordo com as restrições impostas pelo problema. Programação dinâmica e otimização combinatória estão entre as principais aplicações;
- Memórias associativas: consiste em recuperar informações mesmo as variáveis sendo fornecidas de forma incertas ou imprecisas. As principais aplicações são os processamentos de imagens e transmissão de sinais.

2.1.1 Redes Neurais Biológicas

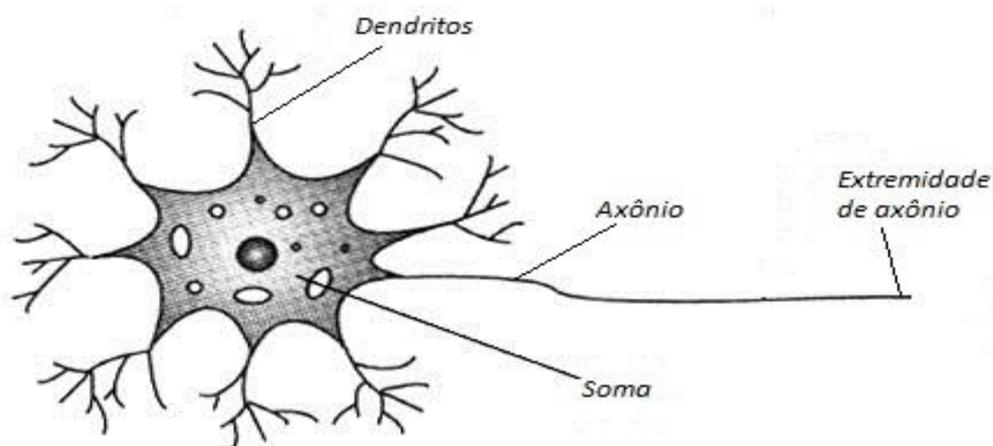
O cérebro humano contém aproximadamente 10^{11} neurônios e cada um deles é interligado por conexões, que são chamadas de sinápticas, que em média pode-se chegar a 6 mil conexões, totalizando 600 trilhões de sinapses[SILVA et al., 2010]. A estrutura desses neurônios, as suas conexões e o comportamento conjunto desses elementos de processamentos naturais formam a base para as Redes Neurais Artificiais (RNAs). Além de o cérebro humano ser responsável por funções sensoriomotoras e autônomas, ele também tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento por experiência e interpretar observações.

As RNAs são uma tentativa de reproduzir as funções das redes neurais biológicas, implementando seu comportamento funcional e sua dinâmica.

Os neurônios biológicos são divididos em três partes: corpo celular, dendritos e axônio e cada um possui uma função específica. Os dendritos têm a função de receber as informações de outros neurônios e conduzi-las até o corpo celular, onde as informações são processadas e novos impulsos são gerados. Esses impulsos são passados a outros neurônios através do

axônio até os dendritos dos neurônios seguintes. A terminação axônica de um neurônio e o dendrito de outro formam um ponto de ligação chamado de sinapse. A sinapse é capaz de controlar a transmissão de impulsos, ou seja, o fluxo de informação, formando assim as redes neurais. A Figura 1 mostra de forma simplificada, os componentes do neurônio biológico. Esse sistema é responsável pela maioria das funções realizadas pelo nosso cérebro. A capacidade de realizar funções complexas surge com a operação em paralelo de todos os neurônios do nosso sistema nervoso [BRAGA et al., 2014].

Figura 1: Neurônio Biológico [BRAGA et al., 2014].



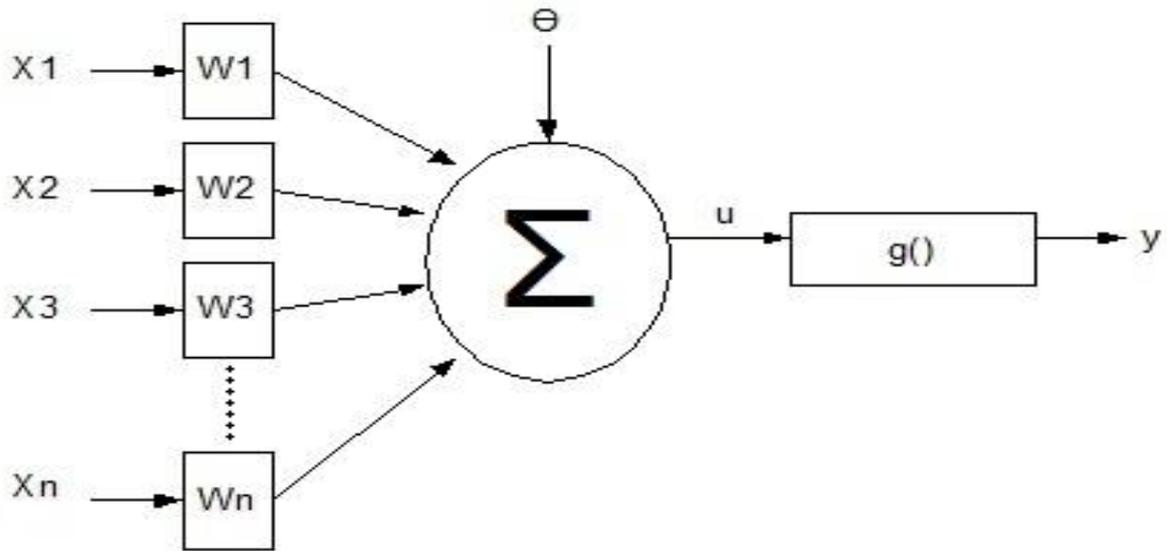
2.2 Redes Neurais Artificiais

2.2.1 Neurônio Artificial

Redes Neurais Artificiais foram desenvolvidas a partir de estudos do sistema biológico humano. Em 1943, *McCulloch&Pitts* desenvolveram um modelo de RNA para reproduzir de forma simples os estudos da época, tendo sua expressão matemática resultado em um modelo de n terminais de entrada recebendo vários valores de ativação e terminando com apenas um terminal de saída [BRAGA et al., 2014].

A Figura 2 representa um neurônio artificial recebendo um conjunto de sinais de entrada $\{X_1, X_2, X_3, \dots, X_n\}$, que analogamente são impulsos elétricos captados pelos dendritos no neurônio artificial.

Figura 2. Neurônio Artificial [SILVA et al., 2010].



Nas extremidades de axônio ou junção sinápticas o conjunto de pesos é representado pelos pesos sinápticos $\{W_1, W_2, W_3, \dots, W_n\}$. Assim, cada entrada X_i do neurônio é executada por meio de ponderações dos pesos sinápticos W_i , tornando a saída do corpo celular ou soma, sendo denotada por u , a soma ponderada de suas entradas [SILVA et al., 2010].

De acordo com a Figura 2, além dos sinais de entradas $\{X_1, X_2, X_3, \dots, X_n\}$, pesos sinápticos $\{W_1, W_2, W_3, \dots, W_n\}$, potencial de ativação u , tem-se também o limiar de ativação " Θ ", que representa uma variável, para que o resultado produzido pelo combinador linear " Σ " seja disparado para a saída do neurônio, a função $g()$ que limita a saída do neurônio e o sinal de saída " y ". Portanto, a ligação entre os neurônios é que forma a Rede Neural Artificial, ou simplesmente, RNA [SILVA et al., 2010].

2.2.2 Arquiteturas de Redes Neurais Artificiais

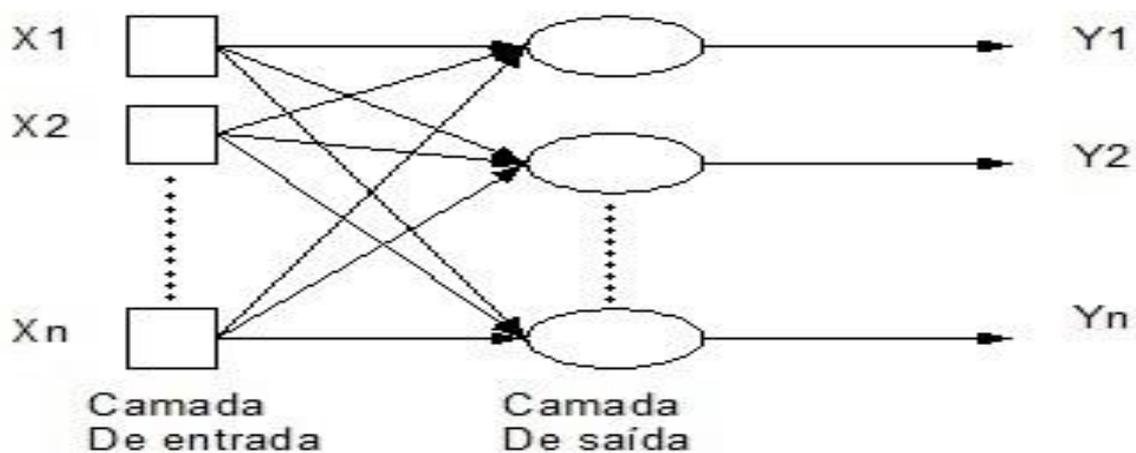
Para definir uma arquitetura de RNAs pode-se dividi-las em três etapas. A primeira é a Camada de Entrada, responsável por capturar as informações de entrada vinda do meio externo. Já segunda etapa é conhecida como Camada (s) escondida (s) ou Intermediária (s), onde se encontram os neurônios artificiais. Esta segunda etapa é responsável por todo o processamento interno da rede, ou seja, por extrair as características do processo associado. Por fim, a terceira etapa é chamada de Camada de Saída, onde também se encontram

neurônios para a apresentação do resultado final da rede [SILVA et al., 2010; BRAGA et al., 2014].

Existem várias arquiteturas de redes neurais artificiais, para isso são consideradas as disposições dos neurônios, a forma de interligação entre eles e a quantidade de camadas intermediárias.

A arquitetura *feedforward* de camada simples tem apenas uma camada de entrada e uma camada de neurônios que é a mesma camada de saída, como é mostrado na Figura 3.

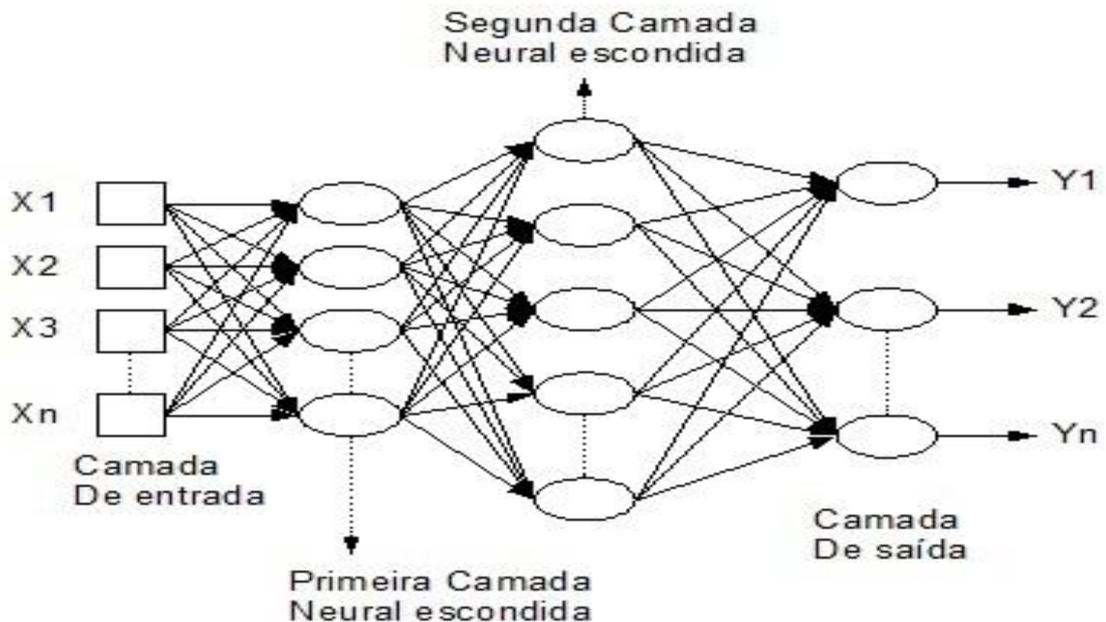
Figura 3. Redes *feedforward* de camada única [SILVA et al., 2010].



Já a arquitetura *feedforward* de camadas múltiplas contém uma ou mais camadas intermediárias de neurônio, como a Figura 4.

Na Figura 4 tem-se uma quantidade diferente de neurônios que compõem a primeira camada escondida em relação à segunda camada escondida. Isto pode variar de acordo com o tipo e a complexidade do problema a ser mapeado pela rede. Assim, a quantidade de valores de saída dependerá da quantidade de neurônios dessas camadas.

Figura 4. Redes *feedforward* de camadas múltiplas [SILVA et al., 2010].



Entre os tipos de redes com arquitetura *feedforward* tem-se a *Multilayer Perceptron* (MLP) ou *Perceptron* de Múltiplas Camadas (PMC), que será mostrada mais a diante.

2.2.3 Aspectos de Aprendizado e Processo de Treinamento

O aspecto de aprendizado de uma rede neural artificial pode ser realizado de duas maneiras, que são: aprendizado supervisionado e o aprendizado não-supervisionado.

Sendo assim, a principal característica de uma RNA é a capacidade de aprender a partir de padrões que mostram o comportamento do sistema. Onde, generaliza soluções a partir do aprendizado e torna a rede capaz de produzir saída desejada a partir de quaisquer sinais de entrada [SILVA et al., 2010].

Para Ludwig JR. e Costa [2007], no aprendizado supervisionado a rede é treinada com pares de conjuntos de entrada e de saída desejada. Desta maneira, durante o treinamento, é apresentado para a rede um conjunto de entrada, ela fornece como resultado um conjunto de saída. Nesse processo são gerados pesos sinápticos (conhecimento nas conexões da rede). Os resultados obtidos são comparados com o conjunto de saída desejada. Assim, a rede ajusta

seus pesos sinápticos de forma a minimizar a diferença entre o conjunto de saída da rede e o conjunto de saída desejada.

Já para o aprendizado não-supervisionado, Ludwig JR. e Costa [2007] nos mostram que a rede não recebe o conjunto de informações de saída desejada. Desta forma, a rede aprende apenas pela experiência, logo, a rede é treinada com valores de entrada e organiza sua estrutura de forma a classificar valores em grupos.

Uma Rede Neural Artificial aprende sobre o seu problema, com ajustes de seus parâmetros. Mas para isso, o treinamento de uma RNA consiste na aplicação de passos ordenados, para os ajustes nos pesos sinápticos e nos limiares de seus neurônios.

Pandorfi et al. [2011], em seu estudo para prever índices zootécnicos na fase de gestação e maternidade na suinocultura, utilizou um processo de seis passos para o treinamento de sua rede, onde os 3 primeiros passos foram realizados para iniciar os pesos e parâmetros de treinamento, já os 3 últimos passos foram utilizados para calcular o erro, para retropropagar o erro e para calcular o erro acumulado da rede.

Para Silva et al.[2010], o conjunto total de amostras disponíveis é dividido em dois grupos, que são chamados de grupo de treinamento e grupo de teste. O grupo de treinamento é composto aleatoriamente por aproximadamente 60 a 90% das amostras do conjunto total, sendo utilizado para aprendizado da rede. Já o grupo de teste conta com aproximadamente 10 a 40% do conjunto total de amostras, sendo utilizado para testar a generalização de soluções da rede e possibilitar a validação da rede assumida.

De acordo com Pandorfi et al. [2011], foram colhidas amostras em 380 matrizes confinadas e escolhida, aleatoriamente, 27 para compor o banco de dados que foi utilizado para desenvolvimento, treinamento e validação da RNA. Sendo que 70% dos dados foram utilizados para treinamento e os outros 30% para validação da rede, com critério de parada do treinamento, uma convergência no erro médio quadrático em 0,005. Mostrando-se um treinamento satisfatório, ao convergir para o valor do erro em 0,1.

Para Ventura et al. [2012], em seu estudo na predição de valores genéticos para peso aos 205 dias em bovinos da raça Tabapuã, utilizou-se uma base de dados com 19.240 registros, sendo divididos em dois grupos. Com o primeiro grupo para treinamento com 14.430 (75%) amostras e o segundo grupo com 4.810 (25%) das amostras, para avaliação e desempenho da rede, atingindo uma validação de 99,8%. Demonstrando que as RNAs apresentam grande versatilidade em desempenho e tempo de processamento, em relação a outras metodologias de predição.

2.2.4 Treinamento Supervisionado

O treinamento supervisionado baseia-se nos sinais de entradas das amostras de treinamento, para conseguir as saídas desejadas. Para tal, é necessária uma tabela de informações com valores de entradas e saídas do problema conhecido, como atributos e valores, para que a rede consiga formular saída, sobre o que foi aprendido [SILVA et al., 2010].

Para Silva et al. [2010], os pesos sinápticos e limiares precisam estar em constante ajuste, para que a defasagem entre as respostas produzidas pela rede e a desejada sejam ajustadas. A rede será treinada quando a defasagem estiver com valores aceitáveis, de acordo com a generalização de soluções.

Neste trabalho, alguns testes com treinamento supervisionado foram realizados. A Figura 5 mostra uma parte da configuração dos dados, onde os 12 primeiros valores separados por “vírgula” correspondem os dados de entrada da rede (temperaturas reticulo-ruminal) e o último valor representa a saída desejada.

Figura 5. Configuração dos dados de treinamento da rede.

	<i>Entrada: Temperatura Reticulo-Ruminal (Trr)</i>	<i>Saída Desejada: Hora antes do parto</i>
36		
37		
38		
39		
40		
41	39, 38.6, 38.2, 38.7, 39, 39, 39, 39.2, 39.5, 39.1, 38.7, 39.2,	63
42	38.6, 38.2, 38.7, 39, 39, 39, 39.2, 39.5, 39.1, 38.7, 39.2, 39,	62
43	38.2, 38.7, 39, 39, 39, 39.2, 39.5, 39.1, 38.7, 39.2, 39, 39.5,	61
44	38.7, 39, 39, 39, 39.2, 39.5, 39.1, 38.7, 39.2, 39, 39.5, 39.2,	60
45	39, 39, 39, 39.2, 39.5, 39.1, 38.7, 39.2, 39, 39.5, 39.2, 39.5,	59
46	39, 39, 39.2, 39.5, 39.1, 38.7, 39.2, 39, 39.5, 39.2, 39.5,	58
47	39, 39.2, 39.5, 39.1, 38.7, 39.2, 39, 39.5, 39.2, 39.5,	57
48	39.2, 39.5, 39.1, 38.7, 39.2, 39, 39.5, 39.2, 39.5,	56
49	39.5, 39.1, 38.7, 39.2, 39, 39.5, 39.2, 39.5,	55

2.2.5 Redes *Perceptron* de Múltiplas Camadas

Redes *Perceptron* de Múltiplas Camadas tem por características a presença de pelo menos uma camada intermediária, situada entre a camada de entrada e a de saída. A rede MLP possui então três camadas de neurônios, os quais são distribuídos entre camada de entrada, camada intermediária e a camada de saída. As camadas intermediárias realizam combinações internas de acordo com os padrões de entrada, que são utilizadas na camada de saída [SILVA et al., 2010].

Para o processamento de cada neurônio de uma camada é definido uma combinação de processamentos, com seus pesos e limiares, realizados pelos neurônios da camada anterior ligados a ele. Os valores dos pesos e limiares são obtidos através de formula matemática que é chamado de cálculo do erro, onde o erro é obtido pela diferença entre a saída desejada e a saída corrente da rede, para redes de uma única camada. Já para redes de múltiplas camadas, esse procedimento pode ser aplicado para a camada de saída, visto que não existem saídas desejadas definidas para as camadas intermediárias, tornando-se um problema, pois como calcular ou estimar o erro das camadas intermediárias [BRAGA et al., 2014].

Para este problema uma solução foi proposta na década de 1980 com o algoritmo de retro-propagação de erros, ou *back-propagation*. A funcionalidade principal do algoritmo é estimar o erro das camadas intermediárias, por meio de uma estimativa do efeito que causam no erro da camada de saída. Logo, o erro de saída da rede é calculado e este é retroalimentado para as camadas intermediárias, proporcionando o ajuste dos pesos aos valores das conexões entre camadas [BRAGA et al., 2014].

Sendo assim, as funções das múltiplas camadas em uma rede *feedforward* podem ser divididas em três etapas, sendo a primeira etapa a transformação do conjunto de dados de entrada (normalização dos dados), na segunda etapa os ajustes dos erros nas camadas intermediárias e, por fim, em transformar os dados em uma representação tratável para a camada de saída da rede [SILVA et al., 2010].

2.2.6 Princípio de Funcionamento da Rede MLP

Por via da Figura 4, pode-se notar que cada sinal de entrada da rede será propagado aos neurônios de saída da rede. Nota-se que as saídas dos neurônios da primeira camada

escondida serão as entradas da segunda camada escondida e a saída da segunda camada escondida será a entrada dos neurônios pertencentes à camada de saída. Tornando assim, a propagação dos sinais de entrada sempre em um único sentido, ou seja, da camada de entrada para a camada de saída da rede [SILVA et al., 2010].

A camada de entrada recebe os sinais e a partir desses sinais se inicia o funcionamento da rede. As camadas escondidas são responsáveis por extrair a maior parte das informações do seu comportamento e compilar por meio dos pesos sinápticos e dos limiares dos neurônios tornando assim uma representação própria do sistema a ser solucionado. Por fim, a camada de saída recebe os sinais vindos da última camada escondida e produz um padrão de resposta para a rede [SILVA et al., 2010].

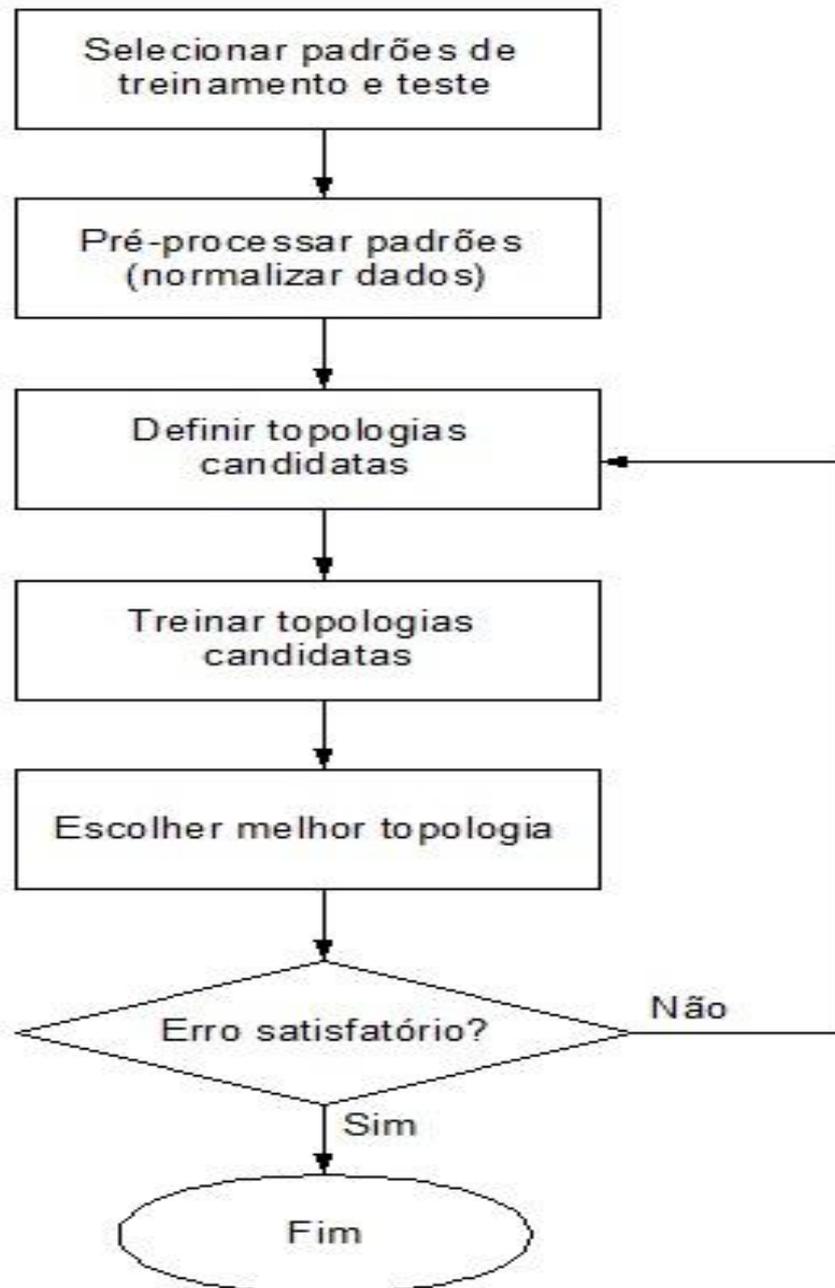
A configuração da arquitetura de uma MLP, assim como o número de neurônios e a quantidade de camadas escondidas, depende principalmente da classe do problema, da quantidade de amostras para treinamento e dos valores dos pesos iniciais atribuídos para o treinamento e da arquitetura da rede. Desta forma, os pesos iniciais podem ser ajustados utilizando o treinamento supervisionado, em que, cada amostra das informações de entrada, gere uma saída desejada [SILVA et al., 2010].

2.2.7 Aspectos de Implementação de Redes *Perceptron* Multicamadas

Para a implementação da rede pode-se dividir em dois métodos: um para a fase de treinamento, conforme Figura 6 e outra para a fase de execução da rede, conforme Figura 7.

Observando-se a Figura 6 há uma necessidade de um pré-processamento das amostras de treinamento e teste desejando, normalmente, assim ocorre uma melhoria do desempenho de treinamento. É, portanto, essencial que todas as entradas e saída da rede sejam normalizadas com seus valores máximos e mínimos, considerando, é claro, todas as informações disponíveis e que os dados estejam dentro do limite do conjunto de treinamento.

Figura 6. Fase de Treinamento [SILVA et al., 2010].



Da mesma forma que a normalização ocorre no pré-processamento a desnormalização deve ocorrer no pós-processamento quando a rede MLP estiver na fase de execução, a fim de converter os valores de saída da rede em valores reais da aplicação, conforme a Figura 7.

Figura 7. Fase de Operação [SILVA et al., 2010].



De acordo com Silva et al. [2010], para a implementação de uma rede *Perceptron* Multicamadas, devem ser considerados alguns aspectos importantes:

- O aumento de neurônios e de camadas na rede não mostra melhoria no potencial de generalização da solução;

- Quando existir duas arquiteturas de MLP que estão generalizando com a mesma precisão é importante definir aquela que possui o menor número de neurônios, pois assim, ela mostra ser capaz de extrair mais conhecimento;
- Designar ao conjunto de treinamento amostras com os valores mínimos e máximos relativos a quaisquer variáveis de entrada e saída da rede MLP;
- Praticar várias vezes a fase de treinamento assumindo valores aleatórios iniciais com o propósito de fugir de eventuais regiões de mínimos locais;
- Segundo LeCun [1989], uma estratégia bem utilizada é aquela vinda de análises efetuadas. Valores dos pesos devem ser pequenos e aleatórios. Esses valores devem estar entre $-2,4/N \leq W \leq 2,4/N$, onde W é o valor do peso e N o número de entradas da rede MLP;
- Definir uma quantidade máxima de épocas como parada, adicionando treinamento da rede, assim torna a estratégia eficiente para parar o treinamento quando a precisão se torna inalcançável;
- Normalizar os valores de entrada e saída da rede evitando a saturação das funções de ativação;
- Sempre definir os dados dos conjuntos de testes para avaliação do potencial de generalização;
- Consumir técnicas de pré-processamento ou ferramentas de extração de características, transformada de *Fourier*, por exemplo, para diminuir as redundâncias e complexidade dos sinais de entrada da rede.

Logo, com as características da rede MLP, o princípio de treinamento e o aspecto de implementação, mostra-se um excelente sistema para a complexidade do trabalho proposto.

Capítulo 3

TRABALHOS RELACIONADOS

As redes MLP são conhecidas pelo grande número de possibilidades de aplicações de diferentes tipos de problemas, em diferentes áreas do conhecimento. Na área de agropecuária são utilizadas em: controle dos elementos meteorológicos, como resposta do comportamento postural; manejo com base nas variáveis fisiológicas; nutrição para produção; melhoramento genético, monitoramento para qualidade do produto final, entre outros. Alguns trabalhos serão descritos a seguir.

Pandorfi et al. [2011] utilizam RNA, para predição de índices zootécnicos nas fases de gestação e maternidade na suinocultura, do tipo *feedforward* com o algoritmo de *backpropagation* para o aprendizado, no desenvolvimento da rede. O estudo, foi realizado em 380 matrizes confinadas e escolhidas, aleatoriamente, sendo 27 para compor o banco de dados que foi utilizado para desenvolvimento, treinamento e validação da RNA. Suas variáveis de entrada da rede foram a temperatura do ar (°C) e taxa respiratória (movimentos/minuto) durante a gestação e de saída foi o peso ao nascimento dos leitões mumificados. A duração da coleta de dados de entrada durou 114 dias e todos eles foram normalizados por meio da Equação 1, onde Y_0 é o valor máximo para normalizar e Y_{max} e Y_{min} são valores máximos e mínimos entre valores reais das variáveis.

$$Y = \frac{(Y_0 - Y_{min})}{(Y_{max} - Y_{min})} \quad \text{Equação 1}$$

Já na arquitetura da rede *backpropagation* foi utilizada uma camada de entrada, uma escondida e outra camada de saída de neurônios. Sendo que 70% dos dados foram utilizados

para treinamento e os outros 30% para validação da rede com critério de parada do treinamento uma convergência no erro médio quadrático em 0,005.

Por fim, de acordo com Pandorfi et al. [2010] o treinamento mostrou-se satisfatório ao convergir para o valor do erro em 0,1. Sendo assim, comprovou a possibilidade de utilização das variáveis de entrada (temperatura do ar e frequência respiratória) para predições de peso ao nascimento dos leitões, como um parâmetro a condições de estresse térmico para tomada de decisão.

Ventura et al. [2012] utiliza RNA para predição de valores genéticos para peso aos 205 dias em bovinos da raça Tabapuã. Nesse estudo, utilizou-se uma base de dados com 19.240 registros sobre os animais da raça Tabapuã como: identificador do animal do pai e da mãe, idade da mãe ao parto e peso no dia 205. Como entrada da rede foi selecionada as variáveis de idade da mãe ao parto, peso aos 205 dias e como saída era esperado o valor genético do animal.

Para normalizar os valores de entrada, também foi utilizado a Equação 1, porém com intervalo de menos um a mais um (-1,1). Dos 19.240 registros que compõem a base de dados foram divididos em dois grupos, onde o primeiro grupo com 14.430 (75%) dos registros foram utilizados para treinamento e ajustes dos pesos já o segundo grupo com 4.810 (25%) registro foi utilizado para avaliação e desempenho da rede. Ventura et al. [2012] utilizou como arquitetura da rede uma camada de neurônio na entrada, uma camada escondida e um neurônio na saída. Porém na camada escondida foram estudadas cinco propostas diferentes que são variações na quantidade de neurônios, entre 30 a 45, e uma variação também no número de iterações (épocas), que variou entre 100 a 1000. A proposta escolhida foi a de 45 neurônios na camada escondida, que apresentou um menor erro quadrático médio (0.0110078) e taxa de aprendizado em 0.008.

Por fim, na validação a acurácia obteve em 99.8%, o que segundo Ventura et al. [2012] mostram que as RNAs apresentam grande versatilidade em desempenho e em tempo de processamento, em relação a outras metodologias de predição.

Já para Franco e Martins [1999] que apresentam seu estudo sobre a avaliação prática de rede neural para o acasalamento de gado nelore, utilizou-se um conjunto de 297 amostras, sendo 198 para o treinamento e 99 para teste, onde para cada vaca foram anotados algumas características e um conjunto de cinco touros, com o touro que melhor apresentou resultado. No total foram 10 características que são: pigmentação, musculabilidade, estrutura, raça, conformação, ônfalo, ganho de peso, tempo de prenhes, desmame e média ponderada dos

anteriores. Já para o touro era validado com o valor um, para o que apresentasse o melhor desempenho com a vaca e o valor zero para os demais touros.

Em relação a RNA utilizou-se uma rede MLP, com uma camada de entrada, uma escondida e outra de saída de neurônios, e três diferentes tipos de algoritmos de treinamento sendo: o *Backpropagation* padrão (*standard*), *Backpropagation Momentum* e *Backpropagation* com *weightdecay*.

Para o treinamento também se utilizou o Simulador Neural SNNS (*Stutgard Neural Network Simulator*). Foram feitas 1.152 simulações com a variação dos seguintes parâmetros:

- Quantidade de ciclos de treinamento, variando de 50 a 6.400;
- Fator de aprendizado com os valores variando em 0.1, 0.2, 0.4 e 0.8;
- Fator de *Momentum* para o algoritmo de *backpropagation* com *Momentum* entre os valores de 0.1, 0.2, 0.4 e 0.8;
- Fator de decaimento para o algoritmo de *backpropagation* com *WeightDecay* com valores entre 0.005, 0.02, 0.08 e 0.5.

Por fim, segundo Franco e Martins [1999] a rede MLP com o algoritmo *backpropagation* com *WeightDecay* não apresentou um bom resultado, pois para números muito grandes de ciclo a rede não conseguia aprender e quando o número não era grande o sistema não convergia. Porém, ainda segundo Franco e Martins [1999], a rede MLP com os outros dois algoritmos de treinamento apresentaram um resultado satisfatório com índices de 85% de acertos, enquanto que outras técnicas de predição apresentam no máximo 75% de taxa de acerto. Portanto, a rede MLP com os algoritmos de treinamento *backpropagation Standard* e *Momentum*, apresentaram um sistema promissor para lidar com este tipo de tarefa.

Ferreira et al. [2011] em seu trabalho, utilizaram redes neurais artificiais como estratégia de previsão de preços no contexto do agronegócio. Apresentou uma metodologia de previsão de preço sobre quatro *commodities* agrícolas, que são: o boi gordo, a soja, o milho e o trigo.

Para o processo de definição da RNA o autor utilizou cinco passos: o primeiro foi à preparação dos dados, na qual a base de dados foi retirada da EMATER-RS, entre os meses de janeiro de 1992 a dezembro de 2006, sendo que todos os valores coletados foram normalizados para valores entre zero e um. Na segunda etapa foi a definição da estrutura da rede, onde se definiu a utilização de dois neurônios na camada de entrada, cinco neurônios na camada escondida e um neurônio na camada de saída. Assim, o objetivo do trabalho limitou-

se a previsão do preço para o mês seguinte, partindo dos dois meses anteriores. Ainda segundo Ferreira et al. [2011] na segunda etapa foram testadas várias composições de redes, sendo alterado a quantidade de neurônios na camada escondida, com três, cinco, nove e doze neurônios. Porém, a que melhor apresentou resultados satisfatórios foi a rede com cinco neurônios na camada escondida.

A terceira etapa foi buscar uma estimativa do modelo, onde se procurou melhor ajuste da rede para um modelo generalizável. Para esta etapa foi definido o valor de 0.025 como limites de erro, assim a rede parava de treinar quando atingia este limite. Na quarta etapa realizou a avaliação dos resultados obtidos pela rede, com a medida da raiz do erro quadrado médio, sendo aceito valores entre 0.05 a 0.08.

Por fim a quinta etapa foi a validação do modelo, cujo objetivo foi garantir que a solução encontrada é a melhor possível e que a RNA seja tão generalizável quanto possível. Para isso, utilizaram-se diferentes produtos agrícolas com diferentes preços chegando a um resultado satisfatório para uma boa decisão de minimização do risco, para o proprietário.

Para Costa Junior [2014], o foco foi avaliar a temperatura reticuloruminal (T_{rr}) como um preditor para parto em novilhas e vacas da raça Holandesa através do teste de desempenho e a curva característica de resposta do observador (curva ROC). O trabalho de Costa Junior [2014] servira como base para o desenvolvimento desse trabalho, e portanto, será detalhado nas seções a seguir.

Existem vários números de trabalhos em pecuária que utilizam a RNA, que obtiveram bons resultados. Entretanto, nas diversas pesquisas realizadas em periódicos, artigos científicos de congressos, dissertações e teses não foram encontrados trabalhos para a predição do momento de parto.

Capítulo 4

METODOLOGIA

Com o objetivo de realizar a predição do momento do parto, em um plantel de gado leiteiro, foram utilizados dados obtidos por Costa Junior [2014]. A proposta foi implementar esta predição utilizando-se de Rede Neural Artificial e comparar os resultados com os de Costa Junior [2014].

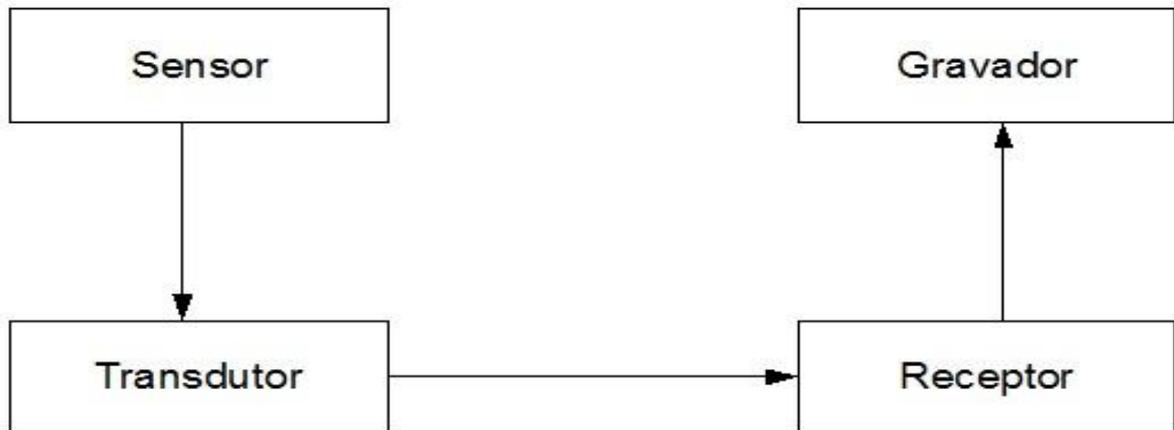
Costa Junior [2014] em sua tese propunha comprovar as seguintes hipóteses:

1. Existem variações da temperatura reticuloruminal (T_{rr}) em vacas e novilhas da raça Holandesa antes do parto;
2. Estas variações da T_{rr} poderão ser usadas como preditor do início do parto em novilhas e vacas da raça Holandesa.

Para tal, Costa Junior [2014] propôs verificar se os padrões de variação da T_{rr} são consistentes para serem usados como preditor do início do processo de parto em novilhas e vacas Holandesas e determinar qual linha média e queda de temperatura apresenta melhor resultado para predizer o início de parto em novilhas e vacas Holandesas.

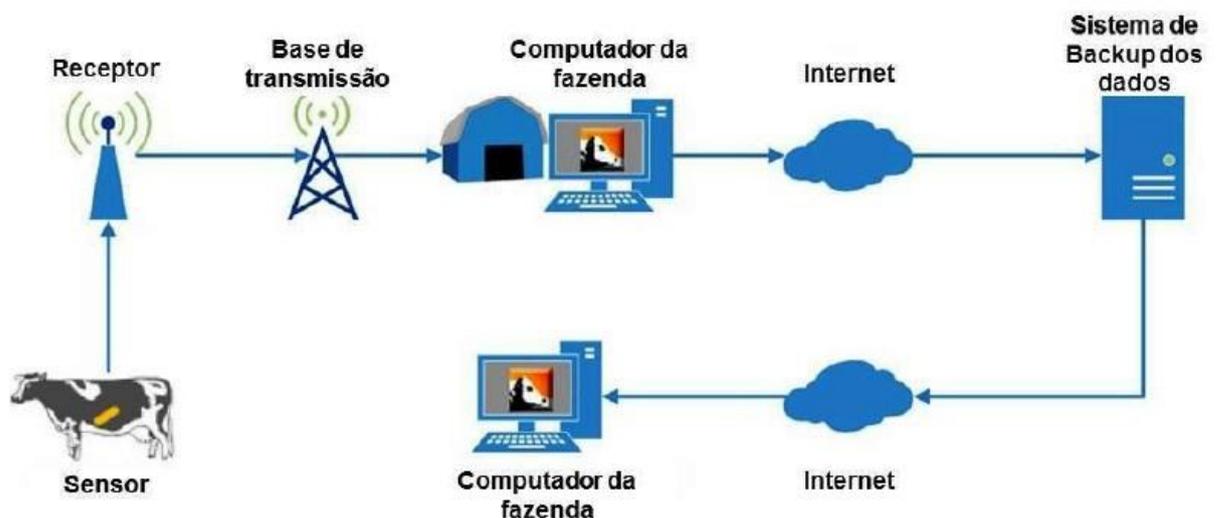
Para a coleta de dados Costa Junior [2014] realizou a pesquisa na Universidade Estadual do Colorado – Colorado – EUA. Assim, utilizou um sistema de telemetria por rádio frequência, como é mostrado na Figura 8. Nessa arquitetura, basicamente um sensor gera um impulso elétrico proporcional à variação fisiológica da T_{rr} do bovino, que é enviado para um transdutor, que repassa o sinal ao receptor, que envia o sinal ao gravador, para armazenar a leitura.

Figura 8. Sistema de telemetria por rádio frequência [COSTA JUNIOR, 2014].



O sensor mencionada (aquele que gera o impulso elétrico) estava localizado no esôfago da vaca a ser monitorada. A transmissão dos dados armazenados no sensor (de dentro do animal) era realizada por telemetria. Para a aplicação do sensor (também conhecido como Bolus) as fêmeas eram deslocadas para um piquete próximo à sede da propriedade e, utilizando uma pistola esofágica, ele era introduzido em cada vaca. O Bolus, que pesava aproximadamente 150 g, e continha um sensor de temperatura para realizar a cada hora uma leitura da Trr. Os Bolus possuem um sensor de temperatura com acurácia de 0,1 °C, leituras frequentes de uma em uma hora, com formato cilíndrico, além de possuírem um sistema de transmissão de dados por telemetria da Trr para em um computador da propriedade, conforme a Figura 9.

Figura 9. Esquema de coleta de dados da Trr pelo sistema de telemetria por rádio frequência [COSTA JUNIOR, 2014].



Além dos Bolus, o sistema era equipado com duas antenas com capacidade de alcance de 10 m de distância, localizados dentro dos piquetes, próximos ao portão de acesso as ordenhadeiras, como mostra a Figura 9. Observa-se ainda que a capacidade de armazenamento dos Bolus era de no máximo 12 leituras, ou seja, 12 horas de registro. Desta forma, havia necessidade de que as vacas se aproximassem das antenas receptoras dos dados pelo menos duas vezes ao dia. Como as vacas eram ordenadas duas vezes ao dia, e o aparelho está próximo as ordenhadeiras, os dados eram recolhidos neste momento.

Os dados obtidos dos sensores eram posteriormente transmitidos, também via antena, para um computador que armazenava os dados de temperatura Trr no *softwareTempTrack*, desenvolvida pela *DVM Systems*.

Costa Junior [2014] nos explica que a variação da Trr é resultado das mudanças fisiológicas do animal, porém, observa-se que a ingestão de dietas e água também pode causar aumento ou queda, respectivamente. O ambiente da coleta de dados apresentou uma temperatura de 39 °C, entretanto os bovinos preferem ingerir água com temperatura entre 16 a 18 °C, o que resulta em queda de 6,9 °C da Trr e um retorno a temperatura normal dentro de 2 horas. Assim o consumo de água pode afetar a eficácia da Trr como preditor do parto em bovinos. Deste modo, Costa Junior [2014] optou pela eliminação das temperaturas abaixo de 37,7 °C.

Obtiveram-se leituras da Trr maiores que 37,7°C, totalizando 9.911 leituras provenientes das 111 novilhas e 12.351 leituras provenientes das 150 vacas. Também se obteve uma categoria composta de todos os animais (novilhas e vacas).

No trabalho de Costa Júnior [2014] foi realizado a média diária da Trr para analisar o efeito de sua variação diária. Esses dois grupos foram analisados estatisticamente no pacote PROC MIXED do SAS. Esses resultados estatísticos serão comparados com os resultados obtidos no presente trabalho, na análise final, salientando-se que são utilizados os mesmos dados de Trr de Costa Júnior [2014].

A proposta, portanto, desse trabalho é validar a hipótese de que é possível realizar a predição de parto usando a Rede Neural Artificial *MultiLayer Perceptron*.

Foi utilizada a Rede Neural Artificial para solução desse problema porque é um modelo adequado para a predição de dados não-lineares e padrões de comportamento, como são os dados de Trr obtidos dos animais.

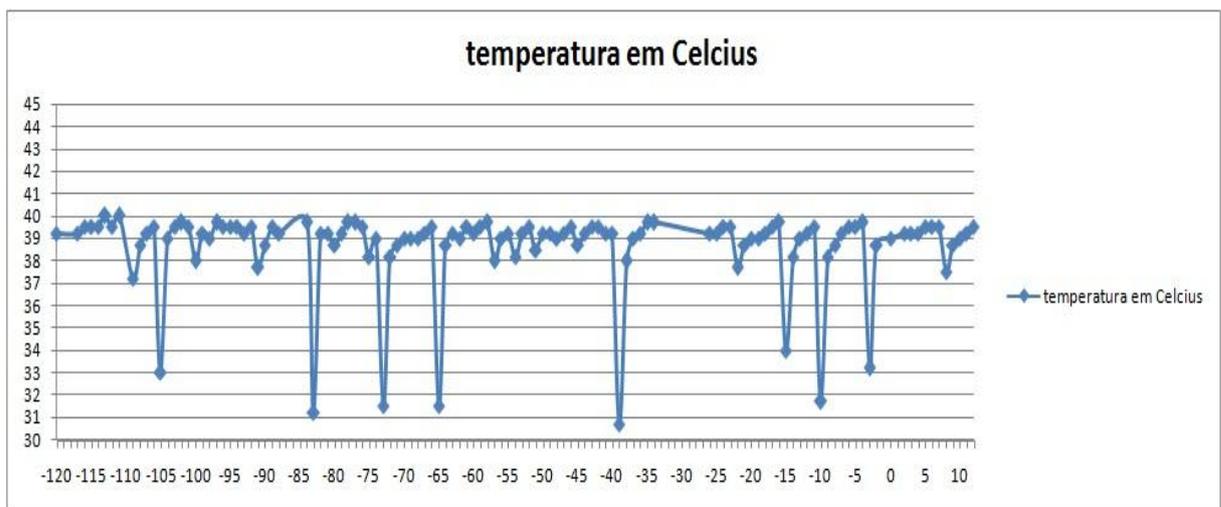
Nota-se que quando é necessário compreender as relações entre o ambiente e a produção animal em um banco de dados, como é o caso desta pesquisa, os modelos que utilizam redes neurais têm potencial de aplicação [LOESCH E SARI, 1996; HAYKIN, 2001].

A utilização das redes neurais apresenta como vantagens principais à tolerância a falhas, a aplicação em tempo real, a capacidade de auto adaptação e a rápida resolução dos problemas práticos sem a necessidade de definição de lista de regras ou de modelos precisos [HAYKIN, 2001].

Desta forma, o objetivo de definição da rede neural artificial é resolver o problema com a menor estrutura possível, com potencial de aplicação em situações que requeiram classificação, identificação e associação de padrões; em predições; em aproximação de funções e; em aprendizado nas áreas que é difícil criar modelos precisos da realidade e com frequentes mudanças de ambiente [HAYKIN, 2001].

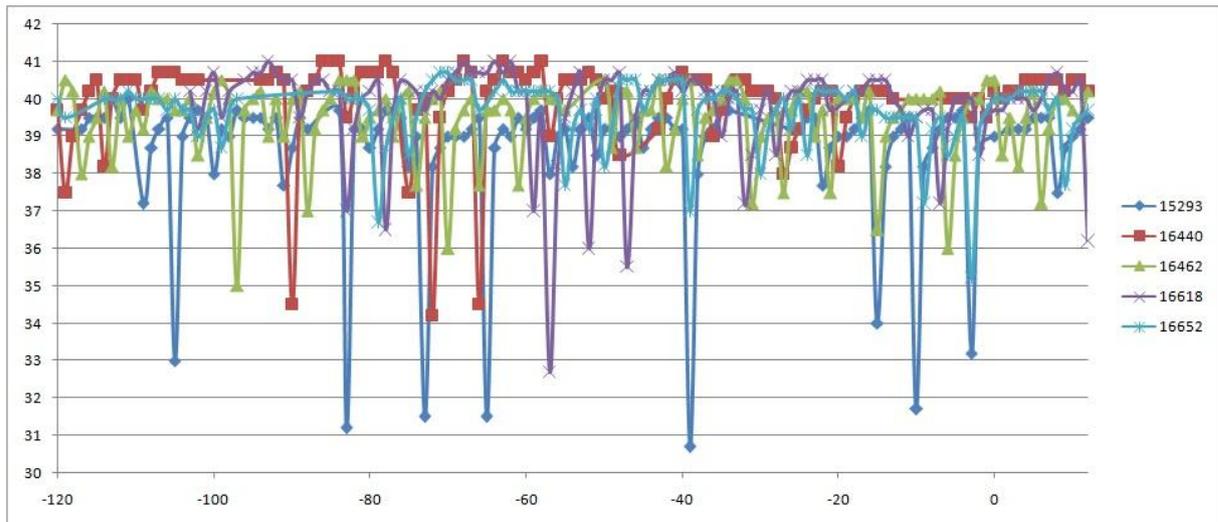
É possível observar na Figura 10 o gráfico dos dados de Temperatura (Trr) em graus Celsius e a quantidade de horas para o parto de uma vaca. Os valores de temperatura *versus* horas para o parto se apresentam de forma aleatória, sem um padrão aparente.

Figura 10.Gráfico contendo a variação de temperatura de um animal.



A Figura 11 apresenta o gráfico com dados de cinco vacas. Sendo assim, nas Figuras 10 e 11, nota-se à variabilidade dos dados, sendo complicado estabelecer correlação entre os dados sem o uso de um ferramental adequado.

Figura 11. Gráfico contendo a variação de temperatura de cinco animais.



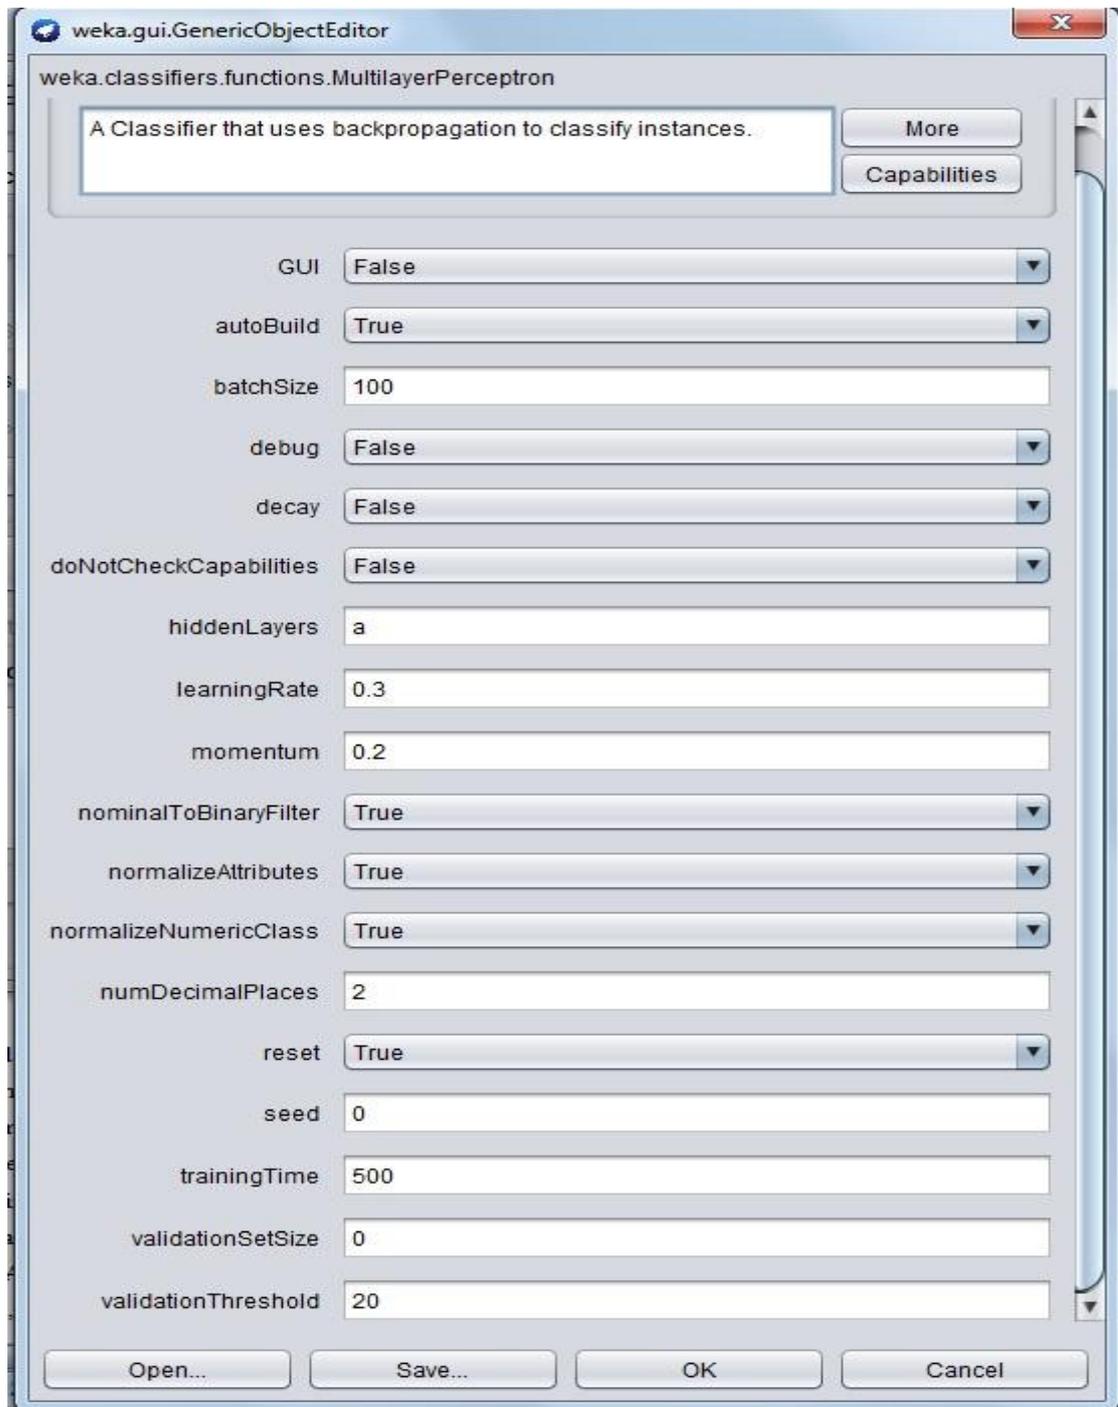
Salienta-se, portanto, após a observação dos dados que a solução deste problema através de RNAs é bastante atrativa, pois o paralelismo natural inerente à arquitetura das RNAs cria a possibilidade de um desempenho superior ao dos modelos convencionais.

A capacidade de aprender através de exemplos e de generalizar a informação aprendida é, sem dúvida, uma característica importante para tal escolha. A generalização, que está associada à capacidade de a rede aprender através de um conjunto reduzido de exemplos e posteriormente dar respostas coerentes para dados não-conhecidos, é uma demonstração de que a capacidade das RNAs vai muito além do que simplesmente mapear relações de entrada e saída. As RNAs são capazes de extrair informações não-apresentadas de forma explícita através de exemplos. Não obstante, as RNAs são capazes de atuar como mapeadores universais de funções multivariáveis, com custo computacional que cresce apenas linearmente com o número de variáveis [BRAGA et al., 2014]. Outra característica importante é a capacidade de auto-organização e de processamento temporal, que, aliada àquelas citadas anteriormente, faz das RNAs uma ferramenta computacional extremamente poderosa e atrativa para a solução de problemas complexos, como é o caso destes dados de Trr, utilizadas para a predição de parto de gado.

O simulador utilizado neste trabalho é o pacote de software Weka (*Waikato Environment for Knowledge Analysis*), desenvolvido pela Universidade de Waikato da Nova Zelândia, na qual possui licença pública (*General Public License*) [WEKA, 2011]. O Weka foi escolhido, pois tem entre os objetivos, implementar uma Rede Neural Artificial *MultiLayer Perceptron*, analisar computacionalmente os dados fornecidos e gerar informações estatísticas a partir dos padrões encontrados, se encaixando perfeitamente na

complexidade deste trabalho. A Figura 12 mostra a janela de configurações, com a configuração padrão do Weka, da Rede Neural Artificial *MultiLayer Perceptron* do software Weka.

Figura 12. Janela de Configurações para RNA MLP do software Weka.



Os dados de Trr utilizados na rede neural foram inseridos de duas maneiras. A primeira utilizou-se os dados brutos (sem manipulação). A proposta era verificar se, nesse

caso, a rede apresentaria bons resultados. Se seria possível aproveitar as características desejadas da rede, tais como, processamento paralelo, que alcança bom desempenho via interconexão de elementos computacionais simples. Isto porque, apesar de desenvolver um programa com instruções sequenciais, os modelos exploram simultaneamente muitas hipóteses, utilizando regras de aprendizagem, que permitem adquirir o poder de generalização. As entradas e saídas de dados dos sistemas são preditas nas análises múltiplas e paralelas da rede.

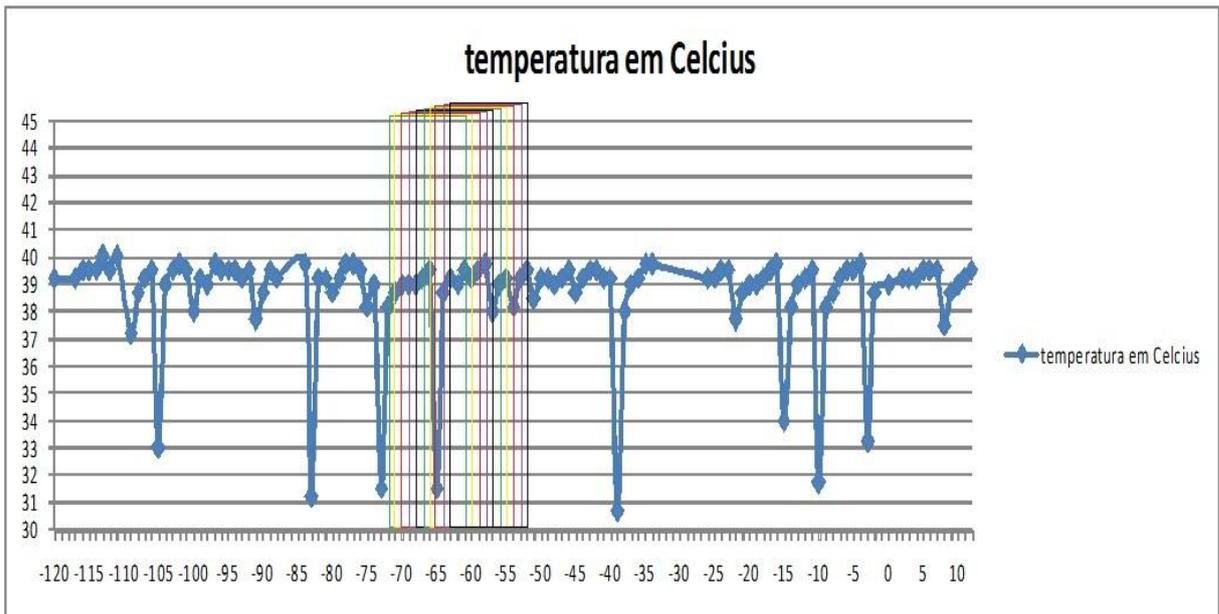
A segunda proposta foi com a substituição das temperaturas menores do que $37,7\text{ }^{\circ}\text{C}$. Ou seja, no instante de tempo que o sensor apresentou a temperatura menor do que $37,7\text{ }^{\circ}\text{C}$ foi calculada uma média entre a temperatura do instante anterior e do instante posterior. Este valor de foi $37,7\text{ }^{\circ}\text{C}$ estipulado no trabalho de Costa Júnior [2014], também era eliminado, pois era o momento em que a vaca tomava água.

Os testes foram implementados com Redes Neurais Artificiais do tipo *Multi Layer Perceptron*. Desta forma, várias arquiteturas da rede com três camadas foram testadas, com variações dos neurônios da camada intermediária e da camada de saída.

Os neurônios de entrada foram as temperaturas T_{rr} das vacas, que foram testadas individualmente e em conjunto. Todos os testes foram realizados com 12 neurônios de entrada. Utilizou-se esta implementação porque é a quantidade de temperatura armazenada nos sensores (Bolus) e que são transferidos de uma única vez para o receptor.

Foram testadas duas formas de inserção das doze temperaturas de entrada. Uma implementação foi realizada com o deslocamento de uma hora em uma hora, no janelamento de 12 horas (neurônios de entrada), no gráfico de temperatura *versus* tempo para o parto, conforme representado na Figura 13.

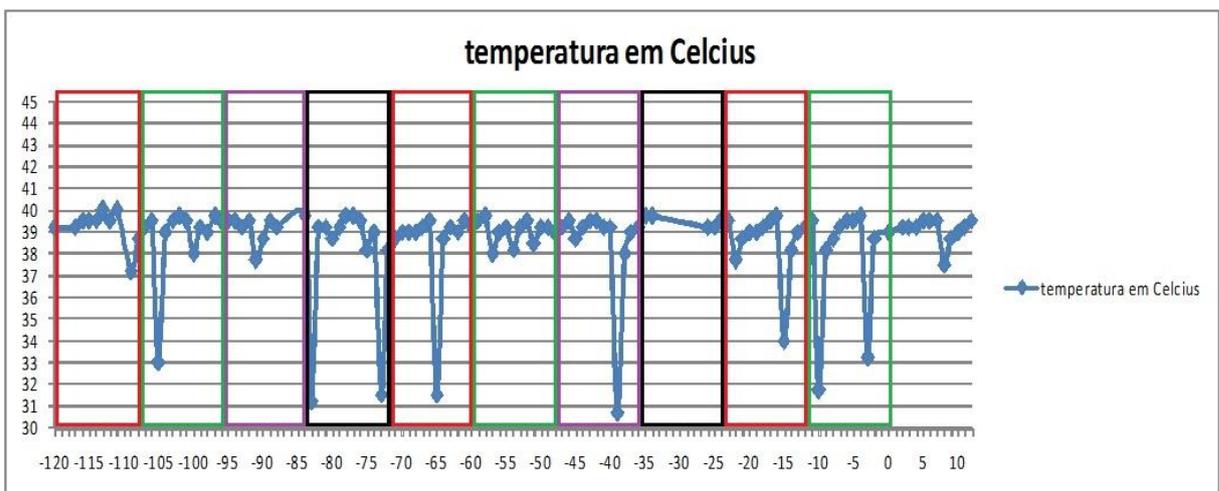
Figura 13. Sistema de janelamento aumentando de uma em uma hora.



Também foram feitos testes, nessa mesma proposta, retirando-se dos dados brutos, as temperaturas menores do que 37,7 °C.

A segunda forma de inserção das doze temperaturas na entrada da rede foi com o seu deslocamento inteiro no gráfico de temperatura *versus* tempo para o parto, conforme representado na Figura 14.

Figura 14. Sistema de janelamento aumentando de 12 em 12 horas.



O número de neurônios na camada intermediária variou de acordo com o conjunto de treinamento utilizado. Para a camada da saída, também ocorreram variações de acordo com o teste realizado.

Com relação à saída, foram realizadas implementações diferentes, uma tentativa com um neurônio de saída com definição de horas para o parto, outra com um neurônio de saída com definição de parto e não parto.

Com essa variabilidade várias arquiteturas e testes, portanto, foram realizados, com variações de alguns parâmetros que serão descritos, individualmente em cada teste.

4.1 Características de Implementação da Rede MLP

Para este trabalho foram construídas várias redes MLP, cujos parâmetros utilizados serão descritos a seguir e, quando necessário, é apresentada uma breve justificativa [BARBOSA, 2004].

- Número de camadas: 3 (totalmente conectadas na topologia original) observando que quando a função consiste de um número finito de pontos ou, quando é utilizada uma função contínua, uma rede de três camadas é capaz de aprender esta função [BRAGA et al., 2014]. Além disso, nas redes MPLs com apenas uma camada intermediária, os neurônios tendem a interagir entre si [HAYKIN, 2001].
- Número de neurônios da camada de entrada: O número de neurônios na entrada, normalmente, corresponde ao número de variáveis de entrada do processo a ser modelada. Para este trabalho cada neurônio corresponde a uma temperatura medida (T_{rr}) em um instante de tempo e quantidade depende da capacidade de leitura/armazenamento do Bolus, totalizando assim 12 neurônios na camada de entrada.
- Número de neurônios na camada de saída: Em alguns testes definiu-se apenas 1 neurônio para a saída desejada, indicando a quantidade de horas restante para o parto. Outros testes com 1 neurônio para a saída desejada, definiu-se como sendo o valor 0 para indicar as 12 últimas horas do momento de parto e o valor 1 para indicar o momento de não parto, onde tem-se a variação de 13 até 80 horas antes do parto. Teve teste com quatro neurônios na camada de saída, cada neurônio referente a um janelamento de uma quantidade de horas, que

antecediam o parto. Nesse caso, as saídas foram neurônio Parto, neurônio 12 horas, neurônio 24 horas e neurônio Não Parto.

- Número de padrões necessário no conjunto de treinamento: Este valor depende da quantidade de exemplos disponível. Neste trabalho, todos os testes realizados foram separados 70 % das informações para treinamento e os outros 30 % divididos entre validação e teste da rede. No Capítulo 5, serão apresentados os valores exatos utilizados para cada teste.
- Número de neurônios na camada intermediária: Na literatura encontram-se várias heurísticas para definir a quantidade e solucionar tal problema. Neste trabalho o número de neurônios na camada intermediária depende do número de exemplos utilizados no treinamento. Para definir a quantidade de ligações sináptica entre dois neurônios, o que chamaremos de número total de pesos (NTP), que envolvem centenas de exemplos de treinamento utiliza-se a Equação 2. Porém para casos com milhares de exemplos utiliza-se a Equação 3.

Equação 2

$$NTP = \frac{\text{núm.deexemplosdetrain.}}{2}, \text{ para poucos exemplos}$$

Equação 3

$$NTP = \frac{\text{núm.deexemplosdetrain.}}{10}, \text{ para vários exemplos}$$

- Algoritmo de treinamento: retropropagação com momento.
- Ordem de apresentação dos exemplos: aleatória.
- Taxa de aprendizagem: Como padrão foi utilizado o valor 0,01, mas em alguns testes apresenta uma variação.
- Constante de momento: Como padrão foi utilizado o valor 0,9, mas em alguns testes apresenta uma variação.
- Número de épocas: Como padrão foi utilizado o valor 100000, mas em alguns testes apresenta uma variação entre 5000 a 50000 épocas.

4.2 Medida de Desempenho de um Classificador

Para medir o desempenho de um classificador tem-se a Sensibilidade (S) (Equação 4), Especificidade (E) (Equação 5), Valor Preditivo Positivo (VPP) (Equação 6) e Valor Preditivo Negativo (Equação 7) [IAIONE, 2003].

$$S = \frac{VP}{VP + FN} 100\% \quad \text{Equação 4}$$

$$E = \frac{VN}{VN + FP} 100\% \quad \text{Equação 5}$$

$$VPP = \frac{VP}{VP + FP} 100\% \quad \text{Equação 6}$$

$$VPN = \frac{VN}{VN + FN} 100\% \quad \text{Equação 7}$$

Nessas equações tem-se o VP como verdadeiro-positivo correspondendo ao número de padrões da classe relevante, que foram classificados corretamente e, VN como verdadeiro-negativo sendo o número de padrões da classe irrelevante, que foram classificados corretamente. Sendo assim, FP como falso-positivo correspondendo ao número de padrões da classe irrelevante, que foram classificados incorretamente e, FN como falso-negativo para o número de padrões da classe relevante, que foram classificados incorretamente.

Desta maneira, a classe relevante é a classe que representa o estado que se deseja detectar. Portanto, S indica a taxa de acerto para a classe relevante, E indica a taxa de acerto para a classe irrelevante, VPP mostra a probabilidade de a classificação na classe relevante estar correta e VPN mostra a probabilidade de a classificação na classe irrelevante estar correta.

Iaione (2003) também nos mostra que é comum a utilização da Taxa de Acerto (TA), Equação 8, e da Taxa de Erro (TE) Equação 9.

$$TA = \frac{VP + VN}{\text{Total de padrões}} 100\%$$

Equação 8

$$TE = \frac{FP + FN}{\text{Total de padrões}} 100\%$$

Equação 9

Por fim, terminado a apresentação da metodologia deste trabalho, o capítulo seguinte apresenta os resultados e discussões obtidos pela Rede Neural Artificial *MultiLayer Perceptron*.

Capítulo 5

RESULTADOS E DISCUSSÕES

Todos os testes realizados possuem o seguinte padrão da configuração: a rede com 3 camadas sendo uma camada de entrada contendo 12 neurônios, uma camada intermediária cuja a quantidade de neurônios pode variar de acordo com a quantidade de exemplos para treinamento e uma camada de saída, onde também pode variar a quantidade de neurônios dependendo da metodologia utilizada para o teste. O parâmetro taxa de momento e a taxa de aprendizagem também teve alteração em alguns testes.

5.1 Teste Inicial com Valores Fictícios

Como dito anteriormente, a ferramenta utilizada para a simulação da rede MLP foi o Weka e, sendo assim, um teste inicial com valores de temperaturas fictícias foi realizado para verificar o domínio do *software*. O arquivo com os dados para treinamento possui 120 exemplos e foi dividido em 60 exemplos com 12 temperaturas com 5°C e saída desejada sendo o valor 1 (um) indicando o período de não-parto. Outros 60 exemplos sendo 11 temperaturas com 5°C e uma temperatura em 2°C e a saída desejada sendo 0 (zero) indicando o período de parto.

A Figura 15 mostra um trecho deste arquivo de dados.

Figura 15. Arquivo com valores fictícios para verificar comportamento do *software* Weka e da rede MLP.

74	5	5	5	5	5	5	5	5	5	5	5	5	5	1
75	5	5	5	5	5	5	5	5	5	5	5	5	5	1
76	5	5	5	5	5	5	5	5	5	5	5	5	5	1
77	5	5	5	5	5	5	5	5	5	5	5	5	5	1
78	5	5	5	5	5	5	5	5	5	5	5	5	5	1
79	5	5	5	5	5	5	5	5	5	5	5	5	5	1
80	5	5	5	5	5	5	5	5	5	5	5	5	5	1
81	5	5	5	5	5	5	5	5	5	5	5	5	5	1
82	5	5	5	5	5	5	5	5	5	5	5	5	5	1
83	5	5	5	5	5	5	5	5	5	5	5	5	2	0
84	5	5	5	5	5	5	5	5	5	5	5	2	5	0
85	5	5	5	5	5	5	5	5	5	5	2	5	5	0
86	5	5	5	5	5	5	5	5	5	2	5	5	5	0
87	5	5	5	5	5	5	5	5	2	5	5	5	5	0
88	5	5	5	5	5	5	2	5	5	5	5	5	5	0
89	5	5	5	5	5	2	5	5	5	5	5	5	5	0
90	5	5	5	5	2	5	5	5	5	5	5	5	5	0
91	5	5	5	2	5	5	5	5	5	5	5	5	5	0

Já na ferramenta Weka a seguinte configuração foi realizada:

- Camada intermediária: 4 neurônios;
- Camada de saída: 1 neurônios;
- Valor de *Momentum*: 0.9;
- Taxa de aprendizagem: 0.01;
- Decaimento: verdadeiro;
- Número de épocas: 100.000;
- Normalização dos atributos: falso;
- Normalização numérica da classe: falso;
- Método de execução: *Percentage split 70%*;

Sendo assim, foram utilizados 84 exemplos para treinamento e 36 exemplos para teste da rede. A Tabela 1 mostra 15 exemplos, dos 36 utilizados para teste da rede, e a resposta fornecida pelo Weka. A segunda coluna da Tabela 1 indica a saída desejada. Já a terceira coluna mostra a saída gerada pela rede e na quarta coluna o cálculo do erro entre a saída desejada e a saída predita da rede. A tabela completa com os 36 exemplos está no Anexo (A.1 Teste Inicial com Valores Fictícios).

Tabela 1. Valores de saída da rede do teste inicial.

Instância	Saída desejada	Predição da rede	Erro
1	1	0.456	-0.544
2	1	0.456	-0.544
3	1	0.456	-0.544
4	1	0.456	-0.544
5	1	0.456	-0.544
6	1	0.456	-0.544
7	1	0.456	-0.544
8	0	0.454	0.454
9	1	0.456	-0.544
10	1	0.456	-0.544
11	0	0.454	0.454
12	1	0.456	-0.544
13	1	0.456	-0.544
14	1	0.456	-0.544
15	0	0.443	0.443

Observa-se que a resposta “pura” do Weka, ou seja, sem nenhuma manipulação, não apresentou resultados adequados. Isso acontece porque na definição de um dos parâmetros do *software* Weka, referente ao neurônio de saída, deve-se estabelecer se é uma classe (*string* ou mais de uma saída) ou um número. Na definição de número, como é nesse caso, a saída apresentada pela rede fica no intervalo de valores entre os valores máximos e mínimos, definidos no conjunto de treinamento. Dessa forma, para uma definição mais precisa da saída da rede, fez-se a convenção (desnormalização) de que valores maiores ou iguais a 0,5 seriam considerados como saída 1 e valores menores que 0,5 seriam considerados 0. Salientando-se que no conjunto de treinamento os valores de saída eram 0 ou 1.

Dessa forma a Tabela 2, apresenta parte dos resultados (15 exemplos dos 36) após normalização dos valores de saída. Os valores completos dos 36 exemplos estão no Anexo (A.1.1 Segundo Teste Inicial com Valores Fictícios Normalizados).

Tabela 2. Valores de saída, do teste inicial, com a os dados de entrada normalizados.

Instância	Saída desejada	Predição a rede	Valores de saída normalizados
1	1	0.456	0
2	1	0.456	0
3	1	0.456	0
4	1	0.456	0
5	1	0.456	0
6	1	0.456	0
7	1	0.456	0
8	0	0.454	0
9	1	0.456	0
10	1	0.456	0
11	0	0.454	0
12	1	0.456	0
13	1	0.456	0
14	1	0.456	0
15	0	0.443	0

Nesse teste, especificamente, são os dados de testes das 36 vacas fictícias, 14 representavam Partos e 22 Não Parto. A resposta da rede, após realizar a desnormalização, foi de 14 Partos (classificados como certo, 38,9%) e 22 de Não Parto foram classificados como Parto (classificados como errado, 61,1%). A Tabela 3 mostra todos os valores estatísticos calculado sobre o teste inicial.

Tabela 3. Tabela com dados estatísticos do Teste Inicial.

	Quant. de Elementos Relevante	Quant. de Elementos Irrelevante	VP	FP	FN	VN	S	E	VPP	VPN	TA	TE
Teste Inicial	14	22	14	22	0	0	100	0	38,8%	0%	38,9%	61,1%

Um segundo teste, com as mesmas informações anteriores foi realizado, com mudança na configuração da rede. Os neurônios de entrada, denominados atributos, e os neurônios de saída, denominados numéricos, foram modificados: `normalizeAttributes` e `normalizeNumericClass` passam a ser verdadeiro. Ou seja, os dados de entrada e de saída passam a ser normalizados pelo *software* conforme é mostrado na Figura 16. Logo, a Tabela 4 mostra os 36 exemplos que foram utilizados para testar a rede. A tabela completa com os 36 exemplos utilizados no teste estão no Anexo (A.1.2 Segundo Teste Inicial com Valores Fictícios Normalizados).

Figura 16. Parte da janela de configurações, com os destaques para as normalizações de entrada e saída.

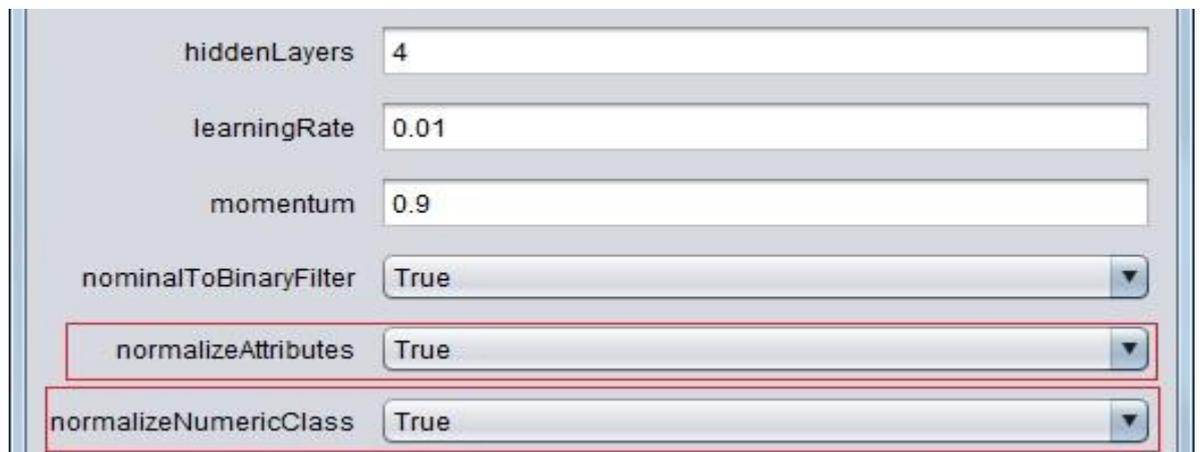


Tabela 4. Valores de saída da rede do segundo teste inicial.

Instância	Saída desejada	Predição da rede	Erro	Valores de saída normalizados
1	1	0.553	-0.447	1
2	1	0.553	-0.447	1
3	1	0.553	-0.447	1
4	1	0.553	-0.447	1
5	1	0.553	-0.447	1
6	1	0.553	-0.447	1
7	1	0.553	-0.447	1
8	0	0.519	0.519	1
9	1	0.553	-0.447	1
10	1	0.553	-0.447	1

11	0	0.519	0.519	1
12	1	0.553	-0.447	1
13	1	0.553	-0.447	1
14	1	0.553	-0.447	1
15	0	0.322	0.322	0

Observa-se que nesse teste houve uma melhora no número de exemplos considerados acerto, sendo 30 exemplos classificados como certo (83,3%) e apenas 6 exemplos classificados como errado (16,7%). Mostrando a importância no pré-processamento com a normalização e pós-processamento com a desnormalização dos dados de entrada e saída da rede, como foi dito anteriormente, no aspecto de implementação da rede neural. A Tabela 5 mostra os dados estatísticos sobre o segundo teste inicial.

Tabela 5. Tabela com dados estatísticos do segundo Teste Inicial.

	Quant. de Elem. Relevante	Quant. de Elem. Irrelevante	VP	FP	FN	VN	S	E	VPP	VPN	TA	TE
Teste Inicial	14	22	8	0	6	22	57,1	100	100%	78,5%	83,3%	16,6%

5.2 Teste com valores brutos

Nesse primeiro conjunto de simulações, foram realizados teste com as Trr de forma bruta, ou seja, os valores de Trr foram testados da mesma forma que estavam no banco de dados. Portanto, foram utilizadas as 120 vacas totalizando um conjunto de 2.299 exemplos divididos em dois grupos, sendo 70% (1.609 exemplos) para o conjunto de treinamento e 30% (690 exemplos) para o conjunto de teste e validação da rede.

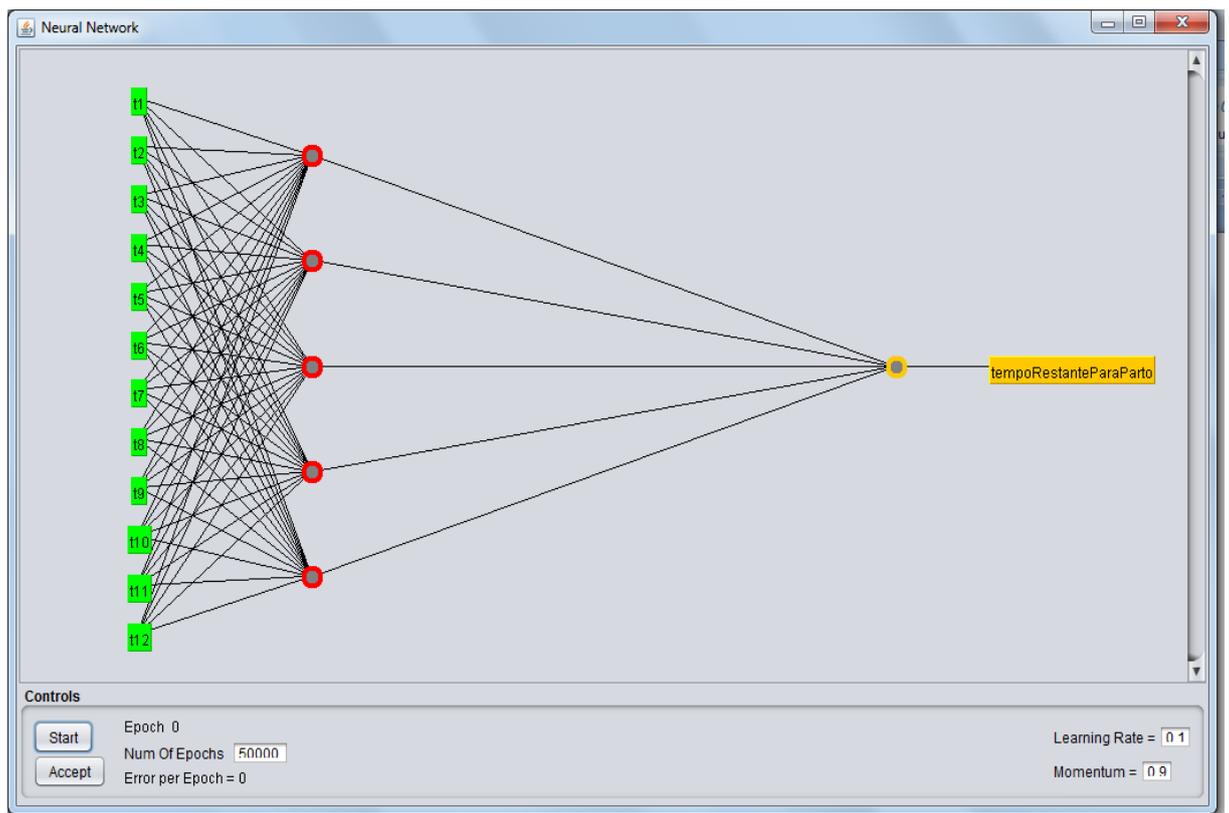
A rede seguiu com a seguinte configuração:

- Camada intermediária: 5 neurônios;
- Camada de saída: 1 neurônios (horas restantes para o parto);

- Valor de *Momentum*: 0.9
- Taxa de aprendizagem: 0.1
- Decaimento: verdadeiro
- Número de épocas: 50.000
- Normalização dos atributos: verdadeiro
- Normalização numérica da classe: verdadeiro
- Método de execução: *Percentage split* 70% (1.609 para treinamento e 690 para teste)

A Figura 17 mostra a rede gerada pelo simulador Weka. Os neurônios de entrada t1, t2, t3, t4, t5, t6, t7, t8, t9, t10, t11 e t12 representa as 12 temperaturas (Trr), seguida pelos cinco neurônios da camada intermediária e o único neurônio (TempoRestanteParaParto) da camada de saída.

Figura 17. RNA gerada pelo Weka para os dados brutos.



A Tabela 6 mostra o resultado de saída gerada pelo simulador Weka. Pode-se observar que erro absoluto relativo da rede foi de 98.0905%, ou seja, para os 690 exemplos de teste, a rede acertou aproximadamente 1.90%, o que indica um resultado ruim.

Tabela 6. Resultado do teste bruto.

Coeficiente de Correlação	0.1194
Erro médio absoluto	5.8747
Raiz quadrada do erro médio	7.8422
Erro absoluto relativo	98.0905%
Raiz quadrada do erro relativo	99.5837%
Total de exemplos	690

5.2.1 Variando configuração da rede: *momentum*

Uma segunda rodada de teste foi realizada. Os dados utilizados para esse segundo teste foram os mesmos do primeiro teste com valores brutos. Sendo uma única mudança na configuração da rede, onde, se variou o valor de *momentum*, passando de 0.9 para 0.5.

Portanto a configuração da rede foi a seguinte:

- Camada intermediária: 5 neurônios;
- Camada de saída: 1 neurônios (horas restantes para o parto);
- Valor de *momentum*: 0.5
- Taxa de aprendizagem: 0.1
- Decaimento: verdadeiro
- Número de épocas: 50.000
- Normalização dos atributos: verdadeiro
- Normalização numérica da classe: verdadeiro
- Método de execução: *Percentage split* 70% (1.609 para treinamento e 690 para teste)

A Tabela 7 com os valores de resultados da rede mostra que houve mudanças significativas, pois o erro absoluto relativo foi de 98.1177%, ou seja, novamente foram apenas 1,89% de acerto, tornando-se a rede totalmente ineficiente.

Tabela 7.Resultado variando o valor de *Momentum* para 0.5.

Coeficiente de Correlação	0.1182
Erro médio absoluto	5.8763
Raiz quadrada do erro médio	7.8425
Erro absoluto relativo	98.1177%

Raiz quadrada do erro relativo	99.588%
Total de exemplos	690

Logo, um terceiro teste com as mesmas informações de *Trr* do teste anterior, e variando apenas o valor de *momentum* foi realizado. Agora, o valor de *momentum* passa a ser de 0.3, como é mostrada na configuração da rede a seguir:

- Camada intermediária: 5 neurônios;
- Camada de saída: 1 neurônios (horas restantes para o parto);
- Valor de *momentum*: 0.3
- Taxa de aprendizagem: 0.1
- Decaimento: verdadeiro
- Número de épocas: 50.000
- Normalização dos atributos: verdadeiro
- Normalização numérica da classe: verdadeiro
- Método de execução: *Percentage split* 70% (1.609 para treinamento e 690 para teste)

Como se pode observar na Tabela 8, o erro absoluto relativo é de 98.0829%, ou seja, a rede obteve apenas, 1.91% de acerto. Tornando-se, a rede e a modificação do valor de *momentum*, totalmente ineficiente.

Tabela 8. Resultado variando o valor de *momentum* para 0.3.

Coefficiente de Correlação	0.1196
Erro médio absoluto	5.8742
Raiz quadrada do erro médio	7.8405
Erro absoluto relativo	98.0829%
Raiz quadrada do erro relativo	99.5624%
Total de exemplos	690

Portanto, as variações do valor de *momentum* não demonstraram mudanças significativas no aprendizado da rede, sendo assim, o valor de *momentum* seguira nos próximos testes com o padrão de 0.9, conforme declarado na seção de características de implementação da rede MLP.

5.2.2 Variando configuração da rede: Taxa de Aprendizagem

Visto que não houve mudança de comportamento na rede com as alterações do valor de *momentum*, outra alternativa foi a alteração do valor da taxa de aprendizagem. Para o presente teste, a taxa de aprendizagem passa a ser de 0.3. Portanto a configuração da rede passa a ser, de:

- Camada intermediária: 5 neurônios;
- Camada de saída: 1 neurônios (horas restantes para o parto);
- Valor de *momentum*: 0.9
- Taxa de aprendizagem: 0.3
- Decaimento: verdadeiro
- Número de épocas: 50.000
- Normalização dos atributos: verdadeiro
- Normalização numérica da classe: verdadeiro
- Método de execução: *Percentage split* 70% (1.609 para treinamento e 690 para teste)

De acordo com Tabela 9, o erro absoluto relativo é de 96.6698%, ou seja, 3.33% de acerto, o que demonstra uma pequena melhora em relação aos testes anteriores (variando o valor de *momentum*), porém uma melhora não significativa, o que torna a rede ineficiente.

Tabela 9. Resultado variando o valor da taxa de aprendizagem para 0.3.

Coeficiente de Correlação	0.2137
Erro médio absoluto	5.7896
Raiz quadrada do erro médio	7.6922
Erro absoluto relativo	96.6698%
Raiz quadrada do erro relativo	97.679%
Total de exemplos	690

Em seguida, outro teste, modificando a taxa de aprendizagem para 0.6, foi realizado. Os dados da Trr foram os mesmos utilizados nos testes anteriores, ou seja, 2.299 exemplos

divididos em dois grupos, sendo, 1.609 exemplos para o grupo de treinamento e 690 para o grupo de teste e validação da rede.

A rede seguiu com a seguinte configuração:

- Camada intermediária: 5 neurônios;
- Camada de saída: 1 neurônios (horas restantes para o parto);
- Valor de *momentum*: 0.9
- Taxa de aprendizagem: 0.6
- Decaimento: verdadeiro
- Número de épocas: 50.000
- Normalização dos atributos: verdadeiro
- Normalização numérica da classe: verdadeiro
- Método de execução: *Percentage split* 70% (1.609 para treinamento e 690 para teste)

A tabela mostra os resultados da rede. Pode-se observar que não há mudança nos resultados da rede, pois o erro absoluto relativo é de 98.0553%, fazendo com que a rede tenha uma taxa de acerto de 1,94%, o que torna a rede totalmente ineficaz.

A Tabela 10 mostra a comparação dos resultados dos testes de variação dos valores de *momentum* e taxa de aprendizagem.

Tabela 10. Tabela Comparativa dos Resultados dos Teste com Valores Brutos.

Testes Resultados	Com valor Bruto	<i>Momentum</i> em 0.5	<i>Momentum</i> em 0.3	Taxa de Aprendizagem em 0.3	Taxa de Aprendizagem em 0.6
Coefficiente de Correlação	0.1194	0.1182	0.1196	0.2137	0.121
Erro médio absoluto	5.8747	5.8763	5.8742	5.7896	5.8726
Raiz quadrada do erro médio	7.8422	7.8425	7.8405	7.6922	7.8409
Erro absoluto relativo	98.0905%	98.1177%	98.0829%	96.6698%	98.0553%

Raiz quadrada do erro relativo	99.5837%	99.588%	99.5624%	97.679%	99.568%
Total de exemplos	690	690	690	690	690

Portanto, pode-se definir que a variação dos valores de *momentum* e taxa de aprendizagem não produz diferença significativa no comportamento da rede.

5.3 Testes com ajustes nas Trr

Como foi dito anteriormente, temperatura menores do que 37,7 °C pode atrapalhar o aprendizado da rede MLP, ou seja, podendo gerar equívocos no momento de treinamento da rede. Assim, para o presente teste, as Trr menores do que 37,7 °C foram substituídas pela média calculada entre a Trr do instante de tempo anterior e da Trr do instante de tempo posterior. Por isso, os testes foram repetidos com as novas Trr.

Foram utilizadas para o conjunto de exemplos as Trr de 120 vacas, totalizando 2.299 exemplos divididos em dois grupos, sendo, 1.609 para o conjunto de treinamento e 690 para o conjunto de teste e validação da rede.

Logo, a rede seguiu com a seguinte configuração:

- Camada intermediária: 5 neurônios;
- Camada de saída: 1 neurônios (horas restantes para o parto);
- Valor de *momentum*: 0.9
- Taxa de aprendizagem: 0.1
- Decaimento: verdadeiro
- Número de épocas: 50.000
- Normalização dos atributos: verdadeiro
- Normalização numérica da classe: verdadeiro

- Método de execução: *Percentage split* 70% (1.609 para treinamento e 690 para teste)

A Tabela 11 mostra os resultados obtidos pelo simulador Weka. Percebem-se uma pequena melhora em relação aos testes com valores brutos anteriores. O erro absoluto relativo é 96.2857%, porém ainda não se pode definir a arquitetura da rede como eficiente, pois, a rede, obteve 3,71% de acerto, mostrando que a rede é inapropriada para a problemática em questão.

Tabela 11. Resultado da alteração das Trr menores do que 37,7 °C .

Coefficiente de Correlação	0.1728
Erro médio absoluto	5.7666
Raiz quadrada do erro médio	7.7666
Erro absoluto relativo	96.2857%
Raiz quadrada do erro relativo	98.6238%
Total de exemplos	690

5.3.1 Ajuste da Trr e variando o valor de *momentum*

O próximo teste foi realizado com a alteração do valor de *momentum* passando de 0.9 para 0.5.

As Trr foram as mesmas utilizados no teste anterior com a substituição das Trr menores do que 37,7 °C.

Assim, a rede seguiu com a seguinte configuração:

- Camada intermediária: 5 neurônios;
- Camada de saída: 1 neurônios (horas restantes para o parto);
- Valor de *momentum*: 0.5
- Taxa de aprendizagem: 0.1
- Decaimento: verdadeiro
- Número de épocas: 50.000

- Normalização dos atributos: verdadeiro
- Normalização numérica da classe: verdadeiro
- Método de execução: *Percentage split* 70% (1.609 para treinamento e 690 para teste)

Logo, a Tabela 12 mostra o resultado gerado pela rede. Agora, o erro absoluto relativo se encontra com 95.9272%, ou seja, a rede obteve uma taxa de acerto em 4,07%.

Tabela 12. Resultado da alteração das Trr menores do que 37,7 °C com valor de *momentum* em 0.5.

Coeficiente de Correlação	0.1947
Erro médio absoluto	5.7451
Raiz quadrada do erro médio	7.7243
Erro absoluto relativo	95.9272%
Raiz quadrada do erro relativo	98.0874%
Total de exemplos	690

No segundo teste, o valor *momentum* passa a ser de 0.3. Assim a configuração é:

- Camada intermediária: 5 neurônios;
- Camada de saída: 1 neurônios (horas restantes para o parto);
- Valor de *momentum*: 0.3
- Taxa de aprendizagem: 0.1
- Decaimento: verdadeiro
- Número de épocas: 50.000
- Normalização dos atributos: verdadeiro
- Normalização numérica da classe: verdadeiro
- Método de execução: *Percentage split* 70% (1.609 para treinamento e 690 para teste)

A Tabela 13 mostra o resultado da rede, indicando, pelo erro absoluto relativo de 95.8517%, que rede se torna ineficiente, com apenas 4.14% de probabilidade de acerto.

Tabela 13. Resultado da alteração das Trr menores do que 37,7 °C com valor de *momentum* em 0.3.

Coeficiente de Correlação	0.1974
Erro médio absoluto	5.7406
Raiz quadrada do erro médio	7.7191
Erro absoluto relativo	95.8517%
Raiz quadrada do erro relativo	98.0215%
Total de exemplos	690

5.3.2 Ajuste da Trr e variando a taxa de aprendizagem

Novos testes foram feitos, mas agora variando o valor da taxa de aprendizagem. Para esse teste a taxa de aprendizagem passa a ser de 0.3, tornando-se a rede com a seguinte configuração:

- Camada intermediária: 5 neurônios;
- Camada de saída: 1 neurônios (horas restantes para o parto);
- Valor de *momentum*: 0.9
- Taxa de aprendizagem: 0.3
- Decaimento: verdadeiro
- Número de épocas: 50.000
- Normalização dos atributos: verdadeiro
- Normalização numérica da classe: verdadeiro
- Método de execução: *Percentage split* 70% (1.609 para treinamento e 690 para teste)

Logo, a Tabela 14 mostra o resultado da rede. Observa-se que o erro absoluto relativo foi de 95.5399%, tornando-se a rede com 4,46% de probabilidade de acerto, acarretando em uma arquitetura de rede ineficiente.

Tabela 14. Resultado da alteração das Trr menores do que 37,7 °C com a taxa de aprendizagem em 0.3.

Coeficiente de Correlação	0.2268
Erro médio absoluto	5.7219

Raiz quadrada do erro médio	7.6699
Erro absoluto relativo	95.5399%
Raiz quadrada do erro relativo	97.3961%
Total de exemplos	690

Conseqüentemente, outro teste variando a taxa de aprendizagem para 0.6 foi realizado.

A rede obteve a seguinte configuração:

- Camada intermediária: 5 neurônios;
- Camada de saída: 1 neurônios (horas restantes para o parto);
- Valor de *momentum*: 0.9
- Taxa de aprendizagem: 0.6
- Decaimento: verdadeiro
- Número de épocas: 50.000
- Normalização dos atributos: verdadeiro
- Normalização numérica da classe: verdadeiro
- Método de execução: *Percentage split* 70% (1.609 para treinamento e 690 para teste)

Logo, pela Tabela 15 observa-se que a arquitetura da rede não obteve bons resultados, pois o erro absoluto relativo foi de 99.2162%.

Tabela 15. Resultado da alteração das Trr menores do que 37,7 °C com a taxa de aprendizagem em 0.6.

Coefficiente de Correlação	0.0625
Erro médio absoluto	7.4003
Raiz quadrada do erro médio	13.2403
Erro absoluto relativo	99.2162%
Raiz quadrada do erro relativo	99.9981%
Total de exemplos	690

Portanto, para motivos de comparação a Tabela 16 apresenta os resultados de todos os testes com os ajustes na Trr.

Tabela 16. Tabela Comparativa dos Resultados dos Teste com ajustes na Trr.

Testes Resultados	Com Ajuste na Trr	<i>Momentum</i> em 0.5	<i>Momentum</i> em 0.3	Taxa de Aprendizagem em 0.3	Taxa de Aprendizagem em 0.6
Coefficiente de Correlação	0.1728	0.1947	0.1974	0.2268	0.0625
Erro médio absoluto	5.7666	5.7451	5.7406	5.7219	7.4003
Raiz quadrada do erro médio	7.7666	7.7243	7.7191	7.6699	13.2403
Erro absoluto relativo	96.2857%	95.9272%	95.8517%	95.5399%	99.2162%
Raiz quadrada do erro relativo	98.6238%	98.0874%	98.0215%	97.3961%	99.9981%
Total de exemplos	690	690	690	690	690

5.4 Teste 1 com saída parto e não-parto

Com a experiência adquirida do teste inicial, com valores fictícios, e dos testes com dados brutos e ajuste de Trr, uma nova sequência de testes foi inicializada, porém modificando a saída da rede. As tabelas completas, contendo a saída desejada e a predição da rede, se encontram na seção Anexo desse trabalho.

5.4.1 Teste com Um Animal

Para este primeiro teste foram utilizados os dados da temperatura de apenas um animal. A Figura 18 mostra uma pequena parte do arquivo, com as informações para treinamento e validação da rede. O arquivo de dados segue o mesmo padrão dos testes iniciais, ou seja, os 12 primeiros valores separados por “virgula” representam as Trr do animal. O último valor é representado por 0 (zero) indicando que é momento parto, período este referente a 12 horas do parto e o valor 1 representa que está fora do período do parto, ou seja, o período fora de 12 horas do parto (13 a 80 horas, antes do parto).

Nesse teste foi usado um conjunto com 120 exemplos, sendo 60 exemplos para não parto (saída 1) e 60 exemplos para parto (saída 0). Seu conjunto de treinamento contou com 84 exemplos e o conjunto de testes com 36 exemplos.

Figura 18. Arquivo de Dados do Segundo Teste com Um Animal.

69	39.5, 39.5, 37.7, 38.7, 39, 39, 39.2, 39.5, 39.7, 38.9, 38.2, 39, 1
70	39.5, 39.5, 37.7, 38.7, 39, 39, 39.2, 39.5, 39.7, 38.9, 38.2, 39, 1
71	39.5, 39.5, 37.7, 38.7, 39, 39, 39.2, 39.5, 39.7, 38.9, 38.2, 39, 1
72	39.5, 39.5, 37.7, 38.7, 39, 39, 39.2, 39.5, 39.7, 38.9, 38.2, 39, 1
73	39.5, 39.5, 37.7, 38.7, 39, 39, 39.2, 39.5, 39.7, 38.9, 38.2, 39, 1
74	39.5, 39.5, 37.7, 38.7, 39, 39, 39.2, 39.5, 39.7, 38.9, 38.2, 39, 1
75	39.5, 39.5, 37.7, 38.7, 39, 39, 39.2, 39.5, 39.7, 38.9, 38.2, 39, 1
76	39.5, 39.5, 37.7, 38.7, 39, 39, 39.2, 39.5, 39.7, 38.9, 38.2, 39, 1
77	39.5, 39.5, 37.7, 38.7, 39, 39, 39.2, 39.5, 39.7, 38.9, 38.2, 39, 1
78	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
79	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
80	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
81	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
82	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
83	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
84	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
85	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0

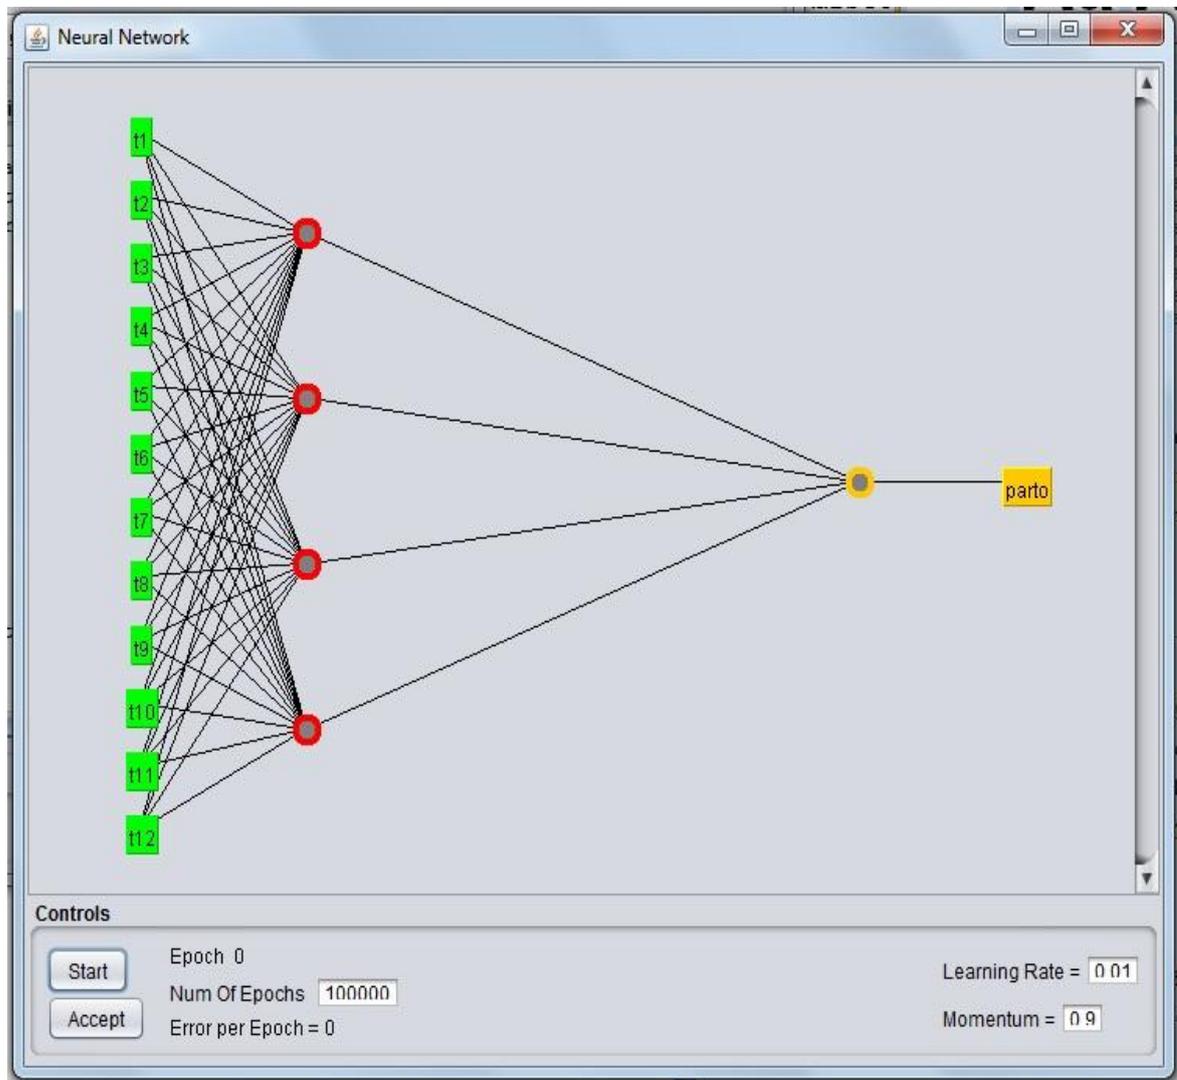
A rede seguiu com a seguinte configuração:

- Camada intermediária: 4 neurônios;
- Camada de saída: 1 neurônios (valor 0 indicando parto e valor 1 indicando não parto);
- Valor de *Momentum*: 0.9;
- Taxa de aprendizagem: 0.01;

- Decaimento: verdadeiro;
- Número de épocas: 100.000;
- Normalização dos atributos: verdadeiro;
- Normalização numérica da classe: verdadeiro;
- Método de execução: *Percentage split 70%* (84 para treinamento e 36 para teste).

A Figura 19 mostra a rede gerada pelo simulador de acordo com a configuração informada, sendo, a primeira camada de 12 neurônios de entrada representada por t1, t2, t3, t4, t5, t6, t7, t8, t9, t10, t11 e t12, seguida pelos 4 neurônios da camada intermediária e por último a camada de saída composta por um único neurônio.

Figura 19. Rede gerada pelo Simulador para testes com temperaturas reais.



A Tabela 17 mostra os resultados de 15 dos 36 exemplos de teste da rede, junto com a saída desejada, a predição da rede, o erro calculado, entre a diferença da saída desejada e

predição da rede e o valor de saída normalizado. A tabela completa, com os 36 exemplos, está representada no Anexo, no item A.2 Teste com Um Animal.

Tabela 17. Saída do Primeiro Teste com Temperaturas Reais.

Instância	Saída desejada	Predição da rede	Erro	Valores de saída normalizados
1	1	0.999	-0.001	1
2	1	0.999	-0.001	1
3	1	1	0	1
4	1	1	-0	1
5	1	0.999	-0.001	1
6	1	1	0	1
7	1	1	0	1
8	0	0	0	0
9	1	1	-0	1
10	1	1	0	1
11	0	0	0	0
12	1	0.999	-0.001	0
13	1	0.999	-0.001	0
14	1	1	-0	1
15	0	0	0	0

Logo se observa pela Tabela 18, com as informações estatísticas da rede, que a taxa de acerto (TA) foi de 100%. Sendo assim, conclui-se que a configuração da rede utilizada foi totalmente eficiente.

Tabela 18. Dados estatísticos do Teste 1 com uma vaca.

	Quant. de Elem. Relevante	Quant. de Elem. Irrelevante	VP	FP	FN	VN	S	E	VPP	VPN	TA	TE
Teste Inicial	14	22	14	0	0	22	100	100	100%	100%	100%	0%

5.4.2 Teste com Dois Animais

O próximo teste, também com temperaturas reais, agora utilizando informações de duas vacas.

O teste foi realizado com 120 exemplos divididos em 60 exemplos para parto e 60 exemplos para não parto. A Figura 20 mostra uma parte da configuração do arquivo, com as temperaturas e saída desejada para teste e validação da rede.

A rede seguiu com a seguinte configuração:

- Camada intermediária: 4 neurônios;
- Camada de saída: 1 neurônios (valor 0 indicando parto e valor 1 indicando não parto);
- Valor de *Momentum*: 0.9;
- Taxa de aprendizagem: 0.01;
- Decaimento: verdadeiro;
- Número de épocas: 100.000;
- Normalização dos atributos: verdadeiro;
- Normalização numérica da classe: verdadeiro;
- Método de execução: *Percentage split* 70% (84 para treinamento e 36 para teste).

Figura 20. Arquivo de Dados do teste com dois Animais.

72	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
73	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
74	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
75	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
76	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
77	39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
78	38.5, 39.2, 40, 39, 39.5, 40, 40, 40.2, 40.2, 40.2, 40.2, 40.5, 1
79	38.5, 39.2, 40, 39, 39.5, 40, 40, 40.2, 40.2, 40.2, 40.2, 40.5, 1
80	38.5, 39.2, 40, 39, 39.5, 40, 40, 40.2, 40.2, 40.2, 40.2, 40.5, 1
81	38.5, 39.2, 40, 39, 39.5, 40, 40, 40.2, 40.2, 40.2, 40.2, 40.5, 1
82	38.5, 39.2, 40, 39, 39.5, 40, 40, 40.2, 40.2, 40.2, 40.2, 40.5, 1
83	40.2, 40.2, 40.2, 40.2, 40, 40, 40, 39.7, 39.7, 39.7, 39.5, 39.1, 1
84	40.2, 40.2, 40.2, 40.2, 40, 40, 40, 39.7, 39.7, 39.7, 39.5, 39.1, 1
85	40.2, 40.2, 40.2, 40.2, 40, 40, 40, 39.7, 39.7, 39.7, 39.5, 39.1, 1
86	40.2, 40.2, 40.2, 40.2, 40, 40, 40, 39.7, 39.7, 39.7, 39.5, 39.1, 1
87	40.2, 40.2, 40.2, 40.2, 40, 40, 40, 39.7, 39.7, 39.7, 39.5, 39.1, 1

A Tabela 19 mostra a resultado obtido. De acordo com a classificação a rede também obteve 100% de acerto com os 36 exemplos para teste da rede. A Tabela 19 mostra o resultado de 15 exemplos e a tabela completa, com os 36 exemplos, está representada no Anexo, no item A.2 Teste com Dois Animais.

Tabela 19. Resultado do teste com dois animais.

Instância	Saída desejada	Predição da rede	Erro	Valores de saída normalizados
1	0	0.28	0.28	0
2	0	0.28	0.28	0
3	0	0.28	0.28	0
4	1	1.034	0.034	1
5	0	0.28	0.28	0
6	1	0.591	-0.409	1
7	0	0.28	0.28	0
8	1	0.735	-0.265	1
9	1	0.528	-0.472	1
10	0	0.28	0.28	0
11	0	-0.011	-0.011	0
12	0	0.28	0.28	0
13	0	0.28	0.28	0
14	1	0.528	-0.472	1
15	1	1.049	0.049	1

A Tabela 20 mostra os valores estatísticos do teste com duas vacas. Observa-se, na tabela, que as probabilidades de classificação da classe relevante (VPP) e a classe irrelevante (VPN) foram classificadas com 100% de acerto o que podemos definir a configuração da rede como totalmente eficiente.

Tabela 20. Dados estatísticos do Teste 1 com duas vacas.

	Quant. de Elem. Relevante	Quant. de Elem. Irrelevante	VP	FP	FN	VN	S	E	VPP	VPN	TA	TE
Teste Inicial	14	22	14	0	0	22	100	100	100%	100%	100%	0%

5.4.3 Teste com Cinco Animais

Similarmente, uma rodada de teste contendo temperaturas reais, foi realizada utilizando a temperatura de cinco animais. Para a configuração da rede segue o mesmo padrão dos testes anteriores, sendo:

- Camada intermediária: 4 neurônios;
- Camada de saída: 1 neurônios (valor 0 indicando parto e valor 1 indicando não parto);
- Valor de *Momentum*: 0.9;
- Taxa de aprendizagem: 0.01;
- Decaimento: verdadeiro;
- Número de épocas: 100.000;
- Normalização dos atributos: verdadeiro;
- Normalização numérica da classe: verdadeiro;
- Método de execução: *Percentage split* 70% (84 para treinamento e 36 para teste).

O conjunto foi de 120 exemplos sendo 60 exemplos para parto e 60 exemplos para não parto, divididos em 84 exemplos para treinamento e 36 para o conjunto de teste da rede. A Tabela 21 mostra os valores de saída da rede para os 15 exemplos utilizados no teste. A tabela completa, com todos os 36 resultados do conjunto de teste estão no Anexo, item A.4 Teste com Cinco Animais.

Tabela 21. Resultados do Teste com Cinco Animais. Os valores destacados referem-se aos valores cuja a predição da rede não condiz com a saída desejada.

Instância	Saída desejada	Predição da rede	Erro	Valores de saída normalizados
1	1	0.614	-0.386	1
2	1	0.84	-0.16	1
3	0	0.293	0.293	0
4	1	-0.12	-1.12	0
5	0	0.293	0.293	0
6	1	1.006	0.006	1
7	0	0.293	0.293	0
8	0	0.256	0.256	0
9	1	-0.12	-1.12	0
10	0	0.293	0.293	0
11	0	0.543	0.543	1
12	1	1.188	0.188	1
13	1	1.188	0.188	1
14	1	-0.073	-1.073	0
15	0	0.124	0.124	0

A Tabela 22 mostra que a TA foi de 77,8%, sendo assim, podemos continuar concluindo que a configuração da rede se mostrou eficiente.

Tabela 22. Dados estatísticos do Teste 1 com cinco vaca.

	Quant. de Elem. Relevante	Quant. de Elem. Irrelevante	VP	FP	FN	VN	S	E	VPP	VPN	TA	TE
Teste Inicial	18	18	15	5	3	13	83,3	72,2	75%	81,2%	77,8%	22,2%

Salienta-se ainda que nesse problema em particular, a pior situação de erro é o FN. Isso porque a rede diz que para aquela vaca não é momento de parto, sendo que o correto seria momento de parto. Dessa forma, a vaca poderia não ser separada para receber

acompanhamento e poderia ter o bezerro sem assistência necessária. Nesse teste houve 3 casos FN, dentre 18, taxa de 81,2%.

5.4.4 Teste com Dez animais

Para este teste foram utilizados os dados de Trr de dez vacas totalizando 240 exemplos, sendo 120 exemplos para parto e 120 exemplos para não parto. Portanto, para o conjunto de treinamento foi separado 168 exemplos e para o conjunto de teste tem-se 72 exemplos.

Diferentemente dos testes anteriores, no presente teste, a quantidade de exemplos para treinamento obteve um aumento, o que acarreta uma mudança na quantidade de neurônios na camada escondida. Testes com 4, 5 e 6 neurônios na camada escondida foi realizado, porém os três testes tiveram os mesmos valores estatísticos. Logo, a rede obteve a seguinte configuração:

- Camada intermediária: 4 neurônios;
- Camada de saída: 1 neurônios (valor 0 indicando parto e valor 1 indicando não parto);
- Valor de *Momentum*: 0.9;
- Taxa de aprendizagem: 0.01;
- Decaimento: verdadeiro;
- Número de épocas: 100.000;
- Normalização dos atributos: verdadeiro;
- Normalização numérica da classe: verdadeiro;
- Método de execução: *Percentage split* 70% (168 para treinamento e 72 para teste).

A Tabela 23 mostra os resultados de 15 exemplos dos 72 utilizados para o teste da rede com dez vacas. A tabela completa, com os 72 exemplos. Está representada no Anexo, no item A.5 Teste com dez animais.

Tabela 23. Resultados do Teste com Dez Animais. Os valores destacados referem-se aos valores cuja a predição da rede não condiz com a saída desejada.

Instância	Saída desejada	Predição da rede	Erro	Valores de saída normalizados
1	1	0.666	-0.334	1
2	0	0.269	0.269	0
3	0	0.264	0.264	0
4	0	0.269	0.269	0
5	1	0.374	-0.626	0
6	0	0.182	0.182	0
7	1	0.841	-0.159	1
8	0	0.264	0.264	0
9	1	1.036	0.036	1
10	1	0.37	-0.63	0
11	1	0.319	-0.681	0
12	1	0.45	-0.55	0
13	1	1.266	0.266	1
14	0	0.188	0.188	0
15	0	0.281	0.281	0

Logo, pela Tabela 24, temos uma TA de 86,1%. Portanto, a configuração da rede se mostrou mais uma vez eficiente.

Tabela 24. Dados estatísticos do Teste 1 com dez vacas.

	Quant. de Elem. Relevante	Quant. de Elem. Irrelevante	VP	FP	FN	VN	S	E	VPP	VPN	TA	TE
Teste Inicial	36	36	36	10	0	26	100	72,2	78,2%	100%	86,1%	13,9%

Neste caso, o FN foi 0, uma situação bastante importante no problema em questão. A VPN com 100%. Dessa forma, nenhuma vaca vai parir sem estar separada e recebendo

assistência adequada. A rede errou na afirmação de que a vaca iria parir, mas não aconteceu, havendo, nesse caso, apenas um “excesso” de cuidado.

5.4.5 Teste com 51 animais

Por fim, um último teste utilizando o mesmo padrão de configurações dos testes anteriores. O teste corrente foi realizado com as Trr de 51 vacas. Os dados obtidos do banco de dados eram de 120 vacas, entretanto, somente 51 tinham os dados completos, sem perda de nenhuma temperatura.

Dessas 51 vacas, totalizou-se 612 exemplos, sendo divididos em 306 exemplos de parto e 306 exemplos de não parto. O teste contou com um conjunto de treinamento com 428 exemplos e um conjunto de teste com 184 exemplos. A configuração da rede no *software* Weka seguiu com os seguintes parâmetros:

- Camada intermediária: 5 neurônios;
- Camada de saída: 1 neurônios (valor 0 indicando parto e valor 1 indicando não parto);
- Valor de *Momentum*: 0.9;
- Taxa de aprendizagem: 0.01;
- Decaimento: verdadeiro;
- Número de épocas: 100.000;
- Normalização dos atributos: verdadeiro;
- Normalização numérica da classe: verdadeiro;
- Método de execução: *Percentage split* 70% (428 para treinamento e 184 para teste).

A Tabela 25 mostra 15 dos 184 exemplos utilizados para o teste, junto com os valores de saída desejada, predição da rede, erro e valor de saída normalizado. A tabela completa, com os 184 exemplos, está representada no Anexo, no item A.6 Teste com 51 animais.

Tabela 25. Resultados do Teste com 51 Animais. Os valores destacados referem-se aos valores cuja a predição da rede não condiz com a saída desejada.

Instância	Saída desejada	Predição da rede	Erro	Valores de saída normalizados
1	1	0.366	-0.634	0
2	1	0.758	-0.242	1
3	0	0.268	0.268	0
4	1	0.67	-0.33	1
5	1	0.445	-0.555	0
6	0	0.321	0.321	0
7	0	0.443	0.443	0
8	1	1.11	0.11	1
9	0	0.443	0.443	0
10	0	0.302	0.302	0
11	1	0.626	-0.374	1
12	1	0.35	-0.65	0
13	0	0.564	0.564	1
14	1	0.875	-0.125	1
15	1	0.278	-0.722	0

A Tabela 26 mostra os valores estatísticos com os resultados dos 184 exemplos utilizados para o teste. Pode-se observar que a TA da rede foi de 72,8%, considerando assim, a configuração da rede eficiente. Nota-se ainda que foram 13 FN, dentre 83 e o VPN 83,1 %, uma situação que se pode dizer adequada.

Tabela 26. Dados estatísticos do Teste 1 com 51 vaca.

	Quant. de Elem. Relevante	Quant. de Elem. Irrelevante	VP	FP	FN	VN	S	E	VPP	VPN	TA	TE
Teste Inicial	83	101	70	37	13	64	84,3	63,3	65,4%	83,1%	72,8%	27,2%

5.5 Teste com 51 animais com a saída em horas

Os testes com valores de Trr brutos e com ajuste de Trr mostraram que não foram eficientes. Já os testes com a saída indicando parto (valor 0) ou não-parto (valor 1) revelaram-se muito mais eficiente.

Por consequência, uma nova tentativa foi testada para que a rede tenha como saída a hora antes do parto.

Nesse teste foram utilizadas as Trr de 51 vacas e com a substituição da temperatura menor e igual a 37,7 °C. Seu conjunto de exemplos contou com 357 exemplos, sendo 250 exemplos para o conjunto de treinamento e 107 exemplos para o conjunto de teste e validação da rede. O conjunto de exemplos foi formado com as seguintes características:

- 51 exemplos para a 0 horas antes (parto);
- 51 exemplos para a 12 horas antes do parto;
- 51 exemplos para a 24 horas antes do parto;
- 51 exemplos para a 36 horas antes do parto;
- 51 exemplos para a 48 horas antes do parto;
- 51 exemplos para a 60 horas antes do parto;
- 51 exemplos para a 72 horas antes do parto;

A Figura 21 mostra um trecho do arquivo com os dados de Trr para treinamento e teste da rede.

Figura 21. Trecho do arquivo com as Trr e saída horas antes do parto.

```

18 39.5, 39.2, 39.5, 39.1, 38.7, 39.5, 39.2, 39.7, 39.4, 39.2, 39.2, 38.7, 72
19 39.2, 39.7, 39.7, 39.5, 38.2, 39, 38.6, 38.2, 38.7, 39, 39, 39, 60
20 39.2, 39.5, 39.1, 38.7, 39.2, 39, 39.5, 39.2, 39.5, 39.7, 38, 39, 48
21 39.2, 38.2, 39.2, 39.5, 38.5, 39.2, 39.2, 39, 39.2, 39.5, 38.7, 39.2, 36
22 39.5, 39.5, 39.2, 39.2, 38.6, 38, 39, 39.2, 39.7, 39.7, 39.2, 39.2, 24
23 39.5, 39.5, 39.1, 38.7, 39, 39, 39.2, 39.5, 39.7, 38.9, 38.2, 39, 12
24 39.2, 39.5, 38.8, 38.2, 38.7, 39.2, 39.5, 39.5, 39.7, 39.2, 38.7, 39, 0
25 40, 40, 40, 39.7, 39.7, 39.7, 40, 40, 40, 39.5, 39, 38.5, 72
26 39.2, 40, 39, 39.5, 40, 40, 40.2, 40.2, 40.2, 40.2, 40.5, 40.2, 60
27 40.2, 40.2, 40.2, 40, 40, 40, 39.7, 39.7, 39.7, 39.5, 39.1, 38.9, 48
28 38.8, 38.7, 39.7, 40.5, 38.5, 39.2, 39.7, 40, 40, 40, 39.7, 39.7, 36
29 39.7, 40, 40, 40, 40, 40, 40, 40, 40, 40, 39.7, 39.5, 24
30 38.7, 38.3, 38, 39, 39.5, 39, 38.7, 39.5, 39.7, 39.7, 39.7, 39, 12
31 39.7, 39.7, 39.7, 39.5, 39.7, 39.7, 39.7, 39.5, 39.5, 38.7, 38, 38, 0

```

Assim, a rede seguiu com a seguinte configuração:

- Camada intermediária: 6 neurônios;
- Camada de saída: 1 neurônios (indicando horas, sendo 0, 12, 24, 36, 48, 60 e 72 horas antes do parto);
- Valor de *Momentum*: 0.9;
- Taxa de aprendizagem: 0.01;
- Decaimento: verdadeiro;
- Número de épocas: 100.000;
- Normalização dos atributos: verdadeiro;
- Normalização numérica da classe: verdadeiro;
- Método de execução: *Percentage split 70%* (250 para treinamento e 107 para teste).

A Tabela 27 mostra o resultado do conjunto de teste da rede, de 15 instâncias, sendo que a tabela completa está no Anexo, item A.7 Teste com 51 animais com a saída em horas.

Tabela 27. Resultado do teste com 51 vacas e saída com horas antes do parto.

Instância	Saída desejada	Predição da rede	Erro
1	24	34.051	10.051
2	60	32.195	-27.805
3	12	33.564	21.564
4	36	43.158	7.158
5	72	44.134	-27.866
6	24	29.938	5.938
7	24	42.253	18.253
8	48	37.282	-10.718
9	12	38.9	26.9
10	24	17.808	-6.192
11	24	30.46	6.46
12	0	19.006	19.006
13	0	33.336	33.336
14	60	38.994	-21.006
15	48	36.912	-11.088

Como, se pode observar na Tabela 27, a rede não obteve bons resultados, pois não houve acertos precisos em nenhum dos 107 exemplos de teste. Indicando mais uma vez que a rede MLP torna-se ineficiente para essa problemática.

5.6 Teste com saídas de parto, pré-parto e não-parto

Uma última rodada de testes foi realizada. Nesse teste, o conjunto de exemplos foi manipulado da seguinte forma: temperaturas entre 0 e 11 horas antes do parto tinham como saída o valor 0, representando o momento do parto; temperaturas entre 12 a 23 horas antes do parto tinham como saída o valor 1, indicando o momento de pré-parto; e as temperaturas entre 24 a 35 horas antes do parto tinham como saída o valor 2, representando o momento de não ocorrência de parto.

A Figura 22 apresenta um trecho do arquivo com o conjunto de exemplos. O conjunto de exemplos foram formados por 102 exemplos com saída 0 (momento de parto), 102 exemplos com saída 1 (pré-parto) e 102 exemplos com saída 2 (não ocorrência de parto), totalizando 306 exemplos divididos em 214 exemplos para treinamento e 92 exemplos para teste e validação.

Figura 22. Trecho do arquivo com o conjunto de exemplos.

17	40.5, 39.5, 39.0, 39.8, 39.5, 39.3, 39.6, 39.7, 39.9, 40.0, 39.9, 39.7, 2
18	39.7, 39.4, 38.8, 39.0, 39.6, 39.7, 39.6, 39.5, 39.6, 39.6, 39.5, 39.1, 1
19	38.4, 38.4, 39.0, 39.1, 39.0, 39.0, 39.1, 39.1, 38.9, 38.9, 38.9, 38.7, 0
20	39.1, 40.3, 40.6, 39.4, 38.3, 39.1, 40.0, 40.6, 40.9, 40.9, 40.8, 40.5, 2
21	40.2, 39.7, 39.4, 39.6, 40.4, 40.7, 40.2, 39.1, 39.1, 39.7, 39.9, 40.3, 1
22	40.1, 39.9, 40.1, 40.0, 39.7, 39.6, 40.1, 40.5, 40.4, 40.4, 39.8, 39.0, 0
23	39.9, 39.6, 39.9, 40.4, 39.3, 38.9, 39.5, 39.5, 39.5, 39.0, 39.2, 40.0, 2
24	40.1, 40.0, 39.9, 39.7, 39.3, 38.4, 38.5, 39.1, 39.2, 39.4, 39.5, 39.3, 1
25	38.8, 39.0, 39.6, 39.7, 39.7, 39.4, 38.8, 38.6, 39.1, 39.5, 39.5, 39.5, 0
26	39.8, 39.3, 39.4, 39.5, 39.2, 39.5, 40.1, 40.2, 40.2, 39.8, 39.1, 39.1, 2
27	39.6, 39.5, 39.4, 39.6, 39.7, 39.7, 39.6, 39.5, 39.5, 39.2, 38.5, 38.6, 1
28	39.3, 39.3, 38.8, 38.9, 39.4, 39.5, 39.5, 39.6, 39.6, 39.5, 39.6, 39.7, 0

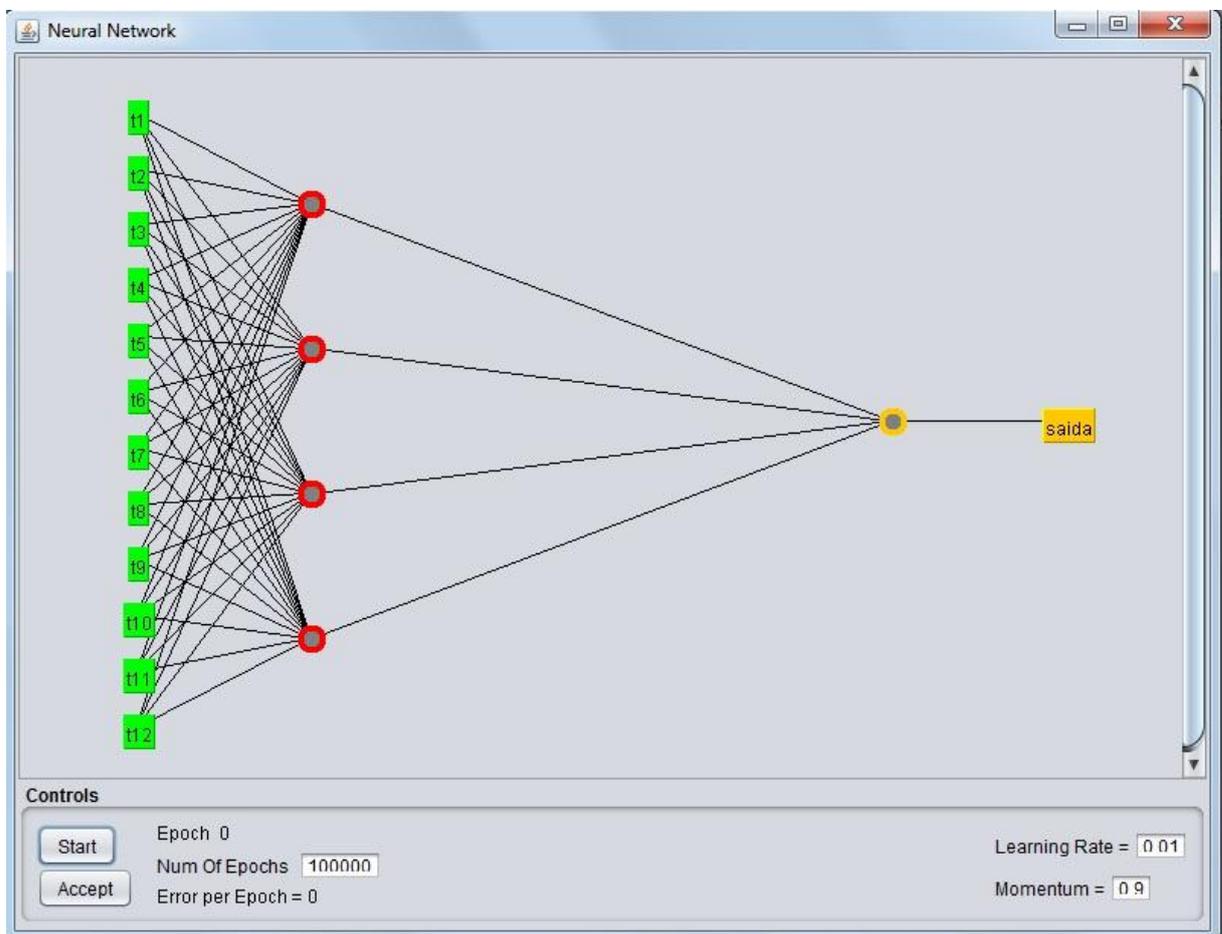
A configuração da rede foi:

- Camada intermediária: 4 neurônios;
- Camada de saída: 1 neurônios (0-momento de parto; 1-pré-parto; 2-não parto)
- Valor de *Momentum*: 0.9;

- Taxa de aprendizagem: 0.01;
- Decaimento: verdadeiro;
- Número de épocas: 100.000;
- Normalização dos atributos: verdadeiro;
- Normalização numérica da classe: verdadeiro;
- Método de execução: *Percentage split 70%* (214 para treinamento e 92 para teste).

A Figura 23 mostra a rede gerada pelo simulador Weka.

Figura 23. Rede gerada pelo simulador Weka para saída com parto, pré-parto e não-parto.



O resultado de 15 dos 92 exemplos de teste é mostrado pela Tabela 28. A tabela completa, com os 92 exemplos, está representada no Anexo, no item A.8 Teste com saídas de parto, pré-parto e não-parto.

Tabela 28. Resultado do teste de parto, pré-parto e não-parto.

Instância	Saída desejada	Predição da rede	Erro
1	1	0.582	-0.418
2	2	1.681	-0.319
3	2	0.801	-1.199
4	1	0.922	-0.078
5	0	0.693	0.693
6	1	1.45	0.45
7	2	0.897	-1.103
8	2	1.557	-0.443
9	2	1.315	-0.685
10	1	0.843	-0.157
11	2	1.257	-0.743
12	2	1.528	-0.472
13	1	0.799	-0.201
14	2	0.725	-1.275
15	1	1.103	0.103

Para critério de avaliação do teste foi adotado o seguinte método:

- Saída desejada 0: é considerado acerto os valores de predição da rede entre 0 a 0.49;
- Saída desejada 1: é considerado acerto os valores de predição da rede entre 0.5 a 1.49;
- Saída desejada 2: é considerado acerto os valores de predição da rede entre 1.5 a 2.

A Tabela 29 mostra a contagem de acerto e erros seguindo o critério de avaliação da rede.

Tabela 29. Tabela de contagem de acerto e erros.

	Quantidade de acerto	Quantidade de erros	Total de exemplos	Taxa de acerto	Taxa de erro
0 (momento de parto)	1	24	25	4%	96%
1 (pré-parto)	27	7	34	79.41%	20.59%
2 (não-parto)	6	27	33	18.19%	81.81%

Costa Junior [2014] cita em seu trabalho a ocorrência de um padrão de temperatura, na raça Holandesa, indicando uma quantidade de horas restante para o parto. Ou seja, quando ocorre esse padrão na temperatura é um sinal de que faltam algumas horas antes do parto.

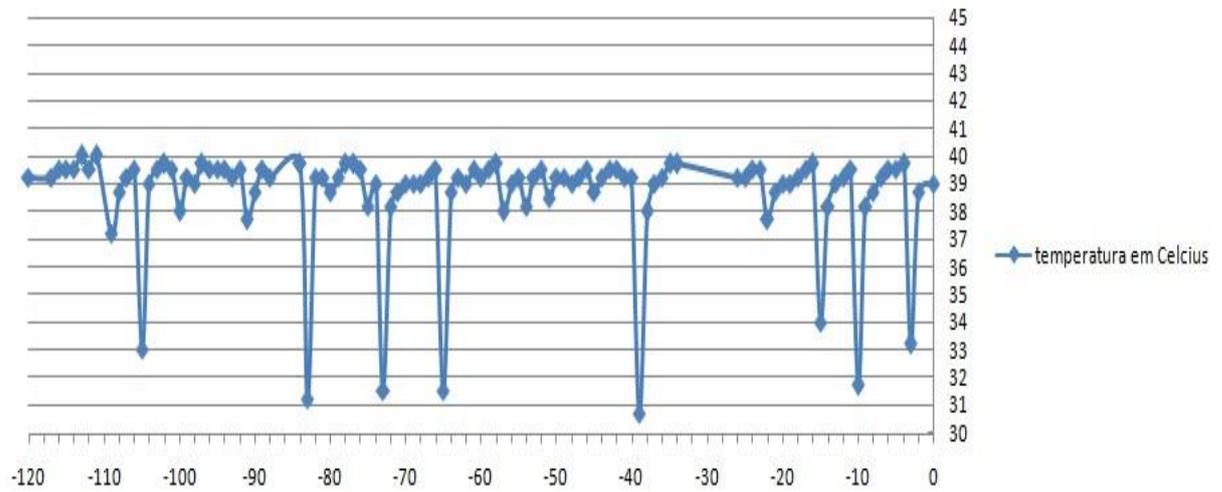
De acordo com o presente teste, apresentado na Tabela 29, há uma grande quantidade de erros nos momento de parto e não-parto, o que indica que a rede não conseguiu determinar um parâmetro para esses instantes. Já para o momento de pré-parto a rede consegue ter um número elevado de acerto, o que mostra que a rede conseguiu determinar um indicador para acertar as Trr desse momento.

Indiscutivelmente, não se pode afirmar que o padrão de temperatura dito por Costa Junior [2014] esteja nesse momento de pré-parto, pois para isso são precisos testes mais aprofundados. Entretanto, de acordo com a resposta da rede, tem-se um indicativo que existe um padrão que identifica o momento de pré-parto.

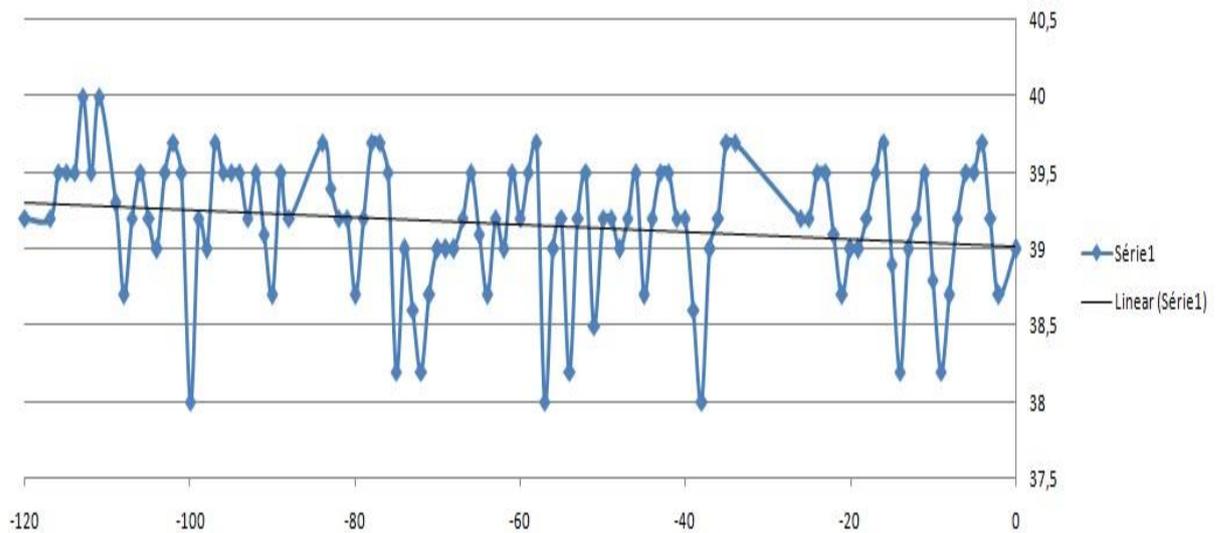
5.7 Teste com filtro de média móvel

Tendo em vista a resposta da rede para o teste anterior (parto, pré-parto e não-parto), um teste com a aplicação de um filtro de média móvel foi realizado. Nesse teste o objetivo é deixar claro o indicador nas Trr que antecede o parto, ou seja, no período intitulado de pré-parto.

Para um aspecto comparativo, a Figura 24 mostra as leituras de Trr puras, ou seja, leituras de Trr que estão na base de dados. Observa-se que existe ponto indicando as temperaturas abaixo dos 37,7 °C. Assim, não se consegue observar uma queda progressiva de 0,2 °C horas antes do parto, como é mencionado por Costa Junior [2014].

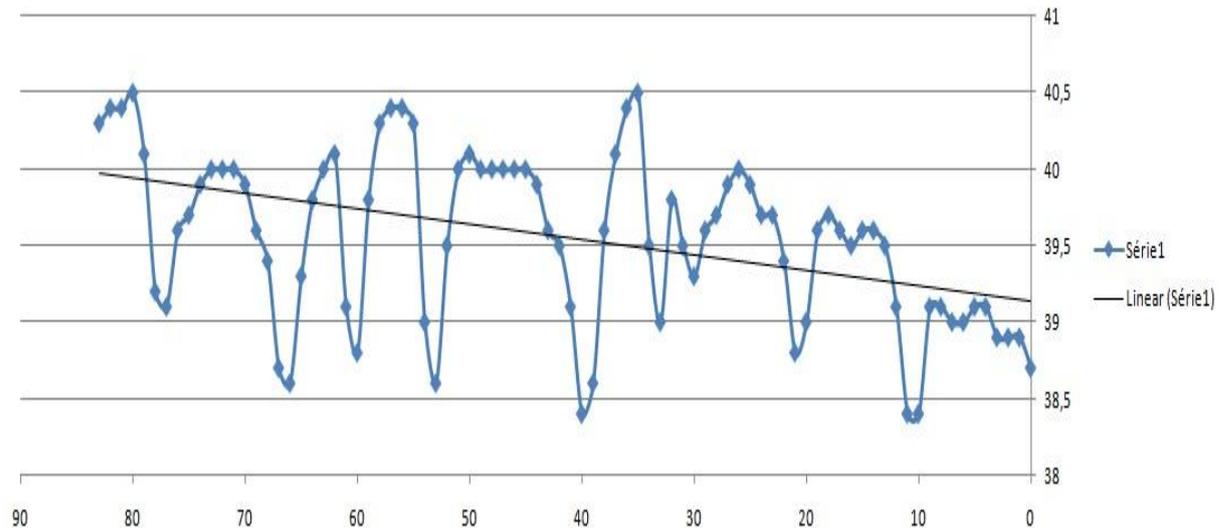
Figura 24. Dados de Trr sem ajustes e sem filtro.

Aplicando-se o ajuste na Trr com os dados da mesma vaca, ou seja, substituindo as Trr menores do que 37,7 °C, obteve-se a Figura 25. Pode-se observar então, pela linha linear, uma pequena queda.

Figura 25. Dados de Trr com ajustes, mas sem filtro.

Porém com a aplicação de um filtro, média móvel, essa queda da Trr fica perceptível. Como se nota na Figura 26.

Figura 26. Dados de Trr com ajuste e com filtro de média móvel.



Os filtros, em especial o filtro de média móvel utilizado no presente trabalho, são basicamente utilizados para separação de sinais combinados e/ou para restauração de sinal que foi distorcido. Portanto, a restauração de um sinal (Trr) distorcido, é garantir que as Trr estejam suavizadas, ou seja, sem ruídos.

Logo, um teste foi realizado com os dados de Trr e com o filtro de média móvel. Foram utilizadas 51 vacas, totalizando 153 exemplos. O arquivo com os exemplos tinha 51 exemplos para parto, 51 exemplos para pré-parto e 51 exemplos para não-parto.

A configuração da rede foi a seguinte:

- Camada intermediária: 6 neurônios;
- Camada de saída: 1 neurônios (0-momento de parto; 1-pré-parto; 2-não parto)
- Valor de *Momentum*: 0.9;
- Taxa de aprendizagem: 0.01;
- Decaimento: verdadeiro;
- Número de épocas: 100.000;
- Normalização dos atributos: verdadeiro;
- Normalização numérica da classe: verdadeiro;
- Método de execução: *Percentage split 70%* (107 para treinamento e 46 para teste).

Com parte dos resultados da rede, apresenta-se a Tabela 30. A tabela completa está representada no Anexo, no item A.9 Teste com filtro de média móvel.

Tabela 30. Resposta da rede com Trr sobre filtro média móvel.

Instância	Saída desejada	Predição da rede	Erro
1	2	1.335	-0.665
2	0	1.233	1.233
3	0	0.998	0.998
4	1	1.364	0.364
5	1	1.04	0.04
6	0	0.546	0.546
7	0	0.936	0.936
8	0	0.971	0.971
9	0	1.157	1.157
10	2	1.751	-0.249
11	2	1.497	-0.503
12	0	0.374	0.374
13	1	1.37	0.37
14	0	0.945	0.945
15	0	0.474	0.474

De acordo com os critérios de avaliação já discutidos anteriormente, obteve-se com a taxa de acerto e taxa de erro, conforme Tabela 31.

Tabela 31. Tabela de contagem de acerto e erros Trr sobre filtro de média móvel.

	Acerto	Erro	Total	Taxa de acerto	Taxa de erro
0	2	20	22	9.10%	90.90%
1	9	0	9	100%	0%
2	2	13	15	13.33%	86.67%

Observa novamente, que a taxa de acerto com dados de Trr sobre o filtro de média móvel foi de 100%. Desde modo, fica nítida a ocorrência de um padrão nas Trr no período intitulado de pré-parto (Trr entre 12 e 23 horas antes do parto).

5.8 Discussões

Nesse trabalho foram realizados 20 testes para predição de parto, com o uso de Redes Neurais Artificiais do tipo MLP, descritos na seção anterior, e os principais resultados obtidos foram resumidos e estão apresentados na Tabela 32. Desta forma, é possível uma análise comparativa e uma definição de qual implementação é a mais adequada para a predição de parto do gado holandês, utilizando-se dados obtidos no banco de dados de Costa Júnior (2014). Na Tabela 32 os dados são apresentados juntamente com as características de cada rede implementada. Para testes cujo a saída da rede mostra momento de parto e momento de não parto tem-se a representação pela classe relevante e classe irrelevante, respectivamente. O valor de Verdadeiro-Positivo (VP), Verdadeiro-Negativo (VN), Falso-Positivo (FP), Falso-Negativo (FN), Sensibilidade (S), Especificidade (E), Probabilidade da classificação na classe relevante (VPP), Probabilidade da classificação na classe irrelevante (VPN), Taxa de Acerto (TA) e Taxa de Erro (TE), são apresentados para os testes que apresentam a possibilidade desses valores serem calculados.

Observa-se que alguns testes foram realizados para confirmar se a configuração do *software* Weka, que seria utilizado na simulação da Rede MLP, estava adequada. Dessa forma, nos primeiros testes foram criados dados fictícios para verificar se a implementação que estava sendo desenvolvida poderia identificar os padrões conhecidos nos dados.

Para tal verificação, foram feitas duas implementações, sendo uma delas com uma pequena diferença de valor entre as temperaturas (apenas 0,2), para verificar se esta pequena diferença seria “identificada” pela rede. Este pequeno valor foi especificado por que no trabalho de Costa Júnior (2014), essa diferença nos valores de temperatura foi identificada como possíveis alterações marcadoras do momento de parto. Entretanto, a rede neural não forneceu respostas adequadas, quando os dados não foram normalizados, identificando dessa forma, a necessidade de manipulação nos dados de entrada. Após a implementação desse mesmo teste, com as devidas normalizações nos dados, verificou-se que a rede MLP, acertou 100% das respostas. Comprovando-se, dessa forma, que a forma de utilização do simulador estava correta. Essa preocupação surgiu por causa da dificuldade de uso do *software* Weka, que normalmente é mais utilizado para mineração de dados. Houve dificuldade para se encontrar manuais ou outro tipo de instruções para esse *software*, dificultando o seu uso. Entretanto, após o entendimento de seu uso, verificou-se que esse *software* se mostrou uma

ferramenta adequada para simulação das redes MLP e com grande vantagem de ser um *software* livre.

Os resultados com os valores de Trr de forma bruta não apresentaram bons resultados, o que de certa forma era esperado. Isso porque quando se “plota” as temperaturas *versus* tempo, observa-se a natureza estocástica do sinal, não apresentando padrões aparentes. Salienta-se ainda que no banco de dados das 120 vacas, nem todos os dados estavam adequados, dificultando o treinamento da rede. Isso foi percebido porque em quase todos os animais, o seu conjunto de temperatura, apresentava em algum instante de tempo, uma temperatura menor do que 37,7°C. Ocasionalmente, dessa forma, grandes dificuldades para o aprendizado da rede, que identificava essas quedas de temperatura em todos os períodos de tempo. Ou seja, essa diminuição de temperatura não tinha nenhuma relação com alteração hormonal do animal ou indicativo de parto e, de certa forma, “confundia” a rede. Outro problema observado em relação aos dados do banco de dados é que algumas vacas provavelmente tiveram problemas com o sensor, sendo que em alguns instantes de tempo, não tinham registro de temperatura. Como consequência, os testes realizados com esses dados puros apresentaram erros elevados.

Ainda nos testes com valores brutos, realizou-se a retirada dos valores com temperaturas menores de 37,7 °C, pois se referia ao momento que o gado bebeu água. Para eliminar tal valor foi feita a média entre o valor anterior e posterior ao instante de tempo que apresentava a Trr menor do que 37,7 °C. A resposta da rede foi ruim, mesmo com a variação de arquitetura e parâmetros da rede. Assim, os ajustes nas Trr a mudança de arquitetura e parâmetros da rede não apresentou melhorias às respostas da rede, com dados brutos. Concluiu-se, portanto, que nos testes subsequentes os dados deveriam ser manipulados adequadamente para que a rede pudesse extrair algum padrão para a solução do problema.

Os testes realizados posteriormente se concentraram em verificar se a rede poderia identificar o momento de parto e o momento de não parto. Dessa forma, seria possível verificar se haveria algum padrão nesses dois momentos.

Tabela 32. Tabela de Comparação dos Resultados.

Testes	Características	Classe Relevante - parto	Classe Irrelevante - não parto	VP	FP	FN	VN	S	E	VPP	VPN	TA	TE
Com valores Fictícios	- Dados de entrada e saída não normalizadas - Saída da rede indicando parto (0) ou não-parto (1).	14	22	14	22	0	0	100	0	38,8%	0%	38,9%	61,1%
	- Dados de entrada e saída normalizadas - Saída da rede indicando parto (0) ou não-parto (1).	14	22	8	0	6	22	57,1	100	100%	78,5%	83,3%	16,6%
Com valores Brutos	- <i>Momentum</i> : 0.9 - Taxa de aprendizagem: 0.1 - Dados de entrada e saída normalizadas - Contém Trr menores que 37,7°C - Saída da rede em horas restante para o parto	0	0	0	0	0	0	0	0	0	0	1,90%	98,09%
Com Ajustes na Trr	- <i>Momentum</i> : 0.9 - Taxa de aprendizagem: 0.1	0	0	0	0	0	0	0	0	0	0	3,71%	96,28%

Testes	Características	Classe Relevante - parto	Classe Irrelevante - não parto	VP	FP	FN	VN	S	E	VPP	VPN	TA	TE
	- Dados de entrada e saída normalizadas - Não Contém Trr menores que 37,7°C - Saída da rede em horas restante para o parto												
Com saída indicando momento de parto ou não-parto	- 1 Vaca - Dados de entrada e saída normalizadas -Saída da rede indicando parto (0) ou não-parto (1)	14	22	14	0	0	22	100	100	100%	100%	100%	0%
	- 2 Vaca - Dados de entrada e saída normalizadas -Saída da rede indicando parto (0) ou não-parto (1)	14	22	14	0	0	22	100	100	100%	100%	100%	0%
	- 5 Vaca - Dados de entrada e saída normalizadas -Saída da rede indicando parto (0) ou não-parto (1)	18	18	15	5	3	13	83,3	72,2	75%	81,2%	77,8%	22,2%
	- 10 Vaca	36	36	36	10	0	26	100	72,2	78,2%	100%	86,1%	13,9%

Testes	Características	Classe Relevante - parto	Classe Irrelevante - não parto	VP	FP	FN	VN	S	E	VPP	VPN	TA	TE
	- Dados de entrada e saída normalizadas -Saída da rede indicando parto (0) ou não-parto (1)												
	- 51 Vaca - Dados de entrada e saída normalizadas -Saída da rede indicando parto (0) ou não-parto (1)	83	101	70	37	13	64	84,3	63,3	65,4%	83,1%	72,8%	27,2%
Com 51 vacas	- Dados de entrada e saída normalizadas - Saída da rede em Horas - Não contém Trr menores que 37,7 °C - Sem média móvel nas Trr	0	0	0	0	0	0	0	0	0	0	0%	100%
- Com 51 vacas	Parto (0)	0	0	0	0	0	0	0	0	0	0	4%	96%
- Saída indicando parto (0), pré-parto (1), não-parto (2) - Sem média móvel	Pré-Parto (1)	0	0	0	0	0	0	0	0	0	0	79,41%	20,59%

Testes	Características	Classe Relevante - parto	Classe Irrelevante - não parto	VP	FP	FN	VN	S	E	VPP	VPN	TA	TE
	Não-Parto (2)	0	0	0	0	0	0	0	0	0	0	18,19%	81,81%
Com 51 vacas - Saída indicando parto (0), pré-parto (1), não-parto (2) - Com média móvel	Parto (0)	0	0	0	0	0	0	0	0	0	0	9,10%	90,90%
	Pré-Parto (1)	0	0	0	0	0	0	0	0	0	0	100%	0%
	Não-Parto (2)	0	0	0	0	0	0	0	0	0	0	13,33%	86,67%

Dessa forma, foram realizados 5 testes. O primeiro com as Trr de uma vaca, o segundo teste com Trr de 2 vacas, o terceiro com 5 vacas, o quarto com 10 vacas e o último com 51 vacas. Observa-se que das 120 vacas no banco de dados, apenas 51 vacas tinham os seus valores de temperatura completos, considerados, dessa maneira, o total de vaca. Todos os dados de entrada e saída da rede forma normalizados pelo sistema Weka.

Nesses testes a rede apresentou um bom índice de Taxa de Acerto (72,8%) e um baixo índice de Falsos Negativos (para o teste com 51 vacas, obteve-se 13 exemplos classificados como FN do total de 83 exemplos). Nota-se que para esse problema de predição de parto, o FN é o índice mais importante, após a TA. Isso porque um falso negativo indica que uma vaca, que está em momento de parto, é definida pela rede como não momento de parto. Um erro de tal natureza implicaria na não separação dessa vaca para acompanhamento de parto e ela poderia ter seu bezerro sem assistência. Dessa forma, a vaca ou bezerro poderiam ter problemas, podendo resultar em mortes e perdas para o proprietário.

Observando-se os testes, verifica-se que os melhores resultados se referem aos testes indicando o momento de parto e o momento de não parto. Porém, esses testes não demonstram ser a melhor solução para a automatização do processo de predição de parto. Isso porque para determinar o momento de parto e não parto, a rede necessita inclusive das 12 últimas horas que incluem o momento de parto. Ou seja, nesse caso, a rede só determina o momento de parto, quando a vaca já se encontra em trabalho de parto.

Dessa forma, a ideia de se automatizar o processo de predição, necessitaria de um sistema que indicasse o momento do parto com antecedência. Por isso, várias tentativas de treinamento da rede MLP com a saída sendo em horas, foi realizada. No entanto, como dito anteriormente, nenhum dos testes com a saída sendo em horas deram bons resultados.

Apesar disso, pensou-se em testes tendo como saída o momento de parto, pré-parto e não-parto. Considerou-se que de acordo com relatos de Costa Junior [2014], há uma ocorrência de diminuição de 0,2 °C na Trr, o que determinava que nas próximas horas ocorreria o parto.

Por consequência, foram realizados testes para uma tentativa de identificar, com precisão, a ocorrência da diminuição de Trr horas antes do parto, como é citado por Costa Junior [2014].

Dentre desses testes, com saída de parto, pré-parto e não parto, o que apresentou melhor resultado foi o teste com a aplicação do filtro de média móvel, pois obteve 100% de acerto para o período de pré-parto, tornando assim, a arquitetura da rede e os parâmetros os mais indicados para a automatização do sistema.

Na Figura 27 são mostrados os resultados obtidos por Costa Junior [2014] em seu trabalho para predição de parto para vacas Holandesas.

Figura 27. Resultado de desempenho obtido por Costa Junior [2014] para predição dentro de 24 ou 12 horas para vacas Holandesas.

Limiar para a queda da Trr	Performance Test ¹	Linha média 1 ⁶		Linha média 2 ⁷	
		24 h	12 h	24 h	12 h
≤ - 0.2°C	Se. ¹	66 (64 – 68)	69 (67 – 71)	68 (67 – 70)	71 (69 – 73)
	Esp. ²	68 (66 – 68)	64 (63 – 65)	68 (67 – 69)	64 (63 – 65)
	Ac. ³	67	65	68	65
≤ - 0.3°C	Se.	60 (57 – 61)	63 (60 – 65)	60 (58 – 62)	63 (60 – 65)
	Esp.	75 (74 – 75)	71 (70 – 72)	75 (74 – 76)	73 (72 – 74)
	Ac.	71	70	72	70
≤ - 0.4°C	Se.	51 (49 – 53)	54 (51 – 56)	51 (49 – 53)	52 (49 – 55)
	Esp.	80 (79 – 81)	77 (76 – 78)	80 (80 – 81)	77 (76 – 77)
	Ac.	74	74	74	74
	ADC ⁴	0,718	0,707	0,737	0,721
	Teste MWU ⁵	< 0.001	< 0.001	< 0.001	< 0.001

¹Se = Sensibilidade: é a probabilidade de um teste positivo (ocorrência da queda da Trr), dado que a vaca vai parir nas próximas 12 ou 24 h. ²Esp = Especificidade: é a probabilidade de um teste negativo (não ocorrência da queda da Trr), dado que a vaca não vai parir dentro das próximas 12 ou 24 h. ³Ac = é o número dos eventos corretamente classificados dividido pelo número total de eventos. ⁴ADC = Área dentro da curva. ⁵Teste Mann–Whitney U ($P \leq 0.5$).

⁶Linha média 1 = Média das leituras de 4 d anteriores considerando um intervalo de uma h da atual leitura. ⁷Linha média 2 = Média das leituras de 4 d anteriores considerando um intervalo de cinco h da atual leitura.

Na Tabela 33 é mostrada a comparação entre os resultados, com métodos estatísticos, obtidos por Costa Junior [2014] e com a utilização da Rede Neural Artificial. Observa-se que a sensibilidade, que indica a probabilidade de acerto para as classes relevantes (momento de parto) da RNA é maior do que obtido por Costa Junior [2014]. Por consequência, a RNA apresentou uma Taxa de Acerto médio de 75,8%, o que, os métodos estatísticos apresentados por Costa Junior [2014] foi de 65%. Comparando-se os resultados, percebe-se que os valores são melhores para a RNA. Entretanto, e o mais importante, é que o enfoque dos trabalhos que estão sendo comparados é diferente. A tese Costa Júnior tinha como hipótese confirmar se a Trr poderia ser utilizada para prever o momento do parto, quantificando o valor dessa Trr e fornecendo a Taxa de Acerto para esse valor de temperatura. Os resultados dessa dissertação referem-se a uma Taxa de Acerto de predição de momento de parto ou não parto ou pré-parto, para vacas que a rede nunca tinha “visto”. Ou seja, para predição de vacas não usadas no treinamento, demonstrando a generalização do conhecimento da rede. Portanto, a Rede Neural Artificial se mostrou eficiente para a predição de momento de parto.

Tabela 33. Tabela comparativa entre os resultados obtidos por Costa Junior [2014] e os resultados com a utilização de Redes Neurais Artificiais (RNA).

	Linha média 1	Linha média 2	RNA –Teste para parto e não-parto
Sensibilidade	69	71	84,3
Especificidade	64	64	63,3
Taxa de Acerto	65%	65%	72,8%

Capítulo 6

CONCLUSÃO

6.1 Conclusão

Dado o exposto, pôde-se perceber que apesar dos resultados satisfatórios indicando a saída de pré-parto, como a melhor solução para a automatização do processo de predição de parto na raça Holandesa, ainda merece mais atenção e estudos. Para que a automatização seja ainda melhor é necessária a descoberta do instante de tempo exato em que ocorre a diminuição da Trr para o momento de parto. Novo banco de dados poderia ser obtido, com definição exata dessa Trr para um treinamento supervisionado mais eficaz da rede.

A utilização da Rede Neural Artificial, MLP, mostrou-se bastante adequada para a tarefa, pois é um modelo robusto, capaz de se adaptar para cada vaca em particular, de acordo com o treinamento. Ademais, apresenta um bom desempenho quando utilizada juntamente com um filtro digital, como o de média móvel.

Em relação ao mérito do trabalho, acredita-se que este é significativo, pois a detecção de momentos de parto e não parto ou o pré-parto é relevante e ainda não se dispõe de nenhum método estabelecido que desempenhe essa atividade com bons resultados. A detecção automática com antecedência do parto é importante, pois a não detecção pode apresentar uma série de problemas, tais como: a morte da vaca e do bezerro e uma queda financeira ao proprietário.

Por fim, acredita-se que este trabalho incentive e estimule novas pesquisas sobre predição e utilização de Redes Neurais Artificiais.

6.2 Trabalhos Futuros

O presente trabalho não encerra o assunto sobre predição de parto em bovinos da raça Holandesa utilizando Redes Neurais Artificiais, mais especificamente, redes *MultiLayer Perceptron*. Portanto, sugere-se mais algumas atividades para dar continuidade as pesquisas, tais como:

- Analisar a rede MLP para novos dados de temperaturas reticuloruminal. Aparentemente novas versões do Bolus estão surgindo com sensores mais precisos e com correções de erro na leitura das temperaturas, sendo assim, torna-se de grande importância a investigação da rede sobre os novos dados;
- Apurar novos testes com possíveis marcadores de temperatura *versus* tempo. Relatos indicam sobre possíveis padrões de temperaturas envolvendo horas antes do parto. Caso esses padrões existam, tornaria a predição do momento de parto muito mais eficaz;
- Comprovar o uso da rede MLP para temperaturas Trr de outras raças na bovinocultura;
- Desenvolver um sistema para automatizar o processo de predição do momento de parto nos bovinos.
- Realizar mais testes com filtros de média móvel nos dados, com variação do período de avaliação.

REFERÊNCIAS

Afonso, J. A. B. **Cirurgias Frequentes em Vacas no Período de Transição.** Universidade Federal Rural do Pernambuco – UFRPE. Clínica de Bovinos, Campus Garanhuns. Disponível em: <<https://www.revistas.ufg.br/vet/article/download/7661/5434>> Acesso em 15 mai. 2016.

Barbosa, Andréa Teresa Riccio. **Mecanismo de Adaptação Baseado em Redes Neurais Artificiais para Sistemas Hipermídia Adaptativos.** Florianópolis. Tese de Doutorado – Universidade Federal de Santa Catarina, 2004.

Braga, Antônio de Pádua et al. **Redes Neurais Artificiais: Teoria e aplicações.** 2 ed. [Reimpr] – Rio de Janeiro: LTC, 2014.

Carneiro, Ticiane. Distocias Comuns em Gado Leiteiro. Disponível em: <<http://produterra.blogspot.com.br/2013/12/distocias-comuns-em-gado-leiteiro.html>> Acesso em 28 jun. 2016.

Costa Junior, João B. G. **Predição e Comportamento do Parto em Bovinos da Raça Holandesa.** Porto Alegre. Tese de Doutorado – Faculdade de Agronomia – Universidade Federal do Rio Grande do Sul, 2014.

Ferreira, A. de M.; Miranda, J. E. C. de. **Medidas de Eficiência da Atividade Leiteira: Índices Zootécnicos para Rebanhos Leiteiros.** Comunicado Técnico Embrapa/MG. Juiz de Fora, 2007.

Franco, R. B.; Martins, W. Avaliação Prática de Redes Neurais para o Acasalamento de Gado Nelore. **IV Congresso Brasileiro de Redes Neurais.** P. 243 – 246, 1999.

Haykin, Simon. **Redes Neurais – Princípios e Prática.** 2 ed. Bookman Companhia, 2001.

Iaione, Fábio. **Proposta e Implementação de Metodologia para Detecção de Hipoglicemia Baseada na Análise e Classificação do Eletroencefalograma.** Florianópolis. Tese de Doutorado – Universidade Federal de Santa Catarina, 2003.

IBGE, Instituto Brasileiro de Geografia e Estatística. **Produção da Pecuária Municipal.** Volume 43. Rio de Janeiro - Brasil, 2015. Disponível em: <http://biblioteca.ibge.gov.br/visualizacao/periodicos/84/ppm_2015_v43_br.pdf> Acesso em 20 jan 2017.

LeCun, Y. **Generalization and Network Design Strategies.** Technical Report CRGTR – 89 – 4. Department of Computer Science, University of Toronto, Canada. 1989.

Lima Cavalli, D. A. de. **Raça Holandesa, Maior Produtividade e Qualidade do Leite.** Casa do Produtor Rural/Escola Superior de Agricultura Luis de Queiroz – ESLAQ/USP, 2016

LOESCH, C., SARI, S. T. **Redes neurais artificiais: fundamentos e modelos**. Blumenau: Ed. da FURB, 1996.

Pandorfi, H. et al. Uso de Redes Neurais Artificiais para Predição de Índices Zootécnicos nas Fases de Gestação e Maternidade na Suinocultura. **Revista Brasileira de Zootecnia**. V. 40, n. 3, p. 676 – 681, 2011.

Plano Mais Pecuária. Ministério da Agricultura, Pecuária e Abastecimento. Brasília: MAPA/ACS, 2014.

Santos, M. dos; Vasconcelos, J. L. M. **Manejo de Vacas Primíparas Visando Aumentar a Eficiência Reprodutiva Futura**. Disponível em: < <http://www.milkpoint.com.br/radar-tecnico/reproducao/manejo-de-vacas-primiparasvisando-aumentar-a-eficiencia-reprodutiva-futura-47751n.aspx>> Acesso em: 8 set. 2016. 2008.

Silva, Ivan Nunes da et al. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. ed. São Paulo: Artliber, 2010.

Tenhagem, B. A. et al. Effect of Various Degrees of Dystocia in Dairy Cattle on Calf Viability. Milk Production, Fertility and Culling. **JVET MED APhysiolPatholClin Med**. V. 54, n. 2, p. 98 – 102, 2007.

Valle, E. R.. do. **O Ciclo Estral de Bovinos e Métodos de Controle**. Disponível em: < old.cnpgc.embrapa.br/publicacoes/doc/doc48/03cicloestral.html> Acesso em 20 out. 2016.

Ventura, R. V. et al. Uso de Redes Neurais Artificiais na Predição de Valores Genéticos para Peso aos 205 dias em Bovinos da Raça Tabapuã. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**. V. 64, n. 2, p. 411 – 418, 2012.

Weka. **Machine Learning Group at the University of Waikato**, 2011. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>> Acesso em: 20 jul. 2017.

Anexo A

TABELAS COMPLETAS

A.1 Teste Inicial com Valores Fictícios

Instância	Saída desejada	Predição da rede	Erro
1	1	0.456	-0.544
2	1	0.456	-0.544
3	1	0.456	-0.544
4	1	0.456	-0.544
5	1	0.456	-0.544
6	1	0.456	-0.544
7	1	0.456	-0.544
8	0	0.454	0.454
9	1	0.456	-0.544
10	1	0.456	-0.544
11	0	0.454	0.454
12	1	0.456	-0.544
13	1	0.456	-0.544
14	1	0.456	-0.544
15	0	0.443	0.443
16	0	0.44	0.44
17	0	0.453	0.453
18	0	0.452	0.452
19	0	0.453	0.453

20	1	0.456	-0.544
21	0	0.441	0.441
22	0	0.443	0.443
23	1	0.456	-0.544
24	1	0.456	-0.544
25	1	0.456	-0.544
26	0	0.452	0.452
27	1	0.456	-0.544
28	1	0.456	-0.544
29	1	0.456	-0.544
30	0	0.445	0.445
31	1	0.456	-0.544
32	1	0.456	-0.544
33	0	0.451	0.451
34	1	0.456	-0.544
35	0	0.45	0.45
36	0	0.444	0.444

A.1.1 Teste Inicial com Valores Fictícios Normalizados

Instância	Saída desejada	Predição a rede	Valores de saída normalizados
1	1	0.456	0
2	1	0.456	0
3	1	0.456	0
4	1	0.456	0
5	1	0.456	0
6	1	0.456	0
7	1	0.456	0
8	0	0.454	0
9	1	0.456	0
10	1	0.456	0

11	0	0.454	0
12	1	0.456	0
13	1	0.456	0
14	1	0.456	0
15	0	0.443	0
16	0	0.44	0
17	0	0.453	0
18	0	0.452	0
19	0	0.453	0
20	1	0.456	0
21	0	0.441	0
22	0	0.443	0
23	1	0.456	0
24	1	0.456	0
25	1	0.456	0
26	0	0.452	0
27	1	0.456	0
28	1	0.456	0
29	1	0.456	0
30	0	0.445	0
31	1	0.456	0
32	1	0.456	0
33	0	0.451	0
34	1	0.456	0
35	0	0.45	0
36	0	0.444	0

A.1.2 Segundo Teste Inicial com Valores Fictícios Normalizados

Instância	Saída desejada	Predição da rede	Erro	Valores de saída normalizados
1	1	0.553	-0.447	1

2	1	0.553	-0.447	1
3	1	0.553	-0.447	1
4	1	0.553	-0.447	1
5	1	0.553	-0.447	1
6	1	0.553	-0.447	1
7	1	0.553	-0.447	1
8	0	0.519	0.519	1
9	1	0.553	-0.447	1
10	1	0.553	-0.447	1
11	0	0.519	0.519	1
12	1	0.553	-0.447	1
13	1	0.553	-0.447	1
14	1	0.553	-0.447	1
15	0	0.322	0.322	0
16	0	0.321	0.321	0
17	0	0.512	0.512	1
18	0	0.515	0.515	1
19	0	0.512	0.512	1
20	1	0.553	-0.447	1
21	0	0.325	0.325	0
22	0	0.325	0.325	0
23	1	0.553	-0.447	1
24	1	0.553	-0.447	1
25	1	0.553	-0.447	1
26	0	0.515	0.515	1
27	1	0.553	-0.447	1
28	1	0.553	-0.447	1
29	1	0.553	-0.447	1
30	0	0.326	0.326	0
31	1	0.553	-0.447	1
32	1	0.553	-0.447	1
33	0	0.338	0.338	0
34	1	0.553	-0.447	1

35	0	0.339	0.339	0
36	0	0.327	0.327	0

A.2 Teste com Um Animal

Instância	Saída desejada	Predição da rede	Erro	Valores de saída normalizados
1	1	0.999	-0.001	1
2	1	0.999	-0.001	1
3	1	1	0	1
4	1	1	-0	1
5	1	0.999	-0.001	1
6	1	1	0	1
7	1	1	0	1
8	0	0	0	0
9	1	1	-0	1
10	1	1	0	1
11	0	0	0	0
12	1	0.999	-0.001	0
13	1	0.999	-0.001	0
14	1	1	-0	1
15	0	0	0	0
16	0	0	0	0
17	0	0	0	0
18	0	0	0	0
19	0	0	0	0
20	1	0.999	-0.001	1
21	0	0	0	0
22	0	0	0	0

23	1	1	-0	1
24	1	0.999	-0.001	1
25	1	0.999	-0.001	1
26	0	0	0	0
27	1	1	0	1
28	1	1	0	1
29	1	1	0	1
30	0	0	0	0
31	1	0.999	-0.001	1
32	1	0.999	-0.001	1
33	0	0	0	0
34	1	0.999	-0.001	1
35	0	0	0	0
36	0	0	0	0

A.3 Teste com Dois Animais

Instância	Saída desejada	Predição da rede	Erro	Valores de saída normalizados
1	0	0.28	0.28	0
2	0	0.28	0.28	0
3	0	0.28	0.28	0
4	1	1.034	0.034	1
5	0	0.28	0.28	0
6	1	0.591	-0.409	1
7	0	0.28	0.28	0

8	1	0.735	-0.265	1
9	1	0.528	-0.472	1
10	0	0.28	0.28	0
11	0	-0.011	-0.011	0
12	0	0.28	0.28	0
13	0	0.28	0.28	0
14	1	0.528	-0.472	1
15	1	1.049	0.049	1
16	1	1.075	0.075	1
17	0	-0.011	-0.011	0
18	0	-0.011	-0.011	0
19	1	1.181	0.181	1
20	0	0.28	0.28	0
21	1	1.075	0.075	1
22	0	-0.011	-0.011	0
23	1	1.034	0.034	1
24	0	0.28	0.28	0
25	0	0.28	0.28	0
26	0	-0.011	-0.011	0
27	1	0.889	-0.111	1
28	1	0.687	-0.313	1
29	0	0.28	0.28	0
30	1	1.049	0.049	1
31	0	0.28	0.28	0
32	0	0.28	0.28	0
33	1	1.049	0.049	1
34	0	0.28	0.28	0
35	0	-0.011	-0.011	0
36	0	-0.011	-0.011	0

A.4 Teste com Cinco Animais

Instância	Saída desejada	Predição da rede	Erro	Valores de saída normalizados
1	1	0.614	-0.386	1
2	1	0.84	-0.16	1
3	0	0.293	0.293	0
4	1	-0.12	-1.12	0
5	0	0.293	0.293	0
6	1	1.006	0.006	1
7	0	0.293	0.293	0
8	0	0.256	0.256	0
9	1	-0.12	-1.12	0
10	0	0.293	0.293	0
11	0	0.543	0.543	1
12	1	1.188	0.188	1
13	1	1.188	0.188	1
14	1	-0.073	-1.073	0
15	0	0.124	0.124	0
16	1	0.409	-0.591	0
17	0	0.543	0.543	1
18	0	0.124	0.124	0
19	1	1.058	0.058	1
20	1	0.725	-0.275	1
21	1	0.522	-0.478	1
22	0	0.124	0.124	0
23	1	0.705	-0.295	1
24	0	0.293	0.293	0
25	1	1.123	0.123	1
26	0	0.543	0.543	1

27	0	0.125	0.125	0
28	1	-0.073	-1.073	0
29	0	0.293	0.293	0
30	0	0.124	0.124	0
31	0	0.293	0.293	0
32	1	1.06	0.06	1
33	0	0.124	0.124	0
34	1	0.84	-0.16	1
35	0	0.124	0.124	0
36	1	0.848	-0.152	1

A.5 Teste com Dez animais

Instância	Saída desejada	Predição da rede	Erro	Valores de saída normalizados
1	1	0.666	-0.334	1
2	0	0.269	0.269	0
3	0	0.264	0.264	0
4	0	0.269	0.269	0
5	1	0.374	-0.626	0
6	0	0.182	0.182	0
7	1	0.841	-0.159	1
8	0	0.264	0.264	0
9	1	1.036	0.036	1
10	1	0.37	-0.63	0
11	1	0.319	-0.681	0
12	1	0.45	-0.55	0

13	1	1.266	0.266	1
14	0	0.188	0.188	0
15	0	0.281	0.281	0
16	1	0.362	-0.638	0
17	0	0.269	0.269	0
18	0	0.35	0.35	0
19	0	0.269	0.269	0
20	1	0.666	-0.334	1
21	0	0.182	0.182	0
22	0	0.464	0.464	0
23	0	0.326	0.326	0
24	1	1.323	0.323	1
25	0	0.188	0.188	0
26	1	0.654	-0.346	1
27	1	0.685	-0.315	1
28	1	0.641	-0.359	1
29	1	0.924	-0.076	1
30	0	0.368	0.368	0
31	1	0.569	-0.431	1
32	1	0.569	-0.431	1
33	0	0.188	0.188	0
34	0	0.264	0.264	0
35	1	1.323	0.323	1
36	0	0.326	0.326	0
37	1	0.449	-0.551	0
38	0	0.492	0.492	0
39	0	0.182	0.182	0
40	1	0.675	-0.325	1
41	0	0.368	0.368	0
42	1	0.449	-0.551	0
43	0	0.269	0.269	0
44	0	0.188	0.188	0
45	1	0.31	-0.69	0

46	1	0.841	-0.159	1
47	1	1.014	0.014	1
48	1	0.674	-0.326	1
49	0	0.281	0.281	0
50	1	0.813	-0.187	1
51	1	0.944	-0.056	1
52	0	0.269	0.269	0
53	1	1.277	0.277	1
54	0	0.182	0.182	0
55	1	0.642	-0.358	1
56	0	0.35	0.35	0
57	0	0.492	0.492	0
58	0	0.264	0.264	0
59	0	0.492	0.492	0
60	1	1.014	0.014	1
61	1	0.514	-0.486	1
62	0	0.269	0.269	0
63	0	0.368	0.368	0
64	1	1.266	0.266	1
65	0	0.264	0.264	0
66	0	0.35	0.35	0
67	0	0.35	0.35	0
68	1	0.684	-0.316	1
69	1	0.29	-0.71	0
70	1	0.258	-0.742	0
71	1	1.036	0.036	1
72	0	0.464	0.464	0

A.6 Teste com 51 animais

Instância	Saída desejada	Predição da rede	Erro	Valores de saída normalizados
1	1	0.366	-0.634	0
2	1	0.758	-0.242	1
3	0	0.268	0.268	0
4	1	0.67	-0.33	1
5	1	0.445	-0.555	0
6	0	0.321	0.321	0
7	0	0.443	0.443	0
8	1	1.11	0.11	1
9	0	0.443	0.443	0
10	0	0.302	0.302	0
11	1	0.626	-0.374	1
12	1	0.35	-0.65	0
13	0	0.564	0.564	1
14	1	0.875	-0.125	1
15	1	0.278	-0.722	0
16	0	0.171	0.171	0
17	0	0.376	0.376	0
18	0	0.358	0.358	0
19	1	0.856	-0.144	1
20	0	0.374	0.374	0
21	0	0.419	0.419	0
22	1	0.991	-0.009	1
23	1	0.382	-0.618	0
24	1	0.577	-0.423	1
25	1	0.979	-0.021	1
26	0	0.443	0.443	0
27	1	1.082	0.082	1

28	1	0.497	-0.503	0
29	0	0.576	0.576	1
30	0	0.268	0.268	0
31	1	0.68	-0.32	1
32	0	0.509	0.509	1
33	1	0.508	-0.492	1
34	1	0.954	-0.046	1
35	1	0.187	-0.813	0
36	0	0.071	0.071	0
37	0	0.128	0.128	0
38	0	0.531	0.531	1
39	1	0.37	-0.63	0
40	1	0.963	-0.037	1
41	0	0.171	0.171	0
42	1	0.487	-0.513	0
43	0	0.356	0.356	0
44	1	0.508	-0.492	1
45	1	0.309	-0.691	0
46	1	0.628	-0.372	1
47	0	0.351	0.351	0
48	0	0.302	0.302	0
49	1	0.554	-0.446	1
50	1	0.373	-0.627	0
51	0	0.302	0.302	0
52	1	0.763	-0.237	1
53	0	0.128	0.128	0
54	1	0.527	-0.473	1
55	1	0.744	-0.256	1
56	1	0.531	-0.469	1
57	1	1.104	0.104	1
58	0	0.399	0.399	0
59	0	0.374	0.374	0
60	0	0.317	0.317	0

61	1	0.838	-0.162	1
62	0	0.845	0.845	1
63	1	0.575	-0.425	1
64	1	0.456	-0.544	0
65	1	0.385	-0.615	0
66	1	0.372	-0.628	0
67	1	0.338	-0.662	0
68	1	0.714	-0.286	1
69	1	0.544	-0.456	1
70	0	0.329	0.329	0
71	1	1.001	0.001	1
72	0	0.372	0.372	0
73	1	1.018	0.018	1
74	0	0.169	0.169	0
75	1	1.04	0.04	1
76	1	0.529	-0.471	1
77	1	0.236	-0.764	0
78	1	1.085	0.085	1
79	1	0.257	-0.743	0
80	1	0.481	-0.519	0
81	0	0.356	0.356	0
82	1	0.821	-0.179	1
83	0	0.319	0.319	0
84	0	0.399	0.399	0
85	0	0.084	0.084	0
86	1	0.573	-0.427	1
87	0	0.551	0.551	1
88	1	0.182	-0.818	0
89	0	0.071	0.071	0
90	1	0.937	-0.063	1
91	0	0.373	0.373	0
92	0	0.531	0.531	1
93	0	0.509	0.509	1

94	1	0.328	-0.672	0
95	1	0.573	-0.427	1
96	0	0.09	0.09	0
97	1	0.422	-0.578	0
98	1	0.394	-0.606	0
99	0	0.374	0.374	0
100	0	0.374	0.374	0
101	0	0.234	0.234	0
102	1	0.799	-0.201	1
103	1	0.257	-0.743	0
104	0	0.234	0.234	0
105	0	0.399	0.399	0
106	0	0.291	0.291	0
107	1	0.542	-0.458	1
108	1	0.459	-0.541	0
109	0	0.477	0.477	0
110	0	0.384	0.384	0
111	1	0.473	-0.527	0
112	0	0.356	0.356	0
113	0	0.419	0.419	0
114	1	0.98	-0.02	1
115	0	0.302	0.302	0
116	1	0.286	-0.714	0
117	0	0.215	0.215	0
118	0	0.319	0.319	0
119	1	0.428	-0.572	0
120	1	1.052	0.052	1
121	1	1.115	0.115	1
122	1	0.585	-0.415	1
123	1	0.239	-0.761	0
124	1	0.833	-0.167	1
125	0	0.174	0.174	0
126	0	0.531	0.531	1

127	1	0.211	-0.789	0
128	0	0.169	0.169	0
129	1	0.922	-0.078	1
130	0	0.128	0.128	0
131	1	0.715	-0.285	1
132	1	0.546	-0.454	1
133	1	0.985	-0.015	1
134	0	0.317	0.317	0
135	1	0.997	-0.003	1
136	1	0.175	-0.825	0
137	0	0.168	0.168	0
138	1	0.617	-0.383	1
139	1	0.36	-0.64	0
140	0	0.272	0.272	0
141	0	0.501	0.501	1
142	1	0.595	-0.405	1
143	0	0.272	0.272	0
144	1	0.734	-0.266	1
145	1	0.513	-0.487	1
146	1	0.35	-0.65	0
147	1	0.737	-0.263	1
148	0	0.321	0.321	0
149	1	0.62	-0.38	1
150	0	0.215	0.215	0
151	1	0.899	-0.101	1
152	0	0.253	0.253	0
153	1	0.964	-0.036	1
154	0	0.302	0.302	0
155	1	0.528	-0.472	1
156	1	0.723	-0.277	1
157	1	0.395	-0.605	0
158	0	0.493	0.493	0
159	0	0.171	0.171	0

160	1	0.836	-0.164	1
161	0	0.88	0.88	1
162	0	0.508	0.508	1
163	0	0.302	0.302	0
164	1	0.655	-0.345	1
165	0	0.384	0.384	0
166	0	0.551	0.551	1
167	1	0.194	-0.806	0
168	1	0.19	-0.81	0
169	0	0.317	0.317	0
170	1	0.255	-0.745	0
171	0	0.358	0.358	0
172	1	0.502	-0.498	1
173	0	0.181	0.181	0
174	1	0.461	-0.539	0
175	1	0.68	-0.32	1
176	0	0.373	0.373	0
177	0	0.358	0.358	0
178	1	1.005	0.005	1
179	0	0.266	0.266	0
180	0	0.399	0.399	0
181	0	0.329	0.329	0
182	1	0.977	-0.023	1
183	1	0.573	-0.427	1
184	0	0.181	0.181	0

A.7 Teste com 51 animais com a saída em horas

Instância	Saída desejada	Predição da rede	Erro
1	24	34.051	10.051
2	60	32.195	-27.805
3	12	33.564	21.564
4	36	43.158	7.158
5	72	44.134	-27.866
6	24	29.938	5.938
7	24	42.253	18.253
8	48	37.282	-10.718
9	12	38.9	26.9
10	24	17.808	-6.192
11	24	30.46	6.46
12	0	19.006	19.006
13	0	33.336	33.336
14	60	38.994	-21.006
15	48	36.912	-11.088
16	36	40.466	4.466
17	24	40.09	16.09
18	36	30.916	-5.084
19	36	25.505	-10.495
20	48	38.552	-9.448
21	48	48.719	0.719
22	0	46.798	46.798
23	60	52.86	-7.14

24	0	35.787	35.787
25	36	39.421	3.421
26	0	21.741	21.741
27	72	44.773	-27.227
28	0	28.709	28.709
29	12	42.387	30.387
30	36	43.936	7.936
31	24	32.357	8.357
32	0	20.688	20.688
33	36	27.486	-8.514
34	12	36.85	24.85
35	24	35.545	11.545
36	48	46.659	-1.341
37	72	61.728	-10.272
38	48	37.579	-10.421
39	0	32.01	32.01
40	12	43.028	31.028
41	36	31.399	-4.601
42	0	29.331	29.331
43	12	23.925	11.925
44	48	35.554	-12.446
45	24	31.091	7.091
46	60	34.868	-25.132
47	72	42.283	-29.717
48	48	39.05	-8.95
49	0	42.13	42.13
50	0	19.268	19.268
51	36	56.748	20.748
52	0	38.06	38.06
53	12	35.926	23.926
54	60	42.77	-17.23
55	36	35.849	-0.151
56	72	39.786	-32.214

57	0	40.767	40.767
58	12	29.444	17.444
59	72	40.737	-31.263
60	12	43.74	31.74
61	36	37.513	1.513
62	72	40.21	-31.79
63	60	54.934	-5.066
64	12	43.193	31.193
65	12	40.554	28.554
66	0	26.4	26.4
67	72	44.315	-27.685
68	24	38.395	14.395
69	48	49.925	1.925
70	60	38.175	-21.825
71	36	33.45	-2.55
72	36	50.071	14.071
73	36	38.178	2.178
74	48	54.061	6.061
75	12	28.906	16.906
76	0	33.739	33.739
77	36	36.981	0.981
78	72	37.328	-34.672
79	12	27.467	15.467
80	72	37.302	-34.698
81	24	41.697	17.697
82	72	34.57	-37.43
83	36	44.285	8.285
84	48	35.217	-12.783
85	24	46.511	22.511
86	0	19.383	19.383
87	60	33.958	-26.042
88	0	28.397	28.397
89	24	40.238	16.238

90	0	36.331	36.331
91	0	28.477	28.477
92	48	42.325	-5.675
93	48	45.996	-2.004
94	60	47.244	-12.756
95	0	28.403	28.403
96	72	37.693	-34.307
97	60	42.622	-17.378
98	72	29.538	-42.462
99	60	47.048	-12.952
100	60	42.069	-17.931
101	36	56.125	20.125
102	36	31.091	-4.909
103	12	50.866	38.866
104	0	40.393	40.393
105	60	39.13	-20.87
106	36	30.695	-5.305
107	24	40.588	16.588

A.8 Teste com saídas de parto, pré-parto e não-parto

Instância	Saída desejada	Predição da rede	Erro
1	1	0.582	-0.418
2	2	1.681	-0.319
3	2	0.801	-1.199
4	1	0.922	-0.078
5	0	0.693	0.693
6	1	1.45	0.45
7	2	0.897	-1.103
8	2	1.557	-0.443

9	2	1.315	-0.685
10	1	0.843	-0.157
11	2	1.257	-0.743
12	2	1.528	-0.472
13	1	0.799	-0.201
14	2	0.725	-1.275
15	1	1.103	0.103
16	1	0.798	-0.202
17	2	1.427	-0.573
18	2	1.262	-0.738
19	0	0.726	0.726
20	1	0.947	-0.053
21	1	0.634	-0.366
22	0	0.821	0.821
23	0	0.68	0.68
24	0	0.884	0.884
25	1	1.102	0.102
26	2	1.351	-0.649
27	1	1.014	0.014
28	1	0.87	-0.13
29	0	0.837	0.837
30	1	0.449	-0.551
31	0	1.08	1.08
32	2	1.681	-0.319
33	1	0.366	-0.634
34	0	0.798	0.798
35	1	1.192	0.192
36	2	1.068	-0.932
37	0	0.821	0.821
38	2	1.057	-0.943
39	2	1.582	-0.418
40	2	1.046	-0.954
41	2	1.057	-0.943

42	2	1.311	-0.689
43	0	0.745	0.745
44	1	1.359	0.359
45	2	0.714	-1.286
46	1	0.858	-0.142
47	2	0.725	-1.275
48	1	1.732	0.732
49	1	0.767	-0.233
50	1	0.629	-0.371
51	2	1.334	-0.666
52	1	1.732	0.732
53	0	1.362	1.362
54	2	1.534	-0.466
55	0	0.583	0.583
56	2	1.257	-0.743
57	0	1.362	1.362
58	1	0.449	-0.551
59	1	0.354	-0.646
60	0	0.857	0.857
61	1	0.843	-0.157
62	1	1.015	0.015
63	1	0.629	-0.371
64	2	1.403	-0.597
65	0	0.972	0.972
66	2	1.199	-0.801
67	0	1.138	1.138
68	1	1.103	0.103
69	2	0.882	-1.118
70	0	0.812	0.812
71	0	0.492	0.492
72	1	0.989	-0.011
73	2	0.841	-1.159
74	2	0.81	-1.19

75	2	1.443	-0.557
76	2	1.337	-0.663
77	1	0.947	-0.053
78	0	1.157	1.157
79	0	0.595	0.595
80	1	0.56	-0.44
81	0	0.595	0.595
82	0	0.734	0.734
83	1	0.457	-0.543
84	1	0.922	-0.078
85	0	0.972	0.972
86	0	0.532	0.532
87	0	1.08	1.08
88	2	1.124	-0.876
89	2	0.87	-1.13
90	1	1.014	0.014
91	1	1.343	0.343
92	2	1.311	-0.689

A.9 Teste com filtro de média móvel

Instância	Saída desejada	Predição da rede	Erro
1	2	1.335	-0.665
2	0	1.233	1.233
3	0	0.998	0.998
4	1	1.364	0.364
5	1	1.04	0.04
6	0	0.546	0.546
7	0	0.936	0.936
8	0	0.971	0.971
9	0	1.157	1.157

10	2	1.751	-0.249
11	2	1.497	-0.503
12	0	0.374	0.374
13	1	1.37	0.37
14	0	0.945	0.945
15	0	0.474	0.474
16	1	0.534	-0.466
17	0	0.572	0.572
18	2	0.753	-1.247
19	0	1.173	1.173
20	2	0.549	-1.451
21	0	1.47	1.47
22	0	0.778	0.778
23	0	0.71	0.71
24	2	1.465	-0.535
25	0	0.964	0.964
26	0	1.297	1.297
27	0	0.768	0.768
28	2	0.89	-1.11
29	0	0.901	0.901
30	2	0.606	-1.394
31	1	0.848	-0.152
32	2	1.152	-0.848
33	1	0.855	-0.145
34	1	0.891	-0.109
35	2	0.86	-1.14
36	0	0.926	0.926
37	1	1.069	0.069
38	1	0.654	-0.346
39	0	1.126	1.126
40	2	1.666	-0.334
41	0	0.66	0.66
42	2	0.903	-1.097

43	2	0.473	-1.527
44	0	0.652	0.652
45	2	0.909	-1.091
46	2	1.07	-0.93