

**UNIVERSIDADE FEDERAL DO PAMPA**

**CAINÃ LIMA COSTA**

**UTILIZAÇÃO DE CARACTERÍSTICAS ZOOTÉCNICAS E DE MANEJO NA  
PECUÁRIA PARA PREVISÃO DO PESO FINAL E BONIFICAÇÃO DE BOVINOS  
EMPREGANDO REDES NEURAS ARTIFICIAIS**

**Bagé  
2016**

**CAINÃ LIMA COSTA**

**UTILIZAÇÃO DE CARACTERÍSTICAS ZOOTÉCNICAS E DE MANEJO NA  
PECUÁRIA PARA PREVISÃO DO PESO FINAL E BONIFICAÇÃO DE BOVINOS  
EMPREGANDO REDES NEURAS ARTIFICIAIS**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Produção da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Bacharel em Engenharia de Produção.

Orientador: Dr. Marcelo Xavier Guterres

Co-orientadores: Dr. Vinicius N. Lampert  
Eng. Marcelo Coletto Rola

**Bagé  
2016**

C135u Costa, Cainã Lima

Utilização de características zootécnicas e de manejo na pecuária para previsão do peso final e bonificação de bovinos empregando redes neurais artificiais / Cainã Lima Costa.

81 p.

Trabalho de Conclusão de Curso (Graduação) --  
Universidade Federal do Pampa, ENGENHARIA DE PRODUÇÃO,  
2016.

"Orientação: Marcelo Xavier Guterres".

1. Pecuária de corte. 2. Previsão de variáveis. 3. Condições zootécnicas. 4. Práticas de manejo. I. Título.

**CAINÃ LIMA COSTA**

**UTILIZAÇÃO DE CARACTERÍSTICAS ZOOTÉCNICAS E DE MANEJO NA  
PECUÁRIA PARA PREVISÃO DO PESO FINAL E BONIFICAÇÃO DE BOVINOS  
EMPREGANDO REDES NEURAS ARTIFICIAIS**

Trabalho de Conclusão de Curso  
apresentado ao Curso de Engenharia de  
Produção da Universidade Federal do  
Pampa, como requisito parcial para  
obtenção do Título de Bacharel em  
Engenharia de Produção.

Trabalho de Conclusão de Curso defendido e aprovado em: 5 de dezembro de 2016.

Banca examinadora:

---

Eng. Marcelo Coletto Rola  
(UFRGS)

---

Prof. Dr. Sandro da Silva Camargo  
(UNIPAMPA)

---

Dr. Vinicius do Nascimento Lampert  
(EMBRAPA-CPPSUL)

*Este trabalho é dedicado às crianças adultas que,  
quando pequenas, sonharam em se tornar cientistas.*

## **AGRADECIMENTOS**

Deus por me alcançar todos os dias com sua misericórdia e graça, por me iluminar com sua presença, dando-me abrigo e conforto. Por não me deixar esquecer que habita em mim e que sustenta todos os dias.

Aos meus pais, Éder e Ivani, pela compreensão e apoio ininterrupto durante toda a minha vida.

As minhas irmãs, Damiana e Leonara, pelo companheirismo e incentivo na minha graduação.

Ao meu orientador, Professor Dr. Marcelo Xavier Guterres, pelos ensinamentos, compreensão, análise e sugestões para a realização deste trabalho. Quero expressar minha gratidão e admiração pela sua competência profissional e pela forma que conduziu minha orientação.

Ao pesquisador Dr. Vinicius do Nascimento Lampert, pela oportunidade de estagiar na Empresa Brasileira de Pesquisas Agropecuárias (EMBRAPA) e pela sua co-orientação, apoio e motivação desde o início do projeto.

Ao meu co-orientador Marcelo Coletto Rola pela orientação, dedicação, paciência e, principalmente pela amizade durante o meu Trabalho de Conclusão de Curso.

A todos os meus colegas do curso de Engenharia de Produção, que fizeram e fazem parte minha vida acadêmica.

A todos os meus amigos, que de forma direta ou indireta participam da minha vida.

“Se é pouco o que vos deixo, o pouco é muito, porque há tudo de mim neste tão pouco.”

(Apparicio Silva Rillo)

## RESUMO

Devido ao importante papel desenvolvido pela pecuária de corte brasileira no mercado nacional e internacional, as utilizações de modelos de previsão dentro deste contexto vêm sendo amplamente utilizada. Estes modelos, em sua grande maioria, são abastecidos por diversos fatores, destacando-se em particular, as condições zootécnicas do gado, aspectos nutricionais, práticas de manejo, custos de produção, entre outros. Diante deste cenário, o objetivo principal deste trabalho é prever o rendimento dos bovinos de uma propriedade rural, através das variáveis peso de fazenda (PF) e bonificação (BN), utilizando a técnica de Redes Neurais Artificiais (RNA's). A metodologia utilizou uma rede do tipo *Feedforward Backpropagation* para prever o rendimento do pecuarista, usando um banco de dados de uma propriedade rural particular, o qual contém uma série de variáveis zootécnicas e de manejo para uma determinada quantia de bovinos. Os resultados atenderam parcialmente os objetivos esperados, nos quais a previsão do modelo para a variável peso de fazenda obteve uma correlação muito grande, boa generalização, produzindo erros baixos. Porém o resultado para o modelo de previsão de bonificação apresentou erro bem elevado, baixa correlação e generalização insatisfatória devido a uma limitação da ferramenta e da escolha dos dados a serem utilizados na matriz de entrada da rede.

Palavras-chave: Pecuária de corte, Previsão de variáveis, Condições zootécnicas, Práticas de manejo.

## **ABSTRACT**

Due to the importance role played by Brazilian beef cattle in national and international markets, the uses of forecast models within this context have been widely used. These models, for the most part, are supplied by a variety of factors, particularly zootechnical conditions of cattle, nutritional aspects, management practices, production costs, among others. Considering this scenario, the main objective of this work is to predict the yield of the cattle of a rural property, through farm weight (PF) and bonus (BN) variables, using the technique of Artificial Neural Networks (ANNs). The methodology used a Feedforward Backpropagation type network to predict cattle rancher performance using a database of a particular rural property, which contains a series of zootechnical and management variables for a given amount of cattle. Results partially met expected objectives, in which the prediction of the model for the variable farm weight obtained a perfect correlation, good generalization, producing low errors. However, the result for the bonus prediction model presented a very high error, low correlation and poor generalization due to a tool limitation and the choice of data to be used in the network input matrix..

Keywords: Beef cattle, Forecast variables, Zootechnical conditions, Handling practices.

## LISTA DE FIGURAS

Figura 1- Estrutura de um neurônio biológico.....	28
Figura 2 - Esquema do neurônio de McCulloch-Pitts .....	29
Figura 3 - Rede neural de perceptrons.....	30
Figura 4 - Rede Neural Multilayer Perceptron .....	31
Figura 5 - Principais funções de ativação utilizadas nas redes neurais .....	34
Figura 6 - Aprendizado supervisionado de uma rede neural Multilayer Perceptron ..	36
Figura 7 - Funcionamento do algoritmo <i>backpropagation</i> .....	37
Figura 8 - Variáveis utilizadas na matriz de entrada desde o nascimento do bovino até o abate .....	41
Figura 9 - Organização dos dados da RNA.....	42
Figura 10 - Mês de nascimento em função do número de animais .....	49
Figura 11 - Mês de abate em função do número de animais .....	50
Figura 12 - Mês de desmame (%) para os 401 bovinos .....	50
Figura 13 - Tipo de desmame (%) para os 401 bovinos.....	51
Figura 14 - Peso de desmame em função do número de animais .....	52
Figura 15 - GMD em função do número de animais.....	52
Figura 16 - Rede Neural artificial empregada no trabalho .....	53
Figura 17 - Performance do treinamento previsão do peso .....	54
Figura 18 - Gráficos de regressão entre a saída da RNA e o alvo (PF) .....	55
Figura 19 - Resultado do treinamento da RNA para peso.....	56
Figura 20 - Histograma de erro percentual do treinamento .....	57
Figura 21 - Resultado da previsão da RNA .....	58
Figura 22 - Histograma de erro percentual da previsão .....	58
Figura 23 - Performance do treinamento alvo bonificação .....	59
Figura 24 - Gráficos de regressão entre a saída da RNA e o alvo (bonificação) .....	60
Figura 25 - Resultado do treinamento da RNA para bonificação .....	61
Figura 26 - Histograma de erro do treinamento para bonificação .....	62
Figura 27 - Resultado da previsão RNA para bonificação .....	63
Figura 28 - Histograma de erro da previsão de bonificação .....	64

## LISTA DE TABELAS

Tabela 1 - Classificação das variáveis .....	39
Tabela 2 - Variáveis selecionadas nos modelos .....	40
Tabela 3 - Desempenho do treinamento da RNA em função do n° de neurônios .....	45

## SUMÁRIO

1	INTRODUÇÃO.....	12
1.1	Objetivo principal .....	14
1.2	Objetivos específicos.....	15
1.3	Delimitação da pesquisa.....	15
2	A PECUÁRIA DE CORTE.....	16
2.1	O sistema produtivo da pecuária de corte .....	16
2.2	Relacionamento comercial entre pecuaristas e frigoríficos.....	18
2.3	Indicadores do Sistema (Variáveis de Influência) .....	19
2.4	Modelos matemáticos empregando variáveis zootécnicas .....	23
3	REDES NEURAIS ARTIFICIAIS.....	27
3.1	Origem das redes neurais artificiais.....	27
3.2	Histórico de utilização das redes neurais artificiais.....	29
3.3	Tipos de Redes Neurais .....	30
3.4	Funções de ativação.....	32
3.5	Processo de aprendizagem .....	34
3.6	Aprendizado supervisionado.....	35
3.7	Aprendizado não supervisionado.....	36
3.8	Algoritmo <i>backpropagation</i> .....	36
4	METODOLOGIA.....	38
4.1	Seleção e classificação dos dados de entrada da RNA (Etapa I).....	39
4.2	Criação, configuração, treinamento, teste e validação da RNA (Etapa II) .....	43
4.3	Simulação da RNA e processamento dos resultados.....	45
5	RESULTADOS E DISCUSSÕES.....	49
6	CONCLUSÕES.....	65
7	REFERÊNCIAS BIBLIOGRÁFICAS .....	67

## 1 INTRODUÇÃO

A pecuária de corte brasileira assume um papel de destaque no mercado nacional e internacional, movimentando a economia, gerando emprego e renda em vários setores da indústria. Veríssimo (2007) destaca que o setor da pecuária brasileira vem evidenciando-se na economia nacional e assumindo posição de liderança no mercado mundial de carnes. A Associação Brasileira das Indústrias Exportadoras de Carne, afirma que o mercado supracitado consolida-se a partir da década de 2000 como potência na produção e exportação de carne bovina, passando a ocupar a primeira posição no ranking da produção mundial em 2004 (ABIEC, 2016).

Inúmeras normas e condições são essenciais para que a carne produzida no Brasil seja exportada, obedecendo a rigorosos e diferentes padrões de qualidade estabelecidos pelos países importadores. Segundo Euclides Filho (2000), a inserção no comércio internacional é oriunda de vários fatores, entre eles: a erradicação da febre aftosa; a produção em espaços não confinados; a maior parte do rebanho alimentado pelo pasto nativo; e por fim, características como o solo, clima e recursos humanos, somados a extensão territorial. Assim, os fatores mencionados anteriormente permitem uma produção de carne de excelente qualidade, resultando em um produto de alta confiabilidade.

A cadeia produtiva de carne bovina é composta essencialmente por fornecedores de insumos básicos, empresas rurais, frigoríficos, atacados e consumidores (BUAINAIN et al., 2007). O desenvolvimento desta cadeia produtiva é resultado dos avanços obtidos pela pesquisa em produção, sanidade e melhoramento genético, bem como, as melhorias nos processos de gestão e expansão das fronteiras agrícolas nas regiões centro-oeste e norte do Brasil (PEREIRA, 2009).

Esse crescimento ainda demanda novos desafios a todo ciclo da cadeia produtiva, sendo eles: melhorias constantes nas estruturas de gestão; aumentos dos recursos disponíveis; novas *expertises*; desenvolvimento de novas estratégias; e alguns conceitos mais atuais, como o bem-estar animal e a questão da sustentabilidade. No entanto, Raíces (2003) salienta que a maior parcela dos pecuaristas não exerce um bom gerenciamento de seus negócios, a não utilização de ferramentas gerenciais e a ausência de informações resulta na falta de critérios

para a tomada de decisões, tornando-as, por muitas vezes, ineficazes para potencializar os lucros.

Carvalho et al. (2008) alerta que aspectos relacionados a eficiência produtiva também devem ser considerados, pois a produtividade da pecuária nacional é mediana, quando comparada a de outros países. Logo, isto implica numa margem de lucro baixa para os pecuaristas nacionais, sendo necessários estudos e aprimoramentos desta temática.

Observa-se também que a produção pecuária está associada a riscos produtivos e comerciais que impactam na sua receita e, conseqüentemente, na viabilidade econômica da atividade. Isso proporciona a falta de fluxo das informações entre os agentes da cadeia, evidenciando um engessamento dos elos produtivos quanto ao conhecimento dos resultados e eficiência de cada agente.

Para o produtor é muito importante avaliar a época ideal de comercialização dos animais para os frigoríficos a fim de maximizar a sua receita e lucros, bem como ponderar se o animal está adequado para o abate. Entretanto, a decisão pode ser influenciada por diversos fatores, destacando-se, em particular, as condições zootécnicas do gado, aspectos nutricionais, práticas de manejo, custos de produção e a conjuntura macroeconômica do país.

Os fatores macroeconômicos do setor foram investigados pelos autores Moita e Golon (2014) e Clemente e Mattos (2011) a fim de identificar quais sofrem mais influencia no preço futuro da arroba do boi. Porém, mesmo utilizando um modelo econométrico bem ajustado é difícil realizar esta previsão, pois uma série de fatores exerce influência sobre o preço de uma mercadoria. No caso das *commodities*, principalmente as agropecuárias, os seguintes fatores devem ser considerados: a inflação, o nível do preço de commodities substitutas, as mudanças na taxa de câmbio e o nível de oferta da produção em questão (MOITA; GOLON, 2014).

Outros dois pontos econômicos são importantes na caracterização da indústria em estudo, o primeiro ponto refere-se ao poder de mercado exercido pelos frigoríficos, no qual o preço fixado na bolsa de valores raramente é o aplicado pelas indústrias frigoríficas. Segundo Moita e Golon (2014), isso ocorre em algumas localidades devido ao número de compradores ser pequeno contra o alto número de fornecedores, o que poderia ser caracterizado como oligopsônio. Já o segundo ponto relaciona-se a sazonalidade do boi gordo que, em anos atrás, exercia maior influência no preço do produto, essa redução se deve a novas tecnologias para

pastagens cultivadas e novas técnicas de suplementação e/ou confinamento (OAIGEN, 2014).

Além das considerações apresentadas a respeito dos aspectos econômicos, o produtor também precisa avaliar quais outros fatores mais impactam na variação da receita na atividade. Para Barbosa (1999), estes estão ligados ao sistema de produção como um todo, que para ter eficiência zootécnica é preciso ponderar três componentes: 1) eficiência reprodutiva do rebanho de vacas; 2) eficiência do ganho de peso dos animais jovens; e 3) qualidade dos produtos (carne e couro). No que diz respeito ao item três, o produtor que investir no desenvolvimento de produtos de qualidade pode ser bonificado pelo frigorífico obtendo uma remuneração extra por qualidade de carcaça, quando atendidos os padrões estipulados pela indústria.

Ao produtor rural é vantajoso presumir rapidamente o valor a ser pago pelo frigorífico ao seu produto, porém muitas vezes o mesmo não tem acesso a variáveis e ferramentas para estimar o seu valor adequado. Variáveis como o preço médio de mercado, idade, peso vivo, raça, idade do desmame, peso de desmame, entre outras, são de mais fácil acesso aos pecuaristas e ideais a serem empregadas em modelos econométricos e/ou previsão. A utilização das mesmas, em modelos matemáticos, proporcionará vantagens competitivas ao produtor, que poderá determinar quando vender o seu produto, gerando maiores lucros.

Diante disso, a realização de estudos que desenvolvam ferramentas nesta temática é de grande importância. Uma técnica que vem sendo amplamente empregada para previsão são as Redes Neurais Artificiais (RNA's), que utilizam variáveis que exercem influência sobre um sistema a ser investigado, por exemplo, na pecuária de corte a idade de abate, raça, idade do desmame e tipo de desmame interferem no preço final de comercialização.

### **1.1 Objetivo principal**

Pretende-se, por meio de um modelo empregando a técnica de RNA's, prever o rendimento dos bovinos de uma propriedade rural, através das variáveis Peso de Fazenda (PF) e Bonificação (BN). Sendo assim, espera-se que este modelo venha auxiliar os produtores rurais na gestão mais eficiente do seu negócio, proporcionando um aumento do ganho financeiro por parte dos mesmos.

## 1.2 Objetivos específicos

Para que o objetivo geral delineado na seção anterior seja alcançado, os seguintes objetivos específicos foram definidos:

- Realizar a seleção das variáveis zootécnicas e de manejo disponíveis em um banco de dados de uma propriedade rural, visando com que as mesmas sejam de fácil acesso aos pecuaristas.
- Apresentar graficamente o comportamento individual das variáveis selecionadas para os respectivos bovinos;
- Configurar adequadamente a RNA (n° de camadas, n° de neurônios da camada intermediária, função de treinamento e função de aprendizagem) objetivando encontrar um pequeno erro quadrático médio (*Mean Squared Error* - MSE) em sua fase de treinamento.
- Comparar os resultados simulados pela RNA com os valores reais do peso de fazenda e bonificação, respectivamente;
- Apresentar o erro percentual do modelo para ambos os casos;

## 1.3 Delimitação da pesquisa

A presente pesquisa ficará restrita a um banco de dados disponibilizado pela Embrapa Pecuária Sul oriundos de uma propriedade rural da região central do estado, município de Quevedos, região de abrangência do bioma pampa e da bacia hidrográfica do Rio Ibibuí. Os animais (bovinos) foram comercializados para um frigorífico local, entre o período de 07/08/2013 até 05/04/2016. Porém, é importante destacar que a referida delimitação não inviabilizará a aplicação dos resultados em outras propriedades, uma vez que este estudo poderá auxiliar no entendimento de problemas semelhantes no contexto da previsão aplicada a pecuária de corte.

## **2 A PECUÁRIA DE CORTE**

Neste capítulo será abordado o sistema produtivo da pecuária de corte, a relação entre pecuarista-frigorífico, as variáveis de influência ou as principais variáveis desde a cria até o abate e a utilização de modelos matemáticos empregando variáveis zootécnicas e de manejo, dando enfoque especial para a aplicação de redes neurais artificiais.

### **2.1 O sistema produtivo da pecuária de corte**

Um sistema de produção é composto por atividades e operações que interagem entre si para produzir bens ou serviços, a interação entre as partes envolvidas no processo irá determinar o resultado do sistema como um todo (SLACK, 2009). Este esclarecimento de sistema produtivo também é aplicável ao conjunto de atividades agrárias e pecuárias, tendo como elementos característicos (terra, mão de obra, ambiente físico-biológico, ambiente socioeconômico e habilidades do produtor) ocasionadores das táticas e forças produtivas (APOLLIN; EBERHART, 1999; HART, 1990).

O sistema produtivo na bovinocultura sofre influência mútua entre distintos métodos de produção que incidem no interior do mesmo (ANDREATTA, 2009). Essas ocorrem devido ao nível de utilização das formas produtivas, de como são combinadas às funções associadas à agricultura e pecuária, das aplicações entre os meios de produção disponíveis e dos diversos tipos de atividades selecionadas para serem implementadas (BARCELLOS, 2004).

No contexto da pecuária de corte, o sistema produtivo pode ser conceituado como um conjunto de tecnologias e práticas de manejo, bem como o perfil do animal, a intenção da criação, a raça ou grupamento genético e a região onde a atividade é desenvolvida (EUCLIDES FILHO, 2000).

Separados em fases (cria, recria e engorda), os parâmetros produtivos da carne formam um conjunto que é nomeado de ciclo produtivo. A cria, fase base do sistema de produção, concentra-se na produção de terneiros mantidos ao pé da vaca até o desmame, os quais poderão ser vendidos ou recriados e terminados dentro da propriedade (PIRES, 2010). É a fase mais importante do ciclo produtivo

em virtude da geração de terneiros que serão utilizados nas etapas de recria e terminação (BARCELLOS, 2011).

A fase de recria atende a tempo entre o desmame e o início da fase de terminação nos machos e entre o desmame e o primeiro acasalamento das fêmeas (LAZZARINI, 2000). É um período mutável, em que as fêmeas são manejadas de acordo com a idade da primeira reprodução, ao mesmo tempo em que os machos recebem diferentes tratamentos de acordo com a idade de abate.

O engorde é uma fase mais curta, tendo como objetivo a terminação de animais para comercialização. É a etapa mais intensa do ciclo de produção quanto à utilização de insumos, devido à alta demanda energética para deposição de gordura nos animais (GOTTSCHELL, 2005). É comum neste período utilizar pastagens, suplementação e confinamento.

Concomitante com as fases em que o sistema de produção é dividido, existe a classificação do grau de intensificação dos mesmos, estando representado da seguinte forma: extensivo, semi-intensivo e intensivo.

Nos sistemas extensivos os bovinos desenvolvem-se exclusivamente em pastagens nativas ou cultivadas implicando em baixa produção e pouca utilização de insumos. A alimentação restringe-se apenas ao pasto sendo a única fonte de proteína e energia, o que torna esse tipo de sistema muito frágil (EUCLIDES FILHO, 2000). Ao contrário do anterior, os sistemas intensivos utilizam pastagens cultivadas de alta produtividade combinados com suplementação alimentar e/ou confinamento para terminação dos machos (CEZAR et al., 2005).

Ainda segundo o mesmo autor existe um sistema combinado chamado de semi-intensivo o qual é composto por pastagens cultivadas com acréscimo de suplementos proteicos e/ou energéticos. A escolha por um determinado sistema produtivo impactará diretamente no peso final e bonificação do bovino respectivamente, entretanto, qualquer que seja o sistema de produção, a atividade caracteriza-se pela predominância de uso de pastagens.

De acordo com Garcia Filho (1999), são fatores determinantes no sistema a ser empregado, a extensão de terra e a mão de obra. Com alta disponibilidade de área produtiva e baixa mão de obra, provavelmente o produtor optará por sistemas mais extensivos. Ao contrário, irá procurar adotar sistemas intensivos, que apresentem uma maior produtividade por área e força de trabalho superior.

## 2.2 Relacionamento comercial entre pecuaristas e frigoríficos

A comercialização com os frigoríficos é realizada de diversas formas e por diversos agentes, que podem ou não fazer parte dessa etapa conforme, explica Oaigen (2014):

“Quanto à comercialização de animais para abate, também há a presença de corretores, exclusivos ou não dos frigoríficos, mas também surge a dos marchantes, que são descritos como sendo intermediários que podem assumir tanto o papel de agente corretor (vende animais de outros produtores) quanto de intermediário comerciante (compra animais e revende a outro produtor).”

Conforme o mesmo autor, os *modus operandi* de comercialização de abate mais utilizados no Brasil tem como referência: o rendimento de carcaça; o peso vivo; e o rendimento relacionado aos atributos de qualidade de carcaça (peso, sexo, idade e raça).

É importante destacar que os atributos de qualidade de carcaça vêm ganhando espaço nos últimos anos, pois a indústria consegue agregar valor aos produtos originados pelos animais de melhor qualidade. Nesse sentido, de acordo com Felício (2005), no que diz respeito ao Brasil, algumas indústrias frigoríficas implantam com sucesso os sistema de bonificação por qualidade de carcaças. As mesmas buscam valorizar os animais mais jovens pela maturidade dentária com peso e acabamento de gordura desejáveis, formando classes de maior, menor ou nenhum aproveitamento de bonificação.

Particularmente, no Sul do Brasil, os fatores de seleção para a compra de animais para reposição consideram, principalmente, as características raciais ao mesmo tempo em que para os animais de recria e terminação leva-se em conta a conciliação entre peso, preço, e características raciais, sendo que o último item é preponderante (OAIGEN, 2014). A compra dos animais é realizada por duas formas de pagamento: por peso vivo, quando o pecuarista recebe pelo total de quilogramas que seus animais obtiveram no momento do embarque para o frigorífico e a rendimento de carcaça, onde o produtor recebe pelo total de quilogramas obtido após o abate dos animais (CHRISTOFARI, 2008). Nesses sistemas os animais de melhor qualidade e rendimento são mais bem remunerados.

Além disso, conforme destacam Lopes e Carvalho (2002), por meio de análise econômica, o pecuarista pode compreender os resultados financeiros alcançados na prática da atividade da empresa rural. Contudo, é dessa maneira que o pecuarista, de forma consciente, consegue gerir seu processo decisório, compreendendo a uma empresa o seu sistema de produção de gado. Para atingir este objetivo é importante que se conheça o cenário em que a empresa está inserida. Nesse sentido, o grau de conhecimento quanto ao panorama, funcionalidades e a empresa em si, são diretamente proporcionais à capacidade de tomada de decisões de forma coerente.

### **2.3 Indicadores do Sistema (Variáveis de Influência)**

Para analisar um sistema produtivo é indispensável mensurar seus indicadores, só assim o produtor rural terá embasamento para tomada de decisão. Para Oaigen & Barcellos (2008) as variáveis de influência são informações gerenciais de ordem técnica ou econômica que irão contribuir com avaliações precisas dos processos internos da propriedade rural. Estando estes ligados a um nível operacional eficiente e gerencial eficaz. Nas palavras do autor é importante para o pecuarista o seguinte esclarecimento:

"Deve ficar claro que para a empresa rural interessa, sobretudo, a rentabilidade, que é o elemento mais importante na avaliação da atividade econômica praticada em moldes capitalistas. Este indicador de desempenho deve situar-se em nível adequado para que o investimento privado se justifique (OAIGEN, 2010)".

Dentre os inúmeros indicadores (variáveis) zootécnicos e de manejo, serão apresentados na sequência as principais variáveis no que o produtor rural tem acesso, enfatizando que as mesmas devem sempre ser levantadas e acompanhadas conforme indica a literatura.

- **Mês de Nascimento (MN):** A parição é basicamente marcada por duas épocas bem definidas no estado do Rio Grande do Sul, nascimentos na primavera e no outono. É convencional que a natalidade dos animais ocorra na primavera, devido às exigências dos bovinos se adequarem ao período de maior crescimento das pastagens. Porém, existe uma tendência por alguns dos produtores, de conduzir

cruzamentos durante o período de inverno (junho e julho), a fim de obter partos no outono, adiantando a cobertura de novilhas e vacas vazias (SALOMONI & SILVEIRA, 1996). O nascimento de terneiros no outono faz com que as matrizes deem a luz com perfeita condição corporal, propiciando um desenvolvimento fetal no terço final da gestação satisfatório, implicando em maior peso ao nascer. Já na primavera, geralmente os terneiros são mais leves no nascimento, mas encontram uma época favorável para o ganho de peso no período de pré-desmame e apresentam peso superior aos animais de outono, que ao nascerem são pesados, mas ganham menor peso por dia nos meses de inverno (BARCELOS & LOBATO, 1992; CARDELLINO & CARDELLINO, 1984; PONS et al. 1989; MONTGOMERY & DAVIS, 1987). Em pesquisas realizadas com animais de raça europeia no Rio Grande do Sul em duas épocas de nascimento distintas: outono (de fevereiro a junho, com 15% dos nascimentos) e a primavera (de julho à janeiro, com 85% dos nascimentos) foi observado que animais nascidos na primavera foram 12,9% mais pesados à desmama que os animais nascidos no outono (CARDOSO et al., 2000).

- **Idade de Abate (IA):** Quando um bovino chega antecipadamente a idade adulta é nomeado precoce, em palavras técnicas é determinado momento fisiológico em que o esqueleto desenvolve-se antecipadamente ao período médio da espécie (CORRÊA, 1996). Ao tratar da idade é relevante que o animal chegue mais cedo a determinado peso, para produção e reprodução não interessando se atingiu ou não a fase adulta de seu desenvolvimento (DOMINGUES, 1990). São considerados precoces os animais abatidos entre 30-36 meses (CORRÊA, 1996). Ao concluírem dois anos de idade os animais já desenvolveram grande parte de seu sistema muscular, embora continuem crescendo até idades mais avançadas, iguais ou superiores há sete anos (BARBOSA, 1999). A partir da influência entre o ganho de peso diário em relação ao crescimento relativo do animal, é possível compreender que com o passar do tempo a eficiência em ganho de peso na fazenda é reduzida, o que justifica a redução da idade de abate (BARBOSA, 1999). Em um estudo realizado pelo Instituto de Ensino e Pesquisa (INSPER) para se obter o máximo de lucro possível, o pecuarista deve abater os animais próximos de 794 dias de vida (aproximadamente 27 meses). Depois deste período o animal começa a trazer prejuízos, pois continua a comer, porém não

ganha mais peso em quantidade suficiente para compensar os gastos com alimentação (BORTOLUZZO et al., 2011). No entanto, classes etárias mal definidas podem ser oriundas de algumas deficiências na propriedade rural, como coordenação da produção, demandas estruturais, operacionais e técnicas, bloqueando a ação em fatores que exercem influência sobre idade-peso, na razão de diminuir o primeiro e aumentar o segundo simultaneamente (BAPTISTA *et al.* 1999).

- **Dias de Desmame (DD):** O desmame é uma das etapas mais importantes da criação de gado de corte. Ela pode ser determinante na recria do animal e fazer com que esta seja mais longa ou mais curta (VALLE et al., 1996). Geralmente os terneiros são desmamados entre 120 e 290 dias (3 a 10 meses) após o nascimento, mas a maioria dos produtores realizam esse manejo aos 205 dias (6 meses) de idade (CORRÊA, 1996). Quando o animal atinge esta idade consegue ingerir forragem sólida como fonte de nutriente que carece e já pode ser considerado um ruminante, o objetivo desse manejo é comercial e também de preservar as matrizes para próxima parição (EMBRAPA-CNPGC, 1996).
- **Tipo de Desmame (TD):** A prática de separar o terneiro da matriz aos 90-120 dias de vida é chamada de desmame precoce, é recomendável por especialistas em circunstâncias de escassez de forragem, com o propósito de reduzir o estresse da amamentação e manter a condição nutricional das vacas. Desta maneira as mesmas podem reconstruir o estado corporal sem comprometer o próximo cio reduzindo prejuízos (EMBRAPA-CNPGC, 1996). Contudo é necessário um equilíbrio de tal prática, não podendo comprometer o desenvolvimento do terneiro a fim de proporcionar vantagem energética e reprodutiva para as fêmeas. Restle et al. (1999), afirma que no momento que a ingestão de leite é suspensa pelo desmame precoce, o terneiro não consegue aproveitar do pasto a quantia necessária de nutrientes para manter o mesmo ritmo de ganho de peso da amamentação, devido as condições do rúmen. A outra categoria de desmame, denominada como o desmame convencional, e realiza-se com aproximadamente 7 e 8 meses (EMBRAPA-CNPG, 1996).

- **Ganho Médio Diário (GMD):** Mensurar o ganho de peso diário é fundamental para avaliar a eficiência da atividade pecuária. Ao determinar essa variável em algumas etapas do ciclo produtivo poderão ser identificados alguns problemas de manejo dos diferentes setores, tais como estresse, dietas indevidas e doenças. Dificuldades no ganho de peso podem comprometer a maturidade sexual e idade do primeiro parto, desta forma o bovino permanece em uma fase improdutivo gerando custos (SARMENTO, 2003). Não existe uma meta comum para ganho de peso médio diário, isso se deve a algumas dependências particulares de cada propriedade como, por exemplo: idade do animal, peso atual, raça e características do ambiente de inserção (PAULINO, 2008). Porém, algumas metas comumente são instituídas de acordo com as fases (por exemplo: nascimento ao desmame; desmame a inseminação; inseminação ao parto) (DOS SANTOS, 2002).
- **Peso de Desmame (PD):** A pesagem de desmame é um indicador importante na pecuária de corte, irá avaliar o quanto é produtiva determinada matriz, visto que o ganho de peso que o terneiro obteve até o momento de desmame foi à custa da mãe (LIMA, 1983). O mesmo autor salienta que o peso obtido no desmame exerce influencia direta na idade de abate, quanto mais pesado for o terneiro, menor será o tempo necessário para que o novilho chegue ao beneficiamento. Assim como o sexo do terneiro e mês/ano de nascimento são importantes fontes de variação na determinação dos pesos da variável e por isso devem ser considerados.
- **Percentual de Bonificação (PB):** Ao fornecer matéria prima de boa qualidade para frigoríficos, alguns produtores estão recebendo a chamada "bonificação" que tem como objetivo principal agregar valor ao processo produtivo da carne. Atualmente, alguns frigoríficos estabeleceram programas de avaliação de carcaças, estes propiciam um fluxo de informações entre os elos da cadeia, assim os criadores tem acesso a relatórios individuais completos do rebanho (BEEFPOINT, 2008). Para serem contemplados com o bônus é necessária a avaliação de carcaça, esta obedece alguns conceitos preliminares referente à sua categorização. Segundo Sainz (2001) e Felício (2005) existem duas maneiras de julgamento por classificação ou tipificação. A classificação consiste

em "agrupar em classes aquilo que tem características semelhantes ou iguais - por exemplo, as categorias de sexo, maturidade e peso dos animais". Já a tipificação é a "diferenciação das classes em tipos hierarquizados segundo critérios que incluem as categorias da classificação já mencionadas e outras como gordura de cobertura e conformação da carcaça". Como também padrão racial definido de no mínimo 50% de grau de sangue, machos castrados (ou inteiros desde que com zero dente) e fêmeas com até quatro dentes, acabamento de gordura mínimo de 3mm (mediano) e peso mínimo de 225kg de carcaça para machos e 195kg para fêmeas (BEFFPOINT, 2012). Cada unidade frigorífica possui um responsável da raça para avaliação, no qual os índices avaliados são tabelados entre um acordo comercial da associação da raça e da unidade de abate específica. Nas condições descritas acima para raça Hereford e Angus, por exemplo, em plantas do Grupo Marfrig, o produtor pode receber para um novilho jovem de 0-4 dentes com peso na faixa de 240kg a 260kg uma bonificação de 2% a 8% sobre o peso da carcaça. Já para uma novilha com a mesma dentição o beneficiado poderá receber valores de 1% a 6% considerando os preços base da unidade frigorífica (MARFRIG, 2016).

- **Peso de Fazenda (PF):** O peso de fazenda é o peso vivo total do bovino pesado na balança antes de ir ao frigorífico em quilogramas (ARGOLOME et al, 2006). Ao contrário do que geralmente ocorre neste setor quando se fala em arroba, está se referindo ao peso de carcaça, ou seja, o peso carne com o osso, desconsiderando o sebo, o couro, as patas, a cabeças e as entranhas (BAPTISTA et al., 1999).

## 2.4 Modelos matemáticos empregando variáveis zootécnicas

A modelagem matemática é uma ferramenta que tem como propósito auxiliar na compreensão de um determinado sistema produtivo e suas interações. Apresentam-se na forma de equações contendo um conjunto de dados de entrada que implicarão em dados de saída resultante de uma proposição específica (MEIRELLES, 2005). Classificam-se como estáticos ou dinâmicos, de acordo com

sua desempenho ao longo do tempo. Os mesmos podem ser estocásticos ou determinísticos, dependendo do enfoque probabilístico adotado (CHWIF, 2014).

No contexto zootécnico a utilização de modelos matemáticos de simulação incide principalmente nas seguintes áreas de concentração: nutrição, melhoramento genético, reprodução e sanidade.

Na área de nutrição animal foi construído um modelo capaz de estimar a lucratividade ao introduzir uma nova tecnologia de pastagens em um sistema tradicional de criação de bovinos de corte sobre diferentes formas estratégicas de manejo e de tomada de decisões. Os resultados de saída foram satisfatórios o programa mensurou parâmetros econômicos e condições físicas e estratégicas de manejo adotados no sistema tradicional e modificado (CEZAR, 1982).

Em melhoramento genético utilizando o programa Genesys pesquisadores conseguiram obter valores genéticos individuais de uma determinada população de bovinos simulando estruturas e parâmetros genotípicos e fenotípicos investigando diferentes graus de heterogeneidade de variâncias e conectividade genética. Como resultado se obteve similaridades entre as condições reais e simuladas (CARNEIRO et al., 2008).

A rapidez com que as novilhas se tornam vacas prontas para reprodução impacta diretamente em retornos econômicos. O cruzamento das mesmas pode ser eficiente e otimizado se a idade do primeiro parto for manifestada. A fim de descobrir qual idade em que as novilhas são mais reprodutivas, Beretta et al. (2001) avaliou diversas médias de idade do primeiro parto utilizando um modelo estático determinístico que representa-se o ciclo anual da fase de cria em diferentes sistemas equilibrados. A idade para concepção do primeiro parto apontada pelo estudo foi de 24 meses.

De outro modo, existe também uma técnica matemática que visa solucionar problemas mais complexos e que normalmente requerem o uso de inteligência humana, chamadas de Redes Neurais Artificiais. Segundo Costa (2009) elas possuem a singular aptidão de estruturar a resolução de problemas a partir de ponderações dos sistemas complexos deparados na natureza viva, o que torna aliadas da área zootécnica.

Para atingir o objetivo e resolver os problemas as RNA's, que estão inseridas na conjuntura da Inteligência Artificial, aplicam elementos da neurocomputação baseados na percepção conexionista dos neurônios para processar a informação

(SMOLENSKI, 1990). O comportamento inteligente da rede obedece a uma premissa de relação dinâmica entre conexões e nós, denominados neurônios, a onde está representado o conhecimento (COSTA, 2009).

É esta capacidade conexionista que torna as RNA's úteis no estudo de problemas tecnológicos, tais como a previsão de determinados parâmetros zootécnicos.

O autor Brennecke (2007) realizou um estudo de previsão nutricional utilizando RNAs com objetivo de prever as características da planta ainda no seu habitat natural e comparar os valores obtidos com os procedimentos laboratoriais, a fim de reduzir tempo e dinheiro empregados em análises de bancada. Os resultados obtidos tiveram erros dentro do esperado, assim a previsão desvinculou as análises laboratoriais, de qualidade de planta forrageira. Hoje é possível mensurar o grau de proteína utilizando apenas ferramentas computacionais obtendo resultados rápidos e econômicos.

No setor de avicultura programas de alimentação com baixo custo e bom desempenho são cada vez mais necessários. Empregando a técnica de RNA's é possível estimar a produtividade de frangos de corte com base em determinados insumos. Assim, a metodologia aplicada por Ahmadi et al. (2007) mostrou-se eficaz em reconhecer dietas otimizadas e prever com precisão índices de desempenho.

Na bovinocultura especificamente na área de sanidade a temática foi investigada por Cavero et al. (2008) a fim de detectar o controle precoce da mastite bovina em vacas leiteiras ordenhadas por sistema automático. Para realizar a pesquisa um conjunto de dados específico foi coletado utilizando condutividade elétrica. Foi possível identificar diariamente os animais que apresentavam tendência para tal enfermidade.

Já na pecuária de corte, modelos de previsão utilizando séries temporais de preços da carne são os mais encontrados na literatura. Destaca-se o trabalho de Lemes (2014) que identificou as implicações na tomada de decisão a partir da formação do preço da carne. O modelo proposto é capaz de reduzir os riscos e aumentar a rentabilidade para as partes interessadas.

Utilizando duas ferramentas computacionais com o objetivo de auxiliar nas tomadas de decisões na produção de bovinos de corte, Meirelles (2005) utilizou a técnica de simulação Monte Carlo para analisar características de produção e manejo e aplicou RNA's para classificar animais segundo o ganho de peso nas fases

de crescimento com um erro quadrático médio observado de  $7,4 \times 10^{-6}$ . Ventura et al. (2012) realizou uma predição de valores genéticos para peso aos 205 dias em bovinos da raça Tapapuã usando RNA's e relacionando com a metodologia BLUP (Best Linear Unbiased Prediction, ou em português, Melhor Predição Linear Imparcial), no qual para esta aplicação obteve correlação entre 0,74 e 0,68 e um erro quadrático médio igual 0,0001.

### **3 REDES NEURAIS ARTIFICIAIS**

Este capítulo tem como principal objetivo definir alguns conceitos de Redes Neurais Artificiais, tais como: origem, breve histórico de utilização, tipologia de rede, funções de ativação, processos de aprendizagem, algoritmos convencionais e etapas de construção de uma rede.

#### **3.1 Origem das redes neurais artificiais**

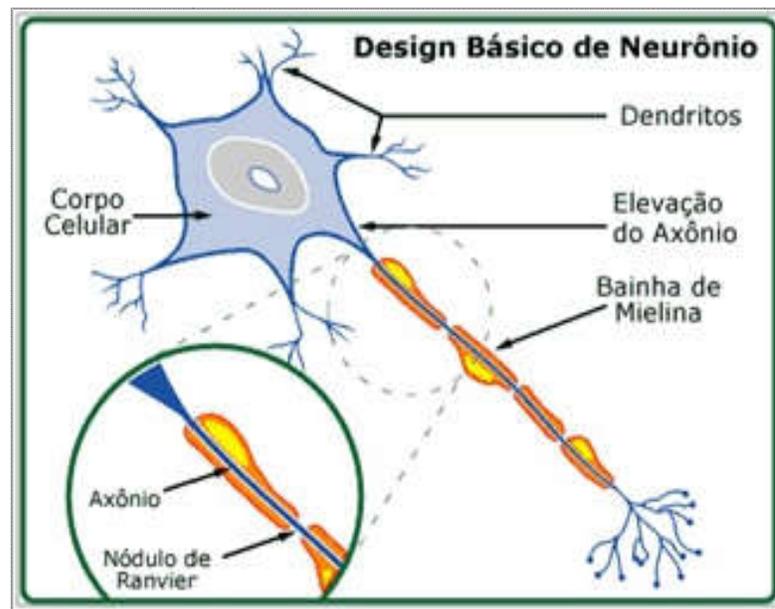
Uma RNA é um paradigma de processamento de informação, a qual é inspirada na forma como os sistemas nervosos biológicos funcionam, tais como o cérebro. De acordo com Haykin (2001), as RNA's representam o funcionamento do cérebro humano de uma maneira simples, os nós sensoriais são chamados de neurônios e conectam-se em uma rede, e são capazes de resolver problemas complexos utilizando os conhecimentos adquiridos a partir do ambiente. O elemento chave desse paradigma é a nova estrutura do sistema de processamento de informações, sendo este composto por um grande número de elementos de processamento altamente interligados (neurônios) que trabalham em conjuntos para resolver problemas específicos.

As redes neurais, assim como as pessoas, aprendem pelo exemplo e está configurada para uma aplicação específica, como reconhecimento de padrões, classificação e previsão de dados, através de um processo de aprendizagem. Aprendizagem em sistemas biológicos envolve adaptações das conexões sinápticas que existem entre os neurônios e isto também ocorre com as RNA's.

O nosso cérebro é considerado um processador contendo enorme quantia de neurônios interligados que formam uma rede neural capaz de processar e armazenar informação. Para transmitir a informação o sistema nervoso utiliza o potencial de ação, fenômeno fisiológico da despolarização rápida seguida pela repolarização da membrana celular. Essa sequência irá gerar descargas elétricas que excitam as células neuronais e musculares (SAVEGNAGO, 2013)

Para que o neurônio ative-se é preciso que potencial de ação ultrapasse uma fronteira de ativação. Estando a fronteira de ação ultrapassada, a célula nervosa é ativada propagando informações ao longo do axônio que irá transmitir para o neurônio adjacente e assim, a informação é transmitida neurônio após neurônio, até chegar ao destino (HALL; GUYTON, 2006). Na figura 1 são apresentados os principais elementos dos neurônios biológicos, corpo da célula, dendritos, e axônio. Os detritos recebem informações (impulsos nervosos) oriundos de outros neurônios. O axônio é responsável pela transmissão de estímulos para o próximo neurônio (BRAGA; CARVALHO; LUDEMIR, 2007).

Figura 1- Estrutura de um neurônio biológico



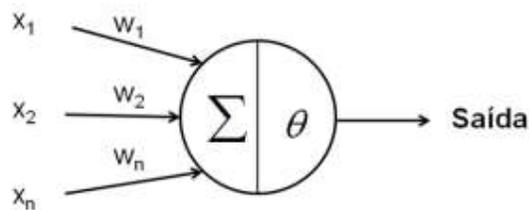
Fonte: (HALL; GUYTON, 2006)

As RNAs distinguem-se conforme sua arquitetura, tais como as redes multicamadas *feedforward*, também conhecidas como redes *multilayer perceptron*, redes neurais de função de base radial, redes recorrentes, redes auto-organizáveis de *Kohonen*, entre outras. A utilização de cada uma destas arquiteturas possui sua especificidade para realizar um tipo de aplicação, seja predição, agrupamento de dados, redução do número de variáveis ou classificação de objetos ou indivíduos (SAVEGNAGO, 2013).

### 3.2 Histórico de utilização das redes neurais artificiais

Em 1943 um modelo de neurônio artificial foi desenvolvido a partir de observações da estrutura cerebral humana (Figura 2). O estudo foi desenvolvido pelo neurologista McCulloch e o matemático Walter Pitts os mesmos concluíram que a resposta de um neurônio é positiva se ele estiver ativado, ou nula se não for ativado e as sinapses são fixas (MCCULLOCH; PITTS, 1943). Os pesos sinápticos até então eram fixos devido à ausência de um algoritmo de aprendizado que alterasse os valores destes pesos para melhorar o modelo, na época isso era o fator limitante da descoberta (SAVEGNAGO, 2013).

Figura 2 - Esquema do neurônio de McCulloch-Pitts



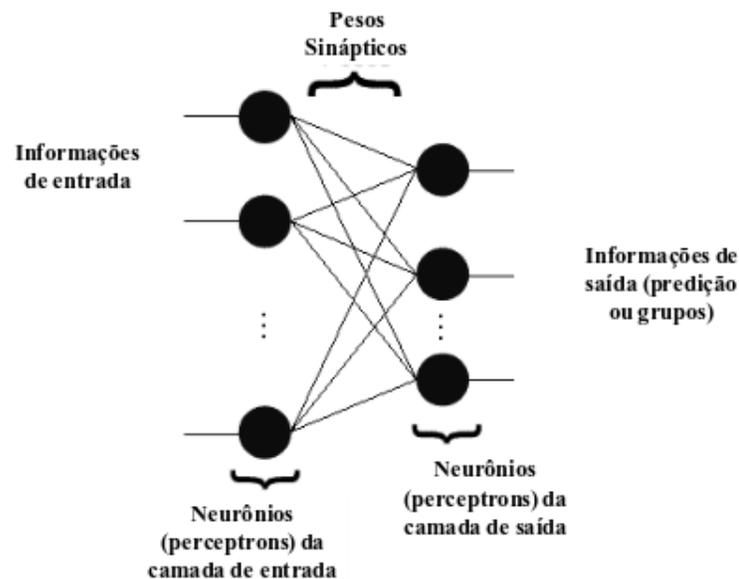
(SAVEGNAGO, 2013).

O esquema ilustrado mostra que:  $x_1, x_2, \dots, x_n$  são os valores de entrada;  $w_1, w_2, \dots, w_n$  são os pesos sinápticos (ponderados);  $\Sigma$  é a função de soma ponderada dos valores de entrada  $x$  com os respectivos pesos sinápticos  $w$ ;  $\theta$  é o valor do limiar de ação do neurônio (BRAGA; CARVALHO; LUDEMIR, 2007).

Foi descoberto pelo psicólogo Hebb (1949), que a aptidão de aprendizagem em redes neurais biológicas é oriunda da alteração das conexões (sinapses) entre os neurônios. O aprender ocorre quando se tem um reforço na conexão neuronal, ou seja, se as células pré e pós-sinápticas forem ativadas. Sua descoberta de aprendizado por reforço das sinapses instigou outros pesquisadores na exploração de novos resultados.

Passado alguns anos Rosenblatt (1958) cria um modelo chamado *perceptron* (Figura 3). O qual é combinado por neurônios de McCulloch-Pitts estabelecidos na forma de camadas e com a possibilidade de ajustar os pesos sinápticos. O *perceptron* foi concebido utilizando um único neurônio e limita-se na ao realizar classificação de padrões com apenas duas classes e linearmente separáveis.

Figura 3 - Rede neural de perceptrons



Fonte: (RONSENBLATT, 1958)

A camada de saída do *perceptron* pode ser ampliada a fim de incluir neurônios, classificando assim mais de duas classes, porém as classes devem ser linearmente separáveis o que significou na limitação da técnica. As redes neurais pioneiras assim como a de Roseblatt (1958) eram usadas exclusivamente para reconhecer e separar grupos de caracteres.

Para resolver problemas não lineares foram introduzidas uma ou mais camadas de neurônios entre a camada de entrada e a de saída, aplicando funções não lineares nos neurônios (SAVEGNAGO, 2013). Sabendo da dificuldade de treinar redes neurais com essa característica, os pesquisadores Hinton, McClelland e Rumelhart (1988) criaram um algoritmo de treinamento chamado *backpropagation*, que hoje é muito utilizado no treinamento e aprendizado, conhecidas como redes *multilayer perceptron* (MLP).

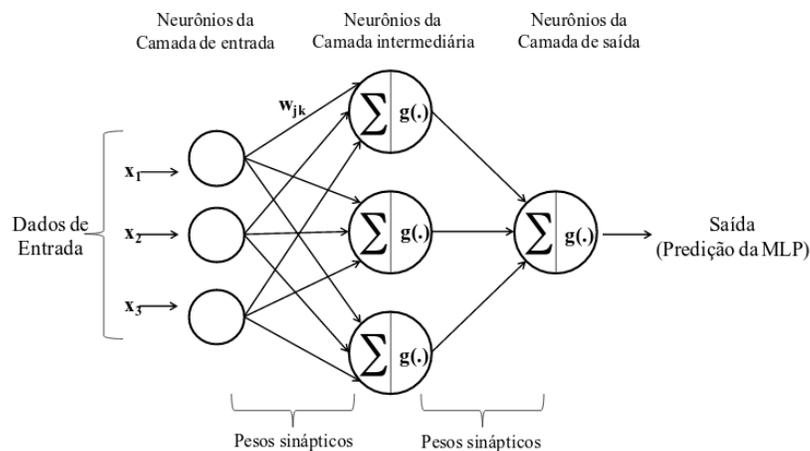
### 3.3 Tipos de Redes Neurais

Como visto na seção anterior a rede *perceptron* é uma das tipologias de rede, composta por uma camada de neurônios de entrada e outra de saída. Estando esta limitada na resolução de problemas linearmente separáveis. Como solução para este tipo foram adicionadas uma ou mais camadas, comumente chamadas de camadas intermediárias ou escondidas.

Assim surgiu o tipo de rede mais utilizada chamada *multilayer perceptron* (MLP) ela é composta por um conjunto de unidades sensoriais (nós de fonte) que equivalem a camada de entrada, uma ou mais camadas ocultas de nós e uma camada de saída de nós. O sinal de entrada se propaga para frente através da rede, camada por camada (HAYKIN, 2001). A figura 4 ilustra o modelo mencionado neste parágrafo.

A aprendizagem desta rede ocorre a partir de exemplos do conjunto de dados. Analogamente como nos seres humanos o aprendizado que a MLP capta do banco de dados é armazenado nas conexões entre os neurônios, chamadas de conexões sinápticas (SAVEGNAGO, 2013). Segundo o autor, semelhantemente aos modelos lineares, as sinapses seriam os ponderadores de modelos que empregam regressão linear, os neurônios da camada de entrada seriam as variáveis preditoras e os neurônios da camada de saída seriam a variável.

Figura 4 - Rede Neural Multilayer Perceptron



Fonte: (SAVEGNAGO, 2013)

A rede (MLP) ilustrada pela figura 4 é composta por três neurônios na camada de entrada, três na camada intermediária e um na camada de saída. Os elementos de entrada são  $x_1$ ,  $x_2$  e  $x_3$ . Os pesos sinápticos entre os neurônios de camadas adjacentes são representados por  $w_{jk}$  em que  $j$  são os neurônios da camada de entrada e  $k$  são os neurônios da camada intermediária;  $\sum$  é a soma ponderada dada por  $\sum_{k=1}^n x_k w_{jk}$  e  $g(\cdot)$  é a função de ativação (BRAGA et al., 2013).

A informação da camada de entrada avaliada pelos pesos sinápticos entre os neurônios oriundos da camada escondida e de entrada é estabelecida pela atividade em cada neurônio da camada escondida de uma MLP (SILVA, 2002).

As respostas que são geradas pelos neurônios de camada intermediária são dependentes das atividades dos neurônios da camada de saída da MLP sendo ponderada pelos pesos sinápticos entre os neurônios da camada de saída e a intermediária (HINTON, 1992).

Para que uma RNA seja um aproximador universal de qualquer função contínua é necessário uma rede com uma camada intermediária (CYBENKO, 1989). Já para permitir a aproximação de qualquer função, contínua ou não é preciso utilizar duas camadas intermediárias (CYBENKO, 1988). Utilizando este tipo de arquitetura é que a não linearidade foi inserida nas redes neurais, no entanto foi indispensável encontrar uma forma de treinar esse tipo de rede neural (SAVEGNAGO, 2013). Com o desenvolvimento do algoritmo *backpropagation* foi possível corrigir os pesos sinápticos por gradiente descendente, que para ser utilizado necessita de uma função de ativação contínua, diferenciável e preferencialmente não decrescente (RUMELHART; HINTON; WILLIAMS, 1988). Assim funções logística e funções sigmoidais são muito empregadas nas redes MLP por atenderem as exigências apresentadas, além de apresentarem não linearidade.

### 3.4 Funções de ativação

São intervenções básicas de uma RNA somar os sinais que entram multiplicados pelos pesos e aplicar uma função de transferência para determinar a saída do neurônio (FERREIRA, 2004). Em termos matemáticos segundo Haykin (2001) essa função de soma é denominada função sináptica ( $v_k$ ), demonstrada pela Equação 1.

$$v_k = b_k + \sum_{j=1}^n w_{jk} x_j \quad (1)$$

onde,  $b_k$  é o valor de um neurônio denominado “bias”,  $x_j$  são as variáveis da camada de entrada e  $w_{jk}$  são os pesos sinápticos entre o neurônio  $j$  da camada de entrada e

$k$  da camada intermediária. Posteriormente os sinais são transformados pela função de ativação definida pelo termo  $f(\cdot)$  responsável pela saída do neurônio. São identificadas pela literatura três tipos básicos de funções de ativação (HAYKIN, 2001; BRAGA, 2000; MATHIAS, 2006) :

1. *Função Sinal*: para este tipo de função, ilustrada na Figura 5a, temos

$$f(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (2)$$

Assim, a ativação de um neurônio  $k$  que usa este tipo de função de ativação é dada por

$$f(v) = \begin{cases} 1 & \text{se } v_k > 0 \\ 0 & \text{se } v_k \leq 0 \end{cases} \quad (3)$$

onde  $v_k$  é o nível de ativação interno do neurônio, definido na Equação 1.

2. *Função Linear por partes*: definida pela Equação 4, ilustrada no gráfico da (Figura 5b). A unidade dentro da região linear é assumida como fator de amplificação. Sendo assim esta forma pode ser descrita como uma proximidade de amplificador não-linear.

$$f(v) = \begin{cases} 1, & v \geq +\frac{1}{2} \\ v, & +\frac{1}{2} > v > -\frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases} \quad (4)$$

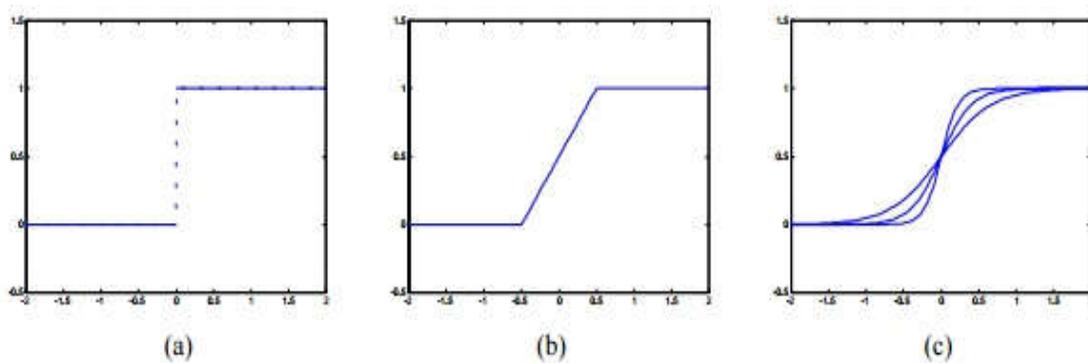
3. *Função Sigmóide*: é o modelo de função de ativação mais utilizado em aplicações com redes neurais. O gráfico desta função, ilustrado na Figura 5c, fornece um comportamento de balanceamento adequado entre linear e não-linear, sendo ainda estritamente crescente. Um exemplo de função sigmóide é a função logística, definida pela Equação 5. Onde  $a$  é o parâmetro de inclinação da função sigmoidal. Variando o parâmetro  $a$  podemos obter funções sigmoidais com diferentes inclinações, como mostrado na Figura 5c.

$$f(v) = \frac{1}{1 + e^{-av}} \quad (5)$$

Em muitas situações é desejável uma função sigmoïdal que varie entre  $-1$  e  $+1$ . Nestas ocasiões, uma função muito empregada é a tangente hiperbólica, definida por.

$$f(v) = \operatorname{tgh}\left(\frac{v}{2}\right) = \frac{1 - e^{-v}}{1 + e^{-v}} \quad (6)$$

Figura 5 - Principais funções de ativação utilizadas nas redes neurais



Fonte: (ZUBEN, 2016)

### 3.5 Processo de aprendizagem

O aprendizado é a capacidade de se adaptar, modificar e melhorar as respostas e comportamentos, sendo portanto uma das características fundamentais dos seres chamados de inteligentes, sendo eles humanos ou não (OSÓRIO; BITTENCOURT, 2000).

Na temática computacional a aprendizagem da máquina tenta fazer com que os programas de computador "aprendam" com os dados que eles "estudam". Sendo assim os programas poderão tomar decisão diferentes fundamentadas nas especificidades dos dados estudados (GUIMARÃES, 2005).

A respeito das RNA, segundo Haykin (2001):

"Aprendizagem é um processo pelo qual os parâmetros livres (pesos sinápticos) de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira na qual a modificação dos parâmetros ocorre".

A definição do autor sobre o processo de aprendizagem implica a seguinte sequência de eventos por ele apontada:

1. A rede neural é estimulada por um ambiente.
2. A rede neural sofre modificações nos seus parâmetros como resultado dessa estimulação.
3. A rede neural responde de uma maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna.

Uma gama de métodos para treinamento de redes foram elaborados, podendo ser agrupados em dois paradigmas principais: aprendizado supervisionado e aprendizado não supervisionado. Nas duas próximas seções os mesmos serão detalhados.

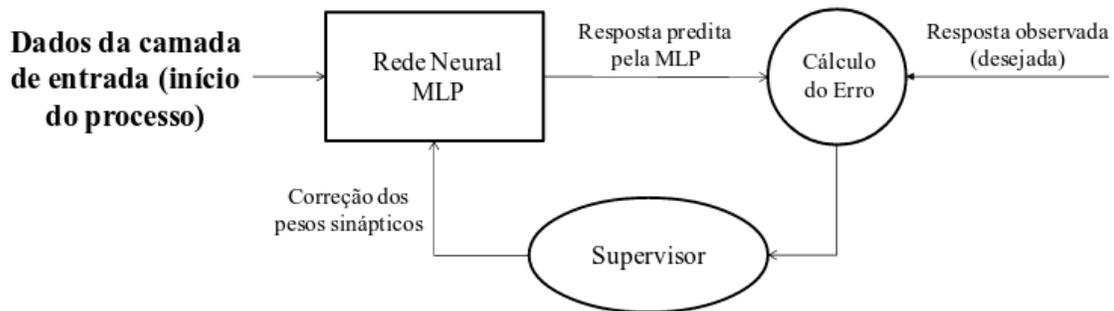
### **3.6 Aprendizado supervisionado**

Nesta aprendizagem o usuário utiliza de um comportamento de referência preciso, que ele pretende treinar a rede. Para isso é necessário que ele mensure a diferença entre os comportamentos atuais e futuros, assim poderá corrigir os pesos de modo que ocorra a redução do erro (OSÓRIO; BITTENCOURT, 2000).

O objetivo principal deste tipo de aprendizado é ajustar os parâmetros da rede neural, de forma que encontre a melhor associação entre as variáveis de entrada e de saída. A saída da rede é predita comparada com a saída que o supervisor deseja, o mesmo irá receber as informações referente aos erros da simulação. Este processo é chamado de ciclo de iteração (Figura 6), em cada ciclo as repostas devem ser comparadas, a fim de ajustar os pesos sinápticos e minimizar o erro de previsão (SAVEGNAGO, 2013).

É considerado como principal desvantagem do aprendizado supervisionado a ausência do supervisor, a rede neural não conseguirá aprender com novas situações não abrangidas pelos exemplos do treinamento da rede (HAYKIN, 2001).

Figura 6 - Aprendizado supervisionado de uma rede neural Multilayer Perceptron



Fonte: (SAVEGNAGO, 2013).

### 3.7 Aprendizado não supervisionado

É quando existe a ausência de supervisão no aprendizado, somente estão disponíveis para a rede os padrões de entrada, oposto do aprendizado supervisionado que possui no conjunto do treinamento pares de entrada e saída (BRAGA, 2000).

Em função dos critérios internos da rede é que os pesos são transformados, como por exemplo, a repetição de padrões de ativação em paralelo de vários neurônios. Os resultados obtidos por esse aprendizado comportam-se usualmente como técnicas de análise de dados empregadas na estatística (OSÓRIO; BITTENCOURT, 2000).

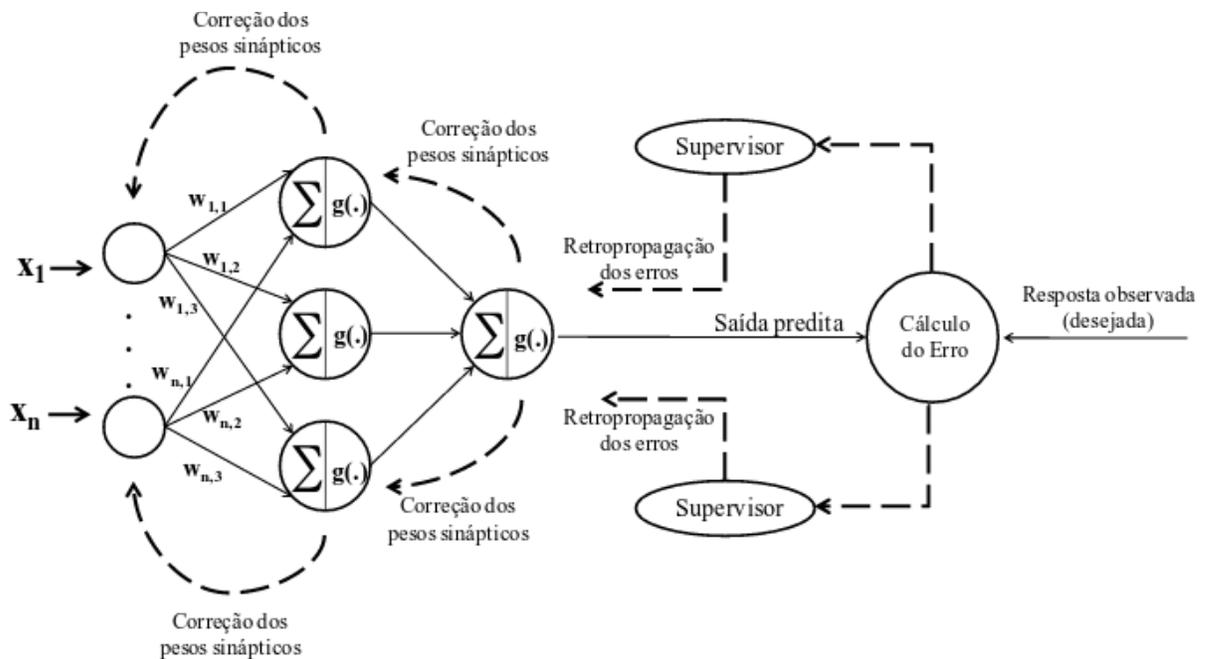
É preciso considerar dois aspectos para este aprendizado, o primeiro é a viabilidade de utilização apenas quando ocorrem repetições dos padrões de informação, tornando-os redundantes, o segundo diz respeito a possibilidade de não existir um supervisor para "ensiná-lá" a buscar padrões (SAVEGNAGO, 2013).

### 3.8 Algoritmo *backpropagation*

O algoritmo backpropagation foi proposto inicialmente na década de sessenta e depois redescoberto inúmeras vezes, todos os métodos de otimização precisam calcular o seu erro utilizando um algoritmo de treinamento específico, o método em questão é particularmente o mais utilizado nos dias de hoje (VICENTE, 2002).

Conforme Savegnago (2013) o método é fundamentado na regra de aprendizado por correção de erro, sendo retroalimentado pelo erro gerado na predição. O seu funcionamento consiste basicamente em, um passo para frente e um passo para trás ao longo das camadas conforme ilustra a Figura 7.

Figura 7 - Funcionamento do algoritmo *backpropagation*



Fonte:(SAVEGNAGO, 2013)

Os pesos sinápticos são fixos no passo dado para frente e as informações da camada de entrada são propagadas camada por camada, logo após ocorre a predição dos valores na camada de saída. Os pesos são ajustados conforme a regra de aprendizado pela correção do erro no passo para trás. O erro é calculado pela subtração da resposta predita pela resposta desejada, depois é propagado para a rede neural novamente com os ajustes sinápticos melhorando as predições na próxima iteração (HAYKIN, 2013; SEVEGNAGO, 2013)

#### 4 METODOLOGIA

O presente trabalho emprega redes neurais artificiais do tipo *Feedforward Backpropagation* para prever o rendimento dos bovinos, o qual será avaliado pelas seguintes variáveis: Peso de Fazenda (PF) e Bonificação (BN). Para realizar a previsão desejada foi utilizado um banco de dados disponibilizado pela Embrapa Pecuária Sul, conforme citado no início do trabalho (delimitação do tema), o qual contém uma série de variáveis zootécnicas e de manejo para uma determinada quantia de bovinos.

A seleção e classificação das variáveis a serem inseridas na matriz de entrada da RNA é uma importante etapa inicial, visto que a RNA irá reconhecer padrões e comportamento das mesmas, visando prever, como uma maior precisão, os objetivos definidos.

A criação, configuração e treinamento da RNA é implementada após a etapa inicial mencionada anteriormente. A configuração da rede influencia diretamente no resultado desejado, sendo assim, a escolha do número de camadas intermediárias, número de neurônios, função de treinamento, função de aprendizado, função de transferência e performance são os principais fatores preponderantes para convergência adequada. O treinamento, teste e validação da RNA irá avaliar se a configuração proposta foi adequada, através dos resultados gerados pelos mesmos, caso contrário, ou a RNA não se mostrou eficaz para problemática desejada, ou deve-se optar por uma nova configuração e realizar este procedimento novamente ou adicionar na matriz de entrada variáveis que possuam uma melhor correlação com o objetivo desejado.

Por fim, depois de treinada a RNA e demonstrada boa generalização, dá-se início a simulação da mesma. Para isso adiciona-se uma matriz de amostra (matriz composta por um conjunto de dados de amostra, contendo o mesmo n° de variáveis da matriz de entrada). Na sequência executa-se a simulação da RNA, a qual irá gerar o resultado da previsão desejada para os respectivos dados da amostra. Com isso, os resultados da simulação podem ser comparados com os valores reais das variáveis de interesse, evidenciando se os mesmos foram satisfatórios e se apresentaram um erro dentro da faixa desejada.

Devido à quantidade de etapas necessárias para realizar a previsão desejada, a metodologia foi dividida em três segmentos descritos a seguir:

- **Etapa I:** Seleção e classificação dos dados de entrada da RNA;
- **Etapa II:** Criação, configuração, treinamento, teste e validação da RNA;
- **Etapa III:** Simulação da RNA e processamento dos resultados.

#### 4.1 Seleção e classificação dos dados de entrada da RNA (Etapa I)

Neste subcapítulo os dados (variáveis zootécnicas) disponibilizados pelo produtor, serão selecionados, organizados e classificados em variáveis qualitativas (nominal ou ordinal) e quantitativas (contínua ou discreta). A Tabela 1 evidencia todas variáveis zootécnicas disponibilizadas, com sua respectiva classificação.

Tabela 1 - Classificação das variáveis

<b>Variáveis</b>	<b>Quantitativa Contínua</b>	<b>Quantitativa Discreta</b>	<b>Qualitativa Nominal</b>	<b>Qualitativa Ordinal</b>
Preço final (R\$)	X			
Bonificação (R\$)	X			
Preço Balcão (R\$)	X			
Sexo			X	
Peso de carcaça (Kg)	X			
Raça			X	
Maturidade		X		
Acabamento		X		
Tipo do animal			X	
Premiação			X	
Mês de Abate				X
Mês de nascimento				X
Idade de abate (meses)		X		
Mês de desmame				X
Desmame (P ou C)			X	
Peso de desmame (Kg)	X			
Peso de fazenda (abate)	X			
GMD	X			
Rendimento de Fazenda	X			
Preço por kg carcaça (R\$)	X			

Fonte: Autoria Própria, 2016.

As informações apresentadas na Tab. 1 demonstram a descrição individual de 1013 bovinos presentes no banco de dados, desde o nascimento até o abate. Devido à quantidade de informações apresentadas e visando a criação de um sistema robusto e simplificado para que produtores rurais possam utilizar, foram selecionadas apenas variáveis que sejam de fácil acesso ao mesmo. Ao realizar as análises preliminares notou-se que o modo mais coerente à proceder qualquer estudo no banco de dados da pesquisa seria separando os dados em machos e fêmeas porque distinguem-se, principalmente nas idades de abate, tornando diferentes as características a serem estudadas pra os sexos dos animais. Desta maneira, na Tab. 2 são apresentadas as variáveis selecionadas para compor a matriz de entrada e alvo da RNA, a qual se escolheu empregar somente os dados dos bovinos machos que totalizam 451 cabeças, juntamente com suas respectivas unidades de medida.

Tabela 2 - Variáveis selecionadas nos modelos

<b>Variável</b>	<b>Unidade de Medida</b>	<b>Matriz da RNA</b>
Mês de nascimento	Mês	Entrada
Idade de abate	Mês	
Mês de desmame	Mês	
Tipo de desmame	Convencional ou Precoce	
GMD	kg/dia	
Peso de desmame	kg	
Percentual de Bonificação	%	Alvo
Peso de fazenda	Kg	

Fonte: Autoria Própria, 2016.

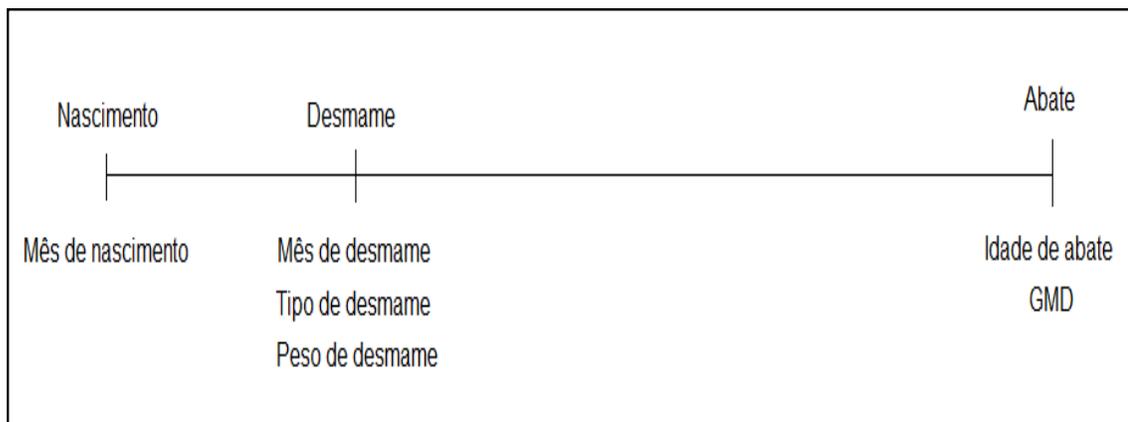
A elaboração da Tab.2 atende ao primeiro objetivo específico deste trabalho, visto que sem a produção da mesma nesta etapa seria impossível dar sequência ao estudo, justificando assim a apresentação deste resultado na metodologia.

Para empregar a metodologia de RNA é necessário dividir os dados da matriz de que serão utilizados como “entradas” e “alvos”. Os dados de entrada dizem respeito às variáveis, Mês de nascimento, Mês de desmame, Tipo de desmame, Peso de desmame, Idade de abate e GMD. A matriz alvo, matriz na qual se deseja

descobrir o resultado, é composta pelas variáveis: Peso de fazenda e Percentual de Bonificação, respectivamente.

Outra justificativa para a escolha destes dados é necessidade de verificar como as variáveis entre o nascimento e desmame (Mês de nascimento, Mês de desmame, Tipo de desmame e Peso de desmame) influenciam no peso de fazenda e percentual de bonificação. Além disso, adicionou-se à matriz de entrada a variável GMD, a qual possui grande importância, pois descreve o ganho médio diário do animal desde o nascimento até o abate. A Figura 8 ilustra a variáveis utilizadas na matriz de entrada desde o nascimento do bovino até o abate.

Figura 8 - Variáveis utilizadas na matriz de entrada desde o nascimento do bovino até o abate



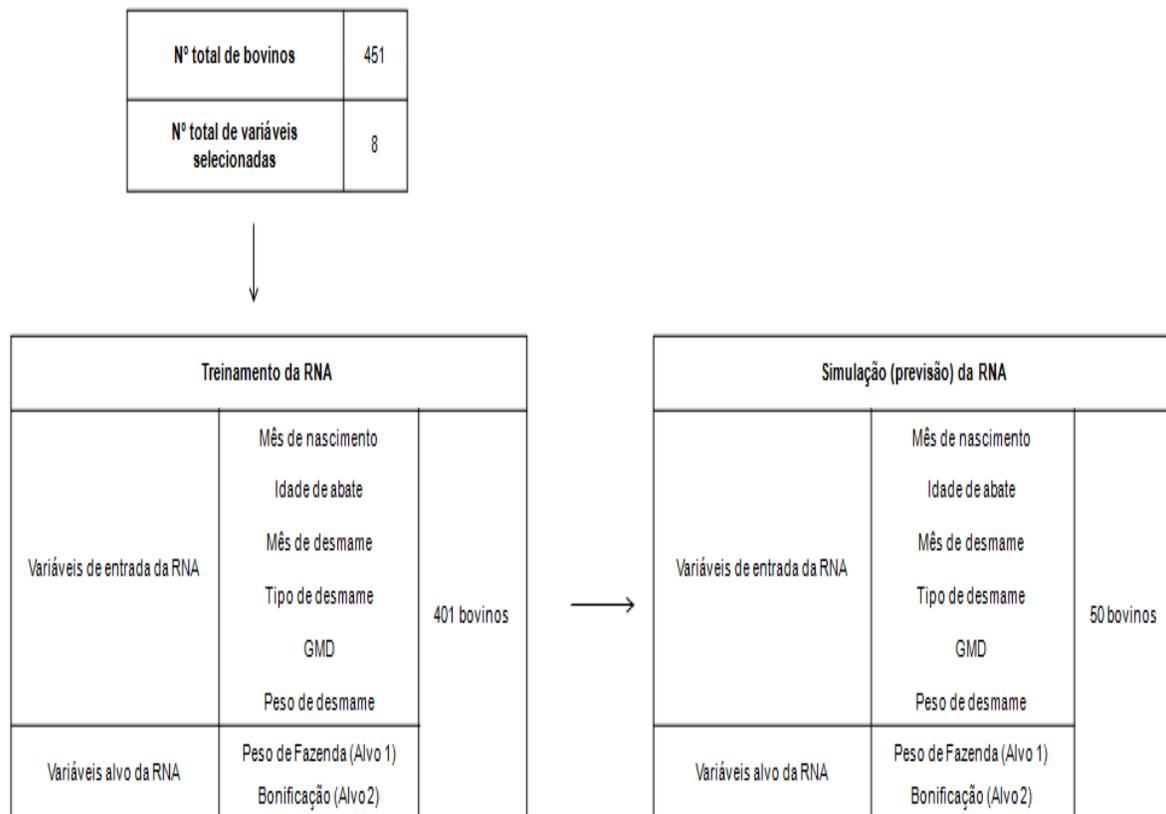
Fonte: Autoria Própria, 2016.

Na sequência o conjunto de dados da RNA foi dividido em duas partes, a primeira parte diz respeito aos dados de treinamento da rede, a qual é composta das seis variáveis (matriz de entrada) de 401 bovinos. A segunda parte destina-se para criação de uma matriz de amostra que será utilizada para realizar a previsão após o treinamento da RNA ter sido concluído, sendo assim, separou-se uma amostra de 50 bovinos contendo as mesmas características da matriz de entrada. Resumidamente, 401 amostras de bovinos machos contendo seis variáveis (matriz de entrada) que os caracterizam serão empregadas para treinar a RNA e 50 amostras com a mesma estrutura serão utilizadas para realizar a previsão da mesma.

No capítulo 5 (Resultados e Discussões) será apresentado graficamente o comportamento individual das variáveis selecionadas para os respectivos bovinos (Tab.2), atendendo ao segundo objetivo específico deste trabalho.

Todos os dados que serão utilizados pela RNA foram normalizados entre o intervalo de -1 a 1, com o objetivo de diminuir o tempo de processamento e evitar que os pesos sinápticos tenham valores muito altos, gerando o mau desempenho da rede neural, Haykin (2001). Para isso empregou-se a função *mapminmax*, do software Matlab®, que normaliza todos os dados de cada variável. A Figura 10 ilustra resumidamente como foram separados os dados de treinamento, previsão e alvo.

Figura 9 - Organização dos dados da RNA



Fonte: Autoria Própria, 2016.

## 4.2 Criação, configuração, treinamento, teste e validação da RNA (Etapa II)

O presente módulo utiliza o software Matlab®, que apresenta uma série de comandos para criar, configurar e simular uma RNA, além de um *toolbox* (pacote) denominado *nntool* que serve exatamente para esta finalidade. Neste estudo optou-se por trabalhar com linhas de comando, visando criar um *script* que importe dados do Excel® e execute as simulações da RNA.

As informações selecionadas no subcapítulo 4.1 foram previamente separadas no programa Excel e importadas para o Matlab®, através da opção “*xlsread*”. Em seguida os dados foram separados em dados de treinamento e simulação (vide Fig. 10), os quais, conforme citado anteriormente foram normalizados.

As variáveis de entrada, que formam a matriz intitulada “entrada”, contêm as seis características dos 401 bovinos (6 linhas por 401 colunas). A matriz “alvo” contêm as variáveis alvo, neste caso o Peso de Fazenda (PF) e a Bonificação (BN), porém elas foram separadas em duas matrizes (alvo PF e alvo BN), cada uma com dimensão 1 x 401, sendo o valor do PF e BO para cada um dos 401 bovinos, respectivamente. Essas três matrizes serão empregadas para realizar o treinamento da RNA, onde o conjunto de dados de entrada tem por objetivo reconhecer padrões (correlações) entre eles para atingir um determinado objetivo, neste caso, o alvo.

Com dimensões de 6 x 50, a matriz “Amostra”, contendo os dados (6 características) de 50 bovinos, foi criada para que seja possível realizar a previsão desejada (PF e BO), ou seja, um conjunto de dados novos contendo as mesmas características dos dados de entrada é adicionado à rede, uma vez que a mesma já foi treinada e validada dar-se-á início a previsão.

A configuração adequada da RNA é muito importante para ocorra uma boa generalização, Haykin (2001). Ainda conforme o autor, uma camada oculta é suficiente para realizar uma previsão e a adição de mais camadas pode fazer com que a rede não consiga generalizar de forma adequada, fundamentando assim a escolha de uma camada oculta para a RNA.

A função de treinamento escolhida foi a função de *Levenberg-Marquardt backpropagation* (*trainlm*), sendo está uma função de treinamento da RNA que atualiza os valores de peso e bias de acordo com a otimização de Levenberg-Marquardt, Matlab (2016). Segundo o tutorial do programa e da literatura existente,

esta função é altamente recomendada como uma primeira escolha de algoritmo supervisionado, porém exige mais memória do que outros algoritmos. Devido a estes fatores e a quantidade de trabalhos existentes na literatura empregando esta função de treinamento, optou-se por utilizá-la neste trabalho.

A função de aprendizagem selecionada para a RNA foi a Gradiente Descendente de Momento (*learngdm*), que calcula a mudança de peso para um determinado neurônio a partir do neurônio de entrada e o erro, ou seja, a função vai variando os pesos até atingir um erro mínimo estipulado pelo usuário. A função de performance adotada foi a de erro quadrático médio (*mean square error* - MSE), a qual monitora o treinamento da rede durante a simulação e também tem por objetivo alcançar um erro mínimo estipulado pelo usuário.

Funções de transferência ou ativação do tipo sigmoidal são ideais para problemas deste tipo, onde há duas ou mais camadas na RNA. Optou-se por escolher a função de transferência tangente hiperbólica sigmoidal (*tansig*), que limita a amplitude do sinal de saída do neurônio para algum valor finito, geralmente o intervalo normalizado entre -1 a 1.

Outra consideração importante a ser feita é referente à escolha do número de neurônios. Para selecionar o número de neurônios na camada intermediária (ou oculta) foi realizada a variação do mesmo na estrutura da RNA, com o objetivo de encontrar o menor erro quadrático médio (MSE) durante o treinamento, validação e teste da rede. Sendo assim, inicialmente selecionou-se, na camada intermediária, a mesma quantidade de variáveis de entrada, neste caso seis, as quais foram variadas em pares até o dobro do número de entradas (12) e a camada de saída possui um neurônio (mesmo número de saídas, neste caso um, visto que cada saída será simulada individualmente). Empregou-se esta metodologia devido à importância de escolher um número adequado de neurônios na camada oculta, onde um pequeno número de neurônios pode não ser capaz de solucionar a RNA, bem como um número grande pode causar problemas na convergência dos resultados e demora no tempo de processamento, Haykin (2001). A Tabela 3 descreve as variações na estrutura da rede e o MSE registrado pela mesma.

Tabela 3 - Desempenho do treinamento da RNA em função do número de neurônios

<b>Caso</b>	<b>Estrutura</b>	<b>MSE</b>
<b>1</b>	6-6-1	3.97e-04
<b>2</b>	6-8-1	8.10e-04
<b>3</b>	6-10-1	4.10e-04
<b>4</b>	6-12-1	2.34e-04

Fonte: Autoria Própria, 2016.

Os critérios de parada ou convergência da rede são estipulados pelo usuário, neste caso os mais utilizados são: número de ciclos (iterações) e erro pretendido. Foram estipulados os valores de 500 iterações e erro pretendido 0 (zero), porém existem mais critérios de parada, os quais podem ser verificados em Matlab (2016).

Depois de finalizada configuração, dá-se início ao treinamento da rede e se a mesma apresentar boa generalização e resultados satisfatórios pode-se seguir para as etapas seguintes (simulação da RNA e processamento dos resultados), caso contrário o usuário deve rever sua configuração. Para analisar o erro do treinamento e posteriormente da previsão, utilizou-se a Equação 5, que calcula o erro percentual para ambos os casos.

$$E = \frac{(R - S)}{R} \times 100 \quad (\%) \quad (5)$$

onde, E é o erro percentual, R é o dado real e S é o dado simulado.

### **4.3 Simulação da RNA e processamento dos resultados**

Conforme descrito anteriormente, após efetuar o treinamento e apresentar convergência, dá-se início a simulação para prever as variáveis de interesse. Ao final os resultados gerados podem ser demonstrados graficamente, também utilizando comandos específicos do Matlab® para isso.

Os valores previstos do PF e BN serão comparados com os resultados reais registrados no banco de dados do produtor, sendo possível analisar a robustez do modelo proposto e se as variáveis selecionadas conseguiram captar os padrões de

reconhecimento necessários para realizar uma previsão satisfatória e com menor erro possível.

Na sequência, será demonstrado o passo-a-passo do *script* com seus respectivos comentários, descrevendo o papel de cada comando empregado. É importante lembrar que os alvos foram mudados manualmente no *script*, inicialmente o alvo 1 (PF) e posteriormente o alvo 2 (BN). Além disso, para que fosse possível desenvolver essa metodologia todas as dúvidas e conhecimento adquiridos sobre os comandos foram retirados do site do Matlab® (MATLAB, 2016).

```
clear all      % Limpar toda a área de trabalho.
clc           % Limpar toda a janela de comandos.

%%
DADOS= xlsread
('C:\Users\Cainã\ATubeCatcher\Desktop\mat\DADOS.xlsx','A1:QI6'); %Importa a
matriz de entrada do EXCEL.
[DN,PSDN] = mapminmax(DADOS);    %Normalizar os dados da matriz de entrada,
linha por linha.

ALVO1=xlsread ('C:\Users\Cainã\ATubeCatcher\Desktop\mat\PF.xlsx','A1:QI1');
%Importa a matriz Alvo1 (Peso de Fazenda) do EXCEL.
[PF,PSPF] = mapminmax(ALVO1);    %Normalizar dados do Peso de Fazenda
(ALVO1).

ALVO2=xlsread
('C:\Users\Cainã\ATubeCatcher\Desktop\mat\BON.xlsx','A1:QI1');%Importa a
matriz Alvo2 (Bonificação) do EXCEL.
[BN,PSBN] = mapminmax(ALVO2);    %Normalizar dados de Bonificação (ALVO2).

%%
%Selecionando as 401 variáveis de treinamento da RNA.
E=DN(1:6,1:401);                %Entrada

%Selecionando os 401 variáveis alvo1 da RNA.
A1=PF(:,1:401);                 %Alvo1
normalizado.
A1DESN = mapminmax('reverse',A1,PSPF); %Alvo1
desnormalizado, para gerar os resultados finais.

%Selecionando os 401 variáveis alvo2 da RNA.
A2=BN(:,1:401);                 %Alvo2
A2DESN = mapminmax('reverse',A2,PSPF); %Alvo2
desnormalizado, para gerar os resultados finais.

%%
%Selecionando os 50 variáveis da previsão da RNA.
AM=DN(1:6,402:451);            %Amostra.

%Selecionando os 50 variáveis da previsão do alvo1 da RNA.
PA1=PF(:,402:451);             %Previsão do Alvo1
(PA1), sendo este o dado real.
PA1DESN = mapminmax('reverse',PA1,PSPF); %PA1
```

```

desnormalizado, para gerar os resultados finais.

%Selecionando os 50 variáveis da previsão do alvo2 da RNA.
PA2=BN(:,402:451); %Previsão do
Alvo2, , sendo este o dado real.
PA2DESN = mapminmax('reverse',PA2,PSPF); %PA2
desnormalizado, para gerar os resultados finais.
%%
%Inicialização da RNA
net=newff(E,A1,[12],{'tansig' 'tansig'},'trainlm','learngdm','mse');
%criação da RNA do tipo FFB.
%[12] é o número de neurônios da camada intermediária (oculta).
%{'tansig' 'tansig'} são as funções de transferência da camada
intermediária e de saída, respectivamente.
%'trainlm' é a função de treinamento escolhida, neste caso a função
Levenberg-Marquardt backpropagation.
%'learngdm' é a função de aprendizado escolhida, neste caso a Função de
Gradiente Descendente de momento.
%'mse' é a função de performance, a qual calcula o erro quadrático médio da
RNA.

%Critérios de parada .
net.trainParam.epochs = 500; %Número máximo de épocas de treinamento.
net.trainParam.goal = 0; %Erro desejado.
net.trainParam.show = 25; %Número de iterações que aparece na tela.
view(net); %Visualizar a RNA.
%%
%Treinamento e simulação da RNA
net.divideParam.trainRatio = 70/100; %70% dos dados da matriz de entrada
para o treinamento.
net.divideParam.valRatio = 15/100; %15% dos dados da matriz de entrada
para a validação.
net.divideParam.testRatio = 15/100; %15% dos dados da matriz de entrada
para o teste.
[net,tr]= train(net, E, A1); %Treinamento da RNA.
Saida = net(E); %Resultado do treinamento.
errot = Saida - A1; %Erro do treinamento.
figure, ploterrhist(errot); %Plota o histograma do erro de treinamento.
PERFORMANCE=plotperf(tr) %Plota a performance de treinamento.
perf = mse(net,A1,Saida) %Registra o valor do MSE.
figure, ploterrhist(perf) %Plota o histograma do MSE de treinamento.
ST=sim(net, E); %Simulação dos dados de treinamento.
STDESN = mapminmax('reverse',ST,PSPF); %Desnormalizar os dados simulados
do treinamento para gerar resultados.

%Nesta etapa são plotados os gráficos de performance do teste, validação e
treinamento.
%Resultados do teste
tIndT = tr.testInd;
tstTESTE = net(E(:,tIndT));
tstPerformT = perform(net,A1(:,tIndT),tstTESTE)

%Resultados do validação
tVAL = tr.valInd;
tstVAL = net(E(:,tVAL));
tstPerformV = perform(net,A1(:,tVAL),tstVAL)

%Resultados do treinamento
tTRAIN = tr.trainInd;

```

```

tstTR = net(E(:,tTRAIN));
tstPerformTR= perform(net,A1(:,tTRAIN),tstTR)

%Plotando Gráfico de regressão
trOut = Saida(tr.trainInd);
vOut = Saida(tr.valInd);
tsOut = Saida(tr.testInd);
trTarg = A1(tr.trainInd);
vTarg = A1(tr.valInd);
tsTarg = A1(tr.testInd);
plotregression(trTarg,trOut,'Train',vTarg,vOut,'Validation',tsTarg,tsOut,'T
esting') % Gráfico de regressão.

%%
%%Previsão dos 50 elementos
PREVPF=sim(net, AM); %Simulação dos dados de
previsão.
PREVPFDESN = mapminmax('reverse',PREVPF,PSPF); %Desnormalizar os dados
simulados da previsão para gerar resultados.
errop = PA1 - PREVPF; %Erro da previsão.
figure, ploterrhist(errop); %Plota o histograma do erro
da previsão.

%%
%%Plotando resultados desnormalizados.
figure, plot(A1DESN, 'r.-') %Plotar o alvo 1 desnormalizado
na cor vermelha.
hold on %Opção para agrupar duas
figuras em uma.
plot(STDESN,'k-') %Plotar o resultado do
treinamento desnormalizado na cor preta.
figure, plot(PA1DESN, 'r.-') %Plotar a previsão do alvo 1
desnormalizado na cor vermelha.
hold on %Opção para agrupar duas
figuras em uma.
plot(PREVPFDESN,'k-') %Plotar o resultado da previsão
do alvo 1 desnormalizado na cor preta.
%%
ERT=(( (A1DESN-STDESN) ./A1DESN) *100 %Erro percentual do
treinamento.
figure, ploterrhist(ERT) %Plotar histograma de erro
percentual do treinamento.

ERP=(( (PA1DESN-PREVPFDESN) ./PA1DESN) *100 %Erro percentual da previsão.
figure, ploterrhist(ERP) %Plotar histograma de erro
percentual da previsão.

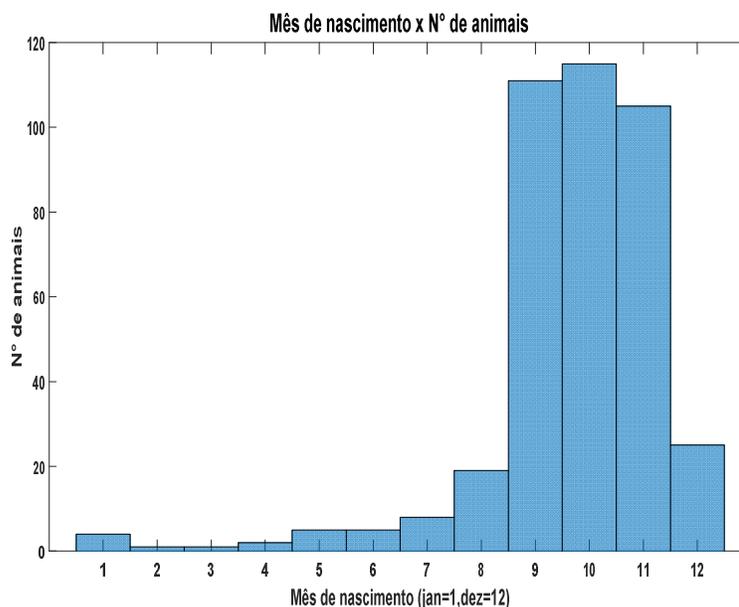
```

## 5 RESULTADOS E DISCUSSÕES

Neste capítulo serão apresentados os resultados e discussões do presente trabalho, que tem como objetivo principal prever o rendimento financeiro dos proprietários de bovinos e ou frigoríficos através da variável Peso de Fazenda (PF) e Bonificação (BN) empregando redes neurais artificiais.

Inicialmente será evidenciado, através de gráficos, o comportamento individual das variáveis selecionadas para os respectivos bovinos (vide Tab.2). As Figuras 10, 11, 12, 13, 14 e 15 ilustram as variáveis o Mês de nascimento, Idade (mês) de abate, Mês de desmame, Tipo de desmame, Peso de desmame e GMD dos 401 animais (bovinos) utilizados na matriz de entrada da RNA.

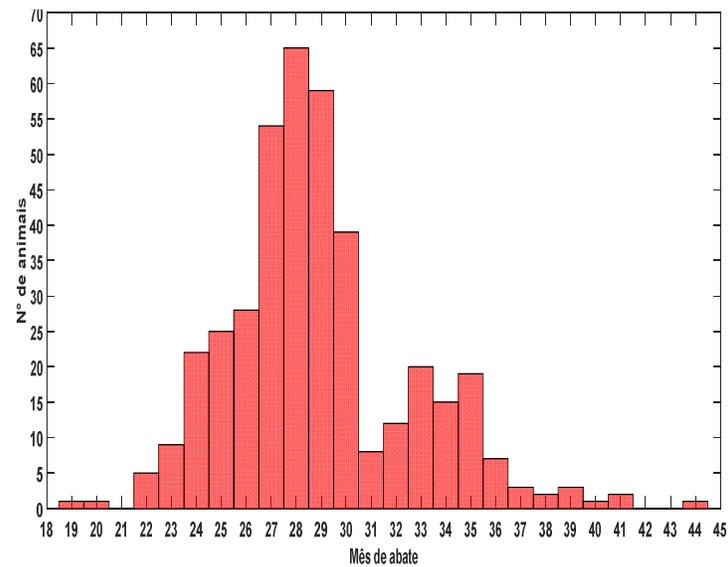
Figura 10 - Mês de nascimento em função do número de animais



Fonte: Aatoria Própria, 2016

Observa-se na Fig. 10 que a grande maioria dos nascimentos dos bovinos ocorreu entre os meses de setembro a novembro, durante a estação da primavera, confirmando a teoria mais tradicional, a qual possibilita adequar a estação de maior crescimento das pastagens com as maiores exigências dos bovinos.

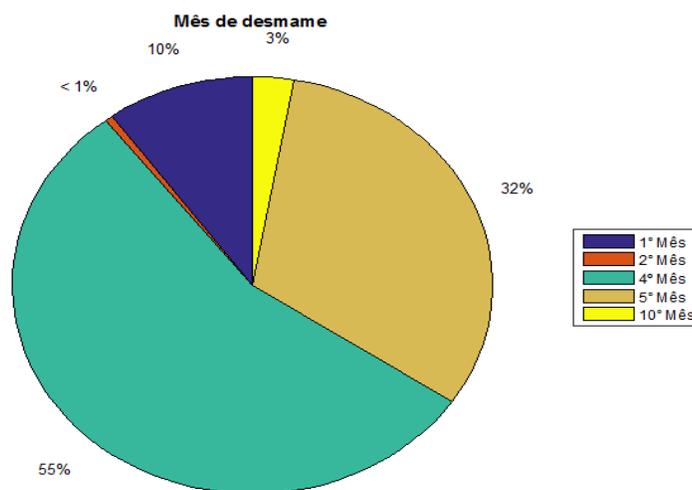
Figura 11 - Mês de abate em função do número de animais



Fonte: Autoria Própria, 2016

Na Figura 11 pode-se constatar que a maioria dos animais foram abatidos entre a faixa de 24 a 30 meses de idade. Comparando este resultado com a indicação encontrada literatura verifica-se que o mesmo está dentro da média, pois segundo Bortoluzzo (2011) para se obter o máximo de lucro possível o pecuarista deve abater os animais próximos de 794 dias de vida (aproximadamente 27 meses).

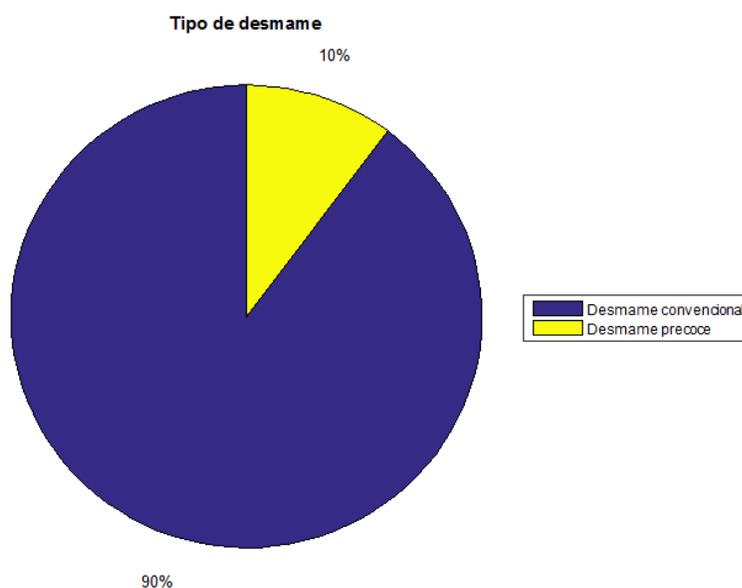
Figura 12 - Mês de desmame (%) para os 401 bovinos



Fonte: Autoria Própria, 2016

O mês de desmame (idade de desmame) apresentado na Fig. 12 mostra que para os 401 bovinos, 87% foram desmamados entre o 4º e 5º mês de vida. O resultado exibido encontra-se dentro do intervalo mencionado na literatura, no qual descreve que os terneiros são desmamados entre 120 e 290 dias (3 a 10 meses) após o nascimento. Porém, o pecuarista optou por desmamar a maioria do rebanho um mês antes dos 205 dias (6 meses) de idade, número médio utilizado pela maioria dos criadores de bovinos.

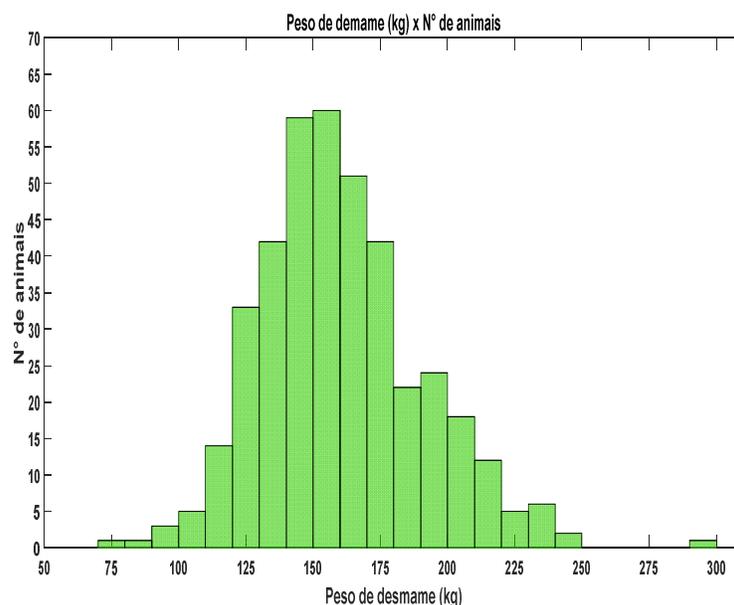
Figura 13 - Tipo de desmame (%) para os 401 bovinos



Fonte: Autoria Própria, 2016

A Figura 13 ilustra o tipo de desmame dos 401 bovinos, dentre os quais 90% são caracterizados como desmame convencional e 10% como desmame precoce. Este resultado evidencia que o terneiro ingeriu, durante a amamentação, os nutrientes necessários para manter um ritmo de ganho de peso adequado, pois na sequência o mesmo será desmamado e inserido em pastagens.

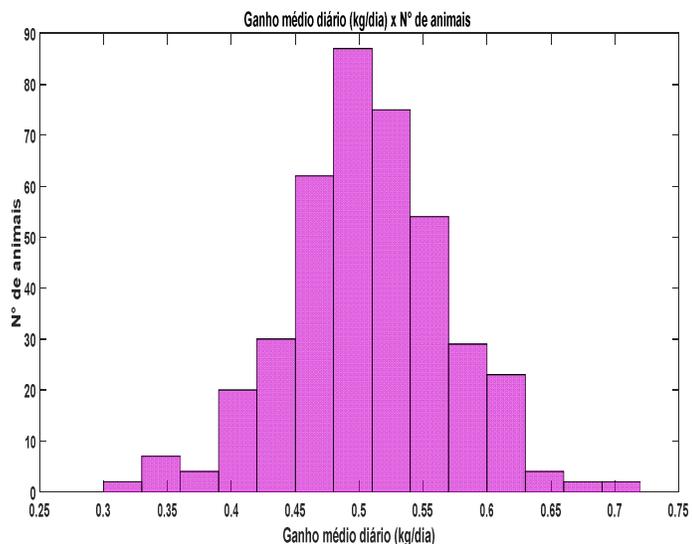
Figura 14 - Peso de desmame em função do número de animais



Fonte: Autoria Própria, 2016

Analisando a Fig. 14, percebe-se que a maioria dos bovinos apresentou peso de desmame entre 120 e 200 kg. Essa variável está diretamente ligada à idade e tipo de desmame, sendo assim a mesma é resultado de ambos os fatores. Contemplando que a grande maioria dos animais teve um desmame convencional e foram desmamados nos períodos corretos, os mesmos possuíam peso superior ao de um terneiro desmamado precocemente (90 kg), EMBRAPA (1996), conforme era esperado.

Figura 15 - GMD em função do número de animais

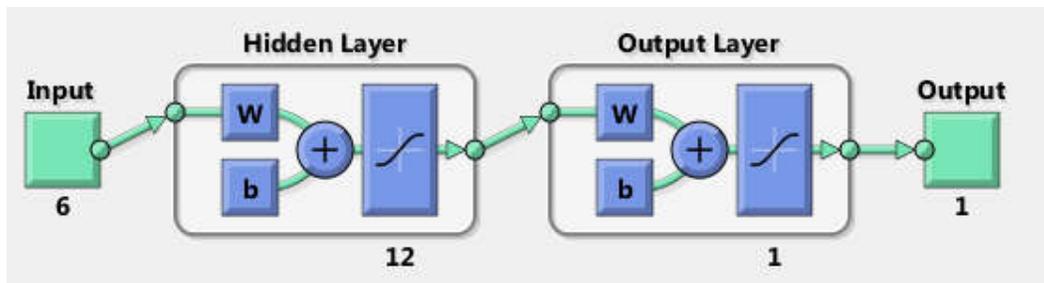


Fonte: Autoria Própria, 2016

Na Figura 15, constata-se que o GMD da maioria dos bovinos está entre 450g a 600g por dia. Esta variável depende de uma série de outras para ser mensurada, porém tendo com base as características apresentadas nas figuras anteriores (Fig. 11 a Fig. 15) destaca-se que os bovinos apresentaram um GMD apropriado, com média em torno de 0,5 kg/dia.

Após apresentado o comportamento das variáveis em razão do número de bovinos em análise, a RNA configurada e apresentando o número de neurônios com o menor erro (MSE), neste caso 12, é ilustrada na Figura 16. Ainda nesta figura, evidencia-se a entrada (*Input*) contendo as 6 variáveis, a camada intermediária ou oculta (*Hidden Layer*), a camada de saída (*Output Layer*) e saída (*Output*).

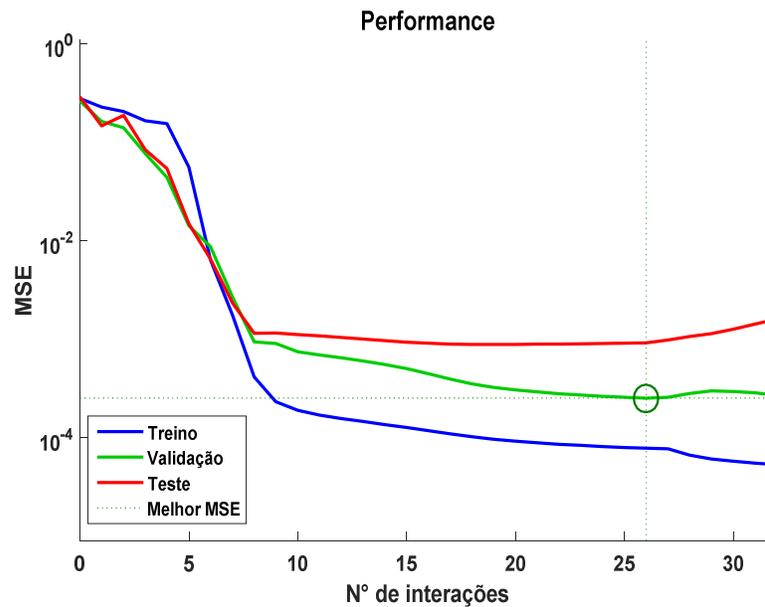
Figura 16 - Rede Neural artificial empregada no trabalho



Fonte: Matlab, 2016

Na Figura 16 vale lembrar que  $w$  corresponde aos pesos sinápticos e  $b$  corresponde as bias, respectivamente. A seguir serão apresentados os resultados da previsão da variável Peso Final, porém inicialmente, na Figura 18, é demonstrada a convergência dos dados de treinamento da RNA para a através do gráfico de performance, levando em consideração os dados de treino, validação e teste, bem como o melhor MSE.

Figura 17 - Performance do treinamento previsão do peso

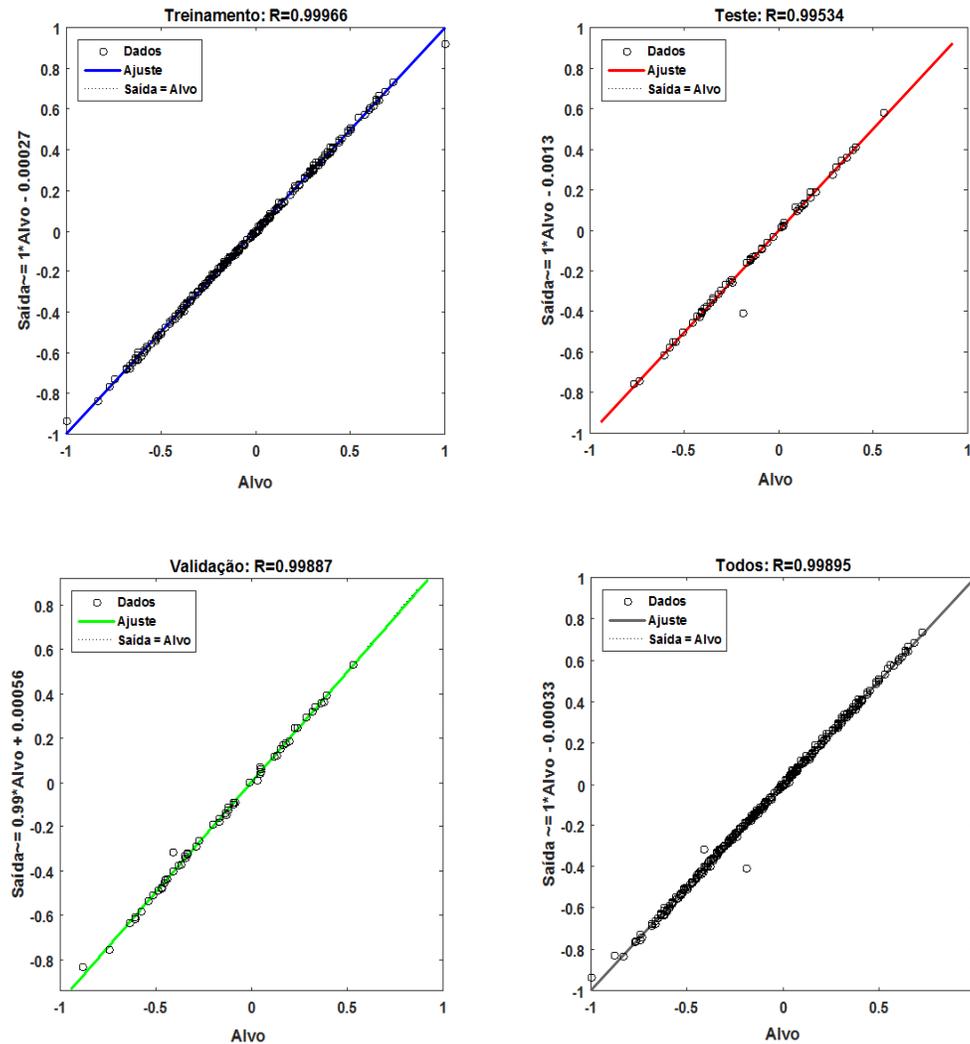


Fonte: Autoria Própria, 2016

O treinamento da RNA convergiu com 32 iterações, conforme demonstra a Figura 17, a qual apresentou um MSE de  $2.34 \times 10^{-4}$ . Pode-se verificar que à medida que varia o número de iterações o erro diminui, ou seja, os pesos da rede estão sendo variados e calibrados de forma a atingir o resultado mais próximo do dado alvo. Outro gráfico gerado através do script diz respeito à regressão dos dados de saída gerada pelo treinamento, validação e teste da RNA e o valor real da saída (alvos ou *outputs*). Através destes gráficos também é possível analisar se a rede obteve boa generalização e se foi possível obter uma boa correlação entre os dados (simulados e reais).

A Figura 18 ilustra os gráficos de regressão entre os dados de treinamento, validação, teste e um conjunto contendo os três (Todos = treinamento + validação + teste) em relação aos alvos (dados reais).

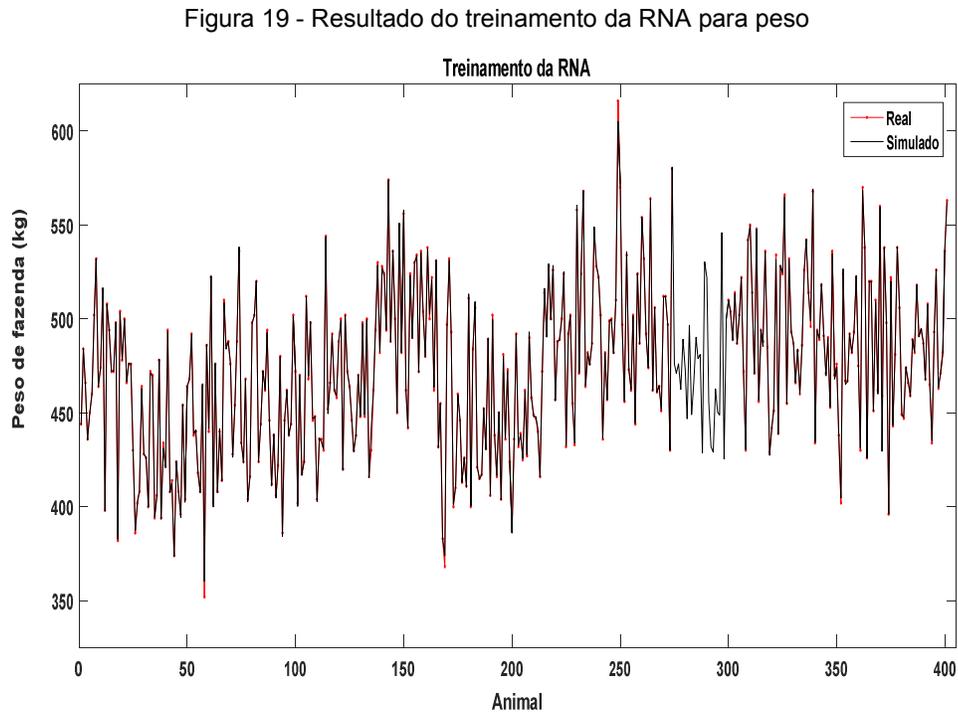
Figura 18 - Gráficos de regressão entre a saída da RNA e o alvo (PF)



Fonte: Autoria Própria, 2016

A linha pontilhada em cada parcela representa o resultado perfeito (Saída = alvo) e a linha sólida representa a melhor linha de regressão ajuste linear entre as saídas os alvos. O valor R é uma indicação da relação entre as saídas e os alvos, se  $R = 1$ , isso indica que há uma relação linear exata entre saídas e o alvo, porém se R é próximo de zero, então não há uma relação linear entre ambos. Nesta simulação, os dados de treinamento indicaram um ótimo ajuste. Os resultados de validação e teste também mostram valores de R muito próximos a um. Sendo assim, pode-se constatar que a rede demonstrou excelente generalização, evidenciando que é possível realizar a simulação desejada para prever o PF com todas as variáveis de entrada selecionadas.

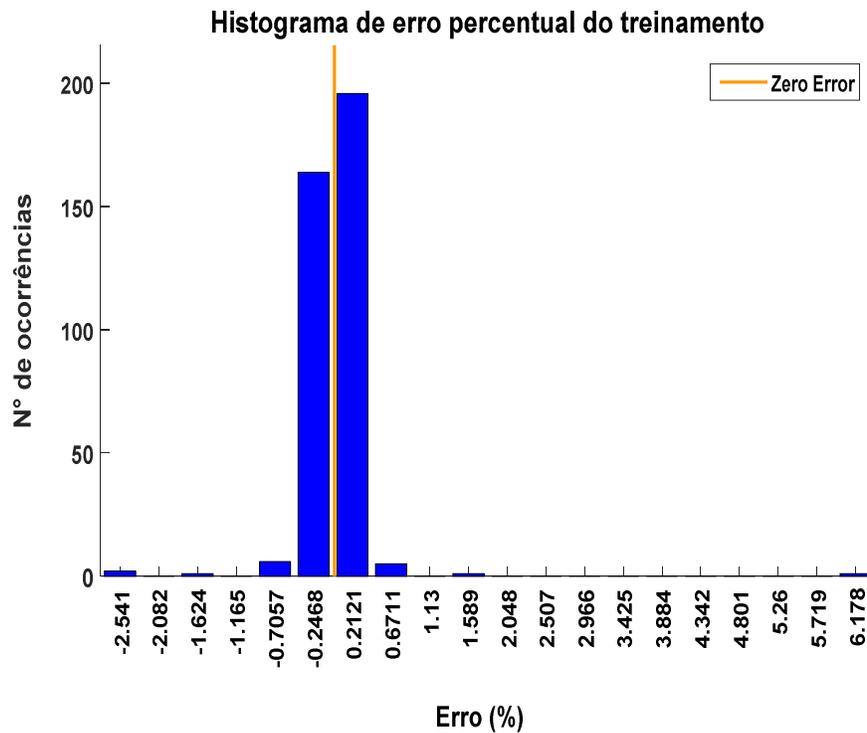
A Figura 19 exibe o resultado do treinamento da RNA (Simulado) comparando-o com o resultado real do peso de fazenda (Real) para os 401 bovinos.



Fonte: Autoria Própria, 2006

Pode-se perceber que o treinamento evidenciou uma grande precisão comparada com o dado real do PF e conforme discutido anteriormente, isso se deve a excelente generalização da RNA. Percebe-se que as maiores diferenças ocorrem nos pontos que possuem valores mais extremos, isso acontece devido ao fato dos dados possuírem poucos valores “fora dos padrões” ou atípicos, fazendo com que esses dados durante o treinamento tenham um erro maior. Na figura 20 é apresentado o histograma de erros percentuais do treinamento.

Figura 20 - Histograma de erro percentual do treinamento

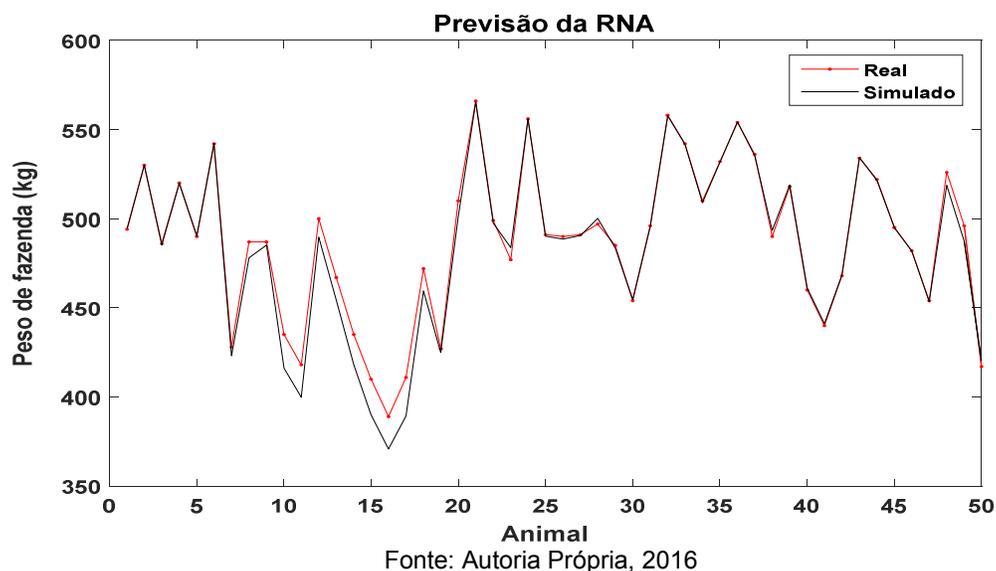


Fonte: Autoria Própria, 2016

Verifica-se que a maioria dos erros percentuais ficou próximo à zero, com maiores variações entre -0,25% e 0,25%. Os erros mais elevados ficaram em torno de 6%, porém as ocorrências deles foram relativamente baixas, demonstrando mais uma vez que as variáveis selecionadas na matriz de entrada são adequadas.

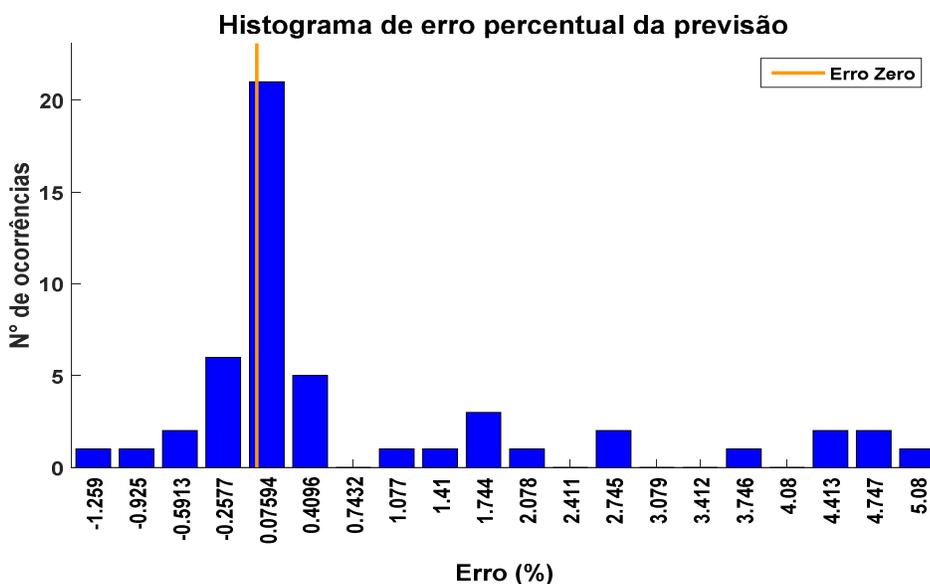
A Figura 21 ilustra o resultado da previsão da RNA (Simulado) comparando-o com o resultado real do peso de fazenda (Real) para os 51 bovinos da amostra.

Figura 21 - Resultado da previsão da RNA



É possível analisar através da Fig. 21 que os resultados Reais e Simulados foram muito próximos, conforme era esperado, devido aos fatores já mencionados anteriormente. As diferenças mais significativas entre eles ocorreram entre os animais 7 e 20, no qual a previsão subestimou os valores reais e este mesmo comportamento ocorre entre os animais 47 a 49, porém com menor intensidade. O histograma de erros percentuais da previsão é apresentado na Figura 22.

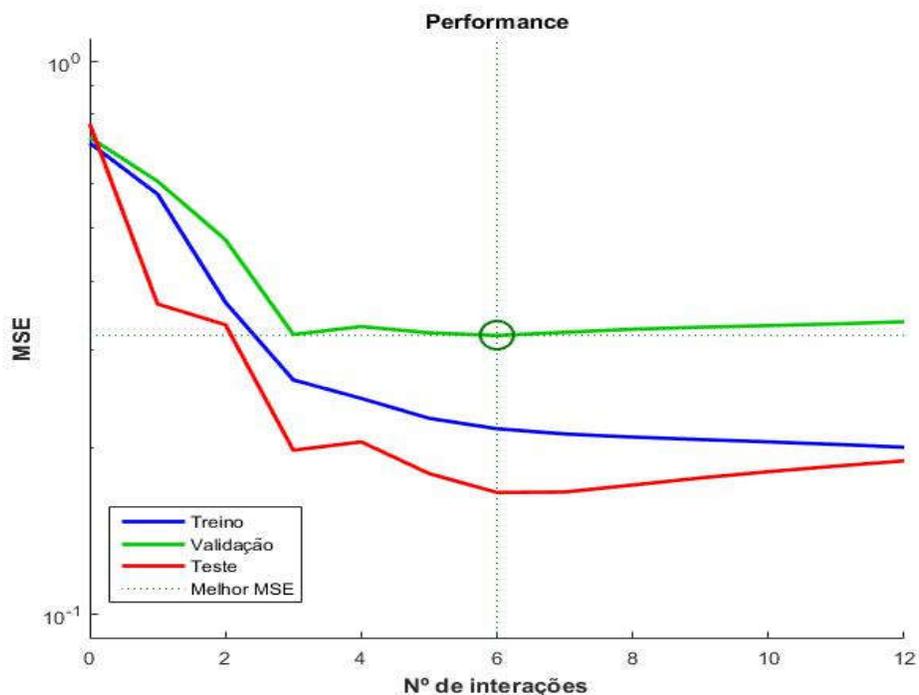
Figura 22 - Histograma de erro percentual da previsão



Neste histograma observa-se que a maioria dos erros percentuais ficou novamente em torno de zero, com maiores variações entre -0,3% e 0,5%. Os erros mais elevados ficaram em torno de 5%, o qual é considerado um erro muito baixo em modelos de previsão.

Na sequência serão demonstrados os resultados obtidos para previsão do segundo alvo, a bonificação (BN). O treinamento para esta RNA convergiu com 12 interações conforme revela a Fig. 23, obtendo um MSE de 0.2168.

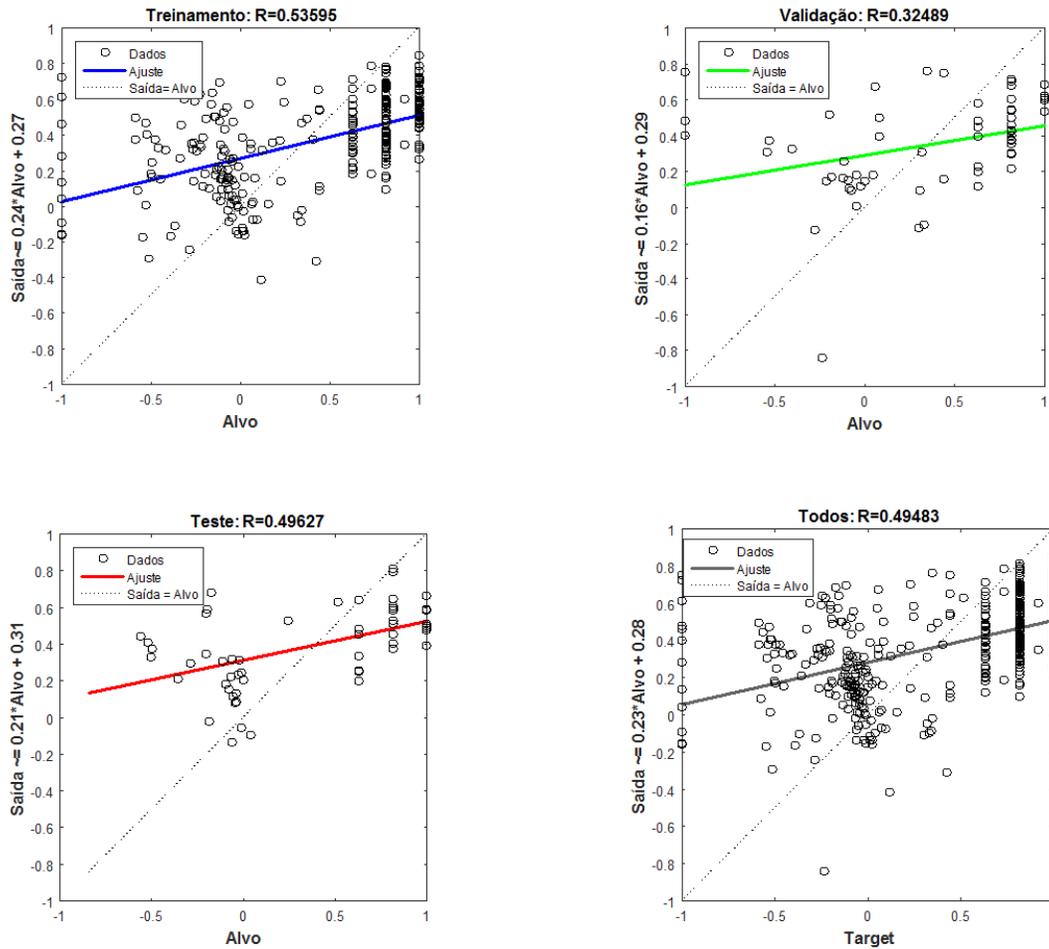
Figura 23 - Performance do treinamento alvo bonificação



Pode-se relatar que o resultado da performance na RNA para este caso apresentou um erro bem maior comparado com o encontrado para o outro alvo (PF, Fig. 17), porém ao final da apresentação destes resultados serão descritas as possíveis considerações para este acontecimento.

Na Figura 24 estão ilustrados os gráficos de regressão entre os dados de treinamento, validação, teste e um conjunto contendo os três (Todos = treinamento + validação + teste) em relação aos alvos (dados reais).

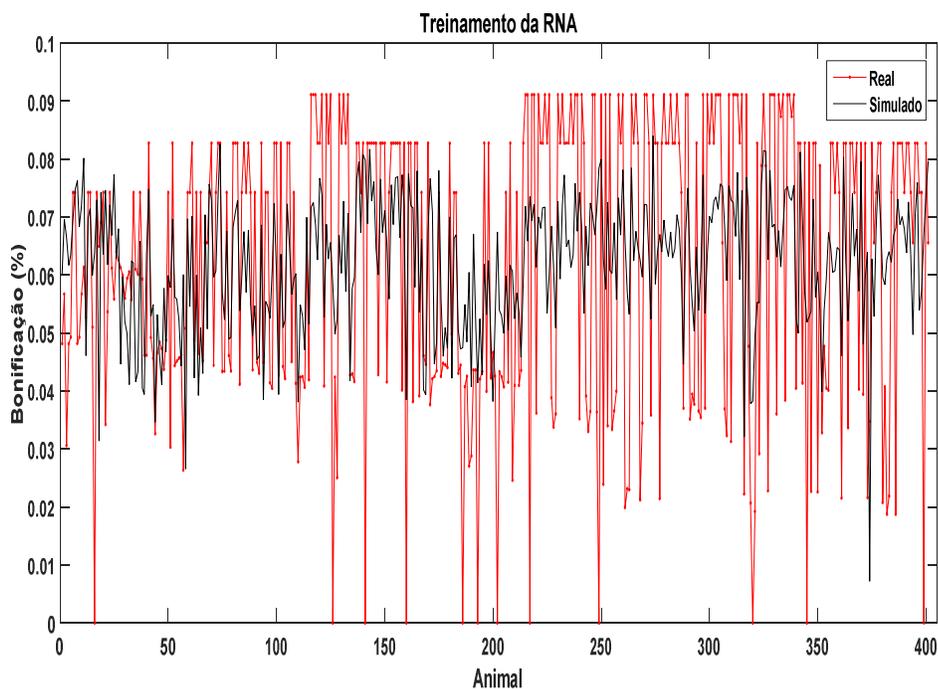
Figura 24 - Gráficos de regressão entre a saída da RNA e o alvo (bonificação)



Fonte: Autoria Própria, 2016

Os resultados da Fig. 24 não foram satisfatórios, o que pode ser comprovado através da distância entre a linha sólida (ajuste) e a linha pontilhada (saída=alvo). O valor de R também demonstra que há uma baixa relação entre as saídas e os alvos, em torno de 0.5, resultado diferente da simulação para peso de fazenda, a bonificação mostrou uma baixa generalização impossibilitando a simulação da previsão. A Figura 25 comprova que os dados simulados na RNA comparando com os dados reais da bonificação estão divergindo significativamente.

Figura 25 - Resultado do treinamento da RNA para bonificação

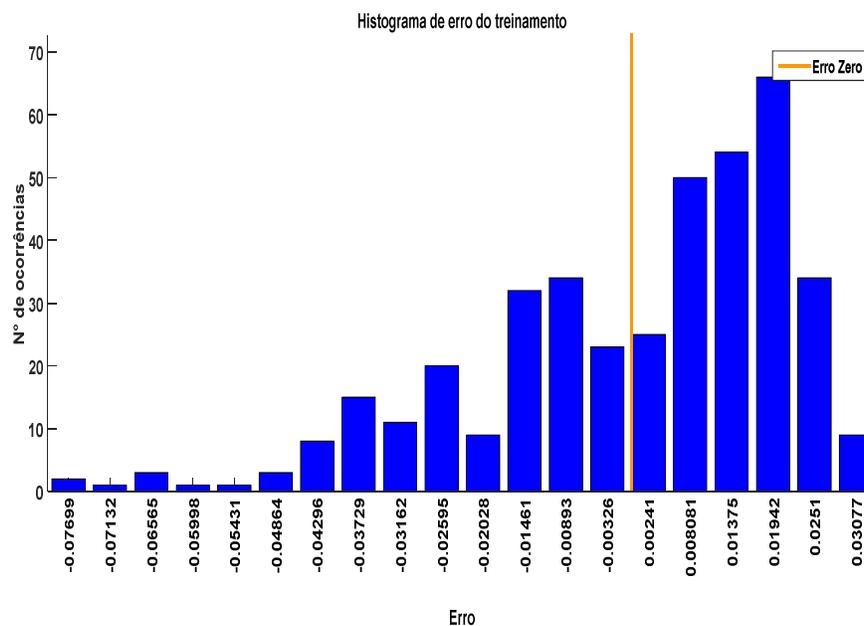


Fonte: Autoria Própria, 2016

Pode-se perceber que os dados reais, em vermelho apresentam grande variação para os 401 bovinos, com poucos valores registrados com bonificação nula (zero) e a maior quantidade de valores registrados entre 0,02 a 0,09%.

Na figura 26 é evidenciado o histograma de erro de treinamento da RNA para BN, sendo este erro a subtração entre o valor real e o valor simulado. Este tipo de cálculo de erro se justifica para evitar divisões por zeros, pois em alguns valores reais da bonificação encontra-se o mesmo.

Figura 26 - Histograma de erro do treinamento para bonificação

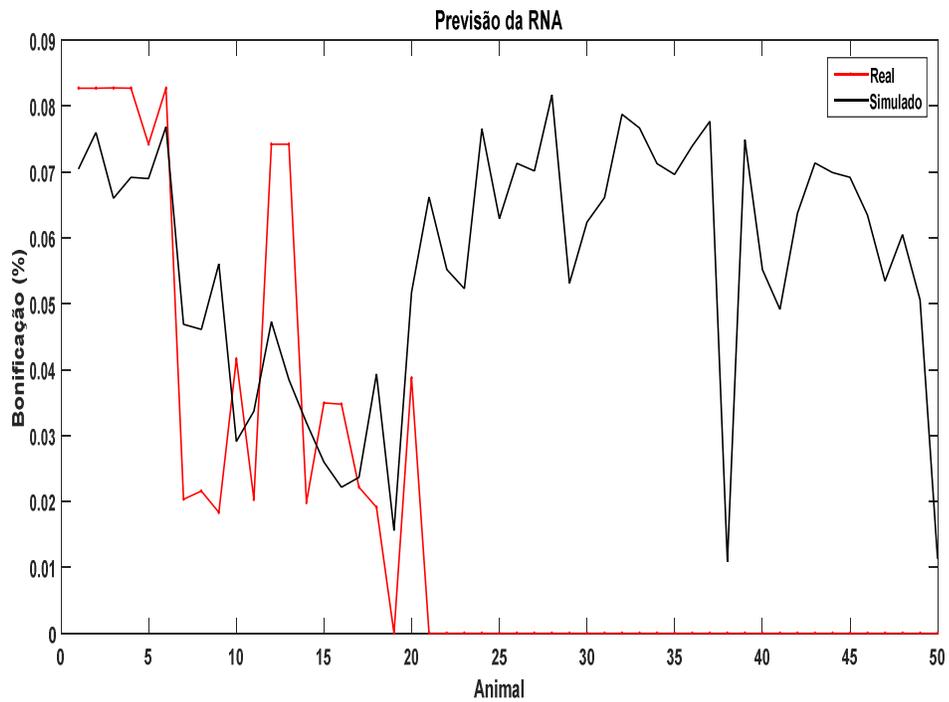


Fonte: Autoria Própria, 2016

Como podemos observar, este histograma descreve a quantidade dos erros do treinamento da RNA em função da subtração do valor real e simulado (Erro). Enfatiza-se que existem erros muito significativos comparados com os obtidos na Fig. 20, porém isso ocorre devido à baixa correlação e/ou influência dos dados selecionados na matriz de entrada para este objetivo.

A Figura 27 ilustra o resultado da previsão da RNA (simulado) comparando-o com o resultado real da bonificação (real) para os 51 bovinos da amostra.

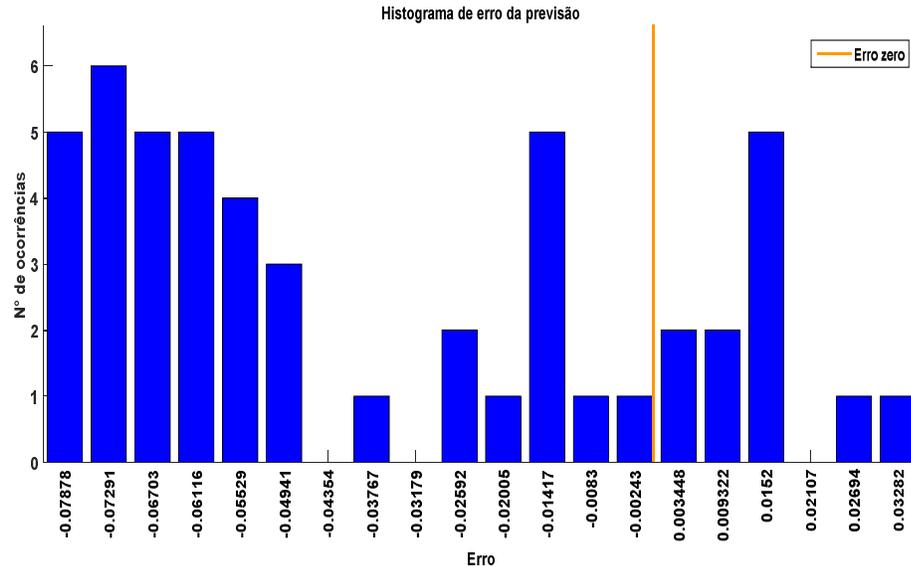
Figura 27 - Resultado da previsão RNA para bonificação



Fonte: Autoria Própria, 2016

É possível constatar que o resultado real e o simulado não foram semelhantes. Entre os animais 1 e 20 a rede ainda consegue fazer um previsão e após a rede não consegue encontrar um padrão de reconhecimento entre os dados da amostra, produzindo um erro elevado. O histograma de erro da previsão (subtração entre o valor real e simulado) é apresentado na Figura 28.

Figura 28 - Histograma de erro da previsão de bonificação



Fonte: Autoria Própria, 2016

Verificando o histograma de erro da previsão da Fig. 28 é possível perceber os mesmos ficam distante do valor ideal (próximo à zero). Outra explicação coerente para esta inconsistência seria o fato da RNA ter sido treinada com poucos valores de bonificação nulo e a amostra possuir mais de 30 valores nesta magnitude. Sendo assim, a rede reconheceu poucos padrões deste gênero, fazendo com que os valores previstos se baseassem na maioria dos dados de bonificação apresentados no treinamento, onde os mesmos eram em sua grande maioria diferentes de zero. Uma alternativa viável seria adicionar ao treinamento mais valores da matriz alvo (bonificação) contendo zero, pois a rede poderia criar mais padrões de reconhecimento deste tipo e conseqüentemente diminuiria o erro. Pode-se ressaltar que para o primeiro alvo, peso de fazendo, e rede se mostrou robusta e com excelente generalização, porém para o segundo alvo, bonificação, ocorreu exatamente o contrário.

## 6 CONCLUSÕES

O presente trabalho teve como objetivo principal empregar a técnica de RNA's para prever o rendimento dos bovinos de uma propriedade rural, através das variáveis peso de fazenda e bonificação, almejando que este modelo venha auxiliar os produtores rurais na gestão mais eficiente do seu negócio e proporcionando um aumento do ganho financeiro.

Foram realizadas a aquisição e seleção de dados zootécnicos e de manejo de uma propriedade rural, bem como a configuração correta, treinamento e simulação da RNA. Todos os resultados foram discutidos no capítulo 5, evidenciando a razão pela qual os mesmos foram obtidos.

Pode afirmar que o trabalho apresentado atendeu parcialmente os objetivos almejados. O modelo de previsão que pretendia prever o valor de duas variáveis alvo (PF e BN) alcançou uma ótima correlação apenas para o alvo PF. Além disso, obteve-se para o mesmo um erro quadrado médio de treinamento da RNA de  $2.34 \times 10^{-04}$ , sendo este valor suficiente para obter previsões razoáveis do indicador estudado.

Já o alvo BN não apresentou boa generalização para o modelo de previsão, o que pode ser explicado pelas características da variável bonificação presente no banco de dados. No momento do treinamento da rede, a matriz de bonificação dos 401 animais apresentou poucos animais com bonificação zero, e quando foi realizada a previsão da matriz amostra contendo a bonificação de 50 bovinos a mesma possuía uma grande quantidade de bonificação nula (zero). Isso implicou em valores baixos de correlação na RNA e conseqüentemente o modelo de previsão não conseguiu produzir uma boa generalização, pois os padrões de reconhecimento deste tipo não foram reconhecidos durante o treinamento da RNA, proporcionando um erro quadrático médio de treinamento da RNA em torno de 0, 2168.

Outro resultado importante deste trabalho é a limitação do uso da ferramenta e também a escolha dos dados de treinamento, visto que isto influenciará diretamente no objetivo desejado conforme podemos observar na previsão da bonificação, sendo assim, possuir um grande conhecimento nesta ferramenta implicará em resultados melhores e erros de menor magnitude.

Em suma, a metodologia proposta se mostrou capaz de servir de base para predição da variável peso de fazenda e os objetivos específicos deste trabalho foram

todos atendidos. Um grande leque de possibilidades se abre devido o desempenho satisfatório demonstrado neste trabalho. O emprego de RNA's como base para criação de uma ferramenta preditora de variáveis zootécnicas se mostrou muito eficaz e robusto, sendo possível utilizá-la para prever outras variáveis dentro do contexto da pecuária de corte.

Como sugestões futuras, pretende-se englobar no modelo algumas variáveis genéticas, pois conforme a literatura, a inserção da mesma em modelos poderá trazer resultados mais significativos. Também se sugere a expansão do banco de dados, através de parcerias com outros produtores rurais, apresentando a eles os resultados obtidos e demonstrando que é possível aumentar seu rendimento financeiro com técnicas adequadas. Outra proposta interessante seria integrar a técnica aos trabalhos que vem sendo desenvolvido pela Embrapa Pecuária Sul no desenvolvimento de aplicativos para *smartphones*, o qual irá proporcionar ao pecuarista a realização de uma previsão financeira, empregando as variáveis disponíveis dentro de sua propriedade rural, por exemplo.

## 7 REFERÊNCIAS BIBLIOGRÁFICAS

ABIEC. **Pecuária Brasileira.** Disponível em: [http://www.abiec.com.br/3\\_pecuaria.asp](http://www.abiec.com.br/3_pecuaria.asp)>. Acesso em: 20 de setembro de 2016.

ABREU, UGP de; CEZAR, Ivo Martins; TORRES, R. de A. **Análise bioeconômica da introdução de período de monta em sistemas de produção de rebanhos de cria na região do Brasil Central.** Revista Brasileira de Zootecnia, v. 32, n. 5, p. 1198-1206, 2003.

ABREU, UGP; AMSTALDEN, M. **Uso de modelagem para análise da eficiência reprodutiva animal.** Simpósio sobre a produção animal e a segurança alimentar, p. 409-415, 2004.

AHMADI, H.; MOTTAGHITALAB, M.; NARIMAN-ZADEH, N. **Group method of data handling-type neural network prediction of broiler performance based on dietary metabolizable energy, methionine, and lysine.** The Journal of Applied Poultry Research, v. 16, n. 4, p. 494-501, 2007.

ANDREATTA, T. **Bovinocultura de corte no Rio Grande do Sul: um estudo a partir do perfil de pecuaristas e organização dos estabelecimentos agrícolas.** Tese (Doutorado em Desenvolvimento Rural) – Programa de Pós Graduação em Desenvolvimento Rural - Universidade Federal do Rio Grande do Sul/UFRGS, p.241, 2009.

APOLLIN, F.; EBERHART, C. **Análisis y diagnóstico de los sistemas de producción en el medio rural** – Guía metodológica. Quito/Equador, p.239, 1999.

ARGOLOME, ALCINDO CIPRIANO; OLIVEIRA, RICARDO DAHER. **Um modelo de simulação de cenários como ferramenta de planejamento na bovinocultura de corte.** In: Congresso Universidade de São Paulo de Controladoria e contabilidade. 2006.

BAPTISTA, F.; MOREIRA, E.C.; SANTOS, W.L.M.; DIEGUEZ, B.R. **Peso de carcaça e idade dos bovinos abatidos em Minas Gerais**. Arquivo Brasileiro de Medicina Veterinária e Zootecnia, v. 51, n. 4. Belo Horizonte, agosto, 1999.

BARBOSA, P. F. **Raças e estratégias de cruzamento para produção de novilhos precoces**. I SIMCORTE-SIMPÓSIO DE PRODUÇÃO DE GADO DE CORTE, v. 1, 1999.

BARCELLOS, J. O. J. et al. **A bovinocultura de corte frente a agriculturização no sul do Brasil**. Ciclo de atualização em medicina veterinária, Centro Agroveterinário de Lages Lages, v. 11, p. 13–30, 2004.

BARCELLOS, J. O. J. et al. **Processos de intensificação dos sistemas de produção de carne bovina para o mercado**. Congresso Latino-americano de buiatria, Centro Médico Veterinário de Paysandu, v.8, 2011.

BARCELOS, J.O.J., LOBATO, J.F.P. Efeitos da época de nascimento no desenvolvimento de bezerros Hereford e suas cruzas. I. Peso ao nascer e ganho médio diário pré-desmama. **Revista da Sociedade Brasileira de Zootecnia**, Viçosa, v.21, n.1, p.137-149, 1992.

BEEFPOINT. **Criador é bonificado por carcaça**. São Paulo-SP, 2008. Disponível em: <<http://www.beefpoint.com.br/parceiros/canal-nelore/criador-e-bonificado-por-carcaca-46538/>>. Acesso em: 24 de agosto de 2016.

BEEFPOINT. **Marfrig e ABHB lançam bonificação de animais Hereford e Braford em MS e SP**. São Paulo-SP, 2012. Disponível em: <<http://www.beefpoint.com.br/cadeia-produtiva/giro-do-boi/marfrig-e-abhb-lancam-bonificacao-de-animais-hereford-e-braford-em-ms-e-sp/>>. Acesso em: 10 de agosto de 2016.

BERETTA, Virgínia; LOBATO, José Fernando Piva; MIELITZ NETTO, Carlos Guilherme A. **Produtividade e eficiência biológica de sistemas pecuários de cria diferindo na idade das novilhas ao primeiro parto e na taxa de natalidade do**

**rebanho no Rio Grande do Sul.** Revista Brasileira de Zootecnia, v. 30, n. 4, p. 1278-1286, 2001.

BISHOP, C. M. **Neural networks for pattern recognition.** [S.l.]: Oxford university press, 1995.

BORTOLUZZO, Adriana Bruscato et al. **Tempo Ideal Para Abate de Gado de Corte Via Maximização do Lucro.** Insper Working Paper, Insper Instituto de Ensino e Pesquisa, 2011.

BRAGA, A. de P.; CARVALHO, ACPLF; LUDERMIR, Teresa Bernarda. **Redes neurais artificiais: teoria e aplicações.** Rio de Janeiro: Livros Técnicos e Científicos, 2000.

BRAGA, A. P.; CARVALHO, A. C.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações,** 2 ed: Editora, LTC, 2007

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

BRIDI, A. M.; CONSTANTINO, C. **Qualidade e avaliação de carcaças e carnes bovinas.** In: Congresso Paranaense dos Estudantes de Zootecnia, Anais... Maringá. [S.l.: s.n.], 2009.

BUAINAIN, A. M. et al. **Cadeia Produtiva de Carne Bovina Volume 8.** [S.l.]: Bib. Orton IICA/CATIE, 2007.

CARDELLINO, M.V.; CARDELLINO R.A. **Efeitos ambientais sobre peso, ganho de peso e conformação à desmama em bovinos Hereford no Rio Grande do Sul.** Revista da Sociedade Brasileira de Zootecnia, Viçosa, v.13, n.4, p.547-556, 1984.

CARDOSO, F. F. *et al.* **Época de nascimento no crescimento de bezerros Aberdeen Angus criados no Rio Grande do Sul e suas implicações no melhoramento genético.** *Ciência Rural*, Santa Maria, v.30, n.6, p.1047-1051,2000.

CARNEIRO, Antonio Souza Policarpo *et al.* **Heterogeneidade e avaliação genética em bovinos, estudo utilizando dados simulados.** DOI:10.4025/. v30i1. 3621. *Acta Scientiarum. Animal Sciences*, v. 30, n. 1, p. 113-119, 2008.

CARVALHO FILHO, E. C. B. **Modelagem, Aplicações e Implementações de redes Neurais.** *Anais da IV Escola Regional de Informática da SBC Regional Sul*,v. 21, p. 36-53, 1996.

CARVALHO, T. B. D. *et al.* **Competitividade da pecuária de corte do Estado de São Paulo vs Mato Grosso do Sul e Mato Grosso.** In: sociedade brasileira de economia, administração e sociologia rural (SOBER). 46th Congress, July 20-23, 2008, Rio Branco, Acre, Brasil. [S.I.], 2008.

CAVERO, D. *et al.* **Mastitis detection in dairy cows by application of neural networks.** *Livestock Science*, v. 114, n. 2, p. 280-286, 2008.

CAVERO, D. *et al.* **Mastitis detection in dairy cows by application of neural networks.** *Livestock Science*, v. 114, n. 2, p. 280-286, 2008.

CEZAR, I. M. *et al.* **Sistemas de produção de gado de corte no Brasil: uma descrição com ênfase no regime alimentar e no abate.** [S.I.]: Embrapa Gado de Corte, 2005.

CEZAR, I. M. **Modelo bioeconômico de produção de bovinos de corte: I. Descrição do modelo.** *Pesquisa Agropecuária Brasileira*, v. 17, n. 6, 1982.

CHEN, Y. R.; NGUYEN, M.; PARK, B. **Neural network with principal component analysis for poultry carcass classification.** *Journal of Food Process Engineering*, v. 21, n. 5, p. 351-367, 1998.

CHRISTOFARI, Luciana F. et al. **Análise do sistema de comercialização e do abate de bovinos no estado do Rio Grande do Sul: um estudo de caso.** Veterinária em Foco, v. 5, n. 2, p. 102-120, 2008.

CHWIF, Leonardo; MEDINA, Afonso **Modelagem e simulação de eventos discretos**, 4ª Edição: Teoria e Aplicações. Elsevier Brasil, 2014.

CLEMENTE, F.; MATTOS, L. B. de. **Precificação de opções sobre contratos futuros de boi gordo na BM&F: análise dos modelos binomial e black e scholes.** Revista Economia e Desenvolvimento, v. 10, n. 1, 2011.

CORRÊA, Afonso Nogueira Simões. **Gado de corte: 500 perguntas e respostas.** Brasília: EMBRAPA, 1996.

COSTA, Ernane José Xavier et al. **Inteligência artificial aplicada à Zootecnia.** Revista Brasileira de Zootecnia, v. 38, n. spe, p. 390-396, 2009.

CYBENKO, G. **Continuous valued neural networks with two hidden layers are sufficient.** Technical report, Department of Computer Science, Tufts University, 1988.

CYBENKO, George. **Approximation by superpositions of a sigmoidal function.** Mathematics of control, signals and systems, v. 2, n. 4, p. 303-314, 1989.

DOMINGUES, O., **O Zebu: sua reprodução e multiplicação dirigida.** São Paulo-SP: Editora Novel, p.188, 1990.

DOS SANTOS, Geraldo Tadeu et al. **Importância do manejo e considerações econômicas na criação de bezerras e novilhas.** Maringa: Anais do II Sul-Leite 2002.

EMBRAPA-CNPGC. **Desmama em bovinos de corte.** Gado de corte divulga. Campo Grande-MS, 1996. Disponível em: < <http://old.cnpgc.embrapa.br/publicacoes/divulga/GCD16.html> >. Acesso em: 30 de março de 2016.

EUCLIDES FILHO, K. **Produção de bovinos de corte e o trinômio genótipo-ambiente mercado.** [S.l.]: Embrapa Gado de Corte, 2000.

FELÍCIO, P. E. **Classificação e tipificação de carcaças bovinas,** Palestra proferida no Congresso CBNA, Texto de conferência proferida no congresso CBNA. Goiânia - GO, 17-18, maio. 2005.

FERREIRA, Fausto Roberto. **O uso de rede neural artificial MLP na predição de estruturas secundárias de proteínas.** Dissertação (Mestrado em Biofísica Molecular) - Universidade Estadual Paulista, São José do Rio Preto, p.76, 2004.

GAIO, L. E.; CASTRO, L. G. de; OLIVEIRA, A. R. de. **Causalidade e elasticidade na transmissão de preço do boi gordo entre regiões do Brasil e a Bolsa de Mercadorias & Futuros (BM&F).** Organizações Rurais & Agroindustriais, v. 7, n. 3, 2011.

GARCIA FILHO, D.P. **Análise diagnóstico de sistemas agrários – Guia Metodológico.** INCRA/FAO, 65p., 1999.

GOTTSCHALL, C. S. **Produção de novilhos precoces: nutrição, manejo e custos de produção.** 2. ed. Agrolivros, p.213, 2005.

GUIMARÃES, A. M. **Aplicação de computação evolucionária na mineração de dados físico-químicos da água e do solo.** Tese (Doutorado em Agronomia - Energia na Agricultura), Universidade Estadual Paulista - UNESP, Botucatu, p. 127, 2005.

HALL, J. E.; GUYTON, A. C. **Textbook of medical physiology.** [S.l.]: Elsevier Inc., 2006.

HART, Robert. **Componentes, subsistemas y propiedades del sistema finca como base para un método de clasificación. Tipificación de sistemas de**

**producción agrícola.** Red Internacional de Metodología de Investigación de Sistemas de Producción. Santiago de Chile, p. 45-62, 1990.

HAYKIN, S. **Redes neurais: princípios e práticas;** trad. Paulo Martins Engel. - 2.ed. -Porto Alegre: Bookman, 2001.

HEBB, D. O. **The organization of behavior.** Wiley: New York, NY, USA, 1949.

HINTON, G. E.; MCCLELLAND, J. L.; RUMELHART, D. E. **Distributed representations, Parallel distributed processing: explorations in the microstructure of cognition,** vol. 1: foundations. [S.l.]: MIT Press, Cambridge, MA, 1986.

HINTON, Geoffrey E. **How neural networks learn from experience.** Scientific American, v. 267, n. 3, p. 145-151, 1992.

JANES, Kevin R.; YANG, Simon X.; HACKER, Roger R. **Pork farm odour modelling using multiple-component multiple-factor analysis and neural networks.** Applied Soft Computing, v. 6, n. 1, p. 53-61, 2005.

LAZZARINI NETO, S. **Cria e recria.** 3. ed. Viçosa, MG: Aprenda fácil, p.120, 2000.

LEMES, Luciene R. **Modelo de avaliação de risco para predição de preços de carne bovina utilizando inteligência computacional.** Tese de Doutorado. Universidade de São Paulo, 2014.

LIMA, F. A. P. **Fatores que interferem no crescimento de bovinos de corte após a desmama.** In: do 3º Simpósio sobre pecuária de corte , Piracicaba-SP, 1983. Fundação Cargill. Campinas-SP, p.212, 1983.

LOPES, M. A.; CARVALHO, F. d. M. **Custo de produção do gado de corte.** Lavras: UFLA, v. 47, 2002.

MACHADO JUNIOR, P.C.; SALOMONI, E.; OSÓRIO, J.C.S. **Desenvolvimento ponderal de bovinos meio-sangue Ibagé-Hereford nascidos em distintas estações do ano.** Ciência Rural, Santa Maria, v.29, n.2, p.325-329, 1999.

MARFRIG. **Programas Pecuários.** Disponível em: <<http://www.marfrig.com.br/pecuaristas/programas-pecuarios/programa-premiacao-angus/>>. Acesso em: 9 de dezembro de 2016.

MATHIAS, Ivo Mário. **Aplicação de redes neurais artificiais na análise de dados de molhamento foliar por orvalho.** Tese (Doutorado em Agronomia) - Universidade Estadual Paulista, Botucatu, p. 135, 2006.

MATLAB. **Toolbox Redes Neurais.** Disponível em: <[https://www.mathworks.com/matlabcentral/answers/43272-new-toolbox-rna-access-the-data-divided-by-net-divide-function?s\\_tid=srchtitle](https://www.mathworks.com/matlabcentral/answers/43272-new-toolbox-rna-access-the-data-divided-by-net-divide-function?s_tid=srchtitle)>. Acesso em: 13 de setembro de 2016.

MCCULLOCH, Warren S.; PITTS, Walter. **A logical calculus of the ideas immanent in nervous activity.** The bulletin of mathematical biophysics, v. 5, n. 4, p. 115-133, 1943.

MEIRELLES, Flávia Devechio Providelo. **Modelo computacional de um rebanho bovino de corte virtual utilizando simulação Monte Carlo e redes neurais artificiais.** (Tese de Doutorado) - Universidade de São Paulo, 2005.

MINSKY, M.; PAPER, S. **Perceptrons: An Introduction to Computational.** [S.l.]: MIT press, 1988.

MOITA, R. M.; GOLON, L. A. **Oligopsônio dos Frigoríficos: Uma Análise Empírica de Poder de Mercado.** RAC-Revista de Administração Contemporânea, Associação Nacional de Pós-Graduação e Pesquisa em Administração, v. 18, n. 6, p. 772-794, 2014.

MONTGOMERY, G.W., DAVIS, G.H. **A comparison of spring and autumn calving for beef cattle production.** In: NEW ZEALAND SOCIETY OF ANIMAL

PRODUCTION, 47, 1987, Palmerston North. **Proceedings** Palmerston North: NZSAP, p.115-118. 256p, 1987.

OAIGEN, R. P. **Gestão na bovinocultura de corte**. [S.l.]: Agro Livros, 2014.

OAIGEN, R.P.; BARCELLOS, J.O.J. **Gerenciamento e custo de produção**. In: MOURA, J. A.; GOTTSCHALL, C. S.; ANDRADE; V. J. (Ed.). Programa de atualização em medicina veterinária. Porto Alegre: ARTMED, p.51-88, 2008.

OAIGEN, Ricardo Pedroso. **Avaliação da competitividade em sistemas de produção de bovinocultura de corte nas regiões sul e norte do Brasil**. (Tese de Doutorado Veterinária) - Universidade Federal do Rio Grande do Sul, 2010.

OSÓRIO, F. S.; BITTENCOURT, J. R. **Sistemas Inteligentes baseados em redes neurais artificiais aplicados ao processamento de imagens**, In: I Workshop de Inteligência Artificial, Apostila Seminário, Santa Cruz do Sul, UNISC - Universidade de Santa Cruz do Sul - Departamento de Informática, 2000.

PAL, S. K.; MITRA, S. **Multilayer perceptron, fuzzy sets, and classification**. IEEE Transactions on Neural Networks, IEEE, v. 3, n. 5, p. 683–697, 1992.

PANDORFI, Héilton 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.

PAULINO, Mário Fonseca et al. **Bovinicultura funcional nos trópicos. Simpósio internacional de produção de gado de corte**, v. 2, p. 275-305, 2008.

PEREIRA, P. R. R. X. **Rastreabilidade e sanidade: desafios para as exportações brasileiras de carne bovina**. 2009.

PERRY, G. A.; SMITH, M. F. **A simulation exercise to teach principles of bovine reproductive management**. *Journal of animal science*, v. 82, n. 5, p. 1543-1549, 2004.

PIRES, Alexandre Vaz. **Bovinocultura de corte**. Piracicaba: FEALQ, v.2, 2010

PITELLI, M. M.; MORAES, M. **Sistema agroindustrial da carne bovina brasileiro: análise do impacto das exigências do consumidor europeu sobre a estrutura de governança**. In: XLII Congresso da Sociedade Brasileira de Economia e Sociologia Rural-SOBER. [S.l.: s.n.], 2004

PONS, S.B.; MILAGRES J.C.; TEIXEIRA, N.M. **Efeitos de fatores genéticos e de ambiente sobre o crescimento e o escore de conformação em bovinos Hereford no Rio Grande do Sul. I – Peso e escore de conformação à desmama**. Revista da Sociedade Brasileira de Zootecnia, Viçosa, v.18, n.5, p.391-401, 1989.

QUADROS, D. G. **Sistemas de produção de bovinos de corte**. Pró-Reitoria de Extensão da UNEB (Universidade Do Estado Da Bahia)-Salvador–Bahia, 2005.

RAÍCES, C. **Guia valor econômico de agronegócios**. [S.l.]: Globo Livros, 2003.

RESTLE, João et al. **Desenvolvimento de bovinos de corte de diferentes grupos genéticos desmamados aos 3 ou 7 meses de idade**. Revista Brasileira de Zootecnia, v. 28, n. 5, p. 1023-1030, 1999.

ROSENBLATT, F. **The perceptron: a probabilistic model for information storage and organization in the brain**. Psychological review, American Psychological Association, v. 65, n. 6, p. 386, 1958.

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. **Learning representations by back-propagating errors**. Cognitive modeling, v. 5, n. 3, p. 1, 1988.

SAINZ, Roberto D.; ARAUJO, Fabiano RC. **Tipificação de carcaças de bovinos e suínos**. In: I CONGRESSO BRASILEIRO DE CIÊNCIA E TECNOLOGIA DE CARNES. 2001. p. 26-52.

SAKUGUTI, E.S; MARTINS, E.N.; SILVA, L.O.C. **Comparison of different selection criteria in populations simulated under growth curve parameters of brazilian zebu cattle**. J. Anim.Sci., Savoy, v.81, 2003.

SALOMONI, E., SILVEIRA, C.L.M. **Acasalamento de outono em bovinos de corte: abrace essa ideia**. Guaíba: Agropecuária, 152p., 1996.

SARMENTO, José Lindenberg Rocha et al. **Efeitos ambientais e genéticos sobre o ganho em peso diário de bovinos Nelore no estado da Paraíba**. Revista Brasileira de Zootecnia, v. 32, n. 2, p. 325-330, 2003.

SAVEGNAGO, R. **Modelos de regressão aleatória, análise multivariada e redes neurais artificiais na avaliação genética da produção de leite de vacas holandesas**. 144 f. Tese (Doutorado em Biologia) – Faculdade de Ciências Agrárias e Veterinárias, Universidade de Estadual Paulistas, São Paulo. 2013.

SILVA, Alexandre Bandeira Monteiro. **Redes Neurais Artificiais, análise de sensibilidade e o comportamento de funções de comércio exterior do Brasil**. 2002. Tese de Doutorado. Universidade Federal do Rio Grande do Sul.

SLACK, Nigel; CHAMBERS, Stuart; JOHNSTON, Robert. **Administração da produção**. Atlas, 2009.

SMOLENSKY, Paul. **Tensor product variable binding and the representation of symbolic structures in connectionist systems**. Artificial intelligence, v. 46, n. 1-2, p. 159-216, 1990.

SMOLENSKY, Paul. **Tensor product variable binding and the representation of symbolic structures in connectionist systems**. Artificial intelligence, v. 46, n. 1-2, p. 159-216, 1990.

TASINAFFO, Paulo Marcelo. **Estruturas de integração neural feedforward testadas em problemas de controle preditivo**. Engineering and space technology doctorate thesis, Spatial Research National Institute, São José dos Campos, 2003.

VALLE, E. R; ENCARNAÇÃO, R. O; THIAGO, L. R. **Métodos de desmama para aumento da eficiência reprodutiva de bovinos de corte**. Campo Grande-MS: EMBRAPA-CNPGC, p. 23, 1996.

VELLASCO, M. M. B. R. **Redes Neurais Artificiais**. Rio de Janeiro, Brasil, PUC, notas de Aula, Brasil, 1994.

VENTURA, R. V. et al. **Use of artificial neural networks in breeding values prediction for weight at 205 days in Tabapuã beef cattle**. Arquivo Brasileiro de Medicina Veterinária e Zootecnia, v. 64, n. 2, p. 411-418, 2012.

VERÍSSIMO, Andrea. **Panorama da carne brasileira no mercado mundial e o marketing internacional**. Biológico, São Paulo, v. 69, n. 2, p. 35-37, 2007.

VICENTE, Renato. **Redes Neurais para Inferência Estatística**. FEA/USP, 2002.

ZUBEN, J. V. **Redes Neurais Multicamadas**. São Paulo-SP, 2016. Disponível em: <[ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/theses/emi\\_mest/cap2.pdf](ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/theses/emi_mest/cap2.pdf)>. Acesso em: 5 de dezembro de 2016.