

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
DEPARTAMENTO ACADÊMICO DE ELETRÔNICA  
BACHARELADO EM ENGENHARIA ELÉTRICA**

**ANDRESSA APARECIDA DE QUADROS ULINICK  
BIANCA SCHASTAI**

**PREVISÃO DE DEMANDA PARA CONTROLE DE ESTOQUE:  
APLICAÇÃO DE REDES NEURAS ARTIFICIAIS EM SÉRIES  
TEMPORAIS**

**TRABALHO DE CONCLUSÃO DE CURSO**

**PONTA GROSSA  
2019**

**ANDRESSA APARECIDA DE QUADROS ULINICK  
BIANCA SCHASTAI**

**PREVISÃO DE DEMANDA PARA CONTROLE DE ESTOQUE:  
APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS EM SÉRIES  
TEMPORAIS**

Trabalho de Conclusão de Curso apresentado como requisito parcial à obtenção do título de Bacharel em Engenharia Elétrica, do Departamento Acadêmico de Eletrônica, da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Hugo Valadares Siqueira

**PONTA GROSSA  
2019**



Ministério da Educação  
**Universidade Tecnológica Federal do Paraná**  
Câmpus Ponta Grossa  
Diretoria de Pesquisa e Pós-Graduação  
Departamento Acadêmico de Eletrônica  
Bacharelado em Engenharia Elétrica



## **TERMO DE APROVAÇÃO**

**PREVISÃO DE DEMANDA PARA CONTROLE DE ESTOQUE:  
APLICAÇÃO DE REDES NEURAS ARTIFICIAIS EM SÉRIES TEMPORAIS**

por

**ANDRESSA APARECIDA DE QUADROS ULINICK  
e  
BIANCA SCHASTAI**

Este Trabalho de Conclusão de Curso foi apresentada às 14:00 de 10 de Dezembro de 2019 como requisito parcial para a obtenção do título de Bacharel em Engenharia Elétrica. O(A) candidato(a) foi arguido(a) pela Banca Examinadora composta pelos professores abaixo citados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Prof. Dr. Hugo Valadares Siqueira  
Orientador

Profa. Dra. Mauren Louise S. C. de Andrade  
Membro Titular

Prof. Dr. Flávio Trojan  
Membro Titular

Prof. Dr. Josmar Ivanqui  
Responsável pelos TCC

Prof. Dr. Sérgio Okida  
Coordenador do Curso

Dedicamos este trabalho a nossas  
famílias e aos nossos amigos, pelos  
nossos momentos de ausência.

## **AGRADECIMENTOS**

Agradecemos primeiramente a Deus, por toda força transmitida por Ele nessa caminhada.

Aos nossos pais, por todo apoio e estímulo para estudar que nos deram desde que eramos crianças.

Aos nossos avôs, pelo amor, paciência e apoio em todos os momentos

Também agradecemos ao demais familiares, que nos apoiaram até aqui.

Ao professor Hugo, por toda dedicação e disponibilidade.

Aos demais professores, que todo dia dão o seu melhor para ensinar aos seus alunos, sempre dispostos a auxiliar na caminhada acadêmica.

Ao nosso colega Matheus Prates, por todas as risadas e auxílio nos estudos.

Aos demais amigos, por serem compreensivos com nossas ausências nesse último ano.

Um computador pode ser chamado de  
inteligente se ele pode enganar uma  
pessoa a pensar que é um ser humano.  
(TURING, Alan, 1950).

## RESUMO

ULINICK, Andressa Aparecida de Quadros; SCHASTAI, Bianca. **Previsão de demanda para controle de estoque: aplicação de redes neurais artificiais em séries temporais**. 2019. 58 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica) – Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2019.

Atualmente, realizar previsões de demanda que apresentem o menor erro possível é um desafio frequente para as organizações. De modo geral, as mesmas têm optado por utilizar modelos qualitativos para realizar previsões de demanda e vendas. Entretanto, na literatura são encontrados resultados imprecisos e tendenciosos, já que o método inclui fatores como julgamentos, experiências, opiniões e intuições. Além disso, muitas empresas preferem basear suas previsões muito mais na experiência de seus gerentes do que em modelos matemáticos. Sabe-se que uma previsão com uma acurácia elevada é capaz de levar a grandes economias, trazendo como efeito não apenas um retorno financeiro, como também um aumento na competitividade e na satisfação de seus clientes. Nesse sentido, nesse trabalho foi proposta a utilização de redes neurais artificiais no problema, pois estas possuem capacidade de aprendizagem, podem processar as variáveis do problema e através delas, criar uma previsão mais assertiva sobre valores futuros de demanda e vendas. Este trabalho fará um estudo sobre o processo de previsão de demanda, em uma unidade comercial do ramo de *pet shop* da cidade de Ponta Grossa-PR. Os resultados obtidos com versões distintas da rede Perceptron de Múltiplas Camadas mostram a viabilidade da proposta.

**Palavras-chave:** Redes Neurais Artificiais. Previsão de demanda. Custo de Estoque.

## ABSTRACT

ULINICK, Andressa Aparecida de Quadros; SCHASTAI, Bianca. **Demand forecasting for inventory control: application of artificial neural networks in time series forecasting**. 2019. 58 p. Final Coursework (Doctorate in Electrical Engineering) – Federal University of Technology – Paraná. Ponta Grossa, 2019.

Nowadays, perform a demand forecasting that present the smallest error is a frequent challenge for organizations. In general, they have chosen to use qualitative models to predict demand and sales. However, inaccurate and biased results are found in the literature, as the method includes factors such as judgment, experience, opinions and intuition. In addition, many companies prefer to base their forecasts much more on their managers' experience than on mathematical models. It is known that a forecast with high accuracy can lead to large savings, resulting not only a financial return, but also an increase in competitiveness and customer satisfaction. In this sense, this work proposed the use of artificial neural networks to solve the problem, because they present learning capacity, can process the variables, and through them, create a more assertive prediction about future demand and sales. This work studies the demand forecasting process in a commercial unit of the pet shop branch from Ponta Grossa-PR. The results obtained with different versions of the Perceptron Multilayer network show the viability of the proposal.

**Keywords:** Neural Network. Demand forecasting. Inventory cost.



## LISTA DE ILUSTRAÇÕES

Figura 1 – Analogia do estoque . . . . .	15
Figura 2 – Curva do custo do pedido . . . . .	17
Figura 3 – Curva do custo de armazenagem . . . . .	18
Figura 4 – Curva do custo total . . . . .	19
Figura 5 – Comportamento dinâmico do processo de previsão . . . . .	21
Figura 6 – Curva do custo total do estoque . . . . .	22
Figura 7 – Métodos de previsão de demanda . . . . .	24
Figura 8 – Precisão e custos na previsão . . . . .	25
Figura 9 – Modelo de evolução horizontal . . . . .	27
Figura 10 – Modelo de evolução sazonal de consumo . . . . .	27
Figura 11 – Modelo de evolução de consumo sujeito à tendência . . . . .	28
Figura 12 – Modelo biológico . . . . .	30
Figura 13 – Modelo artificial . . . . .	32
Figura 14 – Uma rede típica do tipo <i>feedforward</i> (MLP). . . . .	33
Figura 15 – Treinamento: (a) Supervisionado (b) Não supervisionado. . . . .	35
Figura 16 – Rede <i>perceptron</i> multiplas camadas . . . . .	40
Figura 17 – Vendas totais de medicamentos . . . . .	42
Figura 18 – Vendas totais de ração . . . . .	43
Figura 19 – Vendas totais de medicamentos - loja matriz . . . . .	44
Figura 20 – Vendas totais de ração - loja matriz . . . . .	44
Figura 21 – Topologia (a)RNA1 (b)RNA2 . . . . .	47
Figura 22 – Árvore de decisão das topologias de RNA's testadas . . . . .	47
Figura 23 – Perdas RNA1 . . . . .	50
Figura 24 – Perdas RNA2 . . . . .	51
Figura 25 – Previsão vendas de medicamentos - RNA1 . . . . .	51
Figura 26 – Previsão vendas de ração - RNA2 . . . . .	52

## LISTA DE TABELAS

Tabela 1 – Classificação de estoque conforme função . . . . .	16
Tabela 2 – Tendências comuns em métodos qualitativos . . . . .	26
Tabela 3 – Funções de ativação . . . . .	36
Tabela 4 – Cálculo de erros . . . . .	36
Tabela 5 – Fórmulas para normalização dos dados . . . . .	37
Tabela 6 – Erros de teste por topologia para previsão de medicamentos. . . . .	48
Tabela 7 – Erros de teste RNA1. . . . .	48
Tabela 8 – Erros de teste por topologia para previsão de ração. . . . .	49
Tabela 9 – Erros de teste RNA2. . . . .	49

## LISTA DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

### SIGLAS

IBGE	Instituto Brasileiro de Geografia e Estatística
IC	Inteligência Computacional
MLP	<i>Multi Layer Perceptron</i>
PIB	Produto Interno Bruto
RNA	Rede Neural Artificial

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>12</b>
1.1	OBJETIVOS	13
1.2	JUSTIFICATIVA	13
1.3	ORGANIZAÇÃO DO TRABALHO	13
<b>2</b>	<b>ESTOQUE</b>	<b>15</b>
2.1	CUSTO DE ESTOQUE	17
<b>3</b>	<b>PREVISÃO DE DEMANDA</b>	<b>20</b>
3.1	ETAPAS DE UM MODELO DE PREVISÃO	20
3.2	MODELO DE PREVISÃO	23
<b>4</b>	<b>REDES NEURAIS ARTIFICIAIS</b>	<b>29</b>
4.1	HISTÓRICO	29
4.2	INSPIRAÇÃO BIOLÓGICA	29
4.3	MODELO ARTIFICIAL	31
4.4	ARQUITETURA DA REDE	33
4.5	PROCESSO DE APRENDIZAGEM	34
4.5.1	Função de ativação	36
4.5.2	Métricas de Avaliação de redes neurais	36
4.5.3	Pré-tratamento de dados	37
4.5.4	Separação do conjunto de dados	38
4.5.5	Critério para parada de treino	38
4.6	<i>PERCEPTRON DE MÚLTIPLAS CAMADAS</i>	39
<b>5</b>	<b>MATERIAL E MÉTODOS</b>	<b>41</b>
5.1	A EMPRESA	41
5.2	OS DADOS	41
5.3	APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS	43
<b>6</b>	<b>RESULTADOS E DISCUSSÃO</b>	<b>46</b>
6.1	REALIZAÇÃO DA PREVISÃO	46
6.2	AVALIAÇÃO DOS RESULTADOS	47
6.3	RESULTADOS	50
6.4	PREVISÃO	50
6.5	MELHORIAS PARA A EMPRESA	52
<b>7</b>	<b>CONCLUSÕES E PERSPECTIVAS</b>	<b>54</b>
	<b>REFERÊNCIAS</b>	<b>56</b>

## 1 INTRODUÇÃO

Segundo dados oficiais divulgados pelo Instituto Brasileiro de Geografia e Estatística (IBGE) o resultado do Produto Interno Bruto (PIB) aponta uma queda no desempenho da indústria, do comércio e dos serviços no primeiro trimestre de 2019 (IBGE, 2019).

Dessa maneira, ser capaz de prever a venda de produtos é de extrema relevância, dado que a mesma traz pontos para redução de riscos à tomadas de decisões, além de ser um fator importante para que a empresa consiga organizar suas estruturas internas, de forma a atender seus clientes com qualidade, eficiência e com o menor custo possível (SILVA, 2010).

Silva (2003) menciona que existem vários métodos para fazer previsões, sendo essencialmente: quantitativos, objetivos com base matemática e estatística; qualitativos, intuitivos e de natureza prática; e combinações de ambos. Apesar dos métodos qualitativos apresentarem um grau de precisão mais baixo, ainda são os mais utilizados por empresas (MENTZER; COX, 1984).

Através de informações históricas de vendas, pode-se utilizar uma Rede Neural Artificial (RNA) em conjunto com os métodos clássicos, possibilitando complementar as previsões já existentes com o conhecimento adquirido, através da dinâmica de vendas passadas (SILVA, 2010).

Dado o volume de informações armazenadas por empresas atualmente, a utilização de sistemas inteligentes para tratamento das mesmas traz um diferencial atrativo, já que tem o potencial de colocar a empresa em uma posição mais competitiva e preparada para tratar fatores que determinarão seu sucesso, sendo que, quanto mais assertiva a previsão maior será o auxílio na tomada de decisão e organização da empresa.

Neste sentido, este estudo irá abordar a aplicação de Redes Neurais Artificiais nos dados de venda de ração e medicamentos, em uma empresa do ramo de *pet shop* da cidade de Ponta Grossa-PR, com vistas a elevar a acurácia das previsões.

## 1.1 OBJETIVOS

O presente trabalho possui o objetivo de realizar um estudo sobre o processo de previsão de demanda utilizando redes neurais artificiais, fazendo uma análise comparativa entre diferentes topologias de Redes Neurais Artificiais (RNA) do tipo Perceptron de Múltiplas Camadas.

Este trabalho também será composto pelos seguintes objetivos específicos:

- Adquirir as amostras junto à companhia;
- Implementar e avaliar o desempenho de diferentes topologias da RNA;
- Justificar a escolha da melhor topologia para o problema em questão.

## 1.2 JUSTIFICATIVA

A previsão de demanda é uma etapa fundamental para o planejamento de toda empresa, já que através dela é possível avaliar adequadamente os recursos necessários para seu funcionamento, de maneira a evitar perdas com custo de estoque desnecessário.

Devido as redes neurais artificiais possuírem capacidade de aprendizagem, as mesmas podem determinar uma relação entre as entradas e saídas, apresentando uma importante vantagem, visto que é possível trabalhar com dados que apresentem relação não linear sem depender de modelos matemáticos complexos.

Observa-se na literatura a aplicação de muitas topologias de RNA's para previsão de vendas e demanda. Florencio (2010) e Oliveira (2016) aplicaram RNA's para previsão da demanda de peças de reposição de veículos automotores e previsão da demanda de energia elétrica, respectivamente. Segundo os autores, essa metodologia se mostra eficiente para essas aplicações.

## 1.3 ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado por capítulos, de forma que o Capítulo 1 apresenta a introdução, justificativa e os objetivos do trabalho.

No Capítulo 2 é feita uma uma revisão bibliográfica sobre estoque e conceitos de custo.

O Capítulo 3 traz métodos de previsão de demanda, além de sua importância para gestão de estoque.

No Capítulo 4 é feito um estudo teórico sobre redes neurais, apresentando seu histórico, modelo biológico e artificial, assim como características da rede utilizada.

O Capítulo 5 apresenta a empresa e os dados utilizados, além das tratativas utilizadas no pré-processamento dos dados e a escolha da melhor topologia de rede.

No Capítulo 6 os resultados são avaliados e discutidos.


Por fim, no Capítulo 7 tem-se a conclusão e proposta para trabalhos futuros na área.

## 2 ESTOQUE

Pode-se conceituar o estoque como conjunto de mercadorias, matéria-prima ou material de expediente reservado a alguma finalidade (MOREIRA, 2013).

O estoque tem como função determinar o fluxo de negócios e a velocidade de recebimento de mercadorias. Habitualmente, a velocidade de recebimento é diferente da velocidade de saída, fazendo-se essencial a existência do estoque, o qual atua como um amortecedor (*buffer*). Alt e Martins (2009) fazem uma analogia com a caixa d'água, como mostra a Figura 1:

**Figura 1 – Analogia do estoque**



**Fonte: Alt e Martins (2009).**

Na figura, quando a vazão de entrada é maior que o de saídas, o nível de estoque aumenta. Caso o contrário, o estoque diminui. Já se a entrada for igual a saída, o estoque se manterá. Considerando  $V(t)$  o número de entradas/tempo,  $v(t)$  o número de saídas/tempo e  $E$  o estoque, teremos (ALT; MARTINS, 2009):

$$V(t) \times t > v(t) \times t \rightarrow E \text{ aumenta} \quad (1)$$

$$V(t) \times t < v(t) \times t \rightarrow E \text{ diminui} \quad (2)$$

$$V(t) \times t = v(t) \times t \rightarrow E \text{ constante} \quad (3)$$

Dessa forma, a correta determinação do estoque é um elemento de grande interesse e influência para as empresas. Sabe-se que o capital investido em estoques



é custoso e o mesmo zerado torna inviável uma empresa manter-se ativa, pois como já mencionado, funciona como amortecedor a meio das fases da venda (DIAS, 2009).

Dias (2009) aponta que manter o estoque em empresas envolve opiniões conflitantes, decorrentes de diferentes interesses internos entre os setores, pois de um lado existe o setor produtivo, qual reivindica matéria-prima que acarretará no aumento do estoque, e do outro lado tem-se o setor financeiro, demandando a redução do capital investido e provocando diminuição do estoque.

Segundo Schwitzky (2001), o estoque normalmente é calculado como o volume médio entre:

- Oferta e demanda;
- Demanda dos clientes e produtos acabados;
- Produtos acabados e disponibilidade dos componentes;
- Exigências de uma operação e resultado da operação anterior;
- Peças e materiais necessários no início da produção e fornecedores de materiais.

Schwitzky (2001) classifica os estoques de acordo com a sua função, como podemos observar, resumidamente, na Tabela 1.

**Tabela 1 – Classificação de estoque conforme função**

<b>Tipo</b>	<b>Função</b>
Estoque de antecipação	Criado para suprir um pico de vendas, antecipando uma demanda futura.
Estoque de flutuação	Usado para compensar flutuações imprevisíveis no suprimento, na demanda e no tempo de entrega. Também conhecido como estoque de segurança e/ou reserva.
Estoque de tamanho de lote	Gerado quando o tamanho do lote é maior que o necessário. Comumente adquirido em função de promoções e/ou lote mínimo do fornecedor.
Estoque de transporte	Tem função de transportar os produtos de um lugar para o outro. Como por exemplo: da fábrica para o centro de distribuição.
Estoque de especulação	Adquirido quando o valor de certos produtos sofrem muita variação e os compradores têm expectativa de aumento futuro.

**Fonte: Adaptado de Schwitzky (2001).**

Vale salientar que o estoque vem a ser um ativo relevante em consequência a estar conexo à função de elemento decisivo na verificação do lucro líquido e no cál-


culo do valor capital circulante líquido do balanço patrimonial da empresa (ALMEIDA, 2017). Portanto é de extrema importancia manter um estoque preciso afim de satisfazer prioridades gerenciais de forma competente.

## 2.1 CUSTO DE ESTOQUE

De acordo com Dias (2009), “todo e qualquer armazenamento de material gera custos, que podem ser: juros, depreciação, aluguel, equipamentos de movimentação, deterioração, obsolescência, seguros, salário e conservação”. Pode-se resumir essa ideia em três categorias de custos importantes para formação dos mesmos:

- Custo de pedido: Compreende os custos fixos administrativos relacionados ao processamento de compra dos itens necessários para reposição de estoque. Há custos para: preencher um pedido de compra; realizar o serviço burocrático; contabilidade; almoxarifado; e receber o pedido e verificação contra a nota e a quantidade física (SILVA; RABELO, 2017). Podemos notar na Figura 2 adaptada de Dias (2009), que cada vez que conciliamos um pedido com o maior número de produtos faltantes reduzimos o custo do mesmo.

**Figura 2 – Curva do custo do pedido**




Fonte: Dias (2009).

- Custo de armazenagem: São ligados à conservação dos bens físicos, sendo envolvidos os custos de armazenagem, locação, climatização, iluminação, seguro, deterioração e obsolescência, furto e custo de oportunidade de aplicar di-

nheiro em estoque. O custo é diretamente proporcional ao volume estocado, como pode-se perceber na Figura 3.

**Figura 3 – Curva do custo de armazenagem**



Fonte: Dias (2009).

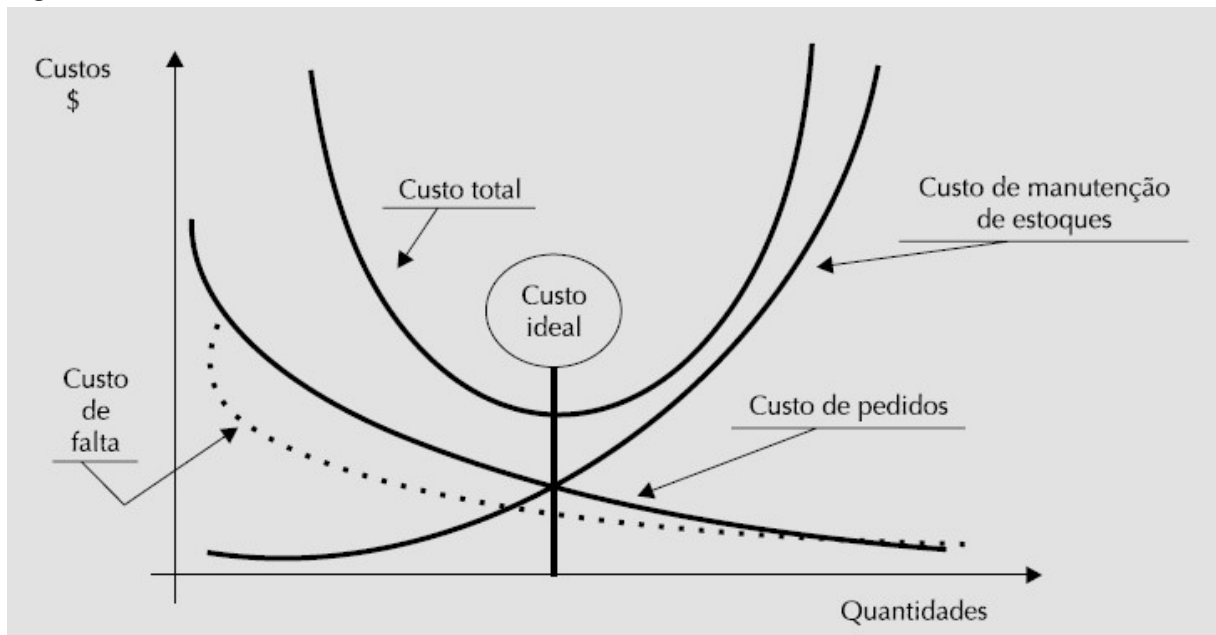
- Custo por falta de estoque: ao manter-se uma quantidade ineficiente de estoque e o mesmo chegar ao esgotamento, haverá custos em consequência a falha no fornecimento aos consumidores. Na hipótese de se tratarem de consumidores externos, os mesmos poderão trocar de fornecedor. No caso interno, a ausência do produto pode levar a tempo improdutivo no processo seguinte, ineficiências e consumidores externos insatisfeitos. (SANTOS et al., 2009). Este custo é complexo de mensurar devido ao envolvimento da satisfação e fidelidade dos consumidores.

Agregando as três classes de custos que incidem no planejamento de estoque listadas acima, adquire-se uma curva de custos, conforme a Figura 4. O propósito é minimizar o custo total, que é o acumulado dos três anteriores.

Para Alt e Martins (2009), pode-se classificar os custos de manter estoques em três grandes categorias: custos diretamente proporcionais, inversamente proporcionais e independentes da quantidade estocada. Segundo o mesmo são eles:

- Custos diretamente proporcionais: ocorrem quando os custos crescem com o aumento da quantidade média estocada;

**Figura 4 – Curva do custo total**



Fonte: Pozo (2015).

- Custos inversamente proporcionais: são os custos ou fatores de custos que diminuem com o aumento do estoque médio, isto é, quanto mais elevados os estoques médios, menores serão tais custos (ou vice-versa). São os denominados custos de obtenção, no caso de itens comprados, e custos de preparação, no caso de itens fabricados internamente;
- Custos independentes: são aqueles que independem do estoque médio mantido pela empresa, como o aluguel de um galpão. Geralmente é um valor fixo, independentemente da quantidade estocada.

Conseqüentemente, a empresa visa determinar um estoque preciso em relação a demanda, negociação com fornecedores, oscilações de mercado, satisfação do cliente e garantir um correto balanceamento dos custos de armazenagem, de pedido e de falta. Isto garante um controle de seus recursos monetários, gerando uma economia que poderá ser usada para aprimorar seu patrimônio (processos, novos equipamentos, expansão, diversificação da atividade), resultando em mais eficiência e competitividade (POZO, 2015).

### 3 PREVISÃO DE DEMANDA

De acordo com Kotler (1997), dá-se o nome de demanda refere-se, em linhas gerais, a procura por determinado serviço ou bem. A previsão de consumo ou de demanda é uma maneira de presumir seu valor futuro, através da antecipação do que os compradores eventualmente exercerão em um certo conjunto de situações (CAVALHEIRO, 2003). Refere-se, então, ao ato de avaliar quais, quanto e quando tais itens serão comprados pelos consumidores. A previsão possui algumas pequenas particularidades mencionadas por Dias (2009):

- É o ponto de partida de todo planejamento;
- Não é uma meta de vendas;
- Sua precisão deve ser compatível com o custo de obtê-la.

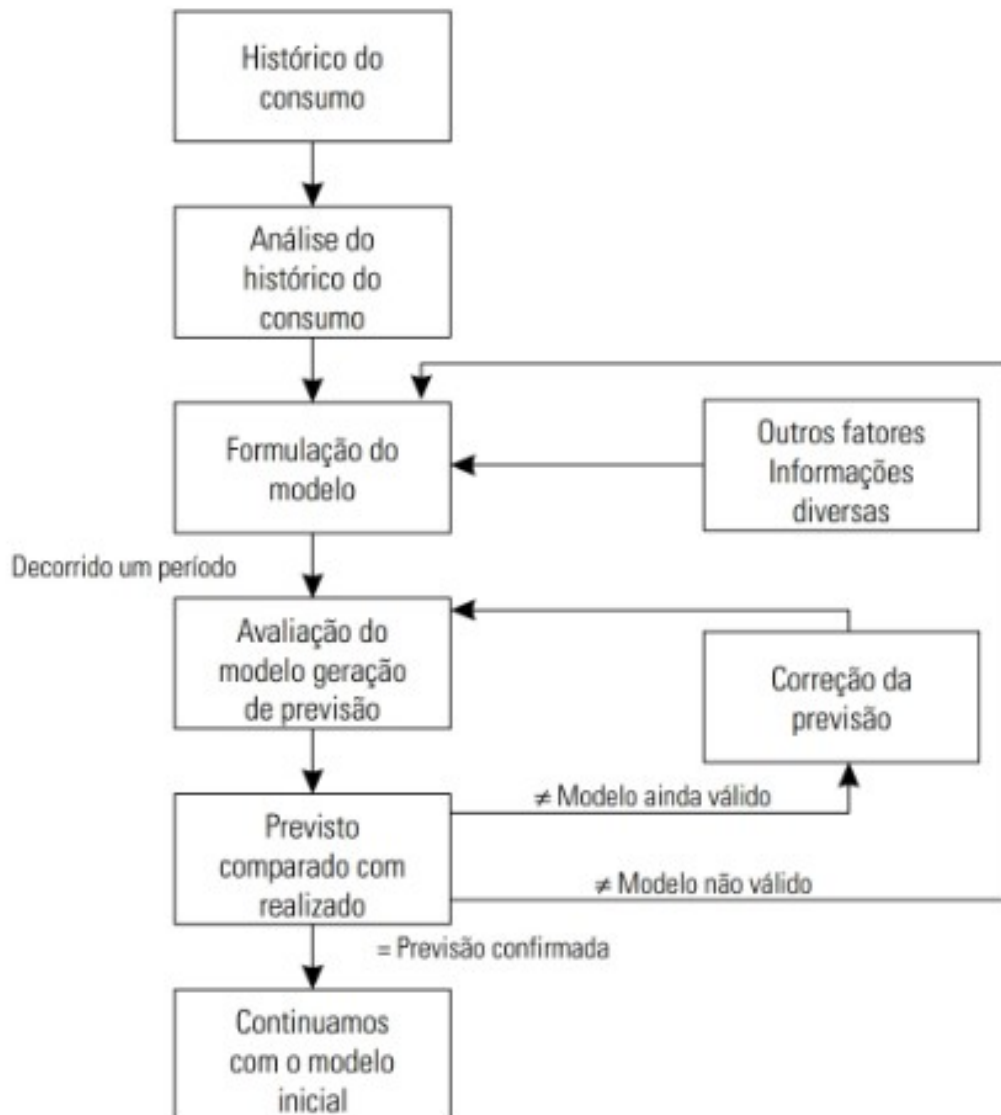
#### 3.1 ETAPAS DE UM MODELO DE PREVISÃO

É representado na Figura 5 um fluxograma a respeito das etapas do processo de previsão de demanda, sendo dividido em cinco passos principais:

Na Figura 5, os blocos podem ser descritos como:

- Histórico do consumo: tem como objetivo a escolha de um produto de acordo com a relevância do mesmo em meio ao propósito da previsão;
- Análise do histórico do consumo: análise dos dados históricos do produto escolhido para se fazer a previsão;
- Formulação do modelo: é estabelecida qual a técnica mais adequada para realizar a previsão;
- Avaliação do modelo geração de previsão: é avaliado o modelo em comparação a outras técnicas;
- Previsto comparado com realizado: já obtida as previsões futuras da demanda, são confrontados os resultados entre demanda prevista e a demanda real obtida.

**Figura 5 – Comportamento dinâmico do processo de previsão**



**Fonte: Dias (2009).**

O processo de monitorar e de integrar os dados é chamado gestão de demanda (CAVALHEIRO, 2003). Por diversas razões houve um aumento na procura de técnicas de previsão de demanda, com intuito de auxiliar tomadas de decisão dentro das empresas. Dentre as principais razões para isso, pode-se citar: maior complexidade das empresas e do mercado, padronização da tomada de decisão, evolução de métodos e a agilidade para utilização prática dos modelos (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008).

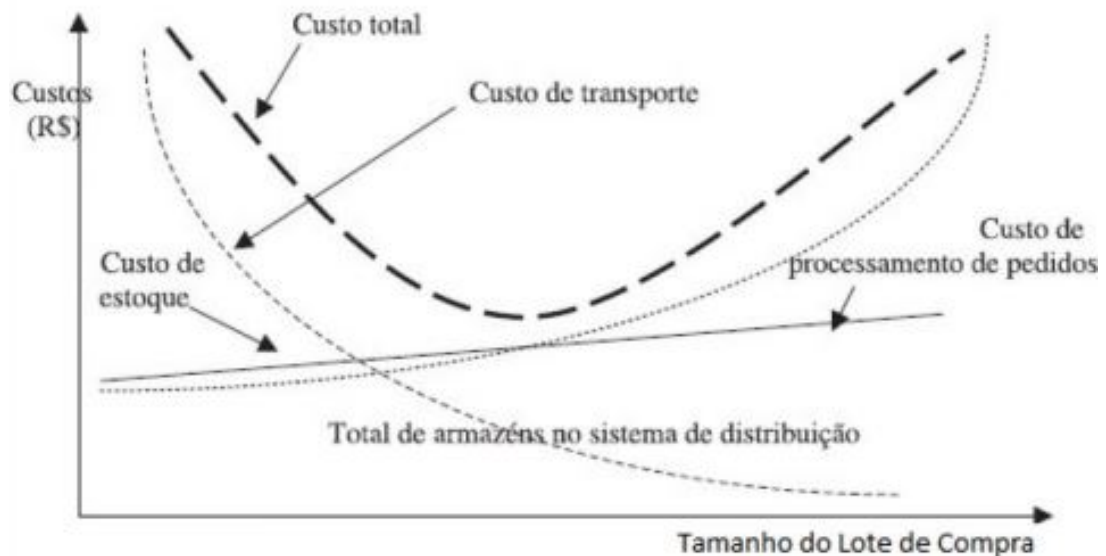
Por conseguinte, a previsão de vendas faz-se imprescindível às empresas no sentido financeiro, tal como na satisfação dos seus clientes. Realizar previsões de

maneira precisa possibilita uma melhor organização da compra de matéria prima, produção e demais pontos relativos ao produto, de modo a evitar imprevistos (SILVA, 2010).

Conforme Mine (2010), a técnica de previsão da demanda traduz uma etapa fundamental para o planejamento empresarial, propiciando avaliar adequadamente os recursos necessários à empresa e, por essa razão, é vista como o eixo do processo de planejamento. Consiste, então, em uma das atividades mais importantes de um sistema de produção promovendo custos quando há excesso ou escassez do produto demandado.

Como já mencionado, para manter-se um estoque há custos, tanto na compra de matéria-prima desnecessária como para condicionamento do mesmo. Desta forma, isto ocasiona um gasto desnecessário, uma vez que tal valor poderia estar sendo reinvestido, diminuindo a liquidez da empresa devido a previsões falhas da demanda de seus produtos (SILVA, 2010). Isto equivale a afirmar que reter um estoque gera custos, tanto na compra de produtos ou matéria-prima desnecessária como o custo para mantê-lo, sendo eles diretamente proporcionais à quantidade estocada, inversamente proporcionais à quantidade estocada e independentes da quantidade estocada, conforme ilustrado na Figura 6 (FLORENCIO, 2010).

**Figura 6 – Curva do custo total do estoque**



Fonte: Florencio (2010).

Distingue-se na Figura 6 três situações relevantes para nossa análise:

1. obtém-se o custo de estoque mínimo, porém o custo total e de transporte são

máximos;

2. obtém-se o custo de transporte mínimo, porém o custo total e de estoque são máximos;
3. obtém-se o menor custo total quando o custo de transporte e de estoque são “medianos”.

Tal comportamento ocorre em consequência aos custos inversamente proporcionais, como o de transporte que é reduzido à medida que aumenta a quantidade estocada. Porém, os custos diretamente proporcionais seguem sendo somados enquanto o estoque aumenta (FLORENCIO, 2010).

Além dos custos de armazenamento, problemas com produtos obsoletos (itens ou serviços que deixam de ser úteis para o estabelecimento pelos surgimentos de um substituto, falta de procura e até vencimento do mesmo) podem gerar um grande problema para as empresas.

Desse modo, observa-se que a previsão de demanda é de grande importância para as empresas e conseqüentemente, uma previsão com maior acuracidade auxilia a mesma como um todo, desde estratégias de vendas até a percepção de qualidade. Isto atinge não só a organização em si, mas todos seus elementos, sendo eles clientes ou fornecedores (FLORES, 2006).

Após ter discutido os conceitos relacionados ao problema, é relevante distinguir as técnicas de previsão de demanda presentes na atualidade, assim como suas distinções associadas à finalidade das mesmas.

### 3.2 MODELO DE PREVISÃO

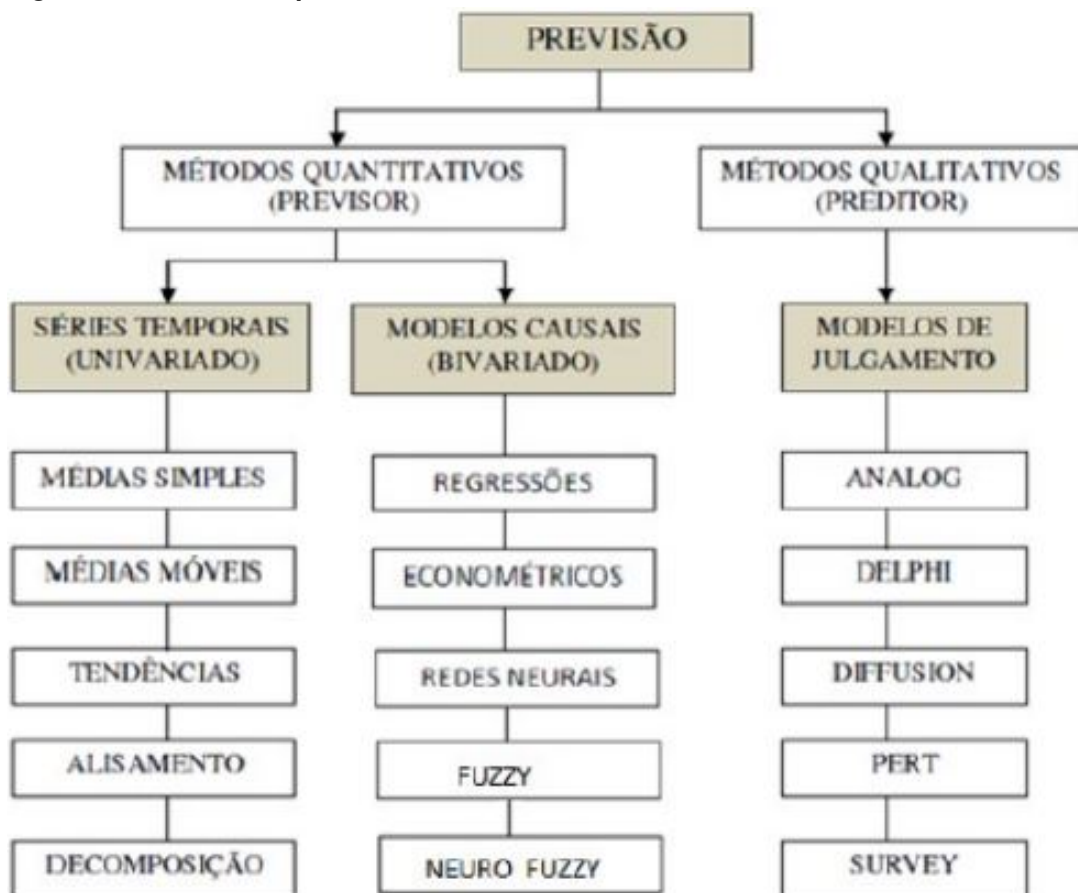
Existem diversas formas de classificar os métodos e técnicas de previsão, como técnicas subjetivas, objetivas, não causais e causais. Diversos métodos relacionados exclusivamente a demanda podem ser divididos em duas categorias principais: qualitativos (preditor) e quantitativos (previsor) (FLORENCIO, 2010).

Conforme um modelo adaptado de Silva (2003) por Florencio (2010), a classificação dos modelos de previsão segue diagrama representado na Figura 7:

Montgomery, Johnson e Gardiner (1990) indicam os seguintes elementos para escolha do método ideal:



Figura 7 – Métodos de previsão de demanda




Fonte: Florencio (2010).

- Forma requerida de previsão;
- Período, horizonte e intervalo de previsão;
- Disponibilidade de dados;
- Acurácia requerida;
- Padrões de demanda;
- Custo de desenvolvimento, instalação e operação;
- Facilidade de operação;
- Compreensão e cooperação da administração.

Existe um ponto de equilíbrio entre os custos totais e a precisão da previsão, como elaborado na Figura 8. Conforme a precisão da previsão aumenta, seu custo se eleva. Porém, custos que estão relacionados com às incertezas geradas pelo erro

diminuem. Pode-se observar que existe um ponto em que tanto os custos totais de incertezas e implantação minimizam o custo total (FURTADO, 2007).

**Figura 8 – Precisão e custos na previsão**



**Fonte: Montgomery, Johnson e Gardiner (1990).**

Dadas as duas categorias principais que regem os demais modelos podemos descrever as mesmas da seguinte maneira como segue.

Métodos qualitativos – são baseados no julgamento e na experiência de pessoas que possam, por suas próprias particularidades e sabedoria, expor opiniões sobre eventos futuros de interesse. Isto não se limita às previsões de demanda, tendo potencial de serem aplicados na análise de tendências de novos produtos, condições econômicas e políticas, movimentos do comércio internacional, rumos da tecnologia futuras, dentre outros (MOREIRA, 2017).

As metodologias qualitativas aplicadas com mais sucesso são: o consenso de executivos, a pesquisa de mercado, a composição da força de vendas e o método Delphi. Esse último é muito vantajoso quando utilizado no lançamento de novos produtos no mercado, em que não há histórico de venda. Do mesmo modo, é muito eficiente quando não se tem dados confiáveis sobre o histórico.

Por seu caráter subjetivo, os métodos qualitativos, quando aplicados de maneira equivocada, geram tendências que podem influenciar os resultados, comprometendo a eficácia de sua previsão. A Tabela 2 indica quais são as tendências mais

comumente observadas e sugere formas de amenizar as consequências das mesmas no processo preditivo (SPEDDING; CHAN, 2000).

**Tabela 2 – Tendências comuns em métodos qualitativos**

<b>Tipo de tendência</b>	<b>Descrição de tendência</b>	<b>Maneiras de reduzir o impacto negativo da tendência</b>
Otimismo	Previsão reflete os resultados desejados pelos tomadores de decisão.	Ter mais de uma pessoa para fazer a previsão.
Inconsistência	Incapacidade de aplicar o mesmo critério de decisão em situações similares.	Formalizar o processo de tomada de decisão e criar regras de tomada de decisão.
Novidades	Os eventos mais recentes são considerados mais importantes que eventos mais antigos, que são minimizados ou ignorados.	Considerar os fatores fundamentais que afetam o evento de interesse. Perceber que ciclos e sazonalidades existem.
Disponibilidade	Facilidade com a qual informações específicas podem ser reutilizadas quando necessário.	Apresentar informações completas que apontem todos os aspectos da situação a ser considerada.
Correlações Ilusórias	Acreditar na existência de padrões e/ou que variáveis são relacionadas quando isto não é verdade.	Verificar significância estatística dos padrões. Modelar relações, se possível, em termos de mudanças.
Conservadorismo	Não mudar ou mudar lentamente o ponto de vista quando novas informações/evidências estão disponíveis.	Monitorar as mudanças e elaborar procedimentos para atuar quando mudanças sistemáticas são identificadas.
Percepção seletiva	Tendência de ver problemas baseado na própria experiência.	Fazer com que pessoas com diferentes experiências façam previsões independentes.


**Fonte: Furtado (2007).**

Métodos quantitativos – são aqueles que aplicam critérios matemáticos para análise dos dados, com embasamento na Estatística, afim de implementar a previsão e possibilitando que diferentes especialistas obtenham resultados similares (MOREIRA, 2017). O modelo de previsão é escolhido de acordo com as componentes da série temporal em estudo. Destas, três nos interessam e possuem definição conhecidas:

- Média: ocorre quando os valores de uma série oscilam entre um valor médio constante. Na Figura 9, o consumo efetivo pode ser sintetizado como con-

sumo médio, de tendência invariável, já que seus valores mudam em função do mesmo.


**Figura 9 – Modelo de evolução horizontal**



Fonte: Dias (2009).

- Sazonalidade: ocorre quando existem padrões cíclicos de variação que se repetem em intervalos relativamente constantes de tempo. Observando a Figura 10, o consumo efetivo apresenta oscilações regulares (positivas ou negativas), apresentando característica sazonal “quando o desvio é no mínimo de 25% do consumo médio e quando aparece condicionado a determinadas causas” (DIAS, 2009).


**Figura 10 – Modelo de evolução sazonal de consumo**



Fonte: Dias (2009).

- Tendência: tal componente existe quando a série, de uma maneira geral, apresenta uma tendência ascendente ou descendente quando analisado um longo período de tempo. A Figura 11 mostra o consumo efetivo com variações que podem ser aproximadas ao consumo médio que segue uma linha de tendência ascendente, dado seu crescimento ao longo do tempo.

**Figura 11 – Modelo de evolução de consumo sujeito à tendência**



Fonte: Dias (2009).

Pozo (2015) cita os métodos quantitativos e os qualitativos como intrinsecamente insuficientes, de maneira a ser fundamental a aplicação em conjunto de modelos matemáticos afim de levar a uma melhor precisão dos dados desejados, na pretensão de reduzir os custos envolvidos e aprimorar os resultados pretendidos.

## 4 REDES NEURAIS ARTIFICIAIS

Durante a última década, o interesse sobre Inteligência Computacional (IC) tem aumentado, visto que o mercado e academia tem buscado novas formas de realizar a solução de tarefas nas mais diversas áreas. Redes neurais artificiais fazem parte desta categoria, que consistem em expressões matemáticas, fundamentadas nas redes de neurônios biológicos dos organismos superiores, com capacidade de aprendizado por meio computacional. Atuam com os dados através de estruturas de armazenamento e processamento, dos quais cada componente capaz de processar a informação equivale a um neurônio artificial (OLIVEIRA, 2016).

### 4.1 HISTÓRICO

De acordo com Haykin et al. (2009), a primeira representação de um neurônio artificial foi apresentada por Warren McCulloch e Walter Pitts em 1943, os quais publicaram *“A Logical Calculus of the Ideas Immanent in Nervous Activity”*, expondo tópicos a respeito de neurônios (nodos), máquinas de estados finitos, elementos de decisão de limiar lineares, representações lógicas, comportamento de memória e, mais adiante, retrata modelos matemáticos afim de caracterizar o comportamento dos neurônios.

Esta primeira obra de McCulloch e Pitts traz maior ênfase na definição do modelo artificial de um neurônio e suas capacidades computacionais do que em expor técnicas de aprendizado. No entanto, nos anos seguintes, Donald Hebb, torna o aprendizado de redes biológicas e artificiais objeto de estudo (SILVA; SPATTI; FLAUZINO, 2010). O conceito apresentado por Hebb é muito utilizado atualmente em algoritmos de aprendizado. Segundo a regra que leva seu nome, no momento que dois neurônios são excitados concomitantemente, a eficiência sináptica entre eles aumenta.


### 4.2 INSPIRAÇÃO BIOLÓGICA

A busca pelo entendimento das atividades do cérebro e do sistema nervoso vem sendo pesquisada há mais de um século. Esta área fundamenta-se em interpretar o funcionamento dos neurônios que são encarregados de gerir, receber e transmitir as

informações recebidas em forma de pulsos elétricos, já que trata-se da célula elementar do sistema nervoso central.

Conforme Braga, Carvalho e Ludermir (2000), o cérebro humano compõe-se de  $10^{11}$  neurônios, aproximadamente, no qual cada um processa e se comunica com milhares de outros continuamente e em paralelo, através das conexões sinápticas, "tendo como objetivo a produção de ações apropriadas para cada uma das suas funcionalidades, tais como pensar e memorizar" (SILVA; SPATTI; FLAUZINO, 2010).

Os neurônios biológicos possuem três principais elementos, que podem ser observados na Figura 12: dendritos, corpo celular e axônio (SILVA; SPATTI; FLAUZINO, 2010).



Fonte: Florencio (2010).

Pode-se discorrer brevemente sobre estes como segue:

- Dendritos – Compostos por inúmeros prolongamentos que formam a árvore dendrital. Seu papel é captar os estímulos recebidos de outros neurônios ou do meio externo;
- Corpo celular – Responsável por processar as informações recebidas pelos dendritos com o intuito de ocasionar um potencial de ativação que apontará se o neurônio poderá disparar um impulso elétrico ao longo do seu axônio;
- Axônio – Formado por um único prolongamento que tem como função transmitir os impulsos para outros neurônios.

Em síntese, a transmissão entre os neurônios é gerada através de pulsos elétricos. No momento que um dado neurônio recebe um novo impulso, o mesmo é

recebido através de seus dendritos sendo processado, direcionado pelo corpo celular para o axônio que, por fim, o transmite para outros neurônios.

### 4.3 MODELO ARTIFICIAL

A disposição das redes neurais artificiais (RNA's) foi fundamentada segundo o sistema nervoso dos organismos superiores, sendo capaz de assimilar e reter conhecimento, sendo dotadas de alto grau de paralelismo e conectividade. As RNA's procuram desempenhar a mesma função após realizar treinamento ou aprendizado. Os elementos computacionais são chamados neurônios artificiais, inspirados nos neurônios biológicos, mas modelados de maneira simplificada.

Os neurônios artificiais são não-lineares (em geral), constituídos de funções simples, e coletam sinais de entradas, processam e produzem uma resposta contínua única, de acordo com sua respectiva função de ativação.

A representação mais utilizada de um neurônio inclui as características fundamentais de uma rede biológica. Segundo Silva, Spatti e Flauzino (2010), o modelo citado é representado segundo a Figura 13. Os sinais de entrada resultantes do meio externo (aplicação) são representados pelo conjunto  $x_1, x_2, x_3, \dots, x_n$ , que são análogos aos impulsos elétricos externos, captados pelos dendritos no neurônio biológico.


Na modelagem, há ponderações exercidas pelas junções sinápticas, as quais são representadas pelo conjunto de pesos sinápticos  $w_1, w_2, w_3, \dots, w_n$ . De forma análoga, a relevância de cada uma das entradas  $x_i$  do neurônio é então executada por meio de suas multiplicações pelos respectivos pesos sinápticos  $w_i$ , ponderando-se, portanto, todas as informações externas que chegam ao neurônio. Assim, torna-se possível verificar que a saída do corpo celular artificial, denotado por  $u$ , sendo a soma ponderada de suas entradas (HAYKIN et al., 2009).

Existem sete elementos básicos existentes no neurônio artificial ou que são inseridos no mesmo, como destacado na Figura 13 (SILVA; SPATTI; FLAUZINO, 2010):

1. Sinais de entrada  $x_1, x_2, \dots, x_n$  - Sinais ou padrões provenientes do meio externo que equivalem aos valores assumidos pelas variáveis de uma aplicação específica. Os sinais de entrada são usualmente normalizados tendo em vista a promoção da eficiência computacional dos algoritmos de aprendizagem. Note



**Figura 13 – Modelo artificial**



**Fonte: Silva, Spatti e Flauzino (2010).**

que apenas os neurônios da camada de entrada são estimulados por tais sinais. Camadas posteriores serão ativadas com as saídas dos neurônios das camadas anteriores;

2. Pesos sinápticos  $w_1, w_2, \dots, w_n$  – Valores que tem como objetivo ponderar cada uma das variáveis de entrada da RNA, possibilitando estimar sua relevância em relação a funcionalidade do respectivo controle. Seus valores são ajustáveis, sendo a ação de treinar uma rede, essencialmente, ajustar os melhores valores dos mesmos;
3. Combinador linear  $\Sigma$  - Tem como finalidade integrar todos os sinais de entrada que foram ponderados pelos respectivos pesos sinápticos com intuito de produzir um valor de potencial de ativação;
4. Limiar de ativação  $-\theta$  - Refere-se a uma variável que determina qual será o nível adequado para que o resultado produzido pelo combinador linear possa gerar um valor de disparo em direção a saída do neurônio. Em geral também possui um peso de ponderação ajustável;
5. Potencial de ativação  $u$  – Trata-se do resultado da diferença do valor do combinador linear e do limiar de ativação;
6. Função de ativação  $g(\cdot)$  – Tem como objetivo limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela sua própria imagem funcional. Insere não linearidade da resposta de saída do mesmo, quando, obviamente, utilizada uma função não-linear para tal fim;

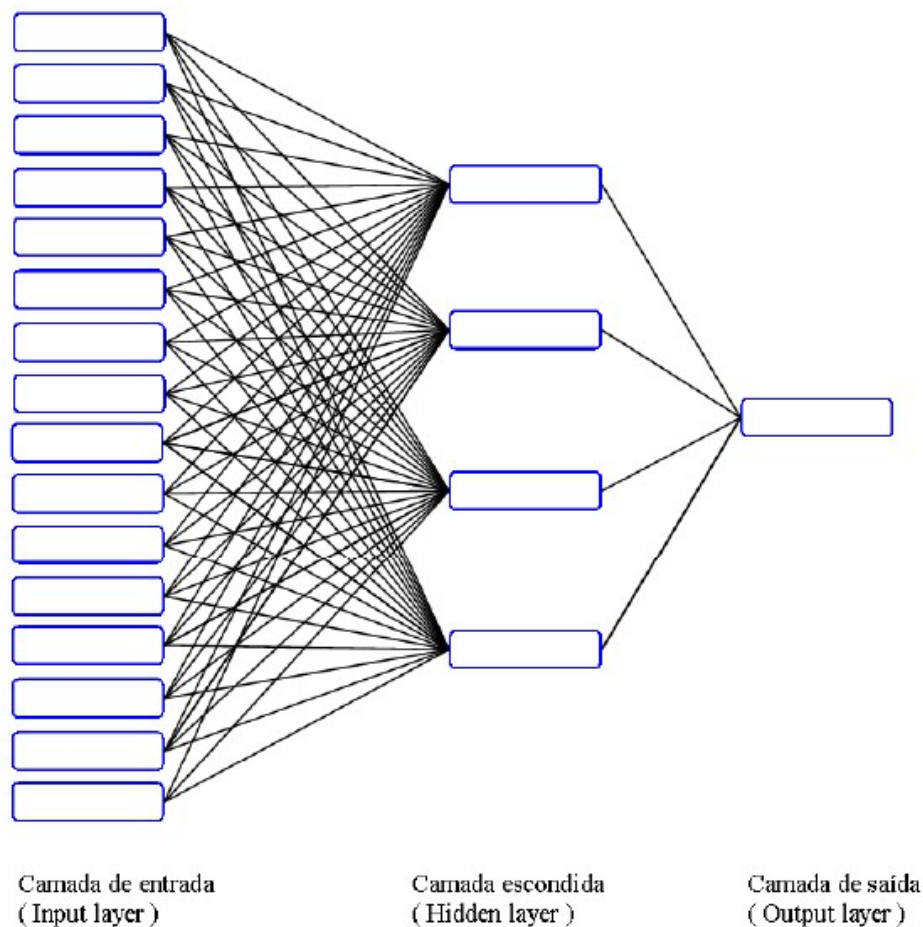
7. Sinal de saída  $y$  - Se trata do valor final produzido pelo neurônio em relação a um determinado conjunto de sinais de entrada, podendo ser também utilizado por outros neurônios que estejam sequencialmente interligados.

Sucintamente, o conhecimento das RNA's é adquirido através de um conjunto de valores dados pelas variáveis de entrada, nas quais são ajustados os pesos sinápticos das conexões entre os neurônios, provocando então um potencial de ativação aplicado em uma função de ativação apropriada. Por fim, é executada a compilação da sua saída.

#### 4.4 ARQUITETURA DA REDE

Redes neurais artificiais contêm diversos neurônios, comumente agrupados em camadas, como podemos observar na Figura 14, qual cada balão representa um neurônio.

**Figura 14 – Uma rede típica do tipo *feedforward* (MLP).**



**Fonte: Sousa (2011).**

A primeira camada, conhecida como camada de entrada (*input layer*), tem papel de transmitir a informação de entrada para as camadas seguintes. A última camada corresponde a saída (*output layer*), da qual obtém-se a previsão. Em muitos casos, esta pode conter neurônios com funções de ativação lineares. Estas camadas são separadas por uma ou mais camadas intermediárias que são chamadas de camadas escondidas (*hidden layers*).

A estrutura também é composta pelos números de neurônios em cada camada, tipo de conexão entre eles e topologia da rede. Esses parâmetros influenciam na qualidade da aplicação abordada. Estas unidades de processamento são responsáveis por calcular as funções matemáticas estabelecidas, estando dispostas em várias camadas e interligadas de maneira unidirecional (*feedforward*) para a abordagem deste trabalho.

Conforme Sousa (2011), no momento que definimos a arquitetura da rede temos que indicar o número de neurônios em cada camada, o número de camadas, as respectivas funções de ativação e a relação de comunicação entre os neurônios.

A quantidade adequada de neurônios da camada de entrada é determinada pelo número de atributos do problema, em razão das informações a respeito da estrutura de auto correlação existente nos dados. Vale a pena salientar que, em alguns casos, é preciso aplicar alguma técnica de seleção de variáveis para melhor desenvolvimento da RNA.

O total de camadas intermediárias e seu número de neurônios respectivos é muito importante de ser determinado, uma vez que são estes que permitem aprender o padrão de comportamento dos dados e estabelecer mapeamentos não lineares complexos entre as variáveis de entrada e saída.

Vale apontar que um número elevado de neurônios pode acarretar um aumento do tempo de treino e poderá piorar a capacidade de generalização da rede (HAYKIN et al., 2009).

#### 4.5 PROCESSO DE APRENDIZAGEM

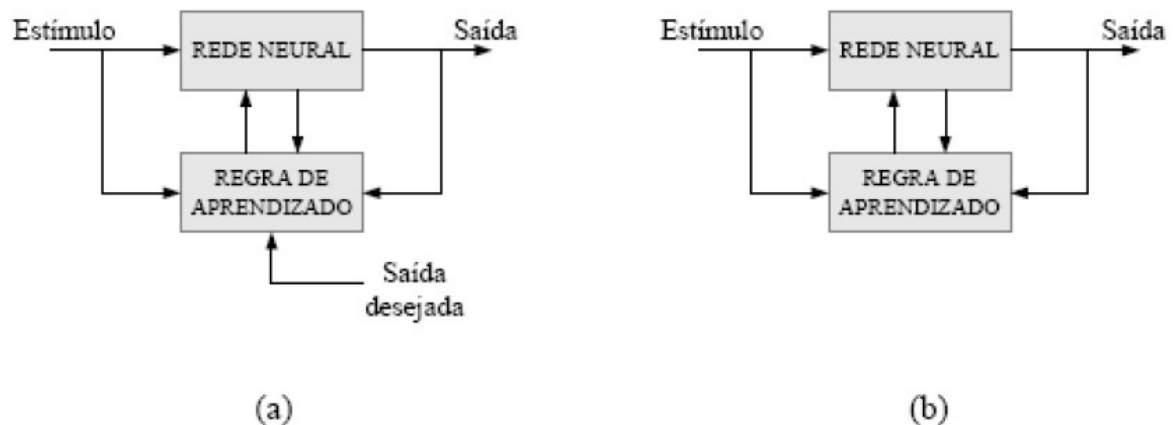
Uma das particularidades mais importante das RNA's é a aptidão de aprender com os dados indicados e, desse modo, melhorar o seu desempenho. O aprendizado da rede acontece com o ajuste de seus pesos, processo este usualmente realizado de

forma iterativa. Os algoritmos de treinamento se diferenciam, podendo ser de forma supervisionada, não supervisionada ou híbrida.

No treinamento supervisionado, a rede recebe amostras que apresentam um conjunto de entradas e suas respectivas saídas, processa essas informações e procura ajustar os pesos de maneira a minimizar o erro, ou a diferença entre saída e a entrada.

O treinamento não supervisionado recebe apenas as entradas do problema e o ajuste de pesos se dá em busca de correlações e regularidades nas amostras. Já o treinamento híbrido une os dois casos citados anteriormente. A Figura 15 ilustra os treinamentos mais comuns, supervisionado e não supervisionado.

**Figura 15 – Treinamento: (a) Supervisionado (b) Não supervisionado.**



Fonte: Higuti (2017).

O algoritmo mais utilizado para o treino supervisionado é intitulado gradiente descendente, com derivadas calculadas pelo conhecido *backpropagation*, ou retropropagação do erro. Neste método, as entradas do problema são apresentadas à rede neural e passadas até a camada de saída. Em seguida, o erro da iteração corrente é calculado, e a derivada da função custo estimada. Em seguida, a lei de ajustes de todos os pesos é aplicada a cada camada, da mais externa (de saída, à direita) a mais interna (entrada) (HAYKIN et al., 2009). Este processo é repetido até ser alcançado o critério de parada definido pelo usuário.

#### 4.5.1 Função de ativação

A função de ativação processa o sinal gerado pela combinação linear das entradas e pesos de um neurônio, afim de gerar um sinal de saída do neurônio. A função de ativação estabelece um grau de não linearidade na resposta da rede. As mais utilizadas são dadas pela Tabela 3:

**Tabela 3 – Funções de ativação**

Designação	Função	Contradomínio
Linear	$f(x) = x$	$]-\infty, +\infty[$
Sigmoide	$f(x) = \frac{1}{1+e^{-x}}$	$[0, 1]$
Sigmóide 1	$f(x) = \frac{2}{1+e^{-x}} - 1$	$[-1, 1]$
Sigmóide 2	$f(x) = \frac{x}{1+ x }$	$[-1, 1]$
Tangente hiperbólica	$f(x) = \tanh x$	$[-1, 1]$
Seno	$f(x) = \sin x$	$[-1, 1]$
Cosseno	$f(x) = \cos x$	$[-1, 1]$
Gaussiana	$f(x) = e^{-\frac{x^2}{2}}$	$[-1, 1]$
ReLU	$f(x) = \max[0, x]$	$[0, +\infty[$

Fonte: Sousa (2011).

#### 4.5.2 Métricas de Avaliação de redes neurais

Para mensurarmos a eficiência da RNA é preciso observar a qualidade de aproximação da previsão. Normalmente, esta é determinada com base em métricas de erro, de forma que se considere a diferença entre o valor real observado e o valor previsto pela RNA. As principais métricas são listadas na Tabela 4 (SIQUEIRA et al., 2018):

**Tabela 4 – Cálculo de erros**

Designação	Fórmula
Erro Absoluto Médio (MAE)	$\frac{1}{n} \sum_{t=1}^n  e_t $
Erro Quadrático Médio (MSE)	$\frac{1}{n} \sum_{t=1}^n (e_t)^2$
Raíz do Erro Quadrático Médio (RMSE)	$\sqrt{\frac{1}{n} \sum_{t=1}^n (e_t)^2}$
Erro Percentual Absoluto Médio (MAPE)	$\frac{1}{n} \sum_{t=1}^n \left( \frac{ e_t }{ y_t } \right) 100$

Fonte: Sousa (2011).

Em que:

- $e_t$  - o erro e previsão no instante  $t$ ;
- $y_t$  - o valor efetivo;

- $n$  - o número de termos do erro;

#### 4.5.3 Pré-tratamento de dados

Posterior a aquisição dos dados do problema, estes precisam ser tratados para que a RNA tenha o funcionamento adequado. As escolhas feitas nessa etapa são fundamentais para a performance da rede.

Um dos métodos mais simples de pré-processamento limita-se a exclusão dos valores inconsistentes (*outliers*), de maneira que o número de entradas diminui e o resultado final não é comprometido por dados inaptos.

Comumente são utilizados métodos de normalização na etapa de pré-tratamento, de modo a criar uma modificação nos dados afim de organizá-los em uma escala pré-definida. Trata-se da última etapa do pré-tratamento. Tem como finalidade, assegurar que a distribuição dos valores de entrada e saída, seja uniforme, e também para que o domínio dos valores inseridos na rede, vá ao encontro do domínio da função de ativação (SOUSA, 2011). Ademais, alguns processos de normalização tem o poder de deixar a série com um comportamento estacionário (SIQUEIRA et al., 2018).

Segundo Sousa (2011), as formulas que são mais frequentemente utilizadas para efetuar a normalização são dadas pela Tabela 5:

**Tabela 5 – Fórmulas para normalização dos dados**

Transformação	Fórmula
Transformação linear para [0,1]	$x_n = \frac{x_0 - x_{min}}{x_{max} - x_{min}}$
Transformação linear para [a,b]	$x_n = (b - a) \frac{x_0 - x_{min}}{x_{max} - x_{min}} + a$
Normalização estatística (z-score)	$x_n = \frac{x_0 - \bar{x}}{S}$
Normalização simples	$x_n = \frac{x_0}{x_{max}}$

**Fonte: Sousa (2011).**

Sendo as variáveis:

- $x_n$  - o valor normalizado;
- $x_0$  - o valor original;
- $x_{min}$  - o valor mínimo da variável no domínio da entrada;

- $x_{max}$  - o valor máximo da variável no domínio da entrada;
- $\bar{x}$  - a média dos dados;
- $S$  - o desvio padrão;

#### 4.5.4 Separação do conjunto de dados

Para construção das RNA's os dados são comumente divididos em dados de treinamento, validação e teste. Os dados de treino são utilizados para ajustar os pesos da rede, o conjunto de validação é empregado para verificar as etapas de treino e determinar quando pará-lo para evitar *overfitting*, enquanto o conjunto de teste é utilizado para estimar a performance de uma RNA ajustada.

Sobretreinamento ou *Overfitting* quer dizer que a rede memoriza os padrões de treino e exibe bons resultados para esses dados, mas, apesar disso, para os de teste o desempenho piora, perdendo capacidade de generalização.

Segundo Haykin et al. (2009) observam, valores típicos para a divisão do conjunto de dados são: 20% dos dados totais utilizados para teste e os demais divididos em 70% para treino e 30% para validação. Entretanto, é importante notar que todos estes conjuntos precisam ser representativos do comportamento estatístico do problema.

#### 4.5.5 Critério para parada de treino

Os critérios de parada indicam quando a RNA está suficientemente treinada. Existem vários critérios para estipular quando parar o processo, como (SOUSA, 2011):

- Após atingir um certo erro;
- Quando não existe mudança de erro durante várias iterações;
- Quando um número máximo de iterações é atingido.

Apesar disso, alguns critérios podem levar à parada prematura ou a um excesso de treino.

Vale salientar que caso a rede tenha sido sujeita a um número excessivo de ciclos de treino, ocorre *overfitting*.

#### 4.6 PERCEPTRON DE MÚLTIPLAS CAMADAS

A principal característica do Perceptron de Múltiplas Camadas (MLP) é a presença de ao menos um camada intermediária (escondida) de neurônios, posicionada entre a camada de entrada e a respectiva camada neural de saída.

Além disso, as MLPs são consideradas uma das arquiteturas mais versáteis no que diz respeito a sua aplicabilidade, uma vez que constam diversas possibilidades em diferentes tipos de problemas relacionados com as mais variadas áreas de conhecimento. Silva, Spatti e Flauzino (2010), citam como potenciais destaques as áreas:

- Aproximação universal de funções;
- Reconhecimento de padrões;
- Identificação e controle de processos;
- Previsão de séries temporais;
- Otimização de sistemas.


A rede *Multi Layer Perceptron* (MLP) refere-se a arquitetura *feedforward* de camadas múltiplas, em outras palavras, sem realimentação, em que seu treinamento é realizado de forma supervisionada. Conforme observa-se na Figura 16, o início da transmissão de informações na estrutura de uma rede MLP surge na camada de entrada, logo após é propagada pelas camadas intermediárias, sendo finalizadas na camada neural de saída.

Haykin et al. (2009) afirma que todas as entradas da rede serão propagadas individualmente em direção a camada de saída da MLP. Diante disso, as saídas dos neurônios da primeira camada escondida se tornarão entradas dos neurônios presentes na segunda camada escondida e assim por diante. Podemos destacar que a camada neural de saída pode ser composta por diversos neurônios.

A topologia da MLP será afetada de acordo com a classe do problema que se deseja tratar, para isto, deve-se configurar a quantidade de camadas ocultas, os números de neurônios das mesmas e os parâmetros de parada do treinamento. Alguns fatores que são observados para o auxílio na definição da topologia são: disposição



Figura 16 – Rede *perceptron* multiplas camadas



Fonte: Silva, Spatti e Flauzino (2010).

especial das amostras de treinamento, valores iniciais de treinamento e matrizes de pesos.

O ajuste de pesos dos neurônios da rede MLP é realizado através do treinamento supervisionado utilizando o algoritmo *backpropagation*, mencionado anteriormente. A lógica de funcionamento está baseada na correção do erro durante a aprendizagem, através de repetições sucessivas do algoritmo, até que se obtenha o valor de erro desejado.

## 5 MATERIAL E MÉTODOS

### 5.1 A EMPRESA

A empresa foco do estudo é uma rede de lojas situada em Ponta Grossa – PR, sendo seu seguimento de atividade comercial um *pet shop*. Possui mais de 15 anos de mercado e dispõem de gestores internos responsáveis pela decisão de compra de seus produtos.

Nos dias atuais, a empresa presente não adota nenhum método sistemático de previsão de demanda. Comumente seus fornecedores apontam uma análise de mercado e apresentam uma lista de sugestão de compra de acordo com os produtos que a empresa comercializa e seu estoque no momento. Posteriormente, esta lista é repassada para os proprietários que então realizam ajustes e emitem a ordem de compra. Percebe-se que a empresa obtém sua previsão de demanda unicamente de maneira qualitativa, em que são levados em consideração a experiência de seus proprietários e opiniões de mercado dos atuais fornecedores.

A empresa em questão comercializa diversas marcas e dispõem de variadas linhas de produtos como medicamentos, rações, acessórios, produtos de higiene e etc. Devido a essas características, o estoque conta hoje com 10.022 itens diferentes, com um investimento de pouco mais de R\$700.000,00.

### 5.2 OS DADOS

O banco de dados nos foi fornecido pela empresa e por questões de confidencialidade os dados foram ajustados, mas continuam representando a realidade e não influenciam a demonstração do resultado.

Os dados de venda apresentam o produto vendido, a data e hora da venda, a loja que realizou a venda e caso o cliente possua cadastro na loja, o nome do cliente.


Também obtivemos os dados relacionados a tabela de cadastro de produtos, estes exibem o produto, o código relacionado ao produto e a categoria superior, que nada mais é que a categoria do produto, sendo elas: ração, medicamentos, acessórios, serviços, animais, petiscos e diversos.

Das informações fornecidas, utilizou-se para treinamento das RNA's somente a quantidade de venda das categorias, primeiro criou-se uma relação entre a tabela de vendas e a tabela de produtos, com isso agrupou-se as vendas por categoria, local e dia, então estes dados agrupados foram ordenados cronologicamente.

Por fim removeu-se os valores que representavam valores inconsistentes, como picos anormais de vendas ou valores nulos. Toda a informação fornecida foi tratada utilizando os softwares Microsoft Office Access e Microsoft Office Excel.

Como já citado anteriormente, filtrou-se os dados em categorias e, por consequência, decidiu-se utilizar apenas a ração e medicamentos devido a quantidade significativa e a qualidade dos dados. Estes são representados nos gráficos das Figuras 17 e 18.

**Figura 17 – Vendas totais de medicamentos**




**Fonte: A autoria própria.**

Obteve-se dados a partir de 2012, mas nos foi alertado pela empresa que no início da implantação do banco de dados houve uma grande quantidade de amostras imprecisas, que não representavam o real cenário. Por essa razão, optou-se em utilizar apenas os dados de 2014 à 2019.

Atentando-se aos detalhes dos dados, percebeu-se que cada unidade física da empresa apresenta uma característica que define uma tendência. Dessa forma, foi

**Figura 18 – Vendas totais de ração**



**Fonte: Autoria própria.**

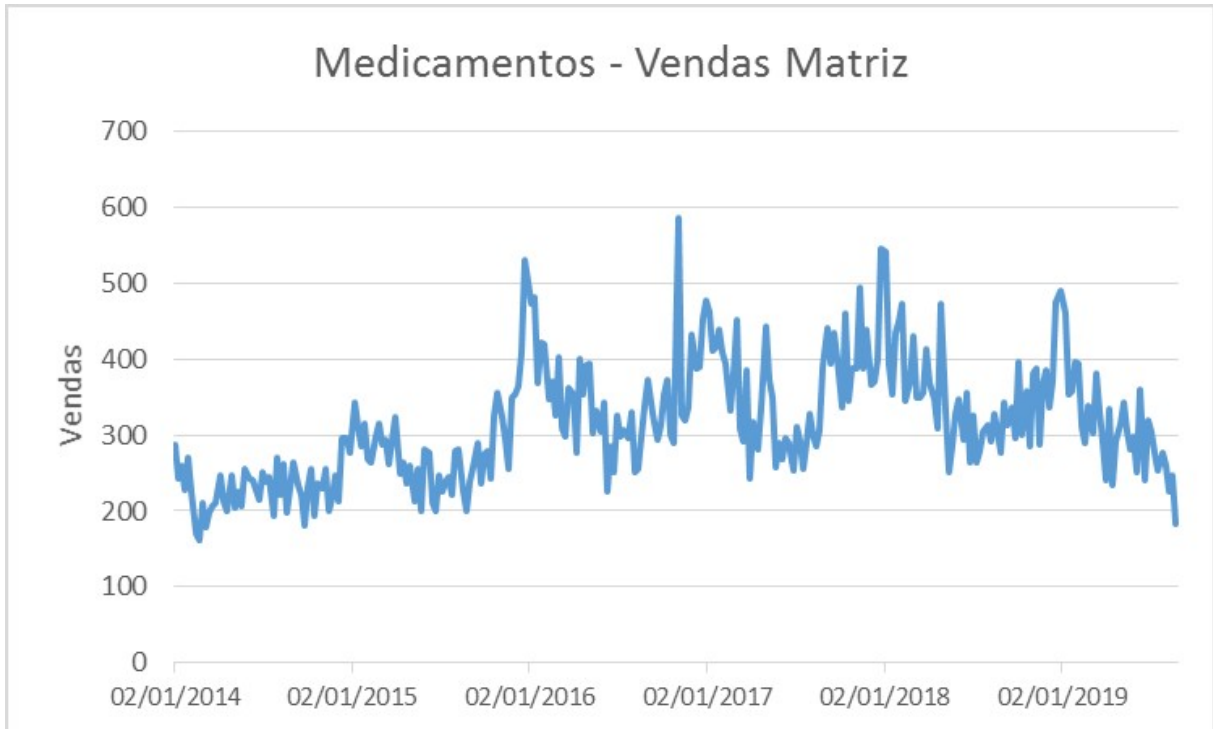
selecionada a unidade matriz para o presente estudo. Nas Figuras 19 e 20 pode-se notar a distinção de demanda existente entre as categorias ração e medicamentos.

Ao se analisar os gráficos das séries temporais das figuras pode-se extrair algumas informações preliminares sobre as categorias selecionadas do conjunto de observações estudado. Na Figura 19 nota-se que a categoria possui, inicialmente, uma tendência crescente e após um período de tempo apresenta estabilidade de consumo. Apesar disso apresenta sazonalidade durante todo o período. Na Figura 20, a categoria evidencia uma tendência constante, isto é, o consumo se mantém regular.

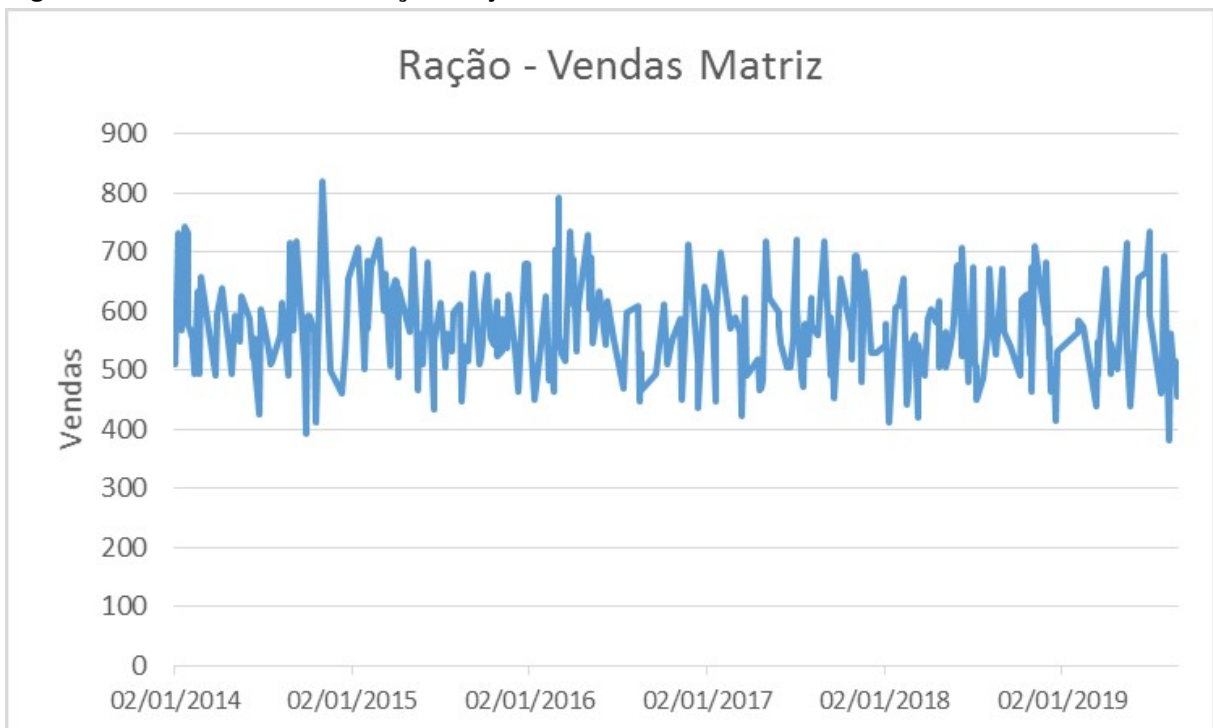
### 5.3 APLICAÇÃO DE REDES NEURAIIS ARTIFICIAIS

Para modelagem das RNA's foi utilizado o *software* IDE *Spyder* sendo *Python* a linguagem aplicada. Os dados foram separados em três grupos: o primeiro utilizado na fase de treinamento, o segundo para a fase de validação e o último para teste.

A princípio realizou-se uma avaliação sobre a estrutura que mais se adequaria ao problema proposto. Em seguida, optou-se por utilizar somente uma estrutura de RNA com arquitetura *perceptron* múltiplas camadas (MLP). Deste modo, foram criadas duas MLPs para previsão dos 489 dias seguintes, visto que serão previstos 163 pontos

**Figura 19 – Vendas totais de medicamentos - loja matriz**

Fonte: Autoria própria.

**Figura 20 – Vendas totais de ração - loja matriz**

Fonte: Autoria própria.

na série temporal, em que cada ponto é a soma da venda de 3 dias. Uma rede irá trabalhar especificamente em cima dos dados de venda de medicamentos e a outra dos de ração.

É de extrema relevância a definição da quantidade de neurônios presente na camada escondida, sendo que o mesmo determina a qualidade e o tempo do treinamento. Assim sendo, ao utilizar um número baixo de neurônios, a rede se torna inapta a modelar dados de maior complexidade, apresentando baixa capacidade de generalização. De maneira oposta, ao utilizar uma quantidade excessiva o treinamento torna-se extremamente longo e a rede pode sofrer com os efeitos do treinamento excessivo (*overfitting*), ocasionando na perda da capacidade preditiva.

Igualmente ao número de neurônios, o número de camadas influencia os resultados gerados pela rede. Florencio (2010) alega que para grande parte dos problemas, uma camada escondida é suficiente, mas, para dados descontínuos, duas camadas ocultas trazem uma boa aproximação das funções de vários tipos ou formas.

Assim, a topologia da rede MLP para a RNA1 é constituída da camada de entrada, seguida por duas camadas ocultas com 6 e 2 neurônios respectivamente e um neurônio na camada de saída. Já a RNA2, usa topologia com camada de entrada, duas camadas ocultas com 8 e 4 neurônios e um neurônio na camada de saída.

Separou-se 70% dos primeiros dados de cada série estudada para serem usados no treinamento da rede e o *backpropagation* como algoritmo de aprendizagem. Durante a fase de teste, a rede foi subdividida em dois passos: validação, utilizando 15% dos dados e o teste utilizando os outros 15%.

## 6 RESULTADOS E DISCUSSÃO

### 6.1 REALIZAÇÃO DA PREVISÃO

A proposta desse trabalho consiste no uso de uma rede neural com entradas anteriormente já descritas e ponderadas. Utilizando o *software Spyder*, através da biblioteca *keras*, disponível na linguagem de programação *Python*, implementou-se a rede neural.

Neste capítulo, são expostos os resultados para os modelos de previsão de demanda de medicamentos e ração da empresa em estudo. Os dados usados para criação da base dos modelos são do ano de 2014 a 2019.

Com o propósito de facilitar o entendimento sobre as topologias utilizadas para previsões das séries temporais, define-se:

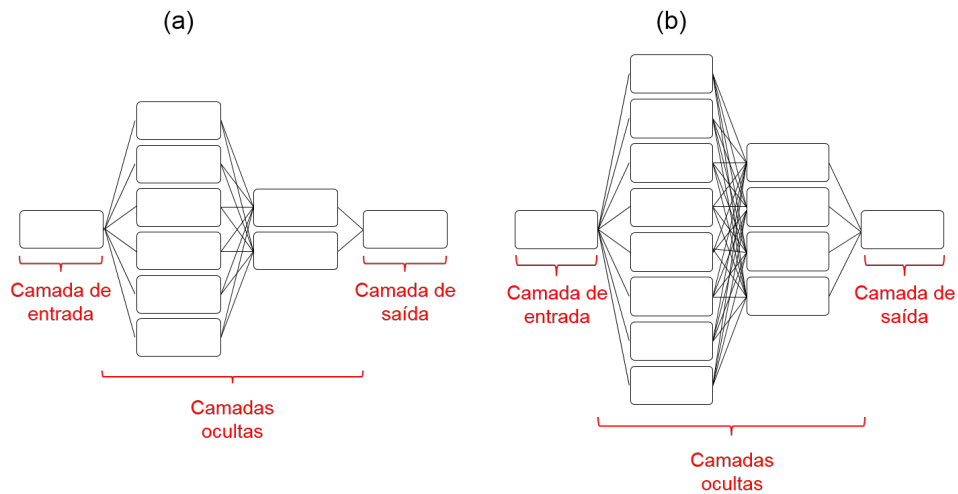
- RNA1 - Rede responsável por prever a demanda de medicamentos da loja matriz;
- RNA2 - Rede responsável por prever a demanda de ração da loja matriz;

O modelo avalia as séries temporais de medicamentos e ração como única entrada para a rede neural, sendo sua arquitetura a rede *perceptron* múltiplas camadas aplicada aos problemas de previsão da demanda.

As topologias de redes aplicadas contém pequenas diferenças para cada série temporal de entrada, sendo a RNA1 constituída da camada de entrada, seguida por duas camadas ocultas com 6 e 2 neurônios respectivamente e um neurônio na camada de saída. Já a topologia da RNA2 apresenta, como singularidade nas suas camadas ocultas, 8 e 4 neurônios. As topologias das RNA's 1 e 2 podem ser observadas na Figura 21.

A definição dessas topologias se deu de forma empírica, uma vez que 25 topologias de redes foram testadas, variando individualmente os neurônios da camada escondida conforme a árvore de decisão ilustrada na Figura 22, onde o valor representado por  $N^o$  foi variado de 2 até 10 com passo de 2 unidades. A escolha do número de neurônios para as camadas escondidas se deu de acordo com a rede que apre-


**Figura 21 – Topologia (a)RNA1 (b)RNA2**



**Fonte: Autoria própria.**

sentou os menores valores de erro para cada grupo de dados. Resultando assim, nas topologias já mencionadas acima.

**Figura 22 – Árvore de decisão das topologias de RNA's testadas**



**Fonte: Autoria própria.**

Ainda, na busca da melhor arquitetura de rede, foi alterado o número de épocas (apresentação dos padrões de treinamento para rede) de forma sucessiva e empírica, iniciando com 100 épocas e variando com passos de 100 unidades até 1.000. Assim adotou-se como critério de parada o número de 1.000 épocas.

## 6.2 AVALIAÇÃO DOS RESULTADOS

Para avaliação do desempenho das previsões obtidas pelos modelos das RNA's foram consideradas os valores do erro quadrático médio (MSE) e a raiz do erro quadrático médio (RMSE), além da correlação entre as séries originais e preditas.

O principal método utilizado para avaliação foi o RMSE. Esse é um dos métodos mais utilizadas para avaliação de erro em modelos de previsão. A expressão dessa métrica foi definida na Tabela 4.



Cada topologia de rede foi submetida 30 vezes ao treinamento, em que os valores de MSE e RMSE foram armazenados em um vetor.

As Tabelas 6 e 8 exibem o menores valores de erro para cada topologia testada para previsão da venda de medicamentos e ração respectivamente.

**Tabela 6 – Erros de teste por topologia para previsão de medicamentos.**

Neurônio na 1 <sup>a</sup> camada oculta	Neurônio na 2 <sup>a</sup> camada oculta	MSE	RMSE
2	2	1615,81	40,1971
	4	1615,10	40,1883
	6	1604,66	40,0582
	8	1609,63	40,1201
	10	1611,05	40,1378
4	2	1625,74	40,3204
	4	1658,53	40,7250
	6	1647,53	40,5897
	8	1638,22	40,4749
	10	1614,16	40,1766
6	2	1604,42	40,0504
	4	1620,83	40,2595
	6	1630,87	40,3840
	8	1625,14	40,3130
	10	1623,46	40,2921
8	2	1637,26	40,4630
	4	1637,01	40,4599
	6	1624,09	40,3001
	8	1640,35	40,5012
	10	1622,98	40,2862
10	2	1635,13	40,4367
	4	1629,07	40,3617
	6	1628,09	40,3495
	8	1639,02	40,4848
	10	1640,99	40,5091

Fonte: Autoria própria.

A Tabela 7 lista os cinco menores valores de erro para a RNA1 e da mesma forma, a Tabela 9 lista os cinco menores valores de erro para a RNA2.

**Tabela 7 – Erros de teste RNA1.**

MSE	RMSE
1604,805	40,03738
1604,042	40,05049
1616,91	40,05737
1608,162	40,06002
1606,541	40,06853

Fonte: Autoria própria.

Apesar dos valores de erro da RNA2 serem maiores que os valores de erro da RNA1, os mesmos não podem ser comparados, visto que cada um refere-se a um

**Tabela 8 – Erros de teste por topologia para previsão de ração.**

Neurônio na 1 <sup>a</sup> camada oculta	Neurônio na 2 <sup>a</sup> camada oculta	MSE	RMSE
2	2	6474,58	80,4647
	4	6478,64	80,4899
	6	6480,52	80,5016
	8	6478,41	80,4885
	10	6482,65	80,5149
4	2	6488,72	80,5525
	4	6475,74	80,4719
	6	6488,55	80,5515
	8	6483,6	80,5208
	10	6482,88	80,5163
6	2	6484,74	80,5278
	4	6475,91	80,4730
	6	6474,32	80,4631
	8	6494,59	80,5890
	10	6483,91	80,5227
8	2	6487,71	80,5463
	4	6451,158	80,3191
	6	6493,54	80,5825
	8	6476,8	80,4785
	10	6487,43	80,5445
10	2	6494,58	80,5889
	4	6490,52	80,5637
	6	6475,54	80,4707
	8	6486,47	80,5386
	10	6474,44	80,4639

**Fonte: Autoria própria.**

**Tabela 9 – Erros de teste RNA2.**

MSE	RMSE
6451,158	80,3191
6453,294	80,3324
6481,617	80,50849
6483,472	80,52001
6489,503	80,55745

**Fonte: Autoria própria.**

conjunto de dados diferentes.


Na RNA1 trabalha-se com uma quantia de vendas que varia entre 26 e 353, enquanto na RNA2 varia entre 140 e 490, portanto relembramos que não se pode comparar os valores de erro entre as Tabelas 6 e 8. Os valores de MSE foram cruciais para a escolha da melhor topologia, como já relatado no início dessa seção.

### 6.3 RESULTADOS

As séries de demanda de medicamentos e ração foram divididas em três categorias (treinamento, validação e teste) e normalizadas entre 0 e 1. Afim de determinar a capacidade de generalização da rede, durante o treinamento foram utilizados os dados de validação para analisar seu desempenho quando submetidos à amostras não conhecidos por ela e então, ao final, utilizados os dados de teste para verificar a eficiência e capacidade de generalização da rede.

Conforme já mencionado, o treinamento da rede é feito através do algoritmo *backpropagation*, por meio do ajuste dos pesos com a minimização do MSE para os padrões de treinamento. O MSE é representado pelas perdas nas Figuras 23 e 24. Vale ressaltar que os gráficos ilustram apenas 100 épocas, pois o erro tende a estabilizar após isso.

**Figura 23 – Perdas RNA1**




**Fonte: Autoria própria.**

Os pontos em destaque nas Figuras 23 e 24 se referem ao menor erro de validação em até 100 épocas. Nestes pontos, verificou-se os pesos atribuídos às redes e utilizou-se os mesmos para a previsão de demanda de medicamentos e ração.


### 6.4 PREVISÃO

A resposta da MLP nos experimentos feitos pode ser visualizada nos gráficos das Figuras 25 e 26, sendo demonstrado na primeira o resultado de teste da RNA1. Em azul, tem-se os dados originais da série e em vermelho os valores estimados pela

**Figura 24 – Perdas RNA2**

Fonte: Autoria própria.


rede que teve o menor erro apresentado na Tabela 7.

**Figura 25 – Previsão vendas de medicamentos - RNA1**

Fonte: Autoria própria.

Já na Figura 26 tem-se o resultado de teste da RNA2. Também em azul os dados originais da série e em vermelho os valores calculados pela rede que teve o menor erro apresentado na Tabela 9.

Lembra-se que as Figuras retratam apenas os dados utilizados para teste e não o universo completo (treinamento, validação e teste). Por este motivo, é possível visualizar apenas dados de 2017 até 2019.

**Figura 26 – Previsão vendas de ração - RNA2**

**Fonte: Autoria própria.**

## 6.5 MELHORIAS PARA A EMPRESA

A partir dos resultados obtidos da previsão de demanda é possível estimar vendas futuras dentro de um período pré estabelecido pela empresa, permitindo realizar compras mais assertivas. Em conjunto com a mesma verificou-se possíveis ações que pode-se colocar em prática a partir do estudo realizado, sendo elas:

- Otimização do volume do estoque – já mencionada a importância de um estoque adequado, pode-se moldá-lo a fim de obter-se o menor custo possível e manter um nível apropriado, com intuito de proporcionar uma maior percepção de qualidade e eficiência aos clientes;
- Organização física do estoque – sabendo-se a saída de mercadorias, pode-se dispor as mesmas no estoque de maneira a reduzir o tempo de reabastecimento do volume disponível para venda e também planejar o espaço físico que cada grupo de mercadoria ocupará no estoque, com o objetivo de ocupar o menor espaço físico possível, aumentando a capacidade de armazenagem;
- Redução de prejuízos – conhecendo o nível adequado de compra é possível evitar a compra de quantias excessivas, evitando assim, perdas de mercadorias;

- Avaliação da rotatividade de cada item – consegue-se analisar cada item individualmente a fim de obter maiores informações sobre o mesmo, sendo possível planejar comprar, ofertas, troca de fornecedores e etc.;
- Redução dos custos – esta meta é alcançada uma vez que previsões precisas ocasionam em um aumento de produtividade, uma maior organização e um maior controle sobre o estoque. Tem-se como resultado a redução geral dos custos.
- Melhor definição de prioridades – sabendo os principais itens que moldam sua lucratividade, pode-se elaborar uma definição de prioridade para diversas ações que podem ser tomada pela empresa.
- Melhor planejamento de médio a longo prazo – existindo a capacidade de prever vendas futuras é possível realizar planejamentos de médio a longo prazo a fim de diminuir os custos já mencionados no decorrer desse trabalho.

## 7 CONCLUSÕES E PERSPECTIVAS

Esta pesquisa teve como objetivo investigar a importância e impacto que previsões pouco assertivas trazem a uma empresa de *pet shop* e também implementar a previsão de séries temporais através de redes neurais artificiais, com o objetivo de verificar sua vantagem quanto à previsão de demandas, a fim de gerir e reduzir custos de estoque, além de garantir maior satisfação do consumidor.

Foram estudadas as RNA's do tipo Perceptron de Múltiplas Camadas (MLP), as quais são arquiteturas *feedforward* treinadas com algoritmo *backpropagation* para a previsão das séries temporais de vendas de medicamentos e de ração.

Após a análise dos resultados, é possível afirmar que a rede com as topologias abordadas possui potencial para se tornar o principal meio de previsão de demanda da empresa, já que a mesma trabalha com uma alta quantidade de linhas e grande parte de seus produtos possui prazo de vencimento, obrigando-a a rever constantemente seus estoques. Além disso, os resultados obtidos demonstraram uma boa assertividade, evidenciando que as RNA's podem realizar previsões de demanda adequadas.

Além disso, outro fator de importância é tornar viável estimar demandas futuras com a precisão demonstrada pelas RNA's, tornando praticável programar ofertas, controlar níveis de estoques e campanhas de venda, por exemplo.

Nota-se que as redes MLP se moldaram adequadamente a demanda com tendência de consumo constante (vendas de ração) e também com tendência sazonal (venda de medicamentos). Assim, embora o modelo possa ser melhorado utilizando mais variáveis de entrada que tragam vantagens em interpretar a série temporal, e também um maior número de dados, ocasionando uma redução dos erros e ampliando a capacidade de compreender mais padrões, pode-se assegurar que as redes neurais artificiais analisadas são viáveis dentro do propósito deste estudo, conseguindo a partir dos resultados chegar a finalidade declarada no início do presente trabalho.

Durante o desenvolvimento deste estudo a empresa relatou muitas baixas não esperadas em suas vendas. Porém fica evidente que não existem tendências decrescentes nas mesmas evidenciando então, que a sensação de "baixa de vendas" se deve a compra do estoque com expectativa de um aumento nas mesmas, passando a sensação de um baixo giro.

A sugestão para trabalhos futuros é realizar a previsão com redes neurais para as demais categorias existentes na empresa e também para os produtos presentes nas categorias, a fim de elevar o potencial de acerto das tomadas de decisões. Além disso, é importante complementar a base de dados com um maior número de amostras, gerando uma maior capacidade de generalização e percepção de quais variáveis externas afetam as séries temporais pode ser objeto de estudo.



## REFERÊNCIAS

- ALMEIDA, Marcelo Cavalcanti. **Auditoria - Abordagem Moderna e Completa**. São Paulo, BR: Editora Atlas SA, 2017. 497 p. Citado na página 17.
- ALT, Paulo Campos; MARTINS, Petrônio Gracia. **Administração de Materiais e Recursos Patrimoniais**. São Paulo, BR: Editora Saraiva, 2009. Citado 2 vezes nas páginas 15 e 18.
- BRAGA, Antônio de Pádua; CARVALHO, APLF; LUDERMIR, TB. **Redes neurais artificiais: teoria e prática**. [S.l.: s.n.], 2000. Citado na página 30.
- CAVALHEIRO, Darlene. **Método de previsão de demanda aplicada ao planejamento da produção de indústrias de alimentos**. 2003. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, 2003. Citado 2 vezes nas páginas 20 e 21.
- DIAS, Marco Aurélio P. **Administração de materiais: princípios, conceitos e gestão**. São Paulo, BR: Editora Atlas SA, 2009. Citado 7 vezes nas páginas 16, 17, 18, 20, 21, 27 e 28.
- FLORENCIO, Paulo Henrique Borba. **Aplicação de Redes Neurais Artificiais na Previsão de Demanda de Peças de Reposição de Veículos Automotores**. 2010. Dissertação (Mestrado) — Pontifícia Universidade Católica de Goiás, 2010. Citado 6 vezes nas páginas 13, 22, 23, 24, 30 e 45.
- FLORES, João Henrique Ferreira. **Aplicação de redes neurais artificiais à previsão de vendas de máquinas agrícolas: um estudo de caso junto a agco do brasil ltda**. 2006. Citado na página 23.
- FURTADO, Maurício Rocha. **Aplicação de um modelo de previsão da demanda total nos credenciados belgo pronto**. 2007. 27 p. Tese (Doutorado) — Universidade Federal de Juiz de Fora, Juiz de Fora, 2007. Citado 2 vezes nas páginas 25 e 26.
- HAYKIN, Simon S et al. **Neural networks and learning machines/Simon Haykin**. [S.l.]: New York: Prentice Hall,, 2009. Citado 6 vezes nas páginas 29, 31, 34, 35, 38 e 39.
- HIGUTI, Elisângela Teles. **Método de previsão de demanda aplicada ao planejamento da produção de indústrias de alimentos**. Trabalho de conclusão de curso, Unviersidade Tuiuti, Curitiba-PR, Brasil, 2017. Citado na página 35.

IBGE. **PIB tem resultado negativo de 0,2% no 1º trimestre de 2019**. 2019. <https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/24653-pib-tem-resultado-negativo-de-0-2-no-1-trimestre-de-2019>. Citado na página 12.

KOTLER, Philip. **Marketing Management: Analysis, Planning, Implementation, and Control**. Prentice Hall, 1997. (International Series in Marketing). ISBN 9780132435109. Disponível em: <<https://books.google.com.br/books?id=r5duSQAACAAJ>>. Citado na página 20.

MAKRIDAKIS, S.; WHEELWRIGHT, S.C.; HYNDMAN, R.J. **FORECASTING METHODS AND APPLICATIONS, 3RD ED**. Wiley India Pvt. Limited, 2008. ISBN 9788126518524. Disponível em: <[https://books.google.com.br/books?id=-f6bo6SfP\\\_cC](https://books.google.com.br/books?id=-f6bo6SfP\_cC)>. Citado na página 21.

MENTZER, John T.; COX, James. Familiarity, application, and performance of sales forecasting techniques. **Journal of Forecasting**, Wiley Online Library, v. 3, n. 1, p. 27–36, 1984. Citado na página 12.

MINE, Otávio Massashi. **Previsão de demanda de autopeças com redes neurais**. 2010. Dissertação (Mestrado) — Universidade Federal do Espírito Santo, 2010. Citado na página 22.

MONTGOMERY, D.C.; JOHNSON, L.A.; GARDINER, J.S. **Forecasting and time series analysis**. McGraw-Hill, 1990. ISBN 9780070428584. Disponível em: <<https://books.google.com.br/books?id=t9HuAAAAMAAJ>>. Citado 2 vezes nas páginas 23 e 25.

MOREIRA, Daniel A. **Administração da Produção e Operações**. São Paulo, BR: Editora Saraiva, 2013. 152 p. Citado na página 15.

MOREIRA, Daniel Augusto. **Administração da produção e operações**. [S.l.]: Editora Saraiva, 2017. Citado 2 vezes nas páginas 25 e 26.

OLIVEIRA, Evandro Lopes. **Previsão de demanda de energia elétrica com redes neurais artificiais e análise por série de Fourier**. 2016. 108 p. Tese (Doutorado) — Universidade Federal de Minas Gerais, Belo Horizonte, 2016. Citado 2 vezes nas páginas 13 e 29.

POZO, Hamilton. **Administração de recursos materiais e patrimoniais: uma abordagem logística**. Rio de Janeiro, BR: Editora Atlas SA, 2015. Citado 2 vezes nas páginas 19 e 28.

SANTOS, Gilberto Antunes et al. Gestão de estoque: um fator de obtenção de lucro através de sua eficiência. 2009. Citado na página 18.

SCHWITZKY, Marcelo. **Acuracidade dos métodos de previsão e a sua relação com o dimensionamento dos estoques de produtos acabados.** nov. 2001. 134 p. Tese (Doutorado) — Universidade Federal de Santa Catarina, Santa Caratina, BR, nov. 2001. Citado na página 16.

SILVA, IN da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes neurais artificiais para engenharia e ciências aplicadas.** [S.l.: s.n.], 2010. v. 23. 33–111 p. Citado 6 vezes nas páginas 29, 30, 31, 32, 39 e 40.

SILVA, Mislene Gontijo; RABELO, Maria Helena Silva. Importância do controle de estoque para as empresas. **Revista Acadêmica Conecta FASF**, 2017. Citado na página 17.

SILVA, RS. **Previsão multivariada da demanda horária de água em sistemas urbanos de abastecimento.** 2003. Tese (Doutorado) — Tese de Doutorado, Universidade Estadual de Campinas, 2003. Citado 2 vezes nas páginas 12 e 23.

SILVA, Rafael Schardosin. **Previsão de venda de produtos em uma indústria de telecomunicação utilizando redes neurais artificiais.** 2010. 78 p. Tese (Doutorado) — Universidade do Vale do Rio dos Sinos, Rio Grande do Sul, BR, 2010. Citado 2 vezes nas páginas 12 e 22.

SIQUEIRA, Hugo et al. Performance analysis of unorganized machines in streamflow forecasting of brazilian plants. **Applied Soft Computing**, Elsevier, v. 68, p. 494–506, 2018. Citado 2 vezes nas páginas 36 e 37.

SOUSA, João Abel Vieira. **Aplicação de Redes Neurais na Previsão de Vendas para Retalho.** 2011. 52 p. Tese (Doutorado) — Faculdade de Engenharia da Universidade do Porto, Porto, PT, 2011. Citado 5 vezes nas páginas 33, 34, 36, 37 e 38.

SPEDDING, Trevor; CHAN, K.K. Forecasting demand and inventory management using bayesian time series. **Integrated Manufacturing Systems**, v. 11, p. 331–339, 09 2000. Citado na página 26.