

Aplicação de Rede Neural Artificial para Previsão de Demanda em uma Empresa Metalmeccânica: Pesquisa-ação



Klaus Henrique Soares (UNASP-EC)
klausoares@hotmail.com

Regina Maura Martins Dias Chiquetano (UNASP-EC)
regina.chiquetano@unasp.edu.br

Mariana Kleina (UFPR)
marianakleina@ufpr.br

Cada vez mais, organizações têm recorrido às tecnologias da indústria 4.0 para suportar tomadas de decisões e minimizar incertezas. Dentre estas tecnologias, destaca-se a inteligência artificial (IA), que se resume na capacidade de simular o raciocínio humano por meio de métodos computacionais para a resolução de problemas. Dentro da esfera de técnicas de IA, foi utilizada uma rede neural artificial, no setor de planejamento e controle da produção, para gerar previsões de demanda de uma sprocket (roda dentada), e comparou-se os resultados com os dos métodos de regressão linear simples e média móvel simples, com o objetivo de avaliar o método com melhor desempenho. Coletados os dados necessários, realizou-se as previsões de demanda pelos três métodos, no qual a rede neural artificial apresentou os melhores resultados.

Palavras-chave: Redes neurais artificiais; Previsão de demanda; Inteligência artificial; Aprendizagem de máquina.

1. Introdução

A previsão de demanda (*demand forecasting*, no inglês), é uma função essencial no planejamento e controle da produção (PCP), tendo a confiabilidade de suas previsões atrelada ao desempenho e competitividade da organização. Segundo Fernandes e Godinho Filho (2016), a previsão de demanda tem papel fundamental no atual mercado competitivo, gerando dados de entrada valiosos para a tomada de decisão em setores como planejamento estratégico da produção, PCP, finanças e vendas.

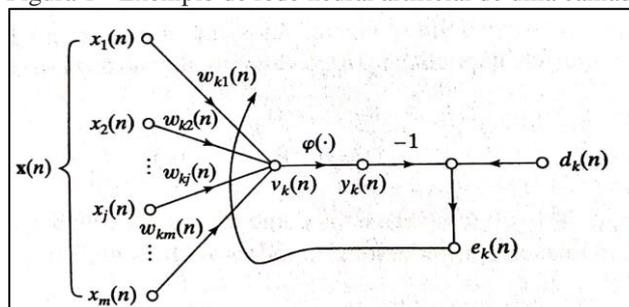
A gestão de demanda visa antecipar as vendas, para minimizar as incertezas no planejamento. Estas incertezas são erros que, quando para mais, elevam produtos em estoque, onerando os custos de estocagem e congelando capital da empresa até o momento de seu faturamento. Quando para menos, a empresa não atende completamente a demanda, comprometendo o nível de serviço, gerando pedidos em carteira e concedendo espaço e oportunidades aos concorrentes. Conceitualmente, a previsão leva em consideração o histórico de vendas, variáveis que influenciam a demanda, informações que justifiquem comportamentos atípicos e o modelo matemático e/ou tecnologias responsáveis pelo processamento dos mesmos. Métodos estatísticos como regressão linear simples (RLS) e média móvel simples (MMS) são comumente utilizados.

Contudo, tecnologias trabalhadas na indústria 4.0 possibilitam reduzir ainda mais as incertezas e variabilidades da demanda. A inteligência artificial (IA) é uma destas tecnologias. Sátyro e Sacomano (2018) elucidam a importância da IA no contexto corporativo:

O objetivo da IA é utilizar dispositivos ou métodos computacionais de forma similar à capacidade de raciocínio do ser humano, resolvendo problemas da maneira mais eficiente possível. Essa IA passaria a controlar não só o processo de produção como também a fornecer sugestões às mais diversas necessidades de decisões.

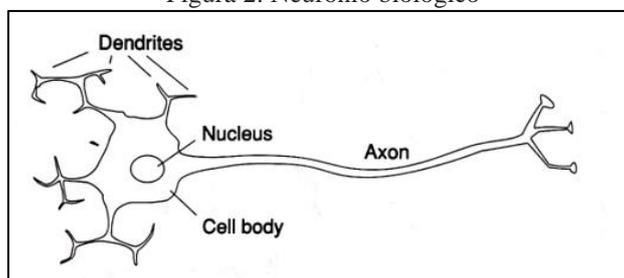
A técnica de IA utilizada neste trabalho é a de redes neurais artificiais (RNA). Uma rede neural artificial objetiva modelar e simular o funcionamento das redes sinápticas do cérebro. As figuras 1 e 2 mostram a analogia entre uma RNA e um neurônio biológico.

Figura 1 - Exemplo de rede neural artificial de uma camada



Fonte: Haykin (2001)

Figura 2: Neurônio biológico



Fonte: Winston (1992)

Assim como no cérebro, para atingir alto nível de desempenho, a RNA é estruturada em camadas de “neurônios” interligados, nos quais dentro do projeto computacional são chamados de células computacionais ou unidades de processamento. Haykin (2001) estabelece a seguinte definição para redes neurais artificiais:

Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

- a) O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
- b) Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

No ambiente corporativo, as redes neurais artificiais são comumente aplicadas em tarefas como: análise e aquisição de ações da bolsa; classificações, como por exemplo a de pacientes com alta probabilidade de possuir câncer de mama; identificação de imagens e previsão de demanda de segmentos industriais, sendo esta última aplicação, o foco abordado neste projeto. Jain et al. (1996, **tradução nossa**) discorreu sobre as previsões realizadas por RNA’s e as esferas impactadas:

Dado um conjunto de n amostras $\{y(T1), y(T2), \dots, y(Tn)\}$ em uma sequência

temporal, T_1, T_2, \dots, T_n , a tarefa (da RNA) é prever a amostra $y(T_{n+1})$ em algum momento futuro. A previsão de demanda tem um impacto significativo na tomada de decisões em negócios, na ciência e na engenharia.

Este artigo apresenta a pesquisa-ação realizada em uma empresa do setor metalmeccânico no interior do estado de São Paulo, que teve como objetivo prever a demanda de uma *sprocket* (roda dentada), que se caracteriza por possuir um cubo em um dos seus lados e 16 dentes, conforme figura 3. As previsões foram realizadas por meio de redes neurais artificiais, regressão linear simples e média móvel simples, utilizando para isso, o histórico de vendas. Por fim, os resultados foram comparados e analisados para determinar o método de melhor desempenho.

Figura 3 – *Sprocket*



Fonte: Elaborada pelos autores (2020)

2. Fundamentação teórica

2.1. Planejamento e controle da produção (PCP)

Objetivando aumentar a eficácia e eficiência do sistema produtivo, o PCP realiza o controle e planejamento antecipado dos recursos materiais, tecnológicos e humanos, bem como a aplicação adequada dos mesmos. Chiavenato (2008) descreve de forma semelhante a função do PCP, no qual este planeja e controla a produção de bens, gerenciando as matérias-primas, mão-de-obra, máquinas, equipamentos e o estoque de produtos acabados disponíveis, para o setor de vendas efetuar as entregas aos clientes. A gestão de demanda é uma dentre diversas atividades inerentes ao PCP.

2.1.1. Gestão da demanda

Segundo Corrêa (2019), a gestão de demanda possui cinco elementos principais, conforme a ilustração da figura 4.

Figura 4 - Principais elementos da gestão de demanda



Fonte: Corrêa (2019)

Para Corrêa (2019), estes elementos são tratados como esforços ou competências que devem ser inerentes à organização em razão de sua eficiência. O autor ainda discorre a respeito de cada um destes elementos:

- Habilidade para prever a demanda: utilização de todas as ferramentas disponíveis para conseguir antecipar a demanda futura com determinada precisão, o que pode envolver uma base de dados do histórico de vendas, assim como informações que expliquem suas variações e comportamento no passado;
- Canal de comunicação com o mercado: se o trabalho de previsão for realizado apenas com base em dados históricos com pouco ou nenhum contato com o mercado, a empresa estará desperdiçando uma fonte inestimável de informações para fazer de seu sistema de previsão de vendas cada vez mais eficaz;
- Poder de influência sobre a demanda: esta influência pode ser praticada incentivando vendedores e representantes de vendas a oferecerem ao mercado determinado mix de produtos que melhor ocupe a capacidade instalada e disponível, ou ainda por meio de promoção e propaganda;
- Habilidade de prometer prazos: importante para garantir desempenho em confiabilidade de entregas;
- Habilidade de priorização e alocação: caso não haja produtos suficientes ou os recursos e materiais necessários não estejam disponíveis, é preciso decidir quais clientes serão atendidos total ou parcialmente e quais terão que esperar.

2.1.2. Previsão de demanda

Segundo Chiavenato (2008), a previsão da demanda normalmente é uma tarefa realizada pelas áreas de *marketing* ou vendas. Porém, cabe também, aos profissionais de PCP, o domínio desta técnica por se tratar da principal informação de entrada para toda a elaboração do planejamento do sistema produtivo e seu uso. Para o autor, o conceito da previsão de demanda, é:

A previsão de vendas representa a quantidade de produtos/serviços que a empresa pretende ou espera vender e colocar no mercado durante um determinado exercício de tempo. A previsão de vendas deve especificar cada produto/serviço da empresa e as vendas previstas para cada mês do exercício. Essa quantidade de vendas prevista mensalmente representa a quantidade de produtos/serviços que deve ser produzida e colocada à disposição do órgão de vendas para a entrega aos clientes.

2.1.3. Relação da previsão de demanda com o MRP

Outra ferramenta utilizada pelo PCP para o alcance de seus objetivos é o planejamento das necessidades de materiais (*material requirement planning*; MRP). Corrêa (2019) elucida a importância da previsão da demanda para esta ferramenta, pois, com base nela, o MRP calcula o tempo e as quantidades que devem ser obtidas, de cada um dos componentes (que constituem o produto acabado), para minimizar as faltas ou excessos, no suprimento das necessidades dadas pela produção do produto em questão.

2.2. Média móvel simples (MMS)

Há três tipos de médias móveis: simples, ponderada e exponencial. O uso da MMS consiste no cálculo da média aritmética de n valores, cuja previsão depende dos dados utilizados, de um determinado período, e a amplitude deste último (FERREIRA, 2018). A equação da MMS é:

Fórmula 1 – Média móvel simples

$$MMS = \frac{P_1 + P_2 + \dots + P_n}{n}$$

Fonte: Adaptado de Ferreira (2018)

Onde:

- n é a amplitude utilizada;
- P_i é o valor da observação no período i , $i = 1, \dots, n$.

2.3. Regressão linear simples (RLS)

De acordo com Fernandes e Godinho Filho (2016), a regressão linear simples envolve a relação linear entre duas variáveis, uma independente, e outra dependente, na qual a primeira influencia

na segunda.

Fórmula 2 – Regressão linear simples

$$a(T) = \frac{2(2T + 1)}{t(T - 1)} \cdot \sum_{t=1}^T Xt - \frac{6}{T(T - 1)} \cdot \sum_{t=1}^T t \cdot Xt$$

$$b(T) = \frac{12}{T(T^2 - 1)} \cdot \sum_{t=1}^T t \cdot Xt - \frac{6}{T(T - 1)} \cdot \sum_{t=1}^T Xt$$

$$Z(T + \tau) = a(T) + b(T) \cdot [T + \tau]$$

Fonte: Adaptado de Fávero (2015)

Onde:

- T é o período atual;
- τ é o valor referente ao período que se deseja prever;
- $a(T)$ é o coeficiente linear;
- $b(T)$ é o coeficiente angular;
- $Z(T + \tau)$ é a variável dependente e o valor da previsão;
- $[T + \tau]$ é a variável independente;
- Xt é o valor da demanda no período t .

2.4. Redes neurais artificiais

2.4.1. Definição de redes neurais artificiais

As redes neurais artificiais surgiram no ano de 1943 com o artigo pioneiro de McCulloch (psiquiatra e neuroanatomista) e Pitts (matemático proeminente). Neste artigo foi apresentado um modelo de rede neural que combinava conceitos da neurofisiologia e cálculos lógicos, porém, este primeiro modelo não computava problemas não-lineares (HAYKIN, 2001).

Vários outros autores contribuíram para o desenvolvimento das RNA's ao longo dos anos. Em 1949, Hebb desenvolveu sua “regra de aprendizagem” que modificava os pesos sinápticos. Von Neumann, em 1956, Winograd e Cowan, em 1963, trabalharam com a “redundância distribuída”, que resultava no aumento da robustez da rede, mediante o grande coletivo de elementos da mesma (HAYKIN, 2001).

Silva et al. (2019) desenvolvem de forma clara o conceito deste método computacional:

As redes neurais artificiais realizam a construção de modelos matemáticos que simulam as atividades do cérebro, descrevendo as atividades mentais por meio da eletroquímica das células cerebrais (os neurônios). Inspiradas na eletroquímica das células cerebrais, algumas aplicações de inteligência artificial buscam criar a computação neural a partir de sistemas de processamento distribuído paralelo, com modelos matemáticos que demonstram o funcionamento dos neurônios.

Apesar de todos os avanços na área, a simulação do processamento de um cérebro humano, em toda sua extensão, é uma tarefa desafiadora. O cérebro é um processador biológico que apresenta alta complexidade e desempenha a resolução de problemas não-lineares paralelamente, como por exemplo o reconhecimento de padrões, percepção de sinais de entrada por meio dos sentidos e controle motor (HAYKIN, 2001).

2.4.2. Perceptron multicamadas (*multilayer perceptron*)

Existem diversos tipos de redes neurais, e dependendo da finalidade a que se destina o estudo, um tipo torna-se mais indicado do que outro. Alguns exemplos são:

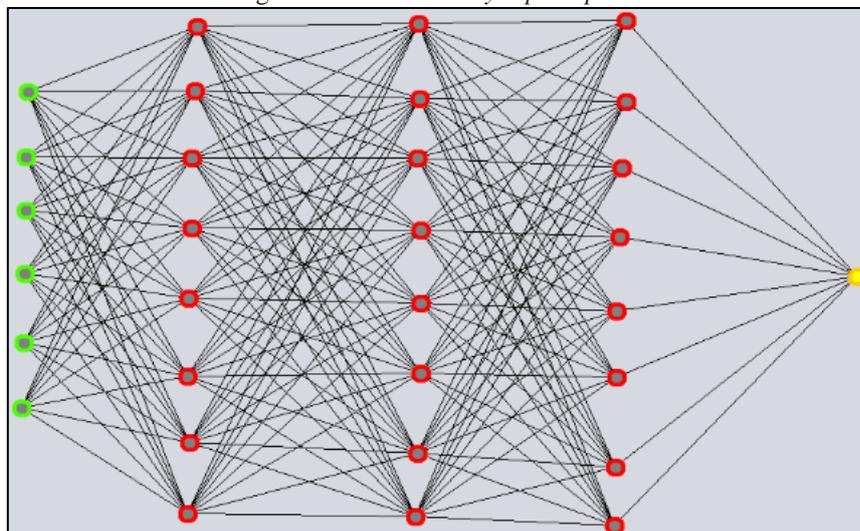
- Perceptron de camada única;
- Perceptron de múltiplas camadas;
- Redes de função de base radial;
- Redes neurais recorrentes;
- Rede de Kohonen;
- Rede neural convolucional;
- Rede Neural Modular.

Para a atividade de previsão de vendas deste trabalho, será utilizada uma rede neural perceptron de múltiplas camadas (*multilayer perceptron*; MLP), conforme a figura 5.

Uma rede *multilayer perceptron* é constituída pelas seguintes camadas:

- Camada de entrada (*input layer*): série de n neurônios cujos valores x são fornecidos. São os dados de entrada a serem trabalhados pela rede, como por exemplo: histórico de vendas, cotação do dólar, dados climáticos e outros fatores de influência na demanda;
- Camadas ocultas (*hidden layer*): série de n neurônios cujos valores de x são o resultado dos sinais de entrada multiplicados pelos respectivos pesos aplicados à função de ativação. Possuem a função de processamento dos dados dentro da rede;
- Camada de saída (*output layer*): geralmente possui um único neurônio, cujo valor de y é o resultado da operação do somatório das saídas da camada oculta aplicado também a uma função de ativação. Neste caso, será a previsão do período desejado.

Figura 5 - RNA *multilayer perceptron*



Fonte: Elaborada pelos autores (2020)

Haykin (2001) trabalha com a ideia de que um perceptron multicamadas possui três características distintivas:

- a) O modelo de cada neurônio da rede inclui uma função de ativação não-linear. O ponto importante a se enfatizar aqui é que a não-linearidade é suave (i.e., diferenciável em qualquer ponto). [...] Uma forma normalmente utilizada de não-linearidade que satisfaz esta exigência é uma não-linearidade sigmóide definida pela função logística:

$$\varphi(v) = \frac{1}{1 + \exp(-v)}$$

- b) A rede contém uma ou mais camadas de neurônios ocultos, que não são parte da entrada ou saída da rede. Estes neurônios ocultos capacitam a rede a aprender tarefas complexas extraindo progressivamente as características mais significativas dos padrões (vetores) de entrada;
- c) A rede exibe um alto grau de conectividade, determinado pelas sinapses da rede. Uma modificação na conectividade da rede requer uma mudança na população das conexões sinápticas ou de seus pesos.

2.4.3. Retropropagação (*back-propagation*)

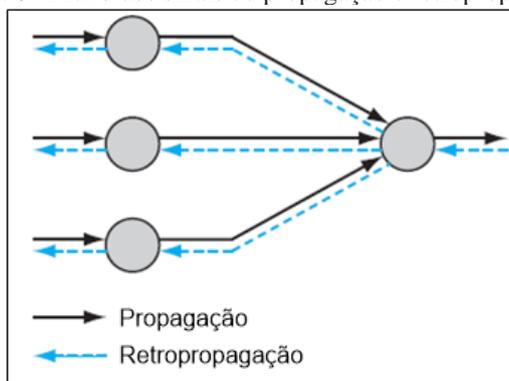
Problemas complexos têm sido resolvidos com aplicação de redes neurais artificiais mediante seu algoritmo de treinamento ou aprendizagem supervisionada, que ocorre quando a rede é treinada a partir de um conjunto de dados em pares de entrada-saída, no qual já se conhece a resposta. Este algoritmo também é conhecido como “retropropagação de erro” (*error back-propagation*), que baseia-se na regra de aprendizagem por correção de erro (RUSSELL; NORVIG, 2013). Haykin (2001) descreve o fluxo de sua funcionalidade:

Basicamente, a aprendizagem por retropropagação de erro consiste de dois

passos através das diferentes camadas da rede: um passo para frente, a propagação, e um passo para trás, a retropropagação. No passo para frente, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais da rede e seu efeito se propaga através da rede, camada por camada. Finalmente, um conjunto de saídas é produzido como a resposta real da rede. Durante o passo de propagação, os pesos sinápticos da rede são todos fixos. Durante o passo para trás, por outro lado, os pesos sinápticos são todos ajustados de acordo com uma regra de correção de erro. Especificamente, a resposta real da rede é subtraída de uma resposta desejada (alvo) para produzir um sinal de erro. Este sinal de erro é então propagado para trás através da rede, contra a direção das conexões sinápticas - vindo daí o nome de "retropropagação de erro" (*error back-propagation*).

A figura 6 demonstra o fluxo de propagação e retropropagação descritos por Haykin (2001)

Figura 6 - Fluxo dos sinais de propagação e retropropagação



Fonte: Haykin (2009)

2.4.4. Cálculos constituintes da MLP

2.4.4.1. Função soma

Refere-se à soma da multiplicação das entradas pelo respectivo peso do neurônio k da camada oculta.

Fórmula 3 – Função soma

$$\sum_{j=1}^m W_{kj} \cdot X_j$$

Fonte: Adaptado de Haykin (2009)

Onde:

- W_{kj} : valor do peso sináptico entre o neurônio j da camada de entrada e o neurônio k da camada oculta;
- X_j : valor de entrada no neurônio j ;

- m : número de dados de entrada.

2.4.4.2. Função de ativação sigmóide

Trata-se de uma função matemática responsável por restringir o valor de um neurônio dentro do intervalo $[0,1]$.

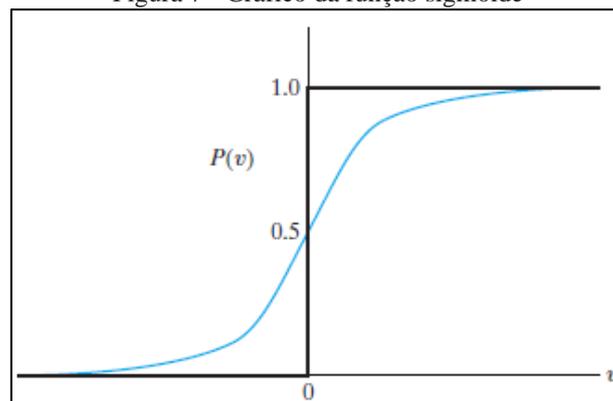
Fórmula 4 – Função de ativação sigmóide

$$\varphi(v) = \frac{1}{1 + \exp(-v)}$$

Fonte: Adaptado de Haykin (2009)

O valor de v é o resultado da função soma. A figura 7 mostra o gráfico da função sigmóide, cuja curva representa a faixa de valores retornáveis.

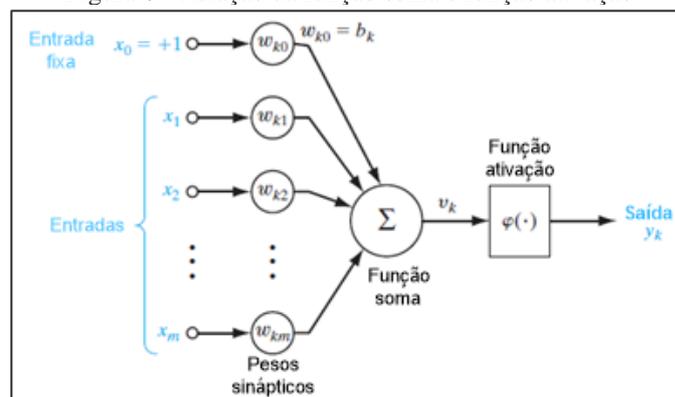
Figura 7 - Gráfico da função sigmóide



Fonte: Haykin (2009)

As funções soma e ativação são responsáveis pelo fluxo de propagação, conforme esquematizado na figura 8.

Figura 8 - Relação da função soma e função ativação



Fonte: Adaptado de Haykin (2009)

2.4.4.3. Cálculo do erro

Operação simples de subtração entre o valor correto (valor fornecido) e o valor calculado.

Fórmula 5 – Erro

$$erro = valor\ correto - valor\ calculado$$

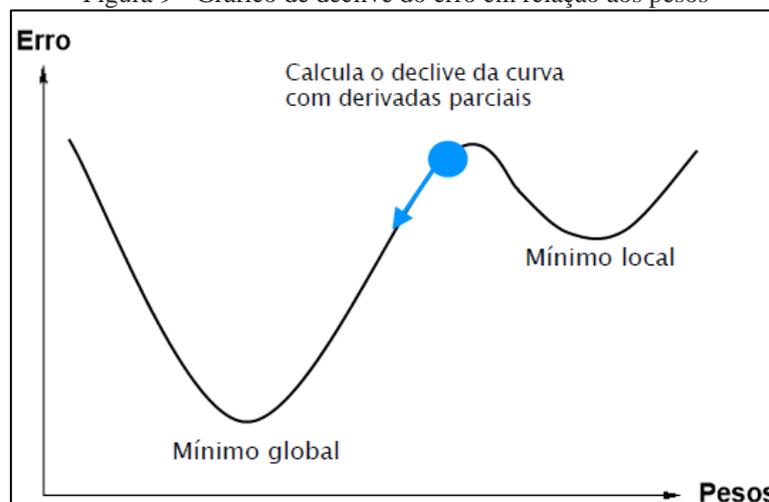
Fonte: Adaptado de Haykin (2009)

O sinal de erro resultante desta operação será retropropagado pela rede, logo, as próximas equações referem-se à retropropagação.

2.4.4.4. Gradiente

O gradiente é responsável pela intensidade do ajuste nos valores dos pesos sinápticos a fim de evitar os mínimos locais e obter o menor valor do erro, chamado de mínimo global, conforme o gráfico da figura 9.

Figura 9 - Gráfico de declive do erro em relação aos pesos



Fonte: Elaborado pelos autores (2019)

O gradiente é obtido através da derivada da função sigmóide:

Fórmula 6 – Cálculo do gradiente

$$\varphi'(v) = \varphi * (1 - \varphi)$$

Fonte: Adaptado de Haykin (2008)

2.4.4.5. Parâmetro delta

O delta é um parâmetro que compõe o cálculo da atualização dos pesos e que engloba o

gradiente, ou seja, a derivada da função sigmóide. O cálculo do delta se distingue quando para a camada de saída e camadas ocultas.

Para a camada de saída:

Fórmula 7 – Delta para camada de saída

$$\delta(\text{saída}) = \text{erro} * \text{gradiente}(\text{camada saída})$$

Fonte: Adaptado de Haykin (2009)

Para camadas ocultas:

Fórmula 8 – Delta para camadas ocultas

$$\delta(\text{camada oculta } n) = \delta(\text{camada } n + 1) * \text{pesos}(\text{camada } n) * \text{gradiente}(\text{camada } n)$$

Fonte: Adaptado de Haykin (2009)

2.4.4.6. Cálculo de atualização dos pesos

O cálculo para a atualização dos pesos sinápticos, ou pesos novos, utiliza as constantes de taxa de aprendizagem (η) e momento (m).

A taxa de aprendizagem define a velocidade de aprendizagem do algoritmo. Se o valor for alto, o processo de aprendizagem ocorre rapidamente, mas aumenta-se o risco de não encontrar o mínimo global do valor do erro. Caso o valor da taxa seja baixo, desprende-se maior tempo para aprendizagem do algoritmo, porém maior precisão em relação ao mínimo global.

O momento, por sua vez, possui função parecida com a da taxa de aprendizagem, dando suporte ao algoritmo para evitar os mínimos locais. A equação para o cálculo dos pesos novos é:

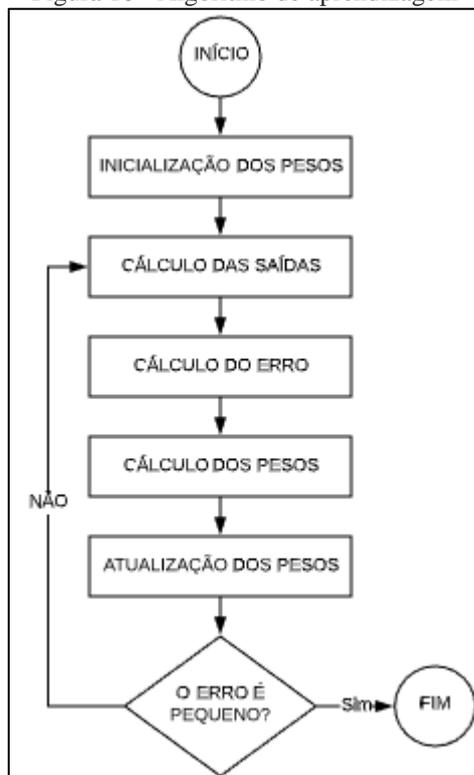
Fórmula 9 – Cálculo dos pesos novos

$$\text{Pesos } n' = (\text{pesos } n * m) + (\text{entradas}(\text{camada } n) * \delta(\text{camada } n + 1) * \eta)$$

Fonte: Adaptado de Haykin (2009)

Após o ajuste dos pesos, repete-se todo o processo até o valor do erro ser mínimo, como no fluxograma do algoritmo apresentado na figura 10.

Figura 10 - Algoritmo de aprendizagem



Fonte: Elaborada pelos autores (2019)

3. Metodologia

3.1. Fluxograma da metodologia

O fluxograma apresentado na figura 11 exibe as etapas e práticas efetuadas neste trabalho. Foram realizadas a coleta e análise dos dados históricos de vendas da *sprocket*. Em seguida foram calculadas as previsões de demanda por meio da RNA e dos métodos estatísticos de regressão linear simples e média móvel simples. Finalizou-se com a análise comparativa dos resultados obtidos e das respectivas raízes dos erros quadráticos médios (REQM) conforme a fórmula 10.

Fórmula 10 – Raiz do erro quadrático médio

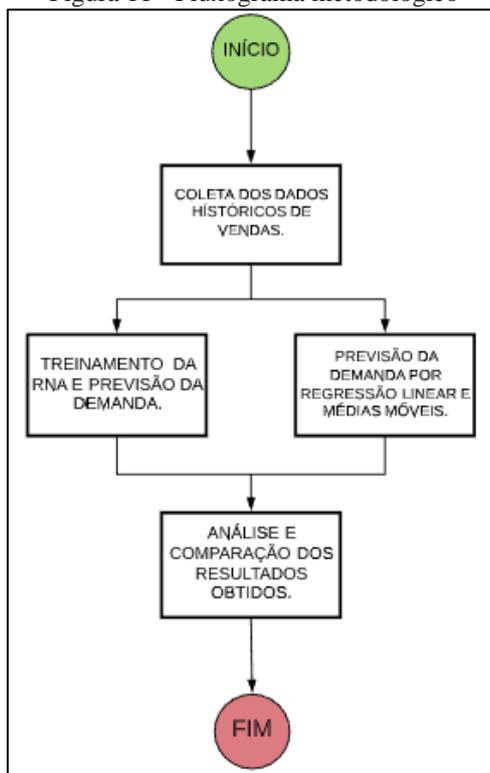
$$REQM = \sqrt{\frac{1}{N} \sum_{i=1}^N (demanda\ real(i) - demanda\ prevista(i))^2}$$

Fonte: Adaptado de Haykin (2009)

Onde:

- N: quantidade de períodos previstos;
- *demanda real(i)*: valor real das vendas no período *i*;
- *demanda prevista(i)*: valor da previsão de vendas para o período *i*.

Figura 11 - Fluxograma metodológico



Fonte: Elaborada pelos autores (2019)

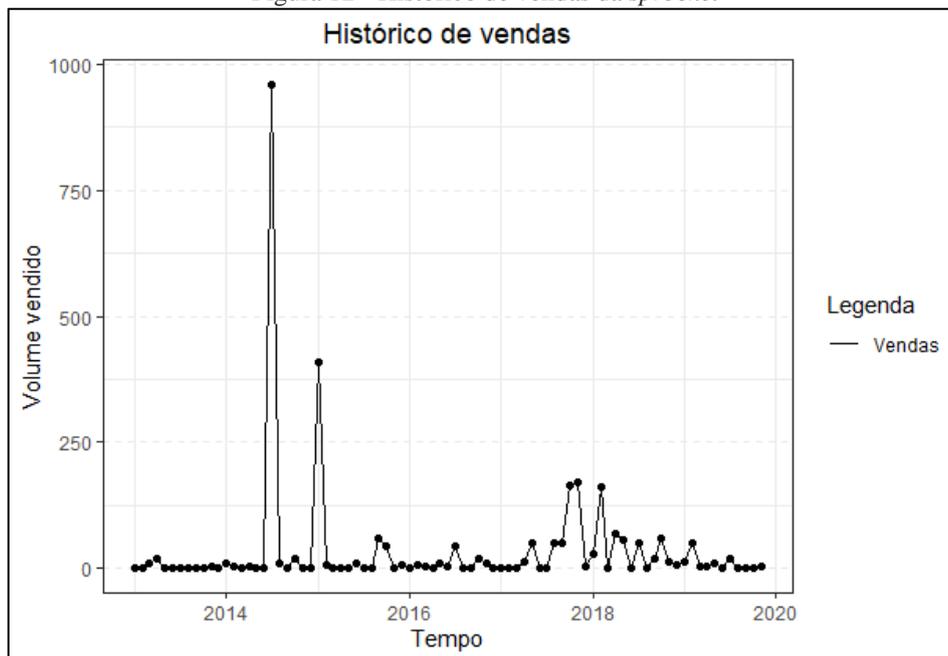
3.2. Dados coletados

Os dados coletados referem-se ao histórico de vendas da empresa, desde o início de suas operações no Brasil, até o mês em que iniciou-se este artigo. Este período diz respeito a janeiro de 2013 até novembro de 2019. Seu comportamento pode ser analisado pelo gráfico da figura 12. Este histórico de vendas foi utilizado para o processo de aprendizagem da RNA.

A partir dos dados coletados, foram realizados testes preliminares para determinar os valores do momento, taxa de aprendizagem, número de iterações e a amplitude de observações para os três métodos. Na execução dos testes, buscou-se reproduzir a demanda dos meses de outubro e novembro de 2019, cujos valores já eram conhecidos.

Como resultado, obteve-se o valor de 1 para o momento, 0,25 para a taxa de aprendizagem nas primeiras 500.000 iterações e 0,025 para as 500.000 iterações finais, totalizando 1.000.000 de iterações. Para as amplitudes, definiu-se seis observações para os métodos RNA e MMS, e nove observações para RLS.

Figura 12 - Histórico de vendas da *sprocket*



Fonte: Elaborado pelos autores (2019)

3.3. Linguagem de programação utilizada

Toda a programação foi implementada utilizando-se a linguagem R versão 3.6.1 para Windows (download: <https://cloud.r-project.org/bin/windows/base/R-3.6.1-win.exe>). O *software* de interface para programação utilizado foi o RStudio, versão 1.2.5001 para Windows (download: <https://download1.rstudio.org/desktop/windows/RStudio-1.2.5001.exe>). A escolha do programa sucedeu-se devido seus recursos práticos, interface simples e por ser um *software* livre.

4. Resultados e discussão

A tabela 1 apresenta o valor real das vendas para os meses de dezembro de 2019 a abril de 2020, bem como o valor das previsões dos três métodos utilizados e seus respectivos valores da raiz do erro quadrático médio em relação às vendas reais.

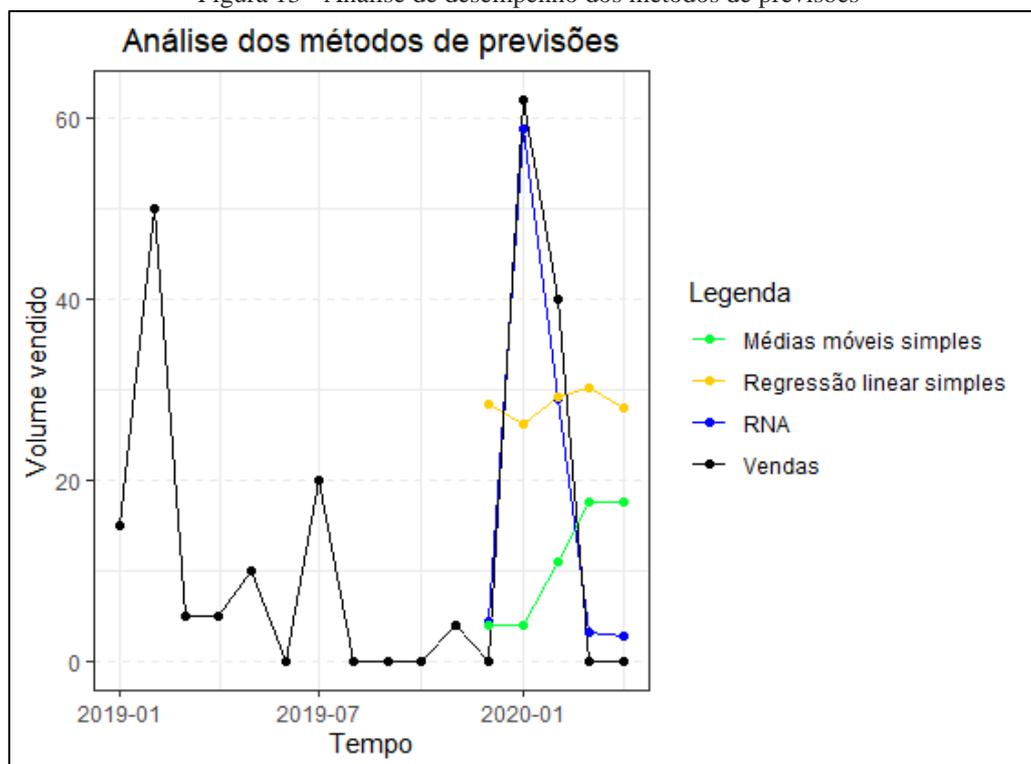
Tabela 1 - Valores das vendas e previsões.

	Dez/19	Jan/20	Fev/20	Mar/20	Abr/20	REQM
Vendas	0	62	40	0	0	-
RNA	4,46	58,73	28,96	3,28	2,87	5,85596
MMS	4,00	4,00	11,00	17,67	17,67	31,1296
RLS	28,43	26,26	29,20	30,22	28,08	27,9414

Fonte: Elaborada pelos autores (2020)

Para o mês de Dez/2019 o método de MMS apresentou resultado mais aproximado da demanda real. Em Fev/2020 o método de RLS teve a previsão mais próxima das vendas. Observa-se que nestes dois casos a RNA também apresentou desempenho similar. Analisando o REQM da tabela 1 e comparando o comportamento de cada método em relação ao das vendas reais no gráfico da figura 13, constata-se um melhor desempenho da rede neural artificial.

Figura 13 - Análise de desempenho dos métodos de previsões



Fonte: Elaborada pelos autores (2020)

5. Considerações finais

Este trabalho teve por objetivo realizar previsões de demanda utilizando-se de três métodos, a fim de identificar o de melhor desempenho com base nos resultados obtidos. Após analisar o comportamento do histórico de vendas da *sprocket* (figura 12), esperava-se que a rede neural artificial apresentasse melhor performance, devido à instabilidade das vendas, que estabelece um cenário desfavorável ao desempenho dos métodos MMS e RLS.

Acredita-se que quando a demanda apresentar um comportamento volátil, sem nenhuma tendência aparente, a RNA terá maior assertividade comparada com os métodos estatísticos apresentados, visto que a rede neural tem a capacidade de generalização a qual aprendeu com

os padrões do histórico de vendas.

Após apresentar os resultados obtidos à diretoria geral da empresa, a RNA foi aprovada como ferramenta de suporte ao PCP, no processo de previsão de demanda para todo o portfólio da linha de transmissão de potência (*power transmission*), a fim de reduzir os custos de estoque.

6. Agradecimentos

Agradeço a Deus em primeiro lugar, por ter me dado saúde, inteligência e força para me dedicar a este maravilhoso curso, enfrentar as dificuldades até o final e poder dar orgulho aos meus pais e familiares.

Agradeço aos meus pais por nunca medirem esforços para me proporcionar esta oportunidade e permitir que chegasse até este momento.

Agradeço aos meus familiares pelo alento, carinho e amor fundamentais para esta minha caminhada.

Agradeço ao professor Roberto Guzman por desempenhar o papel de mentor nesta jornada acadêmica.

Agradeço à minha namorada, Natalli Tanielli, por todo apoio e suporte.

Agradeço às professoras Mariana Kleina e Regina Chiquetano pela brilhante e atenciosa orientação que tive a honra de receber neste trabalho.

REFERÊNCIAS

CHIAVENATO, Idalberto. **Planejamento e Controle da Produção**. São Paulo: Atlas, Manole, 2008.

CORRÊA, Henrique Luiz. **Planejamento e controle da produção**. Rio de Janeiro: Atlas, 2019.

FÁVERO, Luiz Paulo. **Análise de dados: modelos de regressão com Excel®, Stata® e SPSS®**. Rio de Janeiro: Elsevier, 2016.

FERNANDES, Flávio César Faria; GODINHO FILHO, Moacir. **Planejamento e controle da produção: dos fundamentos ao essencial**. São Paulo: Atlas, 2016.

FERREIRA, Pedro Guilherme Costa. **Análise de séries temporais em R: curso introdutório**. Rio de Janeiro: Elsevier, 2017.

HAYKIN, Simon. **Neural networks and learning machines**. Hamilton: Pearson, 2009.

HAYKIN, Simon. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.

JAIN, Anil K.; MAO, Jianchang; MOHIUDDIN, K. M. Artificial neural networks: a tutorial. **LSU – Division of Computer Science and Engineering**. Disponível em: <https://csc.lsu.edu/~jianhua/nn.pdf>. Acesso em: 27 de nov. de 2019.

RUSSELL, Stuart; NORVIG, Peter. **Inteligência artificial**. Rio de Janeiro: Elsevier, 2013.

SACOMANO, José Benedito; SÁTYRO, Walter Cardoso. Indústria 4.0: Conceitos e elementos formadores. *In*: SACOMANO, José Benedito (org.); GONÇALVES, Rodrigo Franco (org.); SILVA, Márcia terra da (org.); BONILLA, Silvia Helena (org.); SÁTYRO, Walter Cardoso (org.). **Indústria 4.0**. Conceitos e fundamentos. São Paulo: Blucher, 2018. p. 27–45.

SILVA, Fabrício Machado da; LENZ, Maikon Lucian; FREITAS, Pedro Henrique Chagas; BISPO, Sidney Cerqueira. **Inteligência artificial**. Porto Alegre: SAGAH, 2019.

WINSTON, Patrick Henry. **Artificial intelligence**. Boston: Addison-Wesley Publishing Company, 1992.