

PREVISÃO DE DEMANDA DE PEÇAS SOBRESSALENTES UTILIZANDO REDE NEURAL ARTIFICIAL

Laura Maria Castro Soares

castroanasilva@gmail.com
Universidade Federal do Vale do
São Francisco – UNIVASF, Petrolina,
PE, Brasil.

Ana Cristina Gonçalves Castro Silva

castroanasilva@gmail.com
Universidade Federal do Vale do
São Francisco – UNIVASF, Petrolina,
PE, Brasil.

José de Castro Silva

castro.silva@univasf.edu.br
Universidade Federal do Vale do
São Francisco – UNIVASF, Petrolina,
PE, Brasil.

Pedro Vieira Souza Santos

pedrovieirass@hotmail.com
Universidade Federal do Vale do
São Francisco – UNIVASF, Petrolina,
PE, Brasil.

RESUMO

Em relação à manutenção de ativos, sabe-se que a previsão de demanda para reposição de peças é uma condição importante para a gestão de estoques, visando diminuir custos e evitar a obsolescência de produtos. É evidente que a utilização de métodos preditivos com maior grau de precisão é uma ferramenta fundamental nesse contexto, frente à falta de peças e a super estocagem. Desse modo, o presente trabalho tem por objetivo avaliar o desempenho de uma rede neural artificial na predição de demanda de peças de reposição de um setor de manutenção de tratores agrícolas. Para isso, utilizou-se como método de avaliação e monitoramento a análise dos erros percentuais médios absolutos da previsão. Com intuito de alcançar o objetivo proposto, buscou-se, primeiramente, o estudo dos principais aspectos teóricos relacionados à gestão de estoques e aos métodos de previsão de demanda. Posteriormente, foi feita a seleção das redes Elman para o estudo, e em relação à seleção de peças para análise, ferramentas de gestão de estoques foram utilizadas, visando explorar itens importantes para o setor. Mediante a utilização da metodologia proposta, os resultados mostraram que as redes neurais possuem uma boa aplicação para o contexto em questão, pois, além de apresentar configurações com erros aceitáveis, por várias vezes a rede acertou os picos de maiores e menores demandas, análise importante para a gestão de estoques.

Palavras-chave: Manutenção; Gestão de Estoques; Previsão de Demanda; Redes Neurais.

INTRODUÇÃO

Diante do cenário atual do mercado de trabalho, é notável que, para as empresas sobreviverem à competitividade, faz-se necessário ter um bom controle sobre suas atividades, proporcionando bons lucros com o menor custo possível. Dessa forma, planejar e acompanhar as atividades da produção se torna um fator crucial para uma boa atuação no mercado. A partir disso, entre as atividades de planejamento da produção estão as políticas de gestão de estoques (Machado & Santos, 2020; Souza Júnior *et al.*, 2022).

Gerenciar bem os estoques de matéria-prima e produtos, em geral, é um quesito que influencia diretamente no desempenho de qualquer empresa, uma vez que há custos de grande relevância envolvidos nesse contexto (Santos & Silva, 2019). Uma forma de gerir o estoque é baseando-se na previsão de demanda, com intuito de obter e acompanhar, da maneira mais eficiente possível, a necessidade de quaisquer itens essenciais para os setores e atividades da empresa, viabilizando, assim, investimentos corretos na capacidade de produção, na aquisição dos produtos e na manutenção do estoque, resultando na redução dos custos desnecessários (Dias, 2009).

O papel das previsões, entre elas a previsão de demanda, é fornecer subsídios para o planejamento estratégico da organização, seja para o acompanhamento dos estoques, mão de obra, vendas, entre outros fatores. A previsão de demanda permite que os administradores dessas organizações antecipem o futuro e planejem de forma mais conveniente suas ações (Tubino, 2017; Santos, 2019).

Segundo Gonçalves (2013), estimar a demanda futura de bens e serviços é condição essencial para a elaboração de um plano de trabalho que inclui o dimensionamento das capacidades envolvidas com a definição de equipamentos, dos recursos financeiros, da disponibilidade de mão de obra e da quantidade de materiais necessários para a produção. Para um setor de manutenção, a previsão de demanda de peças de reposição é um fator de extrema importância, uma vez que auxilia no planejamento das manutenções preventivas e corretivas dos ativos, diminuindo a probabilidade de parar a produção por falta de peça, por exemplo.

Silva (2003) relata que existem vários métodos de se efetuar previsões, alguns mais intuitivos e de natureza prática, conhecidos como qualitativos, e outros mais objetivos, com base matemática e estatística, conhecidos como quantitativos. O fato de não haver um método único e ideal para previsão, aplicável a todas as situações, deixa em aberto um amplo espaço para a pesquisa técnico-científica da aplicabilidade e eficiência de cada técnica.

Em ambos os casos, qualitativos ou quantitativos, a partir dos dados históricos, é possível extrair informações que

permitem elaborar a modelagem do comportamento de um fenômeno, visando prever seu comportamento futuro. Segundo Araújo e Gomes (2005), os dois principais grupos de modelos para previsão de séries temporais baseiam-se em métodos estatísticos e em Redes Neurais Artificiais (RNAs). Para mais, tem-se também técnicas heurísticas.

Nesse contexto, sabe-se que a gestão de estoques é um dos itens importantes da gestão da manutenção. Desse modo, faz-se necessário acompanhar o consumo de materiais nas atividades do setor, com intuito de monitorar os níveis de estoque (máximo, ponto de reposição e estoque reserva), conforme indica Santos (2019).

A partir disso, essa situação é válida para qualquer setor de manutenção. Tratando-se da manutenção de tratores agrícolas, não seria diferente, pois existem itens indispensáveis e mais recorrentes no estoque para as manutenções preventivas, além de ser importante a existência de peças que podem ser necessárias em manutenções corretivas. Dessa forma, para que as manutenções sejam realizadas no momento certo, é indispensável que os materiais necessários estejam disponíveis sempre que preciso.

Na produção de uva, por exemplo, muitas atividades são feitas com auxílio de tratores, seja adubação, aplicação de produtos por meio da pulverização, nivelamento do solo com grade aradora, carregamento dos contentores em carroças, entre outras atividades. Visto isso, os tratores expostos a esses serviços, normalmente, trabalham durante muitas horas, e necessitam de frequentes manutenções. Considerando esse cenário, é evidente a necessidade de reposição constante de material para suprir a demanda.

Dessa forma, tendo em vista a importância do uso de uma metodologia de previsão de demanda para peças de reposição, e considerando as vantagens que o método pode incorporar na gestão de estoques, a questão a ser investigada é a seguinte: como utilizar um modelo de previsão de demanda, baseado em redes neurais, para a gestão de estoques de peças sobressalentes em um setor de manutenção de tratores agrícolas?

Logo, o objetivo desta pesquisa é elaborar um modelo de previsão de demanda, utilizando redes neurais, para auxiliar no gerenciamento de peças sobressalentes de um setor de manutenção de tratores agrícolas em uma fazenda produtora e exportadora de uva do Vale do São Francisco.

REVISÃO BIBLIOGRÁFICA

O estoque, ao mesmo tempo em que é custoso e apresenta risco de deterioração, obsolescência e perda, proporciona certo nível de segurança para a organização, como

citado por Fernandes *et al.* (2021). A gestão do estoque de sobressalentes para a manutenção visa definir uma quantidade suficiente de componentes, os quais devem ser mantidos em estoque, a fim de garantir um rápido reparo das falhas prematuras, mantendo-se à disponibilidade necessária dos equipamentos.

O dimensionamento do estoque de peças de reposição deve garantir que as peças necessárias estarão disponíveis na quantidade certa e na hora certa. Dessa forma, assim como o excesso de peças resulta em prejuízo, a falta de peças é igualmente negativa, representando perdas de produção pelo aumento de tempo de interrupção dos ativos (Xenos, 2014).

Wu e Hsu (2008) afirmam que a disponibilidade dos equipamentos, sob determinado aspecto, depende do seu nível de inventário de peças sobressalentes. Por esse motivo, Molenaers *et al.* (2012) expressam que a importância dos itens sobressalentes tem dimensões bastante diferentes diante do ponto de vista da manutenção e o da logística/inventário, pois a sua gestão adequada deve considerar os aspectos críticos inerentes a ambos os contextos.

Huiskonen (2001) retrata que as pesquisas referentes à logística das peças de reposição estão mais relacionadas com a temática da gestão de inventário, cujo objetivo principal é a obtenção de um nível adequado de serviço ao cliente, com o mínimo de investimentos em estoque e custos administrativos.

A gestão efetiva de estoques tem sido objeto de estudo em organizações que buscam reduzir seus custos operacionais e investimentos com ativos circulantes. Dessa forma, o gerenciamento de estoques de sobressalentes é uma necessidade para organizações que utilizam grande quantidade de ativos físicos em seus processos produtivos.

Ele é significativamente diferente do gerenciamento de estoques regulares. Os sobressalentes são itens de suprimento destinados à eventual substituição de seus similares, instalados em equipamento ou unidade produtiva, por motivo de extravio, desgaste, avaria ou prevenção de avaria. Não fazem parte do negócio principal da organização, mas são a garantia de que os ativos físicos, empregados nos seus processos, funcionem de forma a manter a capacidade produtiva necessária (Ferreira *et al.*, 2009).

As decisões para definição do nível de estoques de sobressalentes devem levar em consideração, além das relações de custo-benefício entre realizar a manutenção (preventiva ou corretiva), os custos de indisponibilidade do sistema, a possibilidade de obsolescência, e o fato de as peças poderem ser provenientes de “canibalismo” (uso, como sobressalentes, de peças em bom estado, retiradas de equi-

pamentos parados por falta de outras peças de reposição). Manter esses estoques pode ser considerado oneroso, ou até desnecessário, já que os sobressalentes podem nunca ser utilizados, ficando obsoletos. Contudo, eles representam uma garantia de que uma falha em um equipamento poderá ser contornada e, assim, a capacidade produtiva se manter (Ferreira *et al.*, 2009).

Ferramentas para gestão de estoques: Curva ABC e Classificação XYZ

Um dos exemplos de ferramentas para administrar a gestão de estoques em uma organização é a metodologia da curva ABC. Também conhecida como Curva 80/20, foi criada pelo engenheiro Vilfredo Pareto em meados do século XX. A análise ABC consiste em verificar e caracterizar, em graus de importância, quais devem ser os itens que necessitam receber maior atenção a partir de sua importância para a empresa (Dias, 2009).

A partir disso, eles serão tratados como prioridade, por apresentarem maior demanda valorizada, a qual se refere à quantidade de demanda vezes o custo unitário do item. E segundo Tubino (2017), a curva ABC é um importante instrumento para o administrador, pois ela permite identificar aqueles itens que justificam atenção e tratamento adequados quanto a sua administração. Obtém-se a curva ABC através da ordenação dos itens conforme a sua importância relativa.

A Classificação XYZ pode ser utilizada como complementar à Curva ABC. Tal curva utiliza como critério de classificação o grau de criticidade ou imprescindibilidade de um material no desempenho de determinada atividade. Segundo Viana (2012), a partir das respostas obtidas, é possível classificar os itens levando em consideração as características: classe X – considerados materiais de baixa criticidade, dada que sua falta não causa interrupção de nenhuma atividade e muito menos risco à segurança da organização; possuem facilidade de substituição por materiais equivalentes e de fácil obtenção no mercado; classe Y são materiais de criticidade intermediária, ou seja, sua ausência provoca prejuízos a determinadas atividades, mas podem ser substituídos por equivalentes com relativa facilidade; classe Z são itens de máxima criticidade. A ausência desses itens pode paralisar uma ou mais áreas da operação e ainda não podem ser substituídos ou não possuem similares no mercado (Viana, 2012).

Métodos de previsão de demanda: Redes Neurais Artificiais

No que diz respeito às metodologias utilizadas para previsão, as que mais se destacam são a Média Móvel Aritmética,

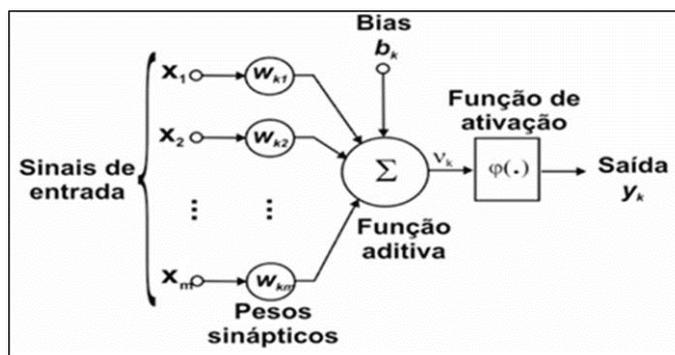


Figura 1. Estrutura básica de um neurônio artificial

Fonte: Haykin (2009)

Média com Suavização Exponencial, Modelos com Tendências e Sazonalidades, Modelos ARIMA (*Box-Jenkins*), Regressão Linear, Modelos Econométricos, e, mais recentemente, as Redes Neurais Artificiais.

Pasquotto (2010) descreve as Redes Neurais como estruturas computacionais que imitam parte do sistema nervoso biológico. O princípio é reproduzir o processamento de informações do cérebro com um modelo artificial de neurônios, os quais se unem funcionalmente através de conexões, formando, assim, as Redes Neurais.

No cérebro humano o neurônio é a unidade básica que recebe os estímulos transmitidos por outros neurônios, a comunicação é realizada através de impulsos. Quando um determinado neurônio recebe os impulsos que chegam através de seus dendritos, ele os processa e, de acordo com um dado limite de ação, produz uma substância neurotransmissora que flui através do axônio para outros neurônios (Pasquotto, 2010).

Da mesma forma que no cérebro humano, as RNAs têm no neurônio artificial sua unidade de processamento mais básica. A **Figura 1** exibe a estrutura básica do neurônio apresentado por Haykin (2009). A saída y é dada pela função do somatório das entradas, x_1, x_2, \dots, x_m , ponderadas por seus respectivos pesos, $w_{k1}, w_{k2}, \dots, w_{km}$, de forma a fornecer um modelo matemático do estado de sua sinapse (excitação ou inibição). O peso w_{k1} aplicado à entrada fixa $b_k = 1$ é chamado bias e tem a finalidade de controlar o nível da saída v do combinador linear (Freitas, 2008).

Em que:

- m é o número de sinais de entrada do neurônio;
- x_m é o m -ésimo sinal de entrada do neurônio;
- w_{km} é o peso associado com o m -ésimo sinal de entrada, no neurônio k ;

- b_k é o limiar do neurônio k , frequentemente chamado de bias;
- v_k é uma combinação ponderada dos sinais de entrada e do bias, no k -ésimo neurônio;
- y_k é o neurônio de saída;
- $\psi(.)$ é a função de ativação, do k -ésimo neurônio.

As entradas x_m do neurônio podem ser saídas de outros neurônios, entradas externas, um viés ou qualquer combinação desses elementos. Elas são ponderadas pelos pesos w_{km} , que são inspirados na força da conexão sináptica. Vale ressaltar que a arquitetura das RNAs varia de acordo com sua finalidade. Além disso, a maneira como os neurônios estão distribuídos em rede também está relacionada com o algoritmo de aprendizagem utilizado.

Ademais, as redes de camada única são as redes com neurônios dispostos em paralelo em uma única camada. Já quando se trata de multicamadas, existe uma ou mais camadas posicionadas entre os nós de entrada e a camada que gera as saídas (Souza *et al.*, 2018).

Vaz (2014) relata que a função de transferência, ou função de ativação, controla a amplitude da saída do neurônio e baseia-se nas reações dos neurônios para os valores de entrada, dependendo também do nível de atividade do neurônio (estado de ativação). Essa premissa se baseia no modelo biológico, em que cada neurônio é, em todos os momentos, pouco ativo. Essencialmente, os neurônios são ativados quando a entrada de rede exceder o gradiente máximo do valor da função de ativação, conhecido como limiar atribuído (Florêncio, 2016).

Ainda de acordo com Vaz (2014), um aspecto fundamental na implementação de redes neurais artificiais é o treinamento. Esse processo deverá ser concebido de modo que a rede aprenda uma tarefa com sucesso. Contudo, deve-se

compreender que uma definição precisa de treinamento é difícil de ser alcançada, pois não há abordagem direta sobre como fazer isso. O processo de aprendizagem consiste no ajuste dos pesos sob algumas regras de aprendizagem.

O conhecimento das Redes Neurais Artificiais (RNAs) se dá através da ponderação que os pesos da conexão entre os neurônios de diferentes camadas trocam entre si. Em relação aos treinamentos das RNAs, pode-se utilizar diferentes algoritmos de treinamento que se diferem, basicamente, pelo modo como é realizado o ajuste dos pesos, dividindo-se em dois paradigmas: aprendizado supervisionado e aprendizado não supervisionado (Freeman & Skapura, 1992).

Haykin (2009) indica que o algoritmo de treinamento mais utilizado é o *backpropagation*, também conhecido como retropropagação. Ele utiliza a técnica do gradiente descendente para o ajuste dos pesos sinápticos, de tal forma que o erro produzido pela rede atinja um limite pré-estabelecido, e ele pode ser utilizado com o aprendizado supervisionado ou com o não-supervisionado.

Redes de Elman

As redes de Elman têm esse nome devido ao seu criador, o professor da Universidade da Califórnia, Jeffrey Elman. Elas são conhecidas como redes recorrentes simples e são um aperfeiçoamento das redes *feedforward* devido à inclusão de realimentação entre as camadas imediata e adjacente, oferecendo à rede uma memória de eventos imediatos anteriores, afetando as atualizações dos pesos em cada uma das camadas da rede (Elman, 1991).

Segundo Elman (1991), nas redes em questão, além das unidades de entrada, 35 intermediárias e de saída, há também unidades de contexto, como nas redes parcialmente recorrentes em geral. As unidades de entrada e saída interagem com o ambiente externo, enquanto as unidades intermediárias e de contexto não o fazem.

As unidades de entrada são apenas unidades de armazenamento (*buffer*) que passam os sinais sem modificá-los. As unidades de saída são unidades lineares que somam os sinais que recebem. As unidades intermediárias podem ter funções de ativação lineares ou não-lineares e as unidades de contexto são usadas apenas para memorizar as ativações anteriores das unidades intermediárias e podem ser consideradas como atraso no tempo em um passo (Elman, 1991).

Na **Figura 2**, tem-se uma rede recorrente de Elman com uma camada oculta. A arquitetura é denotada por Elman ($dE+q, q, 1$), destacando a dimensão do vetor de entrada (dE), a dimensão do vetor de contexto (q), o número de neurônios ocultos (q) e o número de neurônios de saída, sendo apenas um nesse caso.

De acordo com Schatz (2014), a rede Elman funciona da seguinte forma: no instante t (inicial), o sinal é propagado pela rede e as unidades de contexto, inicializadas com a saída da camada escondida com o valor zero, não influenciarão na saída da rede, ou seja, na primeira iteração, a rede se comportará como uma rede *feedforward*.

Ainda na primeira iteração, os neurônios escondidos ativarão os neurônios da camada de contexto e esses armazenarão a saída dessa iteração, que será utilizada no próximo ciclo. O algoritmo *backpropagation* é, então, aplicado para

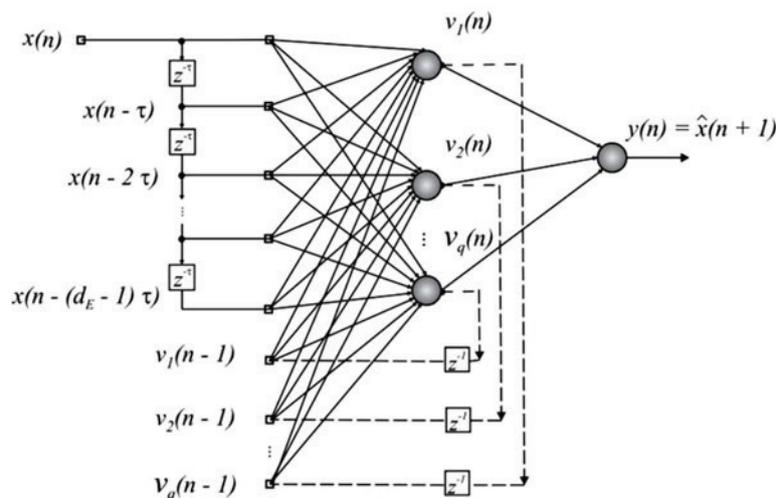


Figura 2. Rede Elman com uma camada oculta

Fonte: Adaptado de Elman (1991)

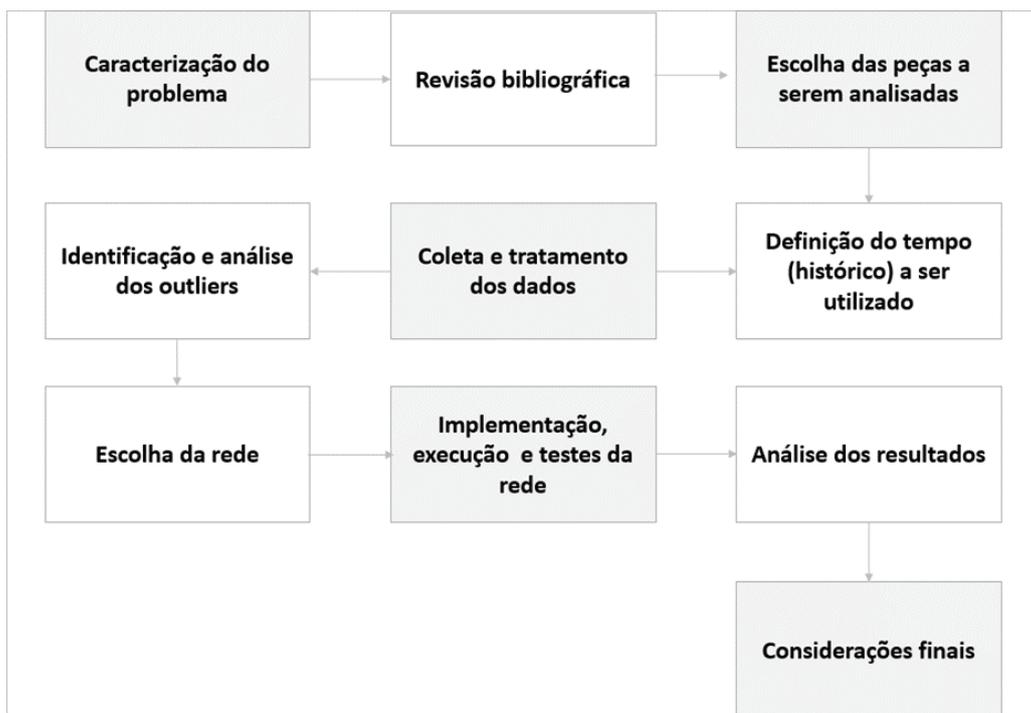


Figura 3. Etapas da pesquisa

Fonte: Autoria própria (2022)

a correção dos pesos sinápticos, com exceção das sinapses recorrentes que são fixas em 1. No instante $(t + 1)$, o processo é repetido. A diferença é que, a partir de agora, os neurônios escondidos serão ativados pelas unidades de entrada e pelas unidades de contexto que possuem o valor de saída dos neurônios escondidos no instante (t) , como cita Schatz (2014).

MÉTODOS E TÉCNICAS DE PESQUISA

Com o intuito de organizar as etapas de estudo, definiu-se uma sequência ordenada de atividades, evidenciadas na **Figura 3**.

Além disso, no **Quadro 1** constam determinadas fases e as ferramentas que foram utilizadas.

Em relação à escolha das peças a serem analisadas, primeiro restringiu-se o objeto de estudo. A pesquisa foi focada em peças de tratores, por serem a maior demanda do setor e por terem um alto grau de importância na produção, uma vez que é a partir desses ativos que os implementos são utilizados.

Ademais, vale ressaltar que a Curva ABC foi utilizada levando em consideração, na porcentagem acumulada, a rotatividade dos produtos (custo x demanda), e para a classificação XYZ, foram utilizados dois métodos: o primeiro foi

numérico, levando em consideração a média de requisições mensais e o desvio dessa média, e o segundo considerou critérios qualitativos. A partir disso, os dados foram cruzados e comparados e, posteriormente, analisou-se a série temporal da demanda de cada item, a fim de obter a seleção final das peças do estudo.

A coleta de dados se deu por meio do sistema de gestão empresarial utilizado pela empresa estudada, ERP (*Enterprise Resource Planning*), da empresa TOTVS, onde tem armazenado em relatórios todas as requisições de peças feitas pelo setor de manutenção.

Com relação ao tratamento dos dados, utilizou-se o *software* Minitab®, em que foram utilizadas cartas de controle de observações individuais e amplitudes móveis para analisar os *outliers* e suavizá-los. E, por fim, o algoritmo da rede foi implementado no *software* Matlab®, no qual foi escolhida a rede Elman.

Escolha da Rede Neural

A escolha da rede neural foi embasada no estudo de Florencio (2016), o qual comparou o desempenho das redes Elman e TDNN (*Time Delay Neural Network*) para revisão de demanda de peças de reposição de veículos automotores. De modo geral, a rede Elman obteve um desempenho me-

Fase	Ferramenta(s) utilizada(s)
Escolha das peças a serem analisadas	Curva ABC e Classificação XYZ
Coleta e tratamento dos dados	Coleta pelo sistema RM TOTVS e tratamento no software Minitab
Identificação e análise dos outliers	Por meio de cartas de controle via Minitab
Implementação, execução e testes da rede	Por meio do software Matlab®

Quadro 1. Fase da pesquisa e ferramentas empregadas

Fonte: Os autores (2022)

lhor nesta pesquisa, e, devido a isso, por ser um estudo aná- logo ao do presente trabalho, optou-se por utilizar tal rede.

Esse mesmo autor retrata que a ferramenta nntool no Matlab® demonstrou ser de pouca interatividade, e, por isso, em seu estudo, preferiu a programação através de coman- dos que, apesar de parecer mais complicada, fornece uma configuração mais detalhada, permitindo alterações em al- guns parâmetros que no toolbox não é possível.

Nesse contexto, o algoritmo utilizado no presente traba- lho foi embasado nas considerações e funções utilizadas por Florêncio (2016). A rede desenvolvida por ele objetivou ser a mais autônoma possível: a partir de uma matriz de entrada linear, busca-se a autocorrelação parcial existente entre os valores para se definir a quantidade de neurônios da entra- da. Com esse valor, o algoritmo refaz as matrizes que serão utilizadas como dados de treinamento, alvo do treinamento, validação, alvos da validação e alvos da previsão de demanda.

Em relação ao algoritmo utilizado, foram definidos os parâmetros da rede: o tamanho do intervalo de previsão foi de 12 meses, máximo de 1500 iterações, máximo de vezes que se permite aumentar o erro da validação igual a 30 e taxa de aprendizado variando de 0,025 a 0,125 (0,025, 0,05, ..., 0,125). Além disso, do mesmo modo como considera- do por Florêncio (2016), optou-se por manter a quantida- de de neurônios na entrada nunca menor que quatro, uma vez que, conforme apresentado por Mine (2010), em testes demonstrou-se ser de baixa eficiência quando se tem uma quantidade reduzida de neurônios na camada de entrada.

Para mais, utilizou-se a função de ativação tansig (tan- gente hiperbólica), algoritmo de treinamento trainlm (*Le- venberg Marquardt para o backpropagation*), função de adaptação de aprendizagem learnngdm (método de aprendi- zado que utiliza o gradiente para ajuste dos pesos do neurô- nio a cada época) e função de performance MSE. As obser- vações mensais do trabalho em questão estão divididas em três partes: treinamento, validação e previsão.

O treinamento da rede constituiu em apresentar a mes- ma os pesos dos neurônios para serem ajustados conforme comportamento da série temporal. Os critérios de parada

buscam o menor erro médio quadrático (MSE) de treina- mento, porém, como comentado anteriormente, ao realizar 30 treinamentos em que o MSE não diminui ou atingindo 1500 iterações, a rede finaliza o treinamento.

APRESENTAÇÃO E ANÁLISE DE DADOS

Para escolha das peças, como comentado anteriormen- te, utilizou-se a Curva ABC e Classificação XYZ, optou-se por selecionar as peças classificadas como “AZ” e “BZ”, já que o segundo método é complemento do primeiro. Inicialmente, utilizou-se a Curva ABC levando em consideração na porcen- tagem acumulada a rotatividade das peças – considerou-se como “A” a porcentagem acumulada menor que 50%, “B” menor que 80% e “C” igual ou maior que 80% –, obtendo os resultados da **Tabela 1** para as peças classificadas como “A” e “B”.

Ademais, para a Classificação XYZ, levou-se em considera- ção a razão entre o desvio médio das quantidades de requi- sições nos meses de 2018 com a média delas – considerou- se como “X” valores menores que 50%, “Y” valores entre 50 e 100% e “Z” valores iguais ou maiores que 100%. Na **Tabela 2**, tem-se a relação de itens classificados como “Z” nesse método.

A partir disso, os dados foram cruzados e as peças classifi- cadas como “AZ” e “BZ” estão evidentes na **Tabela 3**.

Para mais, utilizou-se também a Classificação XYZ, levan- do em consideração agora critérios qualitativos, com intuito de comparar a convergência dos dados selecionados no mé- todo anterior, com base em observações importantes para a gestão de estoques:

X - A falta do material não interrompe a atividade, bem como possui equivalentes no mercado;

Y – Ausência do material causa prejuízos, mas pode ser substituído por equivalentes no mercado;

Z – A falta do material paralisa a atividade, além disso, não pode ser substituído por similares.

Tabela 1. Itens classificados como “A” e “B” na curva ABC

Código	Item	Classificação ABC
15.01.3049	Filtro combustível 12990755800 – R	A
15.02.0484	Bateria 12 V 60 A	A
15.01.3092	Retentor do eixo dianteiro YB40T – 15232	A
15.01.0778	Retentor YB40T – 15213	B
15.01.3050	Filtro de ar TNE8812670	B
15.01.1111	Terminal de direção YB40 – 12070	B
15.01.3572	Elemento filtrante BT4012590	B
15.01.0558	Lâmpada H5 12 V	B
15.01.1638	Correia A – 38	B
15.01.3159	Farol de trabalho	B

Fonte: Os autores (2022)

Tabela 2. Itens classificados como “Z” segundo critérios XYZ

Código	Item	Classificação
15.01.0956	Lâmpada H3 - 12V Philips	Z
15.01.1682	Fusível de lâmina 30 A	Z
15.01.3050	Filtro ar TNE8812670	Z
15.01.3159	Farol de trabalho	Z
15.01.3291	Deslizante YA44-20320	Z
15.01.3572	Elemento filtrante BT4012590	Z
15.01.3573	Elemento segurança BT40T12570	Z
15.01.3671	Bucha 25x31x25 YB-4521340	Z
15.01.4900	Retentor YB40T – 15233	Z
15.02.0484	Bateria 12 V60 A	Z

Fonte: Os autores (2022)

Tabela 3. Classificação inicial das peças

Código	Item	Classificação
15.01.3050	Filtro de ar TNE9912670	BZ
15.01.3159	Farol de trabalho	BZ
15.01.3572	Elemento Filtrante BT404012590	BZ
15.02.0484	Bateria 12 V 60 A	AZ

Fonte: Os autores (2022)

Tabela 4. Itens classificados como “Z”, segundo critérios XYZ qualitativos

Código	Item	Classificação
15.01.0111	Rolamento 6004	Z
15.01.0778	Retentor YB40T-15213	Z
15.01.1112	Terminal de direção YB40-12060	Z
15.01.1500	Rolamento Agulha ROH 2520	Z
15.01.3092	Retentor Eixo Dianteiro YB40T 15232	Z
15.01.3291	Deslizante YA44-20320	Z
15.01.3671	Bucha 25x31x25 YB-4521340	Z

Fonte: Os autores (2022)

Tabela 5. Classificação segundo Curva ABC e critérios XYZ qualitativos

Código	Item	Classificação
15.01.0778	Retentor YB40T – 15213	BZ
15.01.1112	Terminal de direção YB40 – 12060	BZ
15.01.1638	Correia A-38	BZ
15.01.3092	Retentor do eixo dianteiro YB40T – 15232	BZ

Fonte: Os autores (2022)

Tabela 6. Escolha final das peças segundo Curva ABC e classificação XYZ

Código	Item	Classificação
15.01.3050	Filtro de ar TNE8812670	BZ
15.01.3159	Farol de trabalho	BZ
15.01.3572	Elemento Filtrante BTD404012590	BZ
15.01.1112	Terminal de direção YB40 – 12060	BZ
15.01.1638	Correia A-38	BZ

Fonte: Os autores (2022)

A partir disso, novamente cruzou-se os dados da Curva ABC com os novos critérios XYZ, obtendo as peças da **Tabela 5**.

Nesse contexto, nota-se que a quantidade de itens continuou a mesma, porém, não houve convergência deles. Além disso, na segunda combinação não houve item classificado como “AZ”. Com intuito de levar em consideração o resultado de ambas as metodologias, analisou-se o gráfico de demanda dos itens inclusos nos dois métodos, a fim de obter uma escolha final das peças para o estudo, considerando os dados a serem utilizados na Rede Neural. Tem-se adiante, na **Figura 4** (a), (b), (c) e (d) a demanda das peças do primeiro cruzamento de dados.

Nesse contexto, nota-se que, para uma parte dos itens, têm-se uma constante requisição de peças, exceto em um período expressivo referente ao elemento filtrante, situação justificada porque somente em 2014 começou-se a utilizar tratores que necessitam desse item. Além disso, é evidente

que a demanda da bateria foi baixa no intervalo total de tempo analisado. Dessa forma, apesar dessa última ter sido um dos itens selecionados na primeira metodologia, quando se compara os dados da demanda das peças, nota-se que a bateria não seria uma boa escolha de análise na rede. Provavelmente, nos anos anteriores, era utilizado outro código para a requisição de baterias dos tratores, tornando inviável coletar as requisições desse item. Para mais, tratando-se agora da segunda seleção feita, tem-se, na **Figura 5**, (a), (b), (c) e (d), os gráficos referentes às demandas das peças indicadas.

A partir disso, fazendo a mesma análise, os dois retentores também não se mostram interessantes para o estudo de demanda na rede, frente aos dados das outras peças. Dessa forma, fez-se a seleção final dos itens a serem estudados, evidenciados na **Tabela 6**.

É importante ressaltar que, devido à variação da demanda dos itens selecionados, dificulta-se a utilização de uma

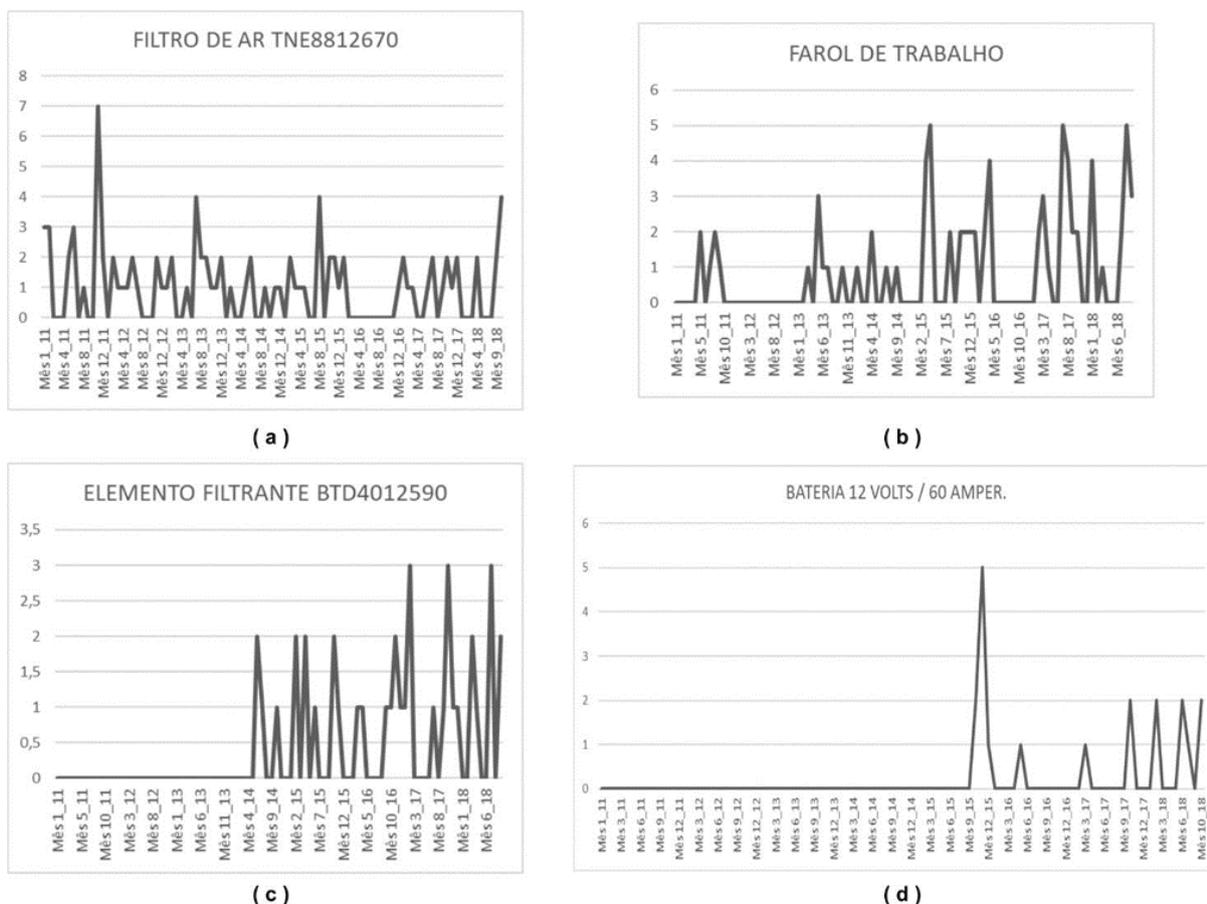


Figura 4. Demanda das peças da primeira seleção

Fonte: Os autores (2022)

única forma de prever a demanda, seja por meio dos métodos qualitativos ou quantitativos tradicionais, seja por meio das Redes Neurais artificiais. Como já mencionado, para o tratamento de dados, utilizou-se o *software* Minitab®, em que foram identificados os *outliers* por meio de cartas de controle de observações individuais e amplitudes móveis e, posteriormente, feitas as suavizações deles.

Aplicação da Rede Neural Artificial

Na **Figura 6**, tem-se a rede de Elman com uma quantidade de neurônios na camada de entrada, na oculta, o algoritmo de treinamento, e a medida de desempenho como sendo o erro médio quadrático.

Nesse contexto, em relação ao número de neurônios de entrada utilizado no estudo, foi definido da mesma forma como abordado por Mine (2010), a partir da autocorrelação parcial dos dados, que é uma medida de correlação usada para identificar a existência de relacionamento entre valores correntes de uma variável com seus valores anteriores, acumulando os efeitos de todos os intervalos (ou *lags*) em constantes de intervalo. Dessa forma, os gráficos com as funções

de autocorrelação das séries do estudo em questão estão explícitos adiante. Na **Figura 7**, percebe-se que a melhor opção de quantidade de entrada para o filtro de ar é de 5 neurônios.

Para o farol de trabalho, de acordo com a **Figura 8**, tem-se como opções para quantidade de neurônios de entrada 1, 11 ou 18. Escolheu-se a opção 11 devido à escolha de não utilizar uma quantidade menor que 4, conforme indicado por Florêncio (2016), e por ter uma correlação maior que a do 18.

Tratando-se do elemento filtrante, de acordo com a **Figura 9**, a melhor opção é a de 7 neurônios de entrada.

Para o terminal de direção, a melhor opção é de 5 neurônios de entrada, **Figura 10**.

Por fim, para a correia, a partir da **Figura 11**, preferiu-se utilizar 4 neurônios de entrada, não foi escolhida uma quantidade superior, como 20, por exemplo, pois, segundo Mileski Júnior (2010), quanto maior for a quantidade de entradas utilizadas, maior será a complexidade do problema a ser resolvido, bem como a quantidade de soluções possíveis para análise pela metodologia neural.

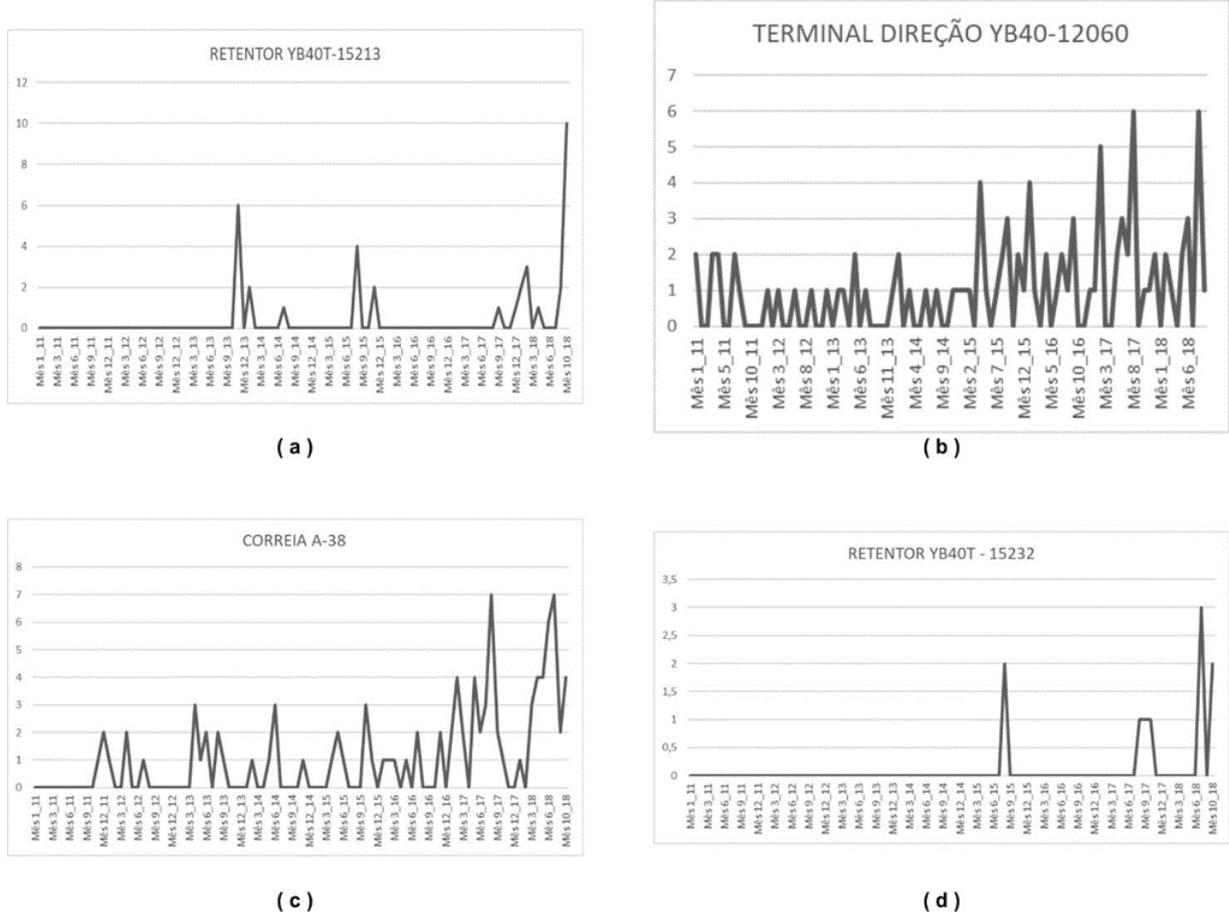


Figura 5. Demanda das peças da segunda seleção

Fonte: Os autores (2022)

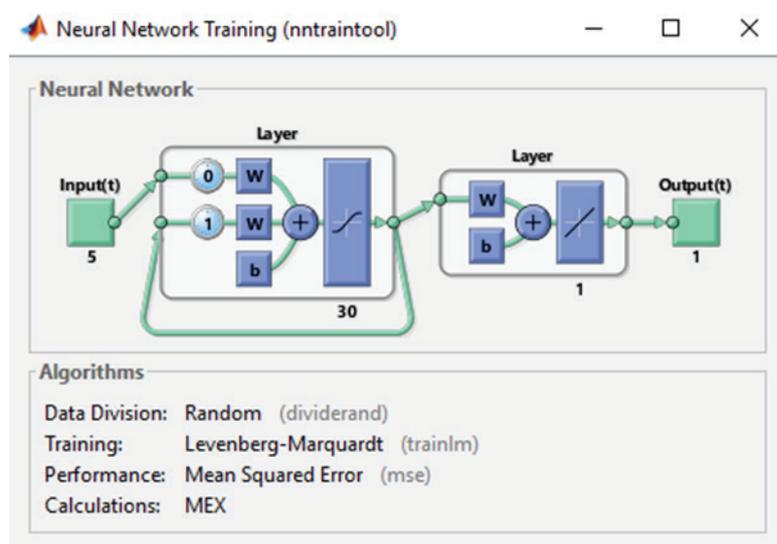


Figura 6. Rede Elman

Fonte: Matlab® R2015a

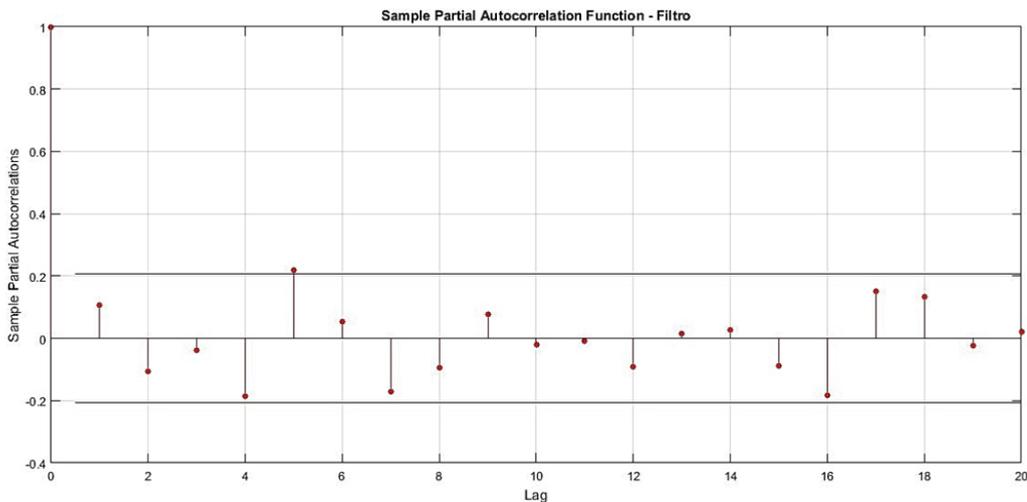


Figura 7. Autocorrelação parcial do Filtro de Ar

Fonte: Os autores (2022)

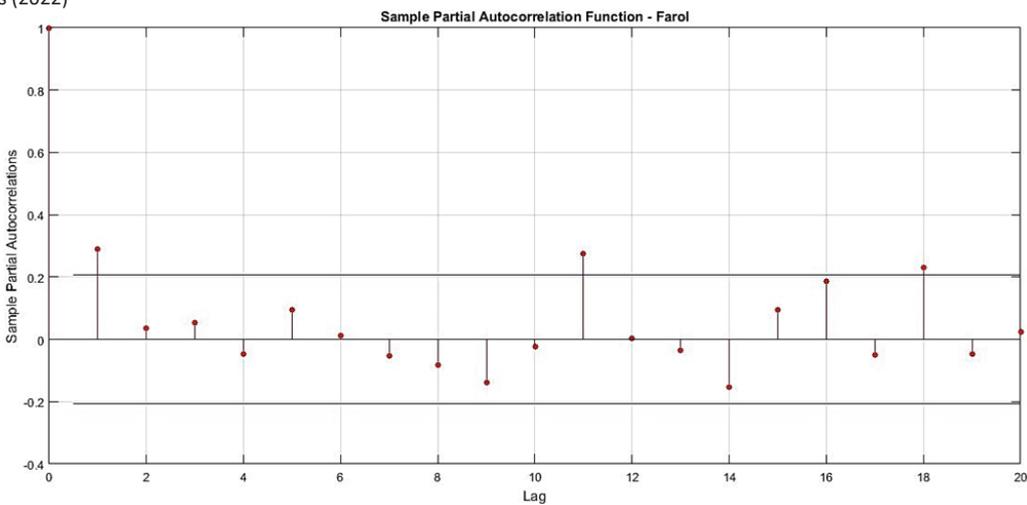


Figura 8. Autocorrelação parcial do Farol de Trabalho

Fonte: Os autores (2022)

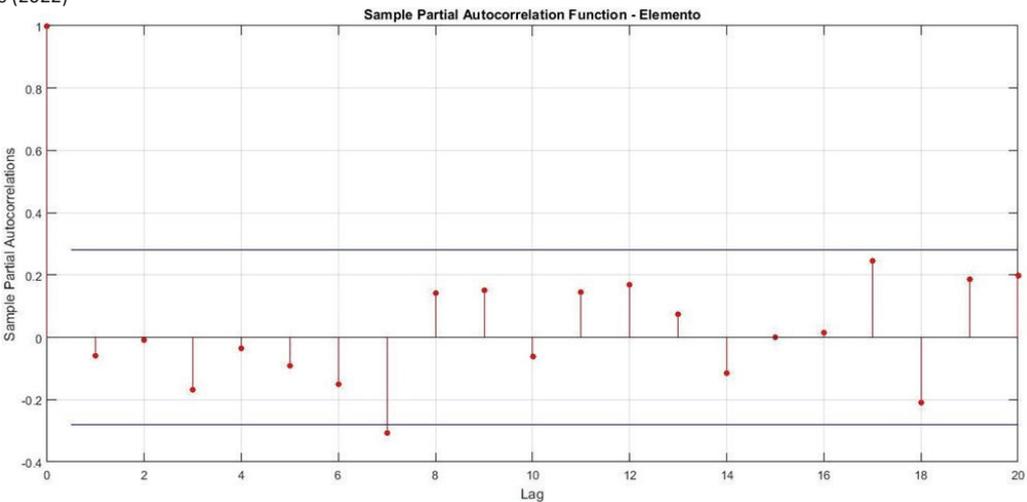


Figura 9. Autocorrelação parcial do elemento filtrante

Fonte: Os autores (2022)

É importante mencionar que um fator que determina a qualidade e velocidade do treinamento da rede é a quantidade de neurônios na camada escondida. Ao utilizar poucos neurônios na camada escondida, a rede é incapaz de modelar dados mais complexos. Em contrapartida, se muitos neurônios forem utilizados, o treinamento irá se tornar longo e a rede pode sofrer problemas de sobreajuste, resultando na perda da capacidade preditiva da rede.

Dados com ruídos ou redundantes podem provocar a falha da rede na convergência de uma solução genérica. Vale ressaltar ainda que a quantidade de camadas também influencia nos resultados. Estudos (Gomes, 2005; Mine, 2010; Pasquotto, 2010; Lima, 2014) mostram que, para a maioria dos problemas, uma camada escondida é suficiente.

A partir disso, foram feitos testes com somente uma camada oculta, variando a quantidade de neurônios entre

cinco e trinta (5, 10, ..., 30), além de variar a taxa de aprendizado entre 0,025 e 0,125 (0,025, 0,05, ..., 0,125). Notou-se que, apesar da limitação das 1500 iterações, os valores do erro médio quadrático tendem a se aproximar de zero muito rapidamente no treinamento.

Para interpretar de forma mais objetiva os resultados obtidos, optou-se por avaliar o MAPE, que fornece uma indicação do tamanho médio do erro, expresso como uma porcentagem do valor observado. A partir disso, notou-se que para cada um dos casos, a configuração para o menor MAPE foi diferente, devido à diversificação das características das demandas, reforçando, assim, a dificuldade em avaliar por um mesmo método diferentes séries.

Com isso, referente aos melhores resultados para o erro, a peça que obteve o menor MAPE nos testes foi o farol de trabalho (5,91%) e a com maior erro foi o elemento filtrante

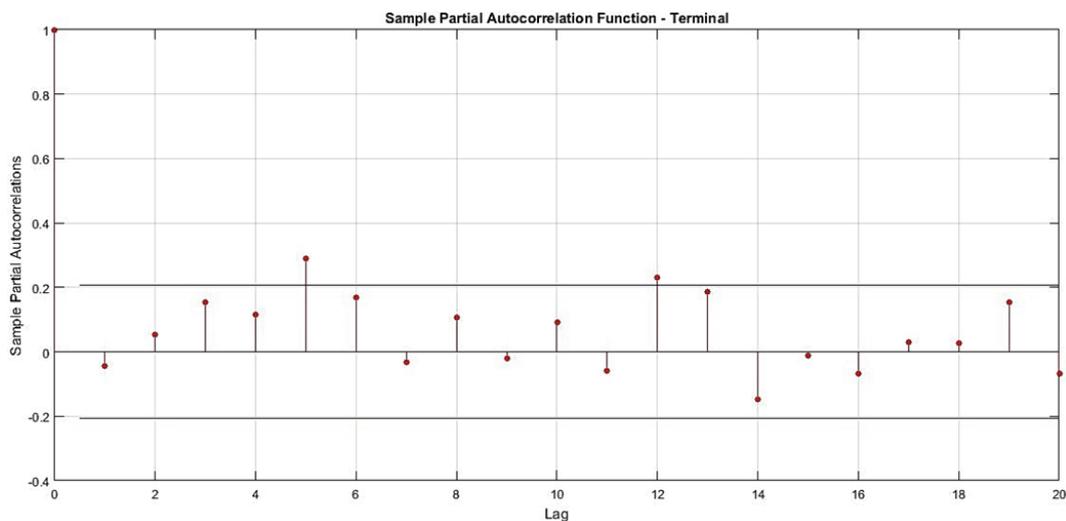


Figura 10. Autocorrelação parcial do terminal de direção

Fonte: Os autores (2022)

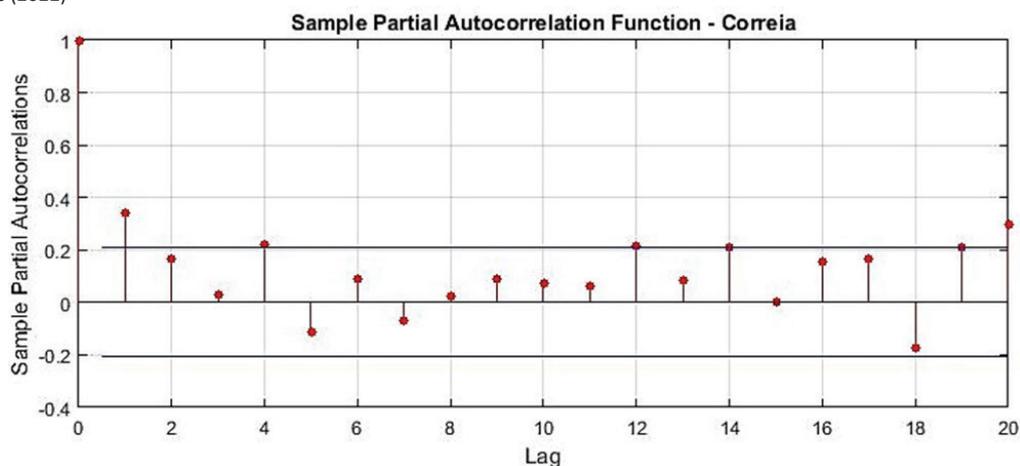


Figura 11. Autocorrelação parcial dos dados da correia

Fonte: Os autores (2022)

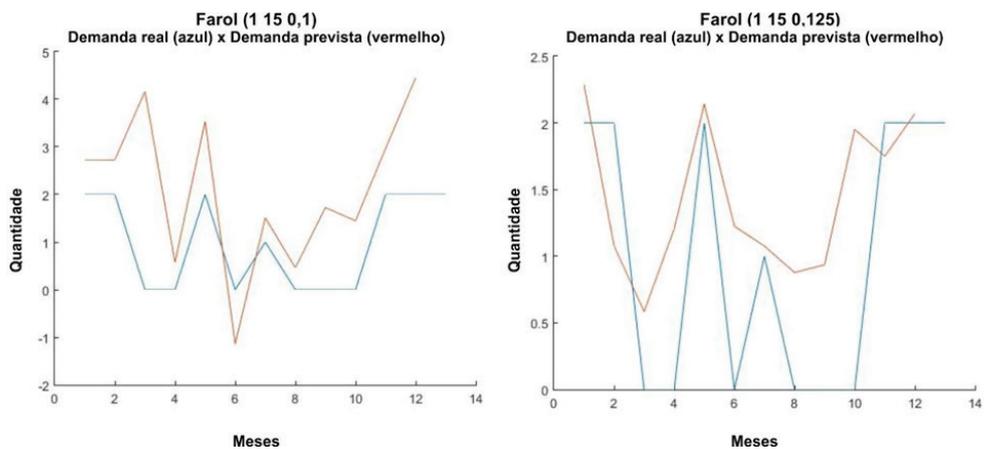


Figura 12. Demanda Real x Demanda Prevista (Farol de Trabalho)

Fonte: Os autores (2022)

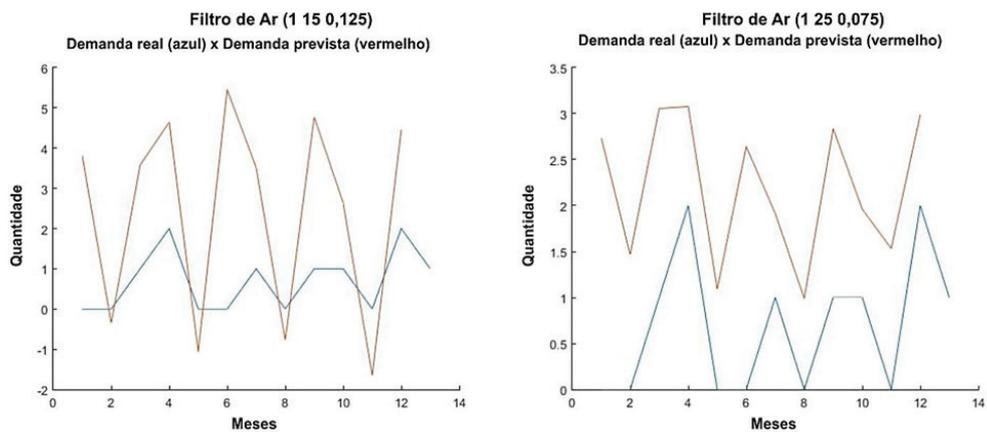


Figura 13. Demanda Real x Demanda Prevista (Filtro de Ar)

Fonte: Os autores (2022)

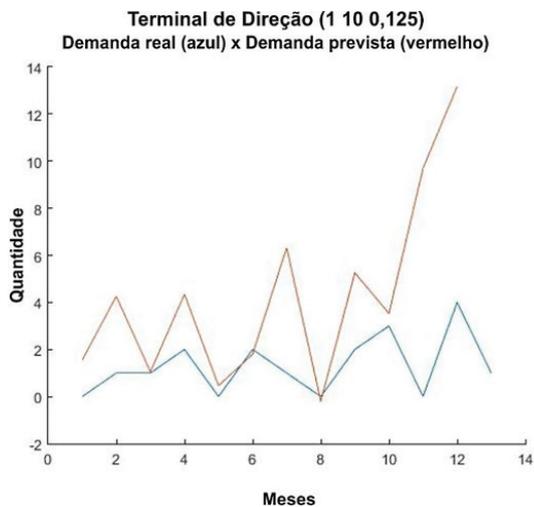


Figura 14. Demanda Real x Demanda Prevista (Terminal de Direção)

Fonte: Os autores (2022)

(20,52%), resultado considerado satisfatório, uma vez que o que está sendo considerado no estudo é somente a autocorrelação dos dados, sem variáveis externas, dificultando ter uma maior assertividade.

Ademais, constatou-se também que, de acordo com a variabilidade de neurônios na camada oculta, nem sempre a maior quantidade é necessariamente a melhor. Além disso, a partir dos erros obtidos, percebe-se que em alguns casos ocorreu o *overfitting*, uma vez que foram encontrados erros muito pequenos na etapa de treino, porém, com uma generalização ruim na previsão, apresentando erros expressivos nessa última fase.

Para tanto, foi feita uma análise gráfica entre a curva da demanda prevista e os valores reais dos últimos 12 meses das demandas estudadas. Em vários casos, a rede conseguiu prever as épocas de picos das demandas, como nas situações evidenciadas nos gráficos das **Figuras 12, 13 e 14**. Visto que os picos estão bem definidos, a otimização do resultado poderia ser possível com algum ajuste na rede, além de mudanças nos parâmetros avaliados (quantidade de neurônios e taxa de aprendizado). Outra tentativa seria mudar a função de ativação, por exemplo.

Nesse cenário, sabe-se que, no estudo de previsão, a análise de picos é muito importante, uma vez que, tratando-se de demanda, é relevante saber se vai haver aumento ou queda do comportamento. Além disso, segundo Tubino (2017), apesar da matemática e dos recursos dos computadores, é impossível prever com exatidão as demandas.

CONSIDERAÇÕES FINAIS

A pesquisa em questão buscou estudar e implementar a rede de Elman, a fim de analisar a eficiência de previsão de peças sobressalentes de um setor de manutenção de tratores e implementos agrícolas, como fonte de opção de metodologia para auxílio no estudo de previsão de demanda dos itens.

Ficou evidente que, de acordo com os erros encontrados, e a análise gráfica de comportamento feita, o método utilizado pode auxiliar na tomada de decisão, mesmo que utilizado com quaisquer outras metodologias que possam otimizar a acurácia da previsão. A rede conseguiu evidenciar quais eram as épocas de maiores e menores picos de demanda de determinadas peças, podendo colaborar com a condução correta da gestão de estoques em uma empresa que trabalha com significativa rotatividade de itens de reposição para os ativos.

Apesar da complexidade na parametrização da rede, devido às diversas possibilidades de combinações dos parâmetros, pode-se afirmar que a rede neural estudada é viável

dentro de um escopo de trabalho, uma vez que, devido aos resultados encontrados, conseguiu chegar no objetivo proposto inicialmente. Outro fator relevante é que a rede prevê a demanda de 12 meses de antecedência. Essa informação poderá contribuir no processo de definição do orçamento previsto da empresa para o ano seguinte.

Em relação à sugestão para trabalhos futuros, trata-se da utilização de variáveis exógenas como entrada da rede, a exemplo: período de safra, quantidade de tratores e manutenções feitas, visando obter uma rede neural que proporcione maior acurácia para os resultados obtidos. Além disso, seria interessante analisar se é possível verificar pela rede futuras obsolescências, decorrentes da diminuição das requisições, a fim de diminuir o custo do estoque.

REFERÊNCIAS

- Araújo, B.C. & Gomes, H.M. (2005), 'Redes Neurais Versus Métodos Estatísticos na Previsão de Séries Temporais', Dissertação de Mestrado, Universidade Federal de Campina Grande, Campina Grande.
- Dias, M.A.P. (2009), *Administração de Materiais: Princípios, Conceitos e Gestão*, 6ª ed, Atlas, São Paulo.
- Elman, J.L. (1991), 'Distributed Representations, Simple Recurrent Networks and Grammatical Structure', *Machine Learning*, no. 7, pp. 195-225.
- Fernandes, C., Silva, A., Ferraz, A. & Santos, P. (2021), 'Aplicação da metodologia DMAIC para redução dos desperdícios em uma indústria de gesso do interior de Pernambuco, Brasil', *Navus - Revista de Gestão e Tecnologia*, vol. 11, pp. 01-19, DOI: <https://doi.org/10.22279/navus.2021.v11.p01-19.1622>.
- Ferreira, V.B., Carvalho, M.G & Brick, E.S. (2009), 'Modelos de estoque para sobressalentes navais', *XXIX Encontro Nacional de Engenharia de Produção*, Salvador, BA, 06-09 outubro.
- Florêncio, PHB 2016, 'Aplicação de Redes Neurais Artificiais na Previsão de Demanda de Peças de Reposição de Veículos Automotores', Dissertação de Mestrado, Pontifícia Universidade Católica de Goiás, Goiânia.
- Freeman, J.A. & Skapura, D.M. (1992), *Neural Networks: Algorithms, Applications and Programming Techniques*, Addison-Wesley Publishing Company, n.p.
- Freitas, F.D. (2008), 'Modelo de Seleção de Carteiras Baseado em Erros de Predição', Tese de Doutorado, Universidade Federal do Espírito Santo, Vitória, ES.
- Gonçalves, O.S. (2013), *Administração de Materiais*, 4ª ed, Elsevier, Rio de Janeiro.
- Haykin, S. (2009), *Neural Networks and Learning Machines*, 3ª ed, New Jersey, Prentice Hall.

- Huiskonen, J. (2001), 'Maintenance spare parts logistics: special characteristics and strategic choices', *International Journal of Production Economics*, no. 71, pp. 125-133.
- Machado, W.R.B. & Santos, P.V.S. (2020), 'Mensuração da capacidade do processo de beneficiamento de uva de mesa em um packing house: estudo de caso em uma empresa no Vale do São Francisco', *NAVUS - Revista de Gestão e Tecnologia*, vol. 10, no. 1, pp. 1-15.
- Mine, O.M. (2010), 'Previsão de Demanda de Autopeças com Redes Neurais', Dissertação de Mestrado, Universidade Federal do Espírito Santo, Vitória.
- Molenaers, A., Baets, H., Pintelon, L. & Waeyenbergh, G. (2012), 'Critically classification of spare parts: A case study', *International Journal of Production Economics*, no. 140, pp. 570-578.
- Pasquotto, J.L.D. (2010), 'Previsão de Redes Temporais no Varejo Brasileiro: Uma Investigação Comparativa da Aplicação de Redes Neurais Recorrentes de Elman', Dissertação de Mestrado, Universidade de São Paulo, São Paulo.
- Santos, P. & Silva, E. (2019), 'Gestão estratégica da qualidade aplicada à redução de devoluções', *Navus - Revista de Gestão e Tecnologia*, vol. 9, no. 4, pp. 30-48, DOI: <https://doi.org/10.22279/navus.2019.v9n4.p30-48.884>.
- Santos, P.V.S. (2019), 'Previsão da demanda como suporte à filosofia lean', *Exacta*, vol. 18, no. 1, pp. 226-243, DOI: <https://doi.org/10.5585/exactaep.v18n1.8935>.
- Schatz, C.H.V. (2014), 'Sistema Inteligente Para Monitoramento e Predição do Estado Clínico de Pacientes Baseado em Lógica Fuzzy e Redes Neurais', Tese de Doutorado, Universidade Tecnológica do Paraná, Curitiba.
- Silva, C.S. (2003), 'Previsão Multivariada da Demanda Horária de Água em Sistemas Urbanos de Abastecimento', Tese de Doutorado, Universidade Estadual de Campinas, Campinas.
- Souza Júnior, W., Santos, P., Silva, A. & Amaral, T. (2022), 'Abordagem matemática aplicada à problemática de escolha de fornecedor de Allium cepa', *Navus - Revista de Gestão e Tecnologia*, vol. 12, 01-19, DOI: <https://doi.org/10.22279/navus.2022.v12.p01-19.1776>.
- Souza, L.L., Silva, S.S. & Santos, V.M.L. (2018), 'Forecast of the volume of sales index in the Brazilian petroleum sector using artificial neural networks', *ITEGAM-JETIA - Journal of Engineering and Technology for Industrial Applications*, no. 4, 27-31.
- Tubino, DF 2017, *Manual de Planejamento e Controle da Produção*, 32ª ed, Atlas, São Paulo.
- Vaz, A.G.C.R. (2014), 'Photovoltaic Forecasting with Artificial Neural Networks', Dissertação de Mestrado, Universidade de Lisboa, Portugal.
- Viana, J.J. (2012), *Administração de materiais: Um enfoque prático*, 1ª ed, Atlas, São Paulo.
- Wu, M.C. & Hsu, Y.K. (2008), 'Design of BOM configuration for reducing spare parts logistic costs', *Expert Systems with Applications*, no. 34, pp. 2417-2423.
- Xenos, H.G. (2014), *Gerenciando a Manutenção Produtiva: O caminho para eliminar falhas nos equipamentos e aumentar a produtividade*, 2ª ed, Minas Gerais, Falconi, 307 p.

Recebido: 1 ago. 2022

Aprovado: 8 dez. 2022

DOI: 10.20985/1980-5160.2022.v17n3.1806

Como citar: Soares, L.M.C., Silva, A.C.G.C., Silva, J.C., Santos, P.V.S. (2022), Previsão de demanda de peças sobressalentes utilizando rede neural artificial, *Revista S&G* 17, 3. <<https://revistasg.emnuvens.com.br/sg/article/view/1806>>.