

## APLICAÇÃO DE BALANCEAMENTO DE LINHA OTIMIZADO CONSIDERANDO PREVISÃO DE DEMANDA E REDES NEURAS ARTIFICIAIS

### OPTIMIZED LINE BALANCING APPLICATION CONSIDERING DEMAND FORECAST AND ARTIFICIAL NEURAL NETWORKS

Nathalia Tessari Moraes\* E-mail: [ntmoraes1@ucs.br](mailto:ntmoraes1@ucs.br)

Leandro Luís Corso\* E-mail: [lcorso@ucs.br](mailto:lcorso@ucs.br)

\*Universidade de Caxias do Sul (UCS), Caxias do Sul, Rio Grande do Sul, Brasil.

**Resumo:** Ter um modelo de balanceamento de linha vinculado às oscilações de demanda pode contribuir diretamente na tão importante redução de custos atrelados à manufatura. Com as organizações sofrendo cada vez mais transformações e confrontando-se com elevada competitividade, é imprescindível adotar métodos quantitativos e processos otimizados que garantam maior eficiência no gerenciamento de recursos. Antever o comportamento do mercado não é uma tarefa simples, principalmente quando há alta variabilidade de demanda. Desta forma, é importante considerar modelos matemáticos robustos com configurações otimizadas para que sejam capazes de reconhecer padrões, a fim de prever o volume de vendas com menor erro possível. Diante disso, foram utilizados os dados históricos de vendas dos cinco principais produtos de uma multinacional, aqueles que representam maior lucro, e foram calculadas as demandas por meio dos modelos de média móvel, suavização exponencial, Box-Jenkins e RNA. Após, com o intuito de escolher o método mais acurado, ou seja, que apresenta o menor erro, foi calculado isoladamente os erros de cada um dos métodos utilizados (RMSE, MAE e MAPE) possibilitando assim a comparação entre eles. Diante do resultado obtido, modelou-se o balanceamento das linhas de montagem em que são produzidos os produtos, calculou-se, por meio de um modelo matemático de programação não linear, o número adequado de funcionários para a demanda prevista, tendo como principal objetivo melhorar a eficiência atual por meio da organização das linhas. Sendo assim, constatou-se que as RNAs representaram maior acurácia para a previsão de demanda e que, em comparação com o atual método utilizado pela empresa, mostrou-se ser um método mais confiável de previsão de quantidades para planejamento de recursos. Após, visualizou-se que o método de balanceamento desenvolvido trouxe importantes adequações de recursos acarretando, assim, o aumento na eficiência das linhas de produção em um percentual de 29%, o que se considera bastante satisfatório.

**Palavras-chave:** Balanceamento de linha. Previsão de demanda. Inteligência artificial.

**Abstract:** Having a line balancing model linked to fluctuations in demand can directly contribute to the important reduction of costs linked to manufacturing. With organizations undergoing more and more transformations and facing high competitiveness, it is essential to adopt quantitative methods and optimized processes that guarantee greater efficiency in resource management. Predicting market behavior is not a simple task, especially when there is high variability in demand. Thus, it is important to consider robust mathematical models with optimized configurations so that they are able to recognize patterns, in order to predict the sales volume with the least possible error. In view of this, the historical sales data of the five main products of a multinational company, those that represent the highest profit,

were used, and the demands were calculated using the moving average, exponential smoothing, Box-Jenkins and RNA models. Afterwards, in order to choose the most accurate method, that is, the one with the lowest error, the errors of each of the methods used (RMSE, MAE and MAPE) were calculated in isolation, thus enabling the comparison between them. In view of the result obtained, the balancing of the assembly lines in which the products are produced was modeled, the number of employees for the expected demand was calculated, using a mathematical model of non-linear programming, having as main objective improve current efficiency by organizing lines. Thus, it was found that the ANNs represented greater accuracy for forecasting demand and that, in comparison with the current method used by the company, it proved to be a more reliable method of predicting quantities for resource planning. Afterwards, it was visualized that the balancing method developed brought important adjustments of resources, thus leading to an increase in the efficiency of the production lines by a percentage of 29%, which is considered quite satisfactory.

**Keywords:** Line balancing. Demand forecast. Artificial intelligence.

## 1 INTRODUÇÃO

Na contemporaneidade, o ambiente das organizações caracteriza-se pelas constantes transformações e alta competitividade. No entanto, cada vez mais busca-se por métodos e técnicas que contribuam na resolução de problemas, minimização de custos, maior satisfação dos clientes e criação de vantagens competitivas (WANKE, 2010; DA SILVA 2018).

Para tornarem-se mais competitivas no mercado, as empresas buscaram alternativas em processos e operações (LOHMANN *et al.*, 2019), sendo que, um dos principais fatores de sucesso nos últimos 20 anos, de acordo com Vitorino (2012), foram as organizações que conseguiram pensar em um jeito rápido e barato de levar os produtos até as mãos dos clientes. Para isso, torna-se imprescindível para qualquer negócio, como ressalta Gonçalves (2013), calcular estimativas ou antever o comportamento do mercado em certo horizonte de tempo futuro, visando adequar recursos e estratégias operacionais, desta forma, faz-se necessário uma previsão de demanda eficaz.

A previsão de demanda possui um importante papel na estratégia dos negócios, haja vista que contribui diretamente na redução de custos de produção e que irá determinar o preço de venda do produto (KUO; XUE, 1998; ARMSTRONG, 2006). Além disso, contribui para uma operacionalização eficiente da produção, a qual viabilizará melhor qualidade dos serviços oferecidos aos seus clientes, bem como fornecerá informações precisas aos seus fornecedores (KOTLER, 1991; MOON *et al.*, 1998; KAHN, 2002). Ainda, de acordo com Miranda *et al.* (2011), as previsões servem

de ponto de partida para o planejamento do fluxo de caixa, planejamento da produção e vendas, controle de estoques, compras e entre outras.

Para evitar os desperdícios - *pensando em uma operacionalização e planejamento de produções eficientes* - em especial os de espera, deve-se melhorar a sincronia entre as necessidades da produção e capacidades da linha, nivelando a produção com a demanda. No entanto, quando a demanda aumenta, ou diminui, o tempo de ciclo da linha deve ajustar-se alinhando o ritmo de produção, por meio da inclusão ou retirada de recursos e/ou redistribuição de atividades entre os operadores (SILVA *et al.*, 2007).

Então, é neste ponto que o balanceamento de linha se torna importante, de acordo com Tubino (2007), balancear a linha de produção é determinar o conjunto de atividades que serão executadas para garantir um tempo de processamento igual, aproximadamente, entre os postos de trabalho. Um balanceamento de linha adequado e adaptado à flutuação de demanda é essencial para as empresas, pois os custos de manufatura são afetados diretamente (FAVARO *et al.*, 2013).

Por isso, é importante que se escolha um método eficiente para predição de demanda, possibilitando, assim, o planejamento adequado da operacionalização das linhas. Ressalta-se, que o modelo mais adequado, segundo Gonçalves (2013), é aquele que melhor representa a variação da demanda no período histórico de dados. Sendo que, quanto menor for o erro de previsão - *erro mensurável entre o real e o previsto* - mais próximo da curva de demanda real esse modelo estará.

A Pesquisa Operacional (PO), por meio da modelagem matemática, propõe métodos quantitativos que garantem uma forma eficaz de estimar demandas e para balancear linhas de montagem. Ainda, aplicando inteligência artificial para previsão de demanda, é possível com a utilização das Redes Neurais Artificiais (RNAs) mapear entradas e saídas de sistemas não lineares, realizar processamentos paralelos e simular sistemas complexos. Por ser uma ferramenta que, segundo Haykin (2001), pode ser aplicada em diversas áreas e na solução de vários problemas, torna-se uma ferramenta potencial na previsão de demandas.

Portanto, o objetivo do trabalho é aplicar modelos de previsão de demanda, incluindo as RNAs programadas em um algoritmo genético, nos dados de vendas dos produtos de uma empresa multinacional, a fim de encontrar o modelo que calcule as

previsões das demandas. Após, utilizará as referidas demandas para direcionar o balanceamento das linhas de produção, que, por meio da programação não linear, será possível concluir qual a melhor forma de distribuição de recursos e operações, proporcionando maior eficiência, o que impactará diretamente na produtividade.

## 2 REFERENCIAL TEÓRICO

Nos tópicos a seguir apresentam-se os principais conceitos utilizados para embasamento do trabalho desenvolvido.

### 2.1 Séries temporais

De acordo com Souza (1989), série temporal é a classe de fenômenos cujo processo observacional e consequente quantificação numérica geram uma sequência de dados distribuídos no tempo. Para Wheelwright e Makridakis (1985), fornece previsões acuradas se o futuro apresentar comportamento similar ao passado. Pode ser representada pela Equação 1 a seguir.

$$X^T = \{x_1, x_2, \dots, x_T\} \quad (1)$$

### 2.2 Modelos de previsão de demanda

Para o cálculo da previsão de demanda consideram-se os modelos de média móvel, suavização exponencial e Box-Jenkins para o desenvolvimento do trabalho. No Quadro 1 expõe-se os métodos e suas respectivas fórmulas.

**Quadro 1 – Modelos de previsão de demanda e fórmulas** (continua)

MODELOS DE PREVISÃO DE DEMANDA		
MODELOS		FÓRMULAS
MÉDIA MÓVEL	Média Móvel Simples	$P_{t+1} = M_t = \frac{(R_1 + R_{t-1} + R_{t-2} + \dots + R_{t-n+1})}{n}$ <p><math>P_{t+1}</math> - previsão para o próximo período; <math>M_t</math> - média móvel no período <math>t</math>; <math>R</math> - valor real observado no período <math>t</math>; <math>n</math>- número de períodos considerados na média móvel.</p>
	Média Móvel Ponderada	$F_t = p_{tD_{t+1}} + p_{tD_{t+2}} + p_{tD_{t+3}} + \dots + p_{tD_{t+1}}$ <p>Onde <math>p_1 + p_2 + \dots + p_a = 1</math> <math>p_1 + p_2 + \dots + p_a = 1</math></p>
SUAVIZAÇÃO EXPO- NENCIAL	Suavização Exponencial Simples	$P_{t+1} = P_t + \alpha(D_t - P_t)$ <p><math>P_{t+1}</math> - previsão de demanda para o período <math>t + 1</math>; <math>P_t</math> - estimativa para a previsão de demanda no período <math>t</math>; <math>\alpha</math>- coeficiente de suavização da média; <math>D_t</math> - demanda ocorrida no período <math>t</math></p>

	Modelo de Holt	$L_t = \alpha Z_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad 0 \leq \alpha \leq 1$ $T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad 0 \leq \beta \leq 1$ $\hat{Z}_{t+n} = L_t + nT_t$ <p><math>L_t</math> - nível estimado para a série no tempo <math>t</math>; <math>T_t</math> - tendência estimada da série no mesmo período de tempo <math>t</math>; <math>\hat{Z}_{t+n}</math> - previsão para o período <math>t + n</math>; <math>n</math> - número de períodos a serem previstos; <math>\alpha</math> e <math>\beta</math> são encontradas por iterações a fim de buscar o menor erro médio quadrático.</p>
	Modelo de Winters	<p style="text-align: center;"><b>Modelo Sazonal Multiplicativo</b></p> $L_t = \alpha \frac{Z_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + T_{t-1}); \quad 0 \leq \alpha \leq 1$ $T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}; \quad 0 \leq \beta \leq 1$ $S_t = \gamma \frac{Z_t}{L_t} + (1 - \gamma)S_{t-s}; \quad 0 \leq \gamma \leq 1$ $\hat{Z}_{t+k} = (L_t + kT_t)S_{t-s+k}$ <p><math>L_t</math> - componente nível; <math>T_t</math> - componente tendência; <math>S_t</math> - componente sazonalidade; <math>\hat{Z}_{t+k}</math> - previsão para <math>k</math> períodos a frente; <math>\alpha</math> - constante de suavização para estimativa de nível (<math>0 \leq \alpha \leq 1</math>); <math>\beta</math> - constante de suavização para estimativa de tendência (<math>0 \leq \beta \leq 1</math>); <math>\gamma</math> - constante de suavização para estimativa de sazonalidade (<math>0 \leq \gamma \leq 1</math>); <math>Z_t</math> o valor real observado no período de tempo <math>t</math>; <math>k</math> - quantidade de períodos futuros a serem previstos.</p> <p style="text-align: center;"><b>Modelo Sazonal Aditivo</b></p> $a(t) = \alpha(Y_t - S_{t-s} + (1 - \alpha)[a(t-1) + b(t-1)]), \quad 0 < \alpha < 1$ $b(t) = \beta[a(t-1) - a(t-2)] + (1 - \beta)b(t-1), \quad 0 < \beta < 1$ $S_t = \gamma[Y_t - a(t)] + (1 - \gamma)S_{t-s}, \quad 0 < \gamma < 1$ <p>Onde a previsão a <math>n</math> passos do modelo de sazonalidade aditiva são obtidas por:</p> $\hat{Y}_{T+n} = \hat{a}(T) + \hat{b}(T)n + S_{T+n-s} \quad \text{onde } n=1,2,3\dots$ <p>Assim, calcula-se a média das primeiras <math>s</math> observações:</p> $\hat{a}(s) = \left(\frac{1}{s}\right) \sum_{t=1}^s Y_t$ $\hat{b}(s) = \left(\frac{1}{s^2}\right) \left( \sum_{t=s+1}^{2s} Y_t - \sum_{t=1}^s Y_t \right)$

(continua)

BOX- JENKINS	Estacionários	<p><b>Modelo Auto regressivo (AR)</b></p> $Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + a_t$ <p><math>Z_t - 1, Z_t - 2, \dots, Z_t - p</math> são termos independentes de <math>a_t</math>; <math>Z_t</math> é uma série formada por combinações lineares dos <math>p</math> valores passados mais um termo <math>a_t</math>.</p> <hr/> <p><b>Modelo de Médias Móveis (MA)</b></p> $Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$ <p><math>Z_t</math> - obtido por meio dos pesos <math>1, -\theta_1, -\theta_2, \dots, -\theta_q</math> aplicado nas variáveis <math>a_t, a_{t-1}, a_{t-2}, \dots, a_{t-q}</math> e movendo os pesos 1 unidade do tempo a frente, aplicando a soma <math>a_{t+1}, a_t, a_{t-1}, \dots, a_{t-q+1}</math> para obter <math>Z_{t+1}</math>.</p> <hr/> <p>Modelos auto-regressivos e de médias móveis (ARMA)</p> $Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$ <p><math>Z_t</math> representa a previsão de demanda de ordem p e q (p,q).</p>
	Não Estacionários	<p><b>Modelos auto-regressivos integrados de médias móveis (ARIMA)</b></p> $w_t = \varphi_1 w_{t-1} + \dots + \varphi_p w_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$ <p>Em que: <math>w_t = \Delta^d Z_t</math></p>
	Modelos Sazonais	$(1 - \varphi_1 L - \dots - \varphi_p L^p)(1 - \varphi_1 L^s - \dots - \varphi_p L^{Ps})(1 - L)^d (1 - L^s)^D Z_t$ $= (1 - \theta_1 L - \dots - \theta_q L^q)(1 - \vartheta_1 L^s - \dots - \vartheta_q L^{Qs}) \varepsilon_t$ <p><math>(1 - \varphi_1 L - \dots - \varphi_p L^p)</math> - parte auto-regressiva não-sazonal de ordem p; <math>(1 - \varphi_1 L^s - \dots - \varphi_p L^{Ps})</math> - parte auto-regressiva sazonal de ordem P e estação sazonal s; <math>(1 - L)^d</math> - parte de integração não-sazonal de ordem d; <math>(1 - L^s)^D</math> - parte de integração não-sazonal de ordem D e estação sazonal s; <math>(1 - \theta_1 L - \dots - \theta_q L^q)</math> - parte não-sazonal de médias-móveis de ordem q; <math>(1 - \vartheta_1 L^s - \dots - \vartheta_q L^{Qs})</math> - parte sazonal de médias móveis de ordem Q e estação sazonal s.</p>

Fonte: O autor (2019).


### 2.3 Inteligência artificial

Uma RNA tenta capturar a informação ou conhecimento pelo aprendizado de forma similar ao cérebro humano. As unidades de processamento simples (neurônios) que compõem uma RNA são adaptáveis ao ambiente por meio de interligações (sinapses). Nestas interligações é onde ocorre o processo de aprendizagem por meio

de conhecimento experimental adquirido que fica armazenado e disponível para uso (HAYKIN, 2001).

Ainda de acordo com Haykin (2001), uma RNA é composta por camadas alinhadas de neurônios. Onde, as entradas estão na primeira camada, denominada de entrada. Essa camada é responsável por distribuir as informações para as camadas escondidas da rede. E a última camada é chamada de saída, camada que fornece a solução do problema. Na Figura 1 estas camadas podem ser identificadas.

**Figura 1** – Camadas de neurônios de uma RNA



**Fonte:** adaptado de Hair Junior *et al.* (2005).

O treinamento de uma RNA consiste em estimar os parâmetros do modelo considerando um conjunto de dados. O mesmo corre por meio de um problema de minimização não linear sem restrições, onde os pesos sinápticos são iterativamente modificados a fim de minimizar o erro quadrático médio entre a resposta desejada e a solução obtida no neurônio de saída.

## **2.4 Balanceamento de linha de montagem**

Balancear a linha de produção é buscar o melhor fluxo contínuo, eliminando os desperdícios que possam bloquear a produtividade, pela quantidade alta de tempo de espera. No entanto, a divisão das operações de trabalho por posto deve estar de acordo com o tempo de ciclo (TAPPING, 2002).

O tempo de ciclo é o tempo máximo permitido para cada estação de trabalho antes que a tarefa seja passada para a estação seguinte (GRAEMI; PEINADO, 2007). Para dimensioná-lo é importante encontrar o *Takt Time*, que é uma métrica que define o ritmo em que um produto deve ser realizado. Segundo definição de Slack *et al.* (2008), a perda por balanceamento é um ponto importante, e pode ser calculada pelo percentual de ociosidade. Já a eficiência é medida pela razão do tempo de trabalho disponível pela relação entre o número de operadores e o tempo de ciclo. As métricas utilizadas para balanceamento estão representadas no Quadro 2 a seguir.

**Quadro 2 – Métricas para balanceamento de linha**

<b>Métricas</b>	<b>Fórmulas</b>	<b>Explicações</b>
<i>Takt Time</i>	$TT = \frac{\sum Ttd(s)}{Dm}$	$\sum Ttd(s)$ = somatório do tempo de trabalho disponível no período em segundos; <i>Dm</i> = demanda em peças ou produtos.
Eficiência	$\varepsilon = \frac{\sum Ttd(s)}{N \times TC(s)}$	$\sum Ttd(s)$ = somatório do tempo de trabalho disponível no período em segundos; <i>N</i> = número de operadores; <i>TC</i> = tempo de ciclo.

Fonte: O autor (2019).

Portanto, o balanceamento de linha é uma ferramenta que, por meio de cálculos, tem como objetivo reduzir tempos ociosos e melhorar a eficiência, dando um fluxo contínuo ao processo e melhorando a produtividade.

### **2.4.1 Programação não linear**

De acordo com Hillier e Lieberman (2010) os problemas práticos de otimização frequentemente envolvem comportamento não linear. Na maioria dos modelos que trata problemas reais apresenta algum grau de não-linearidade. Os problemas que se encaixam em Programação Não-Linear, têm por finalidade resolver problemas que envolvem funções constituídas de variáveis que compartilham relações desproporcionais entre si (não-linearidade). Assim, utilizam-se os mesmos conceitos (otimização, função-objetivo, variáveis de decisão e restrições), embora os procedimentos matemáticos empregados na solução dos problemas de natureza não linear sejam diferentes. Há algumas técnicas para resolver problemas com

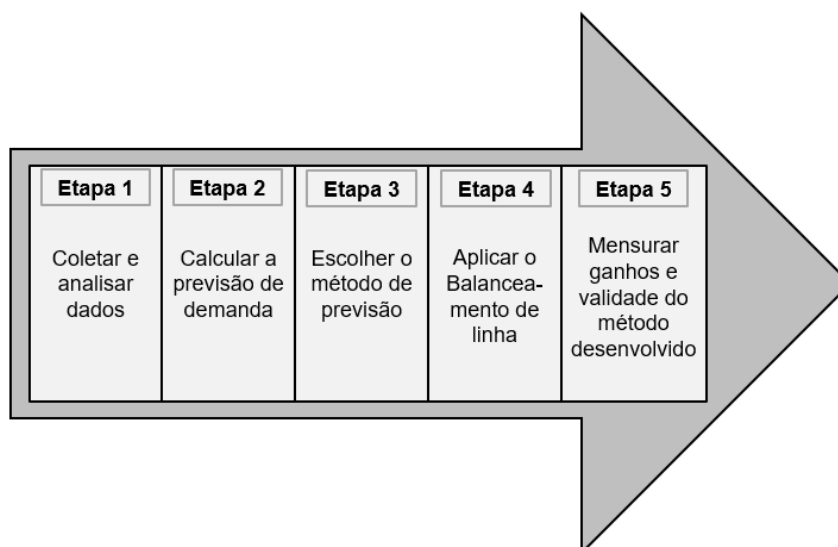


características específicas, tais como: existência de uma ou mais variáveis, existência (ou não) de restrições, funções contínuas ou descontínuas (CORRAR, 2004).

### 3 METODOLOGIA

O trabalho desenvolveu-se com o objetivo de prever a demanda de produtos de uma empresa e usá-los como base para o balanceamento de linha, desta forma, seguindo definições de Martins (1994), pesquisas que buscam gerar conhecimentos com finalidade de aplicação prática são classificadas como aplicada. Para atender aos objetivos, etapas foram traçadas conforme o fluxograma apresentado na Figura 2 e serão detalhadas nos tópicos a seguir.

**Figura 2** – Fluxograma de atividades



Fonte: O autor (2019).

#### 3.1 Coletar a analisar dados

Nesta fase extraíram-se as informações necessárias para a previsão de demanda do sistema utilizado pela empresa, no qual coletou-se um relatório da quantidade faturada semanalmente de cinco tipos diferentes de produtos (aqueles que representam maior faturamento) fabricados pela empresa em suas duas linhas de montagem. Para análise prévia do comportamento, gerou-se um gráfico de linha com os pontos, a fim de verificar se existem pontos anormais, tendências e sazonalidades.

Ainda, para as informações necessárias para o balanceamento, buscou-se os dados de tempos de ciclo nos estudos de métodos e tempos já realizados recentemente pela empresa para os mesmos cinco produtos.

### 3.2 Calcular a previsão de demanda

Nesta etapa, se utilizou o *software Statistical Package for the Social Sciences* (SPSS) para o primeiro cálculo da previsão de demanda. Com base no histórico de fabricação dos cinco produtos semanalmente no período dos últimos dois anos como entrada, o *software* considerou todos os modelos de previsão apresentados neste trabalho e mostrou como resultado o melhor método para cada, ou seja, o que apresenta menor erro calculado.

Depois disso, os mesmos dados foram rodados com RNAs, por meio de um algoritmo desenvolvido e acoplado a otimização para encontrar o melhor número de neurônios ( $nn$ ) e o número de períodos de *delay* ( $nd$ ), que segue o algoritmo genético de Borsato e Corso (2019), de acordo com a Equação 2.

$$\text{Minimizar } ER(nn, nd, AT) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

Sendo que  $nn$  varia de 5 a 150 e  $nd$  de 2 a 7. O termo  $y_i$  é o valor real do  $i$ -ésimo período e  $\hat{y}_i$  é o valor predito para o respectivo período. O  $AT$  se refere ao algoritmo de treinamento da rede, sendo um parâmetro discreto de otimização.

### 3.3 Escolher o método de previsão

Primeiramente, levantaram-se os resultados de previsão das RNAs otimizadas e dos melhores modelos de previsão encontrados entre os modelos referenciados de média móvel, suavização exponencial e Bok-Jenkins, ou seja, aquele que apresenta o menor erro comparado ao real. Após, calculou-se a raiz quadrada da média dos erros quadráticos (RMSE), a média dos erros em valores absolutos (MAE) e a média percentual da divisão entre erro de previsão e valor real (MAPE) entre os dois resultados para analisar qual o melhor método para cada produto, aquele que se

aproxima mais do real, o de menor erro. As fórmulas dos erros podem ser verificadas no Quadro 3 a seguir.

**Quadro 3 – Erros de previsão**

<b>Erros</b>	<b>Fórmulas</b>	<b>Explicações</b>
<i>Root Mean Square</i> – raiz quadrada média do erro	$RMSE = \frac{\sum_t^T \varepsilon_t^2}{T}$	Somatório dos erros de cada período ao quadrado sobre o período total.
<i>Mean Absolute Error</i> – erro absoluto médio	$MAE = \frac{\sum_t^T  \varepsilon_t }{T}$	Somatório dos erros de cada período em módulo sobre o período total.
<i>Mean Absolute Percentage Error</i> – erro médio percentual absoluto	$MAPE = \frac{\sum_t^T  p_t }{T}$	Somatório do percentual de erro de cada período em módulo sobre o período total.

Fonte: O autor (2019).

### 3.4 Aplicar o balanceamento de linha

Após escolher o melhor método para a previsão de demanda para cada produto, as quantidades encontradas foram utilizadas para o balanceamento das duas linhas. Foram utilizadas as últimas 24 semanas, que totalizam 6 meses, para calcular uma média diária de demanda. Após implementou-se o modelo de Programação Não Linear Inteira, a partir da delimitação das restrições do problema para atingir uma ocupação meta, por meio do cálculo do número otimizado de funcionários. Para implementação utilizou-se um Solver comercial, como ferramenta para a obtenção das respostas. O modelo de Programação Não Linear Inteira segue o formato padrão com restrições e  $n$  variáveis, de acordo com Hillier e Lieberman (2010):

Maximizar (ou minimizar)  $f(x)$ ,

sujeito a:  $g_i(x) \leq b_i$ ,

para  $i = 1, 2, \dots, m$

e  $x \geq 0$ ,

Em que  $f(x)$  e os  $g(x)$  são funções dadas das  $n$  variáveis de decisões. A função objetivo foi de minimizar a diferença quadrática entre a ocupação calculada e a

ocupação meta. A ocupação calculada é dada a partir da divisão do tempo total de operações para a demanda informada pelo número de funcionários multiplicado pelo tempo disponível no dia, já a ocupação meta é definida em termos percentuais, descontando paradas não programadas. As variáveis a serem calculadas são do número de funcionários por posto de trabalho, sujeita à restrição do número de funcionários estar entre 0 e 5.

O modelo proposto para balanceamento foi implementado computacionalmente a fim de utilizá-lo no planejamento de produção da empresa. Como dados de entrada têm-se a demanda prevista, o tempo disponível, as operações, os tempos das operações e a meta de ocupação. Com isso, calculou-se o *Takt Time* e o número adequado de operadores, conforme programação não linear, e organizou-se uma proposta de implementação com números inteiros, considerando os devidos ajustes conforme análise de tempos ociosos, baseado no *Takt Time* de cada cada posto de trabalho.

### **3.5 Ganhos e validade do método desenvolvido**

Por fim, objetivou-se validar a importância de um balanceamento de linha atrelado a um método robusto de previsão de demanda. Então, comparou-se o MAPE da previsão calculada pela RNA com o MAPE da previsão calculada pela forma atual adotada pela empresa, por meio da média dos últimos 6 meses, a fim de entender qual mais acurada é a informação de demanda para balancear as linhas de produção.

Ademais, formulou-se as eficiências de cada uma das duas linhas de montagem para o modelo (conforme meta de ocupação), para a proposta (com números inteiros) e da atual com o intuito de compará-las e entender o ganho da implementação do modelo proposto neste trabalho em eficiência e em produtos fabricados.

## **4 ANÁLISE E DISCUSSÃO DOS RESULTADOS**

Nos tópicos a seguir apresentam-se os resultados do trabalho realizado, quanto a previsão de demanda e balanceamento de linha, e uma simulação da integração dos dois conceitos nos dados da empresa.

#### 4.1 Previsão de demanda

Primeiramente, calculou-se a previsão de demanda dos cinco produtos para serem analisados por meio dos modelos de média móvel, suavização exponencial e Box-Jenkins. Para isso, foram utilizados como dados de entrada séries temporais com os históricos de vendas semanais de cada um desses produtos pelo período de 2 anos.

A partir disso, obteve-se os resultados das previsões para cada produto com a indicação do melhor modelo matemático que gerou esta solução, aqueles com menor erro calculado no *software*. Em seguida os mesmos dados de entrada foram utilizados no algoritmo de previsão de demanda por meio de RNAs.

Na Tabela 1 pode ser verificado qual modelo matemático foi selecionado para cada produto e os números de neurônios e número de *delays* utilizados para a melhor configuração de previsão para as RNAs, aquela com o menor MAPE.

**Tabela 1 – Resultados da previsão de demanda**

Produtos	Melhor modelo	Nº de neurônios RNA	Nº de <i>delays</i> RNA
Produto 1	Simplex	10	1
Produto 2	ARIMA (1,0,0)	20	1
Produto 3	Simplex	170	1
Produto 4	ARIMA (0,0,3)	120	1
Produto 5	Simplex	170	1

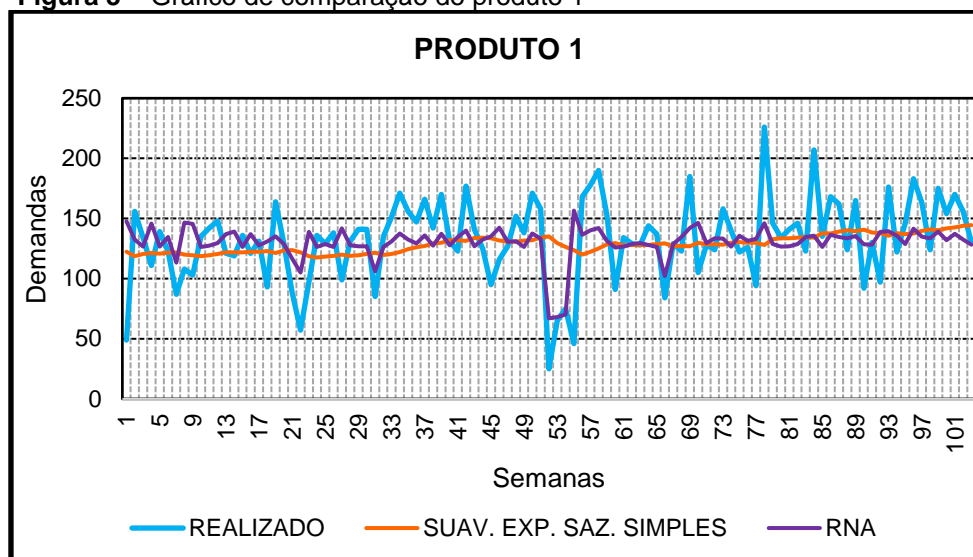
**Fonte:** O autor (2020).

Percebe-se que o modelo escolhido para os produtos 1, 3 e 5 foi a suavização exponencial sazonal simples e para os produtos 2 e 4 ARIMA. Saliendo que, os produtos que utilizaram ARIMA, tiveram configurações que se interpretam como (p, d, q), onde “p” é o número de defasagens, “d” é o número de vezes em que os dados tiveram valores passados subtraídos e “q” é a ordem do modelo de média móvel.

A partir disso, para a avaliação dos modelos, elaboraram-se duas comparações, primeiro entre as quantidades previstas pelos modelos matemáticos para cada produto (incluindo as RNAs) e as quantidades reais fabricadas. E depois, comparando os erros dos melhores modelos de previsão de cada produto com os erros das previsões por RNA, considerando suas melhores configurações.

Para tanto, gerou-se os gráficos para cada um dos produtos, considerando um período de dois anos semanalmente (totalizando 103 semanas analisadas). Na Figura 3 analisa-se a comparação para o produto 1 no período analisado com as previsões por suavização exponencial sazonal simples e RNAs.

**Figura 3 – Gráfico de comparação do produto 1**

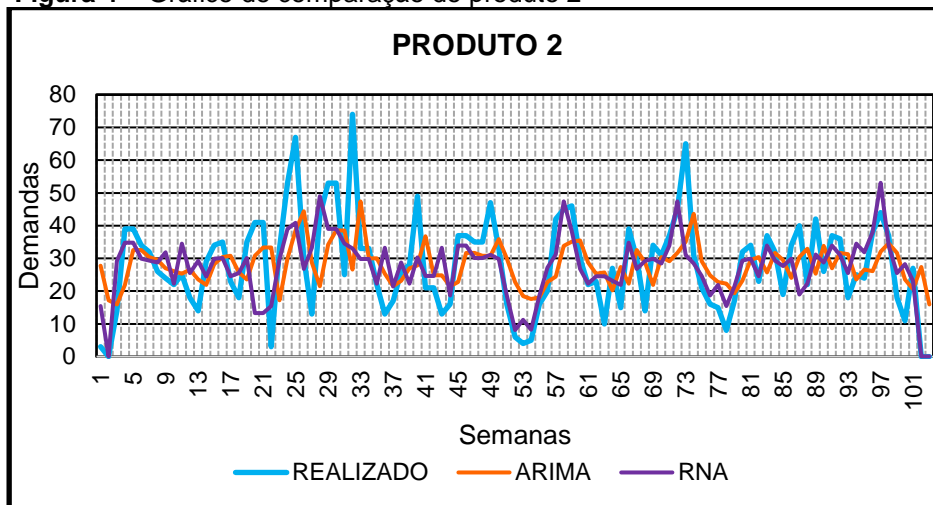


Fonte: O autor (2020).

É possível verificar que as quantidades de produtos fabricados não apresentam um padrão, nota-se bastante variação. A suavização exponencial sazonal simples aproxima valores médios, enquanto a rede neural busca prever melhor os picos e declínios de demanda.

Já na Figura 4, o gráfico segue a mesma lógica de comparação do anterior, observa-se também que para o produto 2 não há um padrão de fabricação, porém percebe-se que o método ARIMA (1,0,0) busca, assim como a RNA, seguir o comportamento do que é realizado e que em alguns períodos de tempo se aproxima bastante do real.


**Figura 4 – Gráfico de comparação do produto 2**



Fonte: O autor (2020).

Para o produto 3 observa-se na Figura 5 um comportamento semelhante ao do produto 1, além de não seguir um padrão facilmente notável, ambos utilizam suavização exponencial sazonal simples. No entanto, para o produto 3 tal método teve uma tendência maior de aproximação nos picos e declínios, não expondo valores médios como no 1.

**Figura 5 – Gráfico de comparação do produto 3**




Fonte: O autor (2020).

Na Figura 6, ao observar o gráfico de comparação para o produto 4, nota-se que, tanto o ARIMA (0,0,3) quanto a RNA, apresentaram dificuldade de prever alguns

picos e declínios acentuados, mas no restante do período há aproximações dos dois métodos utilizados com os dados realizados.


**Figura 6** – Gráfico de comparação do produto 4



Fonte: O autor (2020).

Para o último produto analisado, percebe-se na Figura 7, uma boa confluência de comportamento principalmente com RNA, apesar de prever um pico mais elevado do realizado em um determinado período de tempo. A suavização exponencial sazonal simples apresenta valores mais centralizados em relação ao real comportamento, com algumas tendências de acompanhar picos e declínios.

**Figura 7** – Gráfico de comparação do produto 5

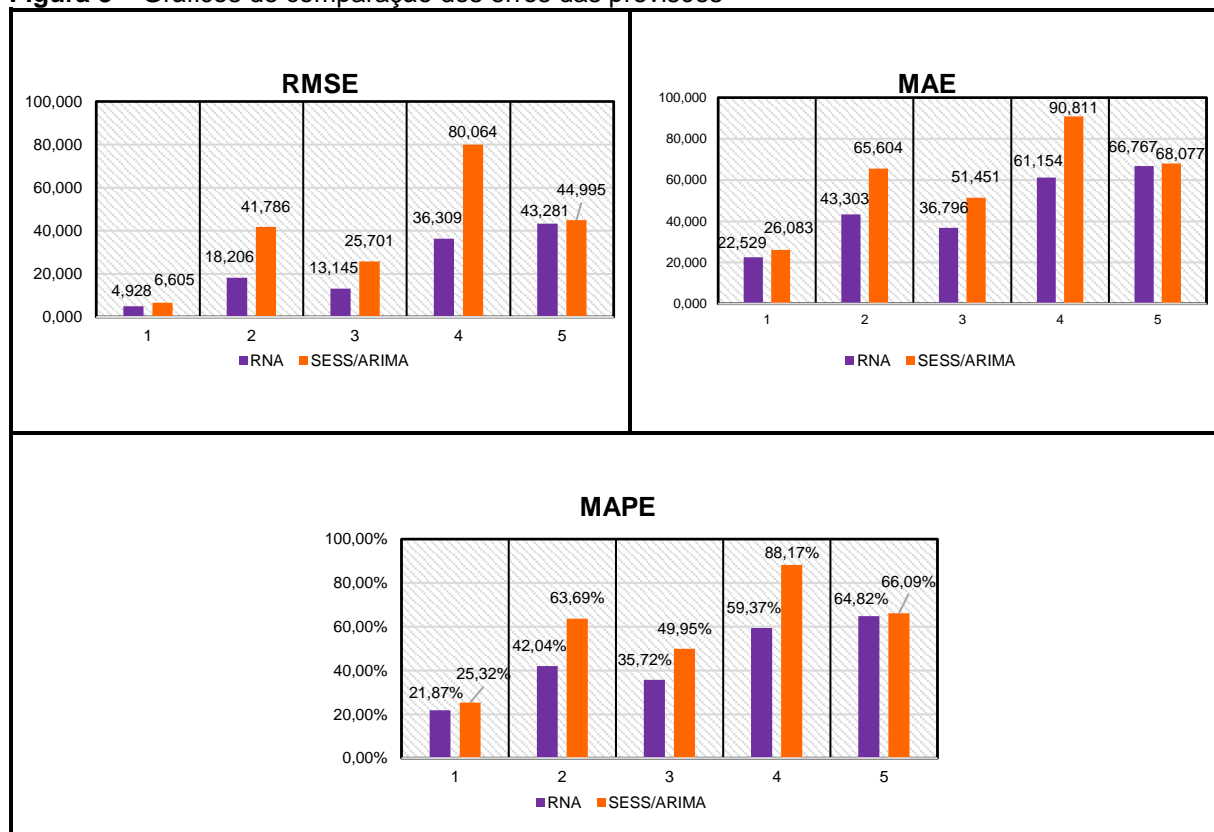


Fonte: O autor (2020).



Por fim, na Figura 8 estão representados os gráficos dos erros RMSE, MAE e MAPE calculados para as previsões de RNAs e dos melhores modelos, suavização exponencial sazonal simples para os produtos 1,3 e 5 e ARIMA para os produtos 2 e 4.

**Figura 8 – Gráficos de comparação dos erros das previsões**



Fonte: O autor (2020).

Portanto, foi viável observar que, nas 3 métricas de erros de previsão de demanda, o melhor modelo matemático de previsão para cada produto apresentou erros maiores comparados aos das previsões com RNAs. O que torna possível concluir que as RNAs propiciaram maior acurácia para a previsão de demanda dos produtos fabricados pela empresa.

## 4.2 Balanceamento de linha

Inicialmente, os dados encontrados na previsão de demanda de maior acurácia dos produtos escolhidos para serem aqui estudados são utilizados como dado de entrada para o balanceamento das duas linhas em que são fabricados.

Para tanto, extrai-se as demandas encontradas para cada produto por meio das RNAs no período dos últimos 6 meses e calcula-se uma média diária de fabricação, que está representada na Tabela 2 juntamente com a especificação do local em que os produtos são montados, divididos em Linha 1 e Linha 2.

**Tabela 2 – Demandas diárias para cada produto**

<b>Produtos</b>	<b>Demandas</b>	<b>Linhas</b>
Produto 1	27	Linha 1
Produto 2	6	Linha 1
Produto 3	5	Linha 2
Produto 4	1	Linha 2
Produto 5	5	Linha 2

**Fonte:** O autor (2020).

Importante ressaltar que o produto 3 é dividido em parte I, partes II e III e parte IV, considerando isso, para a formação do produto são necessárias 5 unidades de cada parte. Contabiliza-se então, 5 unidades da parte I, 10 das partes II e III e 5 da parte IV.

Os tempos das tarefas de cada produto foram coletados das cronoanálises já realizadas pela área de métodos e processos da empresa. A partir disso, elaborou-se uma tabela para cada uma das linhas com as tarefas executadas em cada posto de trabalho e com o tempo de cada tarefa multiplicado pelas respectivas demandas. Na Tabela 3 pode-se observar esta compilação de dados para a linha 1 e na Tabela 4 para a linha 2.

**Tabela 3 – Tempo total por produto no dia linha 1**

(continua)

<b>Postos</b>	<b>Tarefas</b>	<b>Tempo x demanda Produto 1 (min)</b>	<b>Tempo x demanda Produto 2 (min)</b>	<b>Total (min)</b>
1	T1	518,78	93,23	612,01
2	T2	610,97	86,31	697,28
3b	T3	96,72	30,47	127,19
3a	T4	217,69	51,96	269,65
4	T5	441,78	85,70	527,47
5c	T6	227,28	55,40	282,68
5b	T7	374,90	82,65	457,55
5	T8	730,87	109,24	840,12
6	T9	357,58	62,60	420,17
7	T10	270,98	108,74	379,72
8b	T11	161,74	27,03	188,77

8	T12	368,24	58,00	426,23
9	T13	332,53	67,58	400,11

Fonte: O autor (2020).

**Tabela 4** – Tempo total por produto no dia linha 2

Postos	Tarefas	Tempo x demanda Produto 3 – parte I (min)	Tempo x demanda Produto 3 – partes II e III (min)	Tempo x demanda Produto 3 – parte IV (min)	Tempo x demanda Produto 4 (min)	Tempo x demanda Produto 5 (min)	Total (min)
1	T1	42,58	199,17	111,09	5,37	41,41	399,61
2	T2	23,22	119,11	26,53	4,99	38,49	212,34
3b	T3	0	65,00	52,28	3,80	29,34	150,42
3a	T4	117,63	226,80	54,59	15,06	116,18	530,25
4	T5	54,45	120,10	54,45	8,98	69,29	307,28
5	T6	30,31	66,67	30,13	4,41	34,02	165,34

Fonte: O autor (2020).

Considerando o tempo disponível de 498 minutos, como o tempo total de trabalho com os tempos de paradas programadas subtraídos, e as demandas já calculadas, o *Takt Time* da linha 1 resultou em 15,47 minutos por carrinho de montagem e da linha 2 igual a 25,78 minutos por carrinho de montagem. Importante destacar que cada carrinho comporta 1 produto ou 1 parte da subdivisão do produto 3, somando 2 carrinhos na linha 1 e 5 na linha 2.

Contudo, o objetivo do balanceamento de linha é encontrar o número otimizado de funcionários, por meio da programação não linear, a fim de determinar uma ocupação meta definida em 80% para cada uma das linhas. Este número desconsidera possíveis perdas em um total de 20%, considerando paradas não programadas que possam ocorrer como retrabalhos, falta de abastecimento e manutenções corretivas.

A partir do resultado calculado, foi organizada uma proposta de implementação do balanceamento, considerando números inteiros de funcionários nos postos, com devidos ajustes de atividades e agrupamentos de postos para otimizar a ocupação das linhas, com base no *Takt Time* disponível. Ademais, descreveu-se o número de operadores por posto de trabalho atual, do modelo de otimização e da proposta com números inteiros, que podem ser observadas na Tabela 5 para a linha de produção 1.

**Tabela 5 – Balanceamento e eficiência atuais e propostos linha 1**

Postos	Nº operadores atual	Nº operadores modelo de otimização	Nº operadores inteiros
1	2	1,54	2
2	2	1,75	2
3b	1	0,32	1
3a	1	0,68	-
4	1	1,32	2
5c	1	0,71	1
5b	1	1,15	1
5	2	2,11	1
6	1	1,05	1
7	1	0,95	1
8b	1	0,47	1
8	2	1,07	1
9	1	1,00	1
Total	17	14,13	15

Fonte: O autor (2020).

Destaca-se na proposta que um mesmo operador é responsável pelos postos 3a e 3b. Já no posto 4 ficam fixos 2 operadores, porém um deles ajuda no posto 5 em atividades que ocupem o seu tempo em até 8,37 minutos por produto.

Além disso, o operador que ficar fixo no posto 5c deve também ajudar em atividades do posto 5 em até 3,60 minutos por produto. Pode-se considerar neste posto, por ser pré-montagem, em trabalhar adiantado e deixar as montagens prontas para ficar de apoio constante ao posto 5.

Por último, salienta-se que o operador responsável pelo posto 8b possui uma ociosidade de 6,51 minutos por produto, então, este pode ser utilizado para apoio em eventuais necessidades, retrabalhos ou para compensar atrasos no final da linha antes do posto 9.

Já para a linha 2, exibe-se na Tabela 6 o balanceamento atual, do modelo e proposto.

**Tabela 6 – Balanceamento e eficiência atuais e propostos**

Postos	Nº operadores atual	Nº operadores modelo de otimização	Nº operadores inteiros
1	1	1,00	1
2	2	0,53	2
3b	1	0,38	1
3a	2	1,33	-
4	1	0,77	1
5	-	0,42	-
Total	7	4,43	5

Fonte: O autor (2020).


Na organização atual o operador responsável pelo posto 4 é também responsável pelo posto 5 e isso é um ponto negativo, pois para estas 2 atividades soma-se um número necessário de 1,19 operadores, conforme resultado encontrado por meio da programação não linear, o que representa uma sobrecarga possível acarretadora de atraso de produção. Enquanto no posto 2, com a atual distribuição de tarefas, observa-se uma ociosidade, já que foi encontrado uma necessidade de 0,53 operadores.

Para a organização proposta realça-se a diluição de um dos postos de trabalho com a união dos postos 2 e 3a, ficando sob dever de 2 operadores. Além disso, o posto 5 fica como função do operador responsável pelo posto 3b, já que este possui ociosidade e também, por ser pré-montagem, pode trabalhar adiantado e dedicar-se melhor à última tarefa, puxando de forma mais eficaz a linha de produção.

### 4.3 Ganhos e validade do método desenvolvido

Com o intuito de avaliar a funcionalidade do presente modelo de balanceamento de linha atrelado a uma previsão de demanda comparou-se o MAPE da previsão calculada pela RNA e pela forma atual de cálculo na empresa, pela média dos últimos 6 meses. Na Figura 8 pode-se analisar as diferenças destes erros.

**Figura 8** – Gráfico de comparação dos erros de previsão de demanda




Fonte: O autor (2020).

A partir da comparação é possível observar uma redução dos erros na previsão de demanda ao adotar-se um método de precisão mais elevada, como é o caso da RNA. Desta forma, percebe-se que o balanceamento de linha desenvolvido atrelado à

demanda calculada por RNA possui uma acurácia de 28,65% maior para a linha 1 (produtos 1 e 2) e de 77% maior para a linha 2 (produtos 3, 4 e 5) comparado a um balanceamento se desenvolvido com base na demanda estimada por média simples, seguindo forma atual.

Além disso, foram calculadas as eficiências de cada uma das duas linhas de montagem com base no número de operadores atuais e com base no número de operadores encontrados por meio da programação não linear com otimização, considerando valores inteiros e necessárias adaptações, conforme proposta, a fim de compará-las com a eficiência meta do modelo traçada em 80%. Esta comparação pode ser observada na Figura 9.

**Figura 9** – Gráfico de comparação da eficiência das linhas



Fonte: O autor (2020).

Apesar da eficiência proposta apresentar-se menor que a do modelo, devido às adaptações feitas sobre o modelo a fim de obter números inteiros de operadores para o balanceamento, tanto para a linha 1 quanto para a linha 2 pode-se notar um aumento de eficiência. Para a linha 1 obteve-se um ganho de 8,96%, o que representa um aumento de 2,9 produtos por dia, consequência para um total de 57,6 produtos a mais no mês. No entanto, para a linha 2 o ganho obtido foi de 20,18% na eficiência da linha de montagem, correspondendo a um acréscimo de 2,20 produtos por dia, que no mês resulta em 44 produtos.

## 5 CONCLUSÃO

Este trabalho teve como objetivo encontrar o melhor método de previsão de demanda de cinco produtos que representam o maior volume de vendas de uma multinacional, para que, com as quantidades previstas, fosse proposto um modelo de balanceamento otimizado das duas linhas de montagem em que são fabricados, distribuindo de forma mais assertiva os recursos e com um número de operadores adequado, a fim de aumentar a produtividade e garantir melhores resultados.

Com este intuito, primeiramente buscou-se compilar os históricos de vendas dos produtos e analisar seus comportamentos. Observada elevada variabilidade e não padronização, foram realizadas as previsões de demanda com os modelos matemáticos citados no trabalho e com RNAs otimizadas por meio de um algoritmo genético.

Seguidamente, foram calculados os erros de previsão de demanda para o melhor modelo matemático de previsão de cada produto e para RNAs, com o intuito de comparar os erros e encontrar o melhor modelo, ou seja, o de menor erro. Com isso, foi constatado que a RNAs otimizadas apresentou os menores erros, então, foi o método que melhor representou o comportamento de vendas dos produtos.

Com estas constatações, sugere-se à empresa a utilização de RNAs como um método robusto para antever o comportamento do mercado, já que não possui hoje uma metodologia capaz de acompanhar variabilidades. Considera-se imprescindível para uma adequação de recursos e desenvolvimento de estratégias operacionais de forma eficaz, o que reduz perdas recorrentes por falta de assertividade, inclusive para balancear as linhas de montagem.

Devido à validade do cálculo da demanda por RNAs, utiliza-se os dados gerados para o principal objetivo do trabalho: criar um método otimizado de balanceamento de linha. Os dados previstos foram transformados em uma estimativa de venda média diária, e então, buscou-se construir, por meio da programação não linear, o cálculo do número de operadores ótimo para cada posto de trabalho, o que viabiliza melhor organização e adequação de recursos, aumentando a eficiência das linhas.

Para construção do modelo, foram considerados diversos aspectos, como tempo disponível, operações, tempos de operações e meta de ocupação. Modelou-se então, uma planilha que calcula o número ideal de funcionários, *Takt Time*, eficiência e viabiliza uma análise de possíveis adequações.

Percebeu-se então que a programação não linear foi uma eficiente ferramenta para o balanceamento das linhas de montagem e que os aumentos identificados nas eficiências das linhas foram bastante satisfatórios, podendo trazer ganhos significativos para a empresa, somando um total de 29% na eficiência de montagem da empresa, que pode ser convertida em 101 produtos a mais por mês.

Tanto para prever a demanda quanto para balancear as linhas de montagem, a Pesquisa Operacional (PO) apresentou formas robustas de planejamento de estratégias, recursos e produção. A modelagem matemática, com programação não linear para balanceamento de linha e a inteligência artificial, com as RNAs sendo uma forma capaz de reconhecer padrões e antever demandas, simularam sistemas complexos e mostraram-se métodos quantitativos capazes de trazer benefícios para a empresa, como redução de desperdícios e sincronização entre necessidades e capacidades, por meio de um balanceamento adaptado às flutuações de demanda.

Portanto, o objetivo deste trabalho foi alcançado e recomenda-se o modelo de balanceamento desenvolvido também para outros setores da empresa e para mais produtos. De forma que a programação não linear seja incorporada na cultura e nos procedimentos da empresa, como facilitadora de gerenciamento. Além disso, ressalta-se a acurácia dos dados gerados por métodos robustos de previsão de demanda, que podem contribuir significativamente no desempenho da empresa.

Por fim, sugere-se aos futuros trabalhos melhorar as previsões, examinando outros métodos de aprendizagem de máquina. Além disso, indica-se a modelagem computacional do cálculo de previsão de demanda de um banco de dados com histórico de vendas, de forma que os erros sejam calculados e o melhor método seja escolhido, caracterizando um processo de melhoria contínua de predição de quantidades futuras e servindo de dado inicial, automaticamente, para o modelo de balanceamento de linha desenvolvido, gerando um modelo que une as duas técnicas.



## REFERÊNCIAS

ARAUJO, M. A. **Administração de produção e operações**: uma abordagem prática. Rio de Janeiro: Brasport, 2009.

ARMSTRONG, M. **A Handbook of Human Resource Management Practice**. 10th Edition. Kogan Page Publishing: London, 2006.

BORSATO, R.; CORSO, L. L. Aplicação de Inteligência Artificial e ARIMA na Previsão de Demanda no setor metal mecânico. **Scientia Cum Industria**. v. 7, n. 2, p. 165-176, 2019. DOI: <https://doi.org/10.18226/23185279.v8iss2p24>

CORRAR, L. J.; THEÓFILO, C. R. et al. **Pesquisa operacional para decisão em contabilidade e administração**. São Paulo, Atlas, 2004.

SILVA, J. A. B. Customer service logistics como estratégia organizacional: um estudo de caso em uma multinacional. **Brazilian Journal of Production Engineering**. v. 4, n. 4, p. 226-244, 2018.

FAVARO, L.A. *et al.* Otimização e balanceamento de uma linha de montagem de veículos utilitários. **Anais do XXXIII Encontro Nacional de Engenharia de Produção (ENEGEP)**, 2013. DOI: [https://doi.org/10.14488/enegep2021\\_tn\\_sto\\_354\\_1824\\_42050](https://doi.org/10.14488/enegep2021_tn_sto_354_1824_42050)

GONÇALVES, P.S. **Logística e cadeia de suprimentos**: o essencial. Barueri, SP: Manole, 2013.

GRAEMI, A. R.; PEINADO, J. **Administração da Produção**: operações industriais e de serviços. Curitiba: UnicenP, 2007.

GROOVER, M.P. **Automation, production, and computer-integrated manufacturing**. Prentice Hall. 2. ed. New Jersey, 2000.

HAIR JUNIOR, J. F. *et al.* **Análise multivariada de dados**. 5. ed. Porto Alegre: Bookman, 2005.

HAYKIN, S. **Redes Neurais**: princípios e práticas. 2. ed. Porto Alegre: Bookman, 2001.

HILLIER, F. S.; LIEBERMAN, G. J. **Introdução à pesquisa operacional**. 8. ed. Porto Alegre: AMGH, 2010.

KAHN, K. An Exploratory Investigation of New Product Forecasting Practices. **The Journal of Product Innovation Management**. v. 19, n. 2, p. 133-143, 2002. DOI: <https://doi.org/10.1111/1540-5885.1920133>

KOTLER, P. **Marketing management: analysis, planning, implementation and control.** New Jersey: Prentice-Hall, 1991.

KUO, R.J.; XUE, K.C. **A decision support system for sales forecasting through fuzzy neural networks with asymmetric fuzzy weights.** The Netherlands: Elsevier, 1998. DOI: [https://doi.org/10.1016/s0167-9236\(98\)00067-0](https://doi.org/10.1016/s0167-9236(98)00067-0)

LOHMANN, S., LACERDA, D. P., CAMARGO, L. F. R., DRESCH, A. Operations strategy and analysis of competitive criteria: a case study of a food business. **Gestão & Produção**, v. 26, n. 3, p. 2290, 2019. DOI: <https://doi.org/10.1590/0104-530x2290-19>

MARTINS, Gilberto de Andrade. **Manual para elaboração de monografias e dissertações.** 3 ed. São Paulo: Atlas, 1994.

MIRANDA, R. G.; GERBER, J. Z; BORNIA, A. C.; FREIRES, F. G. M. Método estruturado para o processo de planejamento da demanda nas organizações. In: Congresso Internacional de Administração, 2011. **Anais [...]**, Ponta Grossa, 2011.

MOON, M.; MENTZER, J.; SMITH, C.; GARVER, M. Seven Keys to Better Forecasting. **Business Horizons.** v. 41, n. 5, p. 44-52, 1998. DOI: [https://doi.org/10.1016/s0007-6813\(98\)90077-5](https://doi.org/10.1016/s0007-6813(98)90077-5)

SILVA, E. M.; SILVA, E. M.; GONÇALVES, V.; MUROLO, A. C. **Pesquisa Operacional: programação linear.** 3. ed. São Paulo: Atlas, 1998. DOI: [https://doi.org/10.14488/enegep2021\\_tn\\_sto\\_357\\_1845\\_42916](https://doi.org/10.14488/enegep2021_tn_sto_357_1845_42916)

SILVA, G. G. M. P. *et al.*, A manufatura enxuta aplicada no setor de serviços: um estudo de caso. In: XXVII ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO - ENEGEP. Foz do Iguaçu, 2007.

SLACK, N.; CHAMBERS, S.; HARLAND, C. **Administração da Produção.** São Paulo: Atlas, 2008.

SOUZA, R. C. Modelos Estruturais para Previsão de Séries Temporais: Abordagens Clássica e Bayesiana. In: COLÓQUIO BRASILEIRO DE MATEMÁTICA, 17., Rio de Janeiro, 1989. DOI: <https://doi.org/10.11606/d.55.2011.tde-06062011-164536>

TAPPING, D.; LUYSTER, T.; SHUKER, T. **Value Stream Management: eight steps to planning, mapping, and sustaining lean improvements.** New York: Productivity Press, 2002. DOI: <https://doi.org/10.1108/tqmm.2004.16.1.68.2>

TUBINO, D. F. **Planejamento e Controle da Produção: Teoria e Prática.** São Paulo: Atlas, 2007.

VITORINO, C. M. **Logística.** São Paulo: Pearson Education do Brasil, 2012.

WANKE, P. E. **Logística para MBA em 12 lições**. São Paulo: Atlas, 2010.

WHEELWRIGHT, S. C.; MAKRIDAKIS, S. **Forecasting Methods for Management**. 4. ed. New York: John Wiley & Sons Inc, 1985.

WINTERS, P. R. **Forecasting Sales by Exponentially Weighted Moving Averages**. *Management Science*, v. 6, n. 3, p. 324-342, 1960. DOI: <https://doi.org/10.1287/mnsc.6.3.324>



Artigo recebido em: 31/08/2022 e aceito para publicação em: 27/12/2022  
DOI: <https://doi.org/10.14488/1676-1901.v22i2.4734>