

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

Ícaro Romolo Sousa Agostino

COMBINAÇÃO DE PREVISÕES POR MÉTODOS LINEARES E NÃO-
LINEARES: UMA APLICAÇÃO EM SÉRIES INDUSTRIAIS

Santa Maria, RS
2019

Ícaro Romolo Sousa Agostino

COMBINAÇÃO DE PREVISÕES POR MÉTODOS LINEARES E NÃO-LINEARES: UMA
APLICAÇÃO EM SÉRIES INDUSTRIAIS

Dissertação apresentada ao curso de Pós-Graduação em Engenharia de Produção, Área de Concentração em Gerência da Produção, da Universidade Federal de Santa Maria (UFSM, RS) como requisito parcial para obtenção do título de **Mestre em Engenharia de Produção**.

Orientador: Prof. Dr. Adriano Mendonça Souza

Santa Maria, RS
2019

Agostino, Ícaro Romolo Sousa
Combinação de Previsões por Métodos Lineares e Não
Lineares: Uma Aplicação em Séries Industriais / Ícaro
Romolo Sousa Agostino.- 2019.
79 p.; 30 cm

Orientador: Adriano Mendonça Souza
Dissertação (mestrado) - Universidade Federal de Santa
Maria, Centro de Tecnologia, Programa de Pós-Graduação em
Engenharia de Produção, RS, 2019

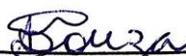
1. Combinação de Previsões 2. Séries Industriais 3.
Modelos de Previsões I. Souza, Adriano Mendonça II. Título.

Ícaro Romolo Sousa Agostino

**COMBINAÇÃO DE PREVISÕES POR MÉTODOS LINEARES E NÃO-LINEARES: UMA
APLICAÇÃO EM SÉRIES INDUSTRIAIS**

Dissertação apresentada ao curso de Pós-Graduação em Engenharia de Produção, Área de Concentração em Gerência da Produção, da Universidade Federal de Santa Maria (UFSM, RS) como requisito parcial para obtenção do título de **Mestre em Engenharia de Produção**.

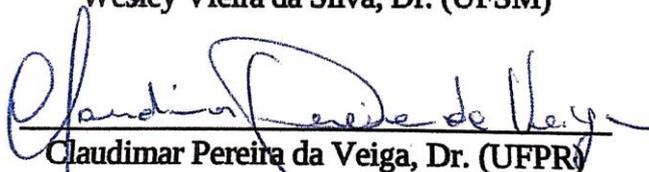
Aprovado em 20 de fevereiro de 2019



Adriano Mendonça Souza, Dr. (UFSM)
(Presidente/Orientador)



Wesley Vieira da Silva, Dr. (UFSM)



Claudimar Pereira da Veiga, Dr. (UFPR)

*"Essentially, all models are wrong, but
some are useful"*

George E. P. Box

RESUMO

COMBINAÇÃO DE PREVISÕES POR MÉTODOS LINEARES E NÃO-LINEARES: UMA APLICAÇÃO EM SÉRIES INDUSTRIAIS

AUTOR: Ícaro Romolo Sousa Agostino
ORIENTADOR: Adriano Mendonça Souza

Realizar previsões é uma importante atividade no planejamento, controle de processos e tomada de decisões, sobretudo no contexto industrial, sendo a combinação de previsões uma abordagem atrativa a fim de obter resultados acurados. Dessa forma, o objetivo da presente pesquisa foi investigar a aplicação e combinação de métodos de previsões objetivando verificar a acurácia e os ganhos em termos de redução de erros para séries temporais do setor industrial. A pesquisa está estruturada em dois artigos: o artigo I aborda uma revisão sistemática de literatura acerca do desenvolvimento e aplicações de modelos de previsão em processos industriais. Nesse estudo foi realizada a busca nas bases Web of Science, Scopus e IEE, compondo um portfólio de 354 artigos publicados em periódicos científicos nos últimos 10 anos. A análise da literatura foi realizada em três etapas: (i) inicialmente foi realizada uma análise das frequências das publicações quanto aos periódicos, anos de publicações, autores, países e número de citações; (ii) foi realizada a análise de cocitação, de acoplamento bibliográfico e análise de similitude da coocorrência dos termos nos estudos; (iii) por fim foi elaborado um framework unificado para classificação das aplicações de métodos de previsão em processos industriais. O artigo II abordou a aplicação da combinação de previsões em um estudo de caso realizado em uma empresa de grande porte do setor de mineração e logística, com séries de produção industrial provenientes de um sistema portuário integrado, neste estudo o objetivo geral foi ajustar um modelo de previsão combinada acurado capaz de capturar o comportamento seriado temporal do sistema. Foram utilizados como preditores individuais os modelos de Suavização Exponencial, a modelagem ARIMA a partir da metodologia de Box-Jenkins e os modelos de Redes Neurais Artificiais. A combinação das previsões foi realizada por três abordagens distintas: a combinação por média aritmética, pelo método da Variância Mínima, consistindo em uma combinação linear a partir da variância dos erros de previsão, e a partir de modelos de cópulas, sendo uma abordagem não linear baseada no grau de dependência das previsões individuais. Como medidas de avaliação dos modelos propostos foram utilizados os critérios RMSE e U-Theil. Os resultados encontrados demonstraram que os modelos ARIMA e ANN foram superiores em termos de acurácia em relação as previsões individuais, e os métodos de combinação por modelo de cópula produziram previsões mais acuradas em relação às demais abordagens de combinações adotadas.

Palavras-chave: Combinação de Previsões. ARIMA. Redes Neurais Artificiais. Variância Mínima. Modelos de Cópulas.

ABSTRACT

COMBINATION OF FORECASTS BY LINEAR AND NON-LINEAR METHODS: AN APPLICATION IN INDUSTRIAL SERIES

AUTHOR: Ícaro Romolo Sousa Agostino

ADVISOR: Adriano Mendonça Souza

Forecasting is an important activity in planning, process control and decision making, especially in the industrial context, and the combination of forecasts is an attractive approach in order to obtain accurate results. The objective of the present research was to investigate the application and combination of prediction methods aiming to verify the accuracy and the gains in terms of error reduction for time series of the industrial sector. The research is structured in two articles: article I discusses a systematic review of the literature on the development and applications of forecasting models in industrial processes. In this study, the Web of Science, Scopus and IEE databases were searched, composing a portfolio of 354 articles published in scientific journals in the last 10 years. The analysis of the literature was carried out in three stages: (i) initially an analysis of the frequencies of the publications was carried out regarding the periodicals, years of publications, authors, countries and number of citations; (ii) analysis of cocitation, bibliographic coupling and similarity analysis of the co-occurrence of the terms in the studies; (iii) finally, a unified framework was developed to classify the applications of forecast methods in industrial processes. Article II addressed the application of the combination of forecasts in a case study conducted in a large mining and logistics company with industrial production series from an integrated port system, in this study the general objective was to fit a model of accurate combined forecasting capable of capturing the serial time behavior of the system. The models of Exponential Smoothing, ARIMA modeling from the Box-Jenkins methodology and the Artificial Neural Networks models were used as individual predictors. The combination of the forecasts was carried out by three different approaches: the combination by arithmetic mean, by the Minimum Variance method, consisting of a linear combination from the variance of the prediction errors, and from Copula models, being a nonlinear approach based on the degree of dependence on individual forecasts. As evaluation measures of the proposed models, the RMSE and U-Theil criteria were used. The results showed that the ARIMA and ANN models were superior in terms of accuracy in relation to the individual predictions, and the methods of combination by model of copula produced more accurate predictions in relation to the other approaches of combinations adopted.

Keywords: Combination of Forecasts. ARIMA. Artificial Neural Networks. Minimum Variance. Copula models.

SUMÁRIO

1	INTRODUÇÃO	7
1.1	JUSTIFICATIVA	8
1.2	OBJETIVOS	9
1.2.1	Objetivo geral	9
1.2.2	Objetivos específicos	9
1.3	ESTRUTURA DO TRABALHO	10
2	REVISÃO DE LITERATURA	11
2.1	MODELOS PARA PREVISÃO DE SÉRIES TEMPORAIS.....	11
2.1.1	Métodos de Suavização Exponencial, Holt e Holt-Winters	14
2.1.2	Metodologia de Box-Jenkins	16
2.1.2.1	<i>Modelos Estacionários</i>	17
2.1.2.2	<i>Modelos Não-Estacionários</i>	19
2.1.2.3	<i>Modelos Sazonais</i>	20
2.1.2.4	<i>Etapas da Metodologia de Box-Jenkins</i>	21
2.1.3	Redes Neurais Artificiais	23
2.2	COMBINAÇÃO DE MODELOS DE PREVISÕES.....	28
2.2.1	Estudos Recentes com Combinação de Previsões.....	29
2.2.2	Método da Variância Mínima	34
2.2.3	Modelos de Cópulas Para Combinação de Previsões.....	36
3	MATERIAIS E MÉTODOS	39
3.1	ESTRUTURA E CLASSIFICAÇÃO DA PESQUISA	39
3.2	DESCRIÇÃO DAS VARIÁVEIS UTILIZADAS	40
3.3	PROCEDIMENTOS DE MODELAGEM E ANÁLISE DOS DADOS	41
4	ARTIGO I - Modelos de Previsão na Indústria: Revisão Sistemática da Literatura Recente e Direções de Pesquisa	44
5	ARTIGO II - Modelagem e previsão de indicadores operacionais: Uma abordagem combinada baseada em modelos lineares e não-lineares.....	58
6	DISCUSSÃO	72
7	CONCLUSÃO	73
	REFERÊNCIAS.....	74

1 INTRODUÇÃO

O atual cenário econômico, acompanhado das constantes evoluções tecnológicas, impôs às organizações dos mais diversos setores a necessidade da busca continuada pela melhor forma de operar seus processos, independente da natureza ao qual esses pertencem. Nesse contexto, os processos de tomada de decisão nas organizações constantemente necessitam de subsídios que fomentem a correta análise dos elementos constituintes do processo decisório, apresentando os métodos de previsão vasta aplicação e relevância para esta temática (SLACK; BRANDON-JONES; JOHNSTON, 2015).

Diversas técnicas são utilizadas para prever o comportamento de variáveis, podendo ser classificadas como qualitativas ou quantitativas. Em geral, a realização de previsões no contexto organizacional utiliza métodos quantitativos, baseados na existência de registros de dados históricos. Dentre os modelos quantitativos existentes para a realização de previsões, se destacam os modelos de séries temporais (MONTGOMERY; JENNINGS; KULAHCI, 2007).

Todos os eventos espaçados de forma regular no tempo geram séries temporais. Dentre as diversas áreas de aplicações possíveis se destacam a economia, engenharia e as ciências sociais (BOX; JENKINS, 1976). Diversas técnicas de previsão estão disponíveis possuindo diferentes características variando acurácia, custos para aplicação, horizonte de tempo e objetivos (ABRAHAM; LEDOLTER, 2005). Dessa forma, para a obtenção de uma previsão adequada é necessário analisar qual técnica fornece as melhores medidas de acurácia (MARTINS; WERNER, 2014).

Entre os modelos de previsões existentes, os Métodos de Suavização Exponencial popularizados por Holt (1957) e Winters (1960) e os modelos Autorregressivos Integrados de Médias Móveis (ARIMA) implementados pela metodologia proposta por Box e Jenkins (1970) se destacam como técnicas de previsões consolidadas para séries temporais. Outro modelo que tem se destacado em termos de acurácia, sobretudo em séries com padrões não-lineares, são os modelos de previsão baseados em Redes Neurais Artificiais (RNA) (LEE; TONG, 2011).

Uma alternativa para obtenção de previsões mais eficazes consiste em combinar técnicas individuais de previsão, resultando em previsões estatisticamente superiores em termos de acurácia, comparados a técnicas individuais (HIBON; EVGENIOU, 2005). Diversos estudos apresentam resultados demonstrando que diferentes métodos de combinações obtiveram resultados mais acurados em relação a previsões individuais (CLEMEM, 1989;

MAKRIDAKIS; HIBON, 2000; STOCK; WATSON, 2004; AMENDOLA; STORTI, 2008; JEONG; KIM, 2009; COSTANTINI; PAPPALARDO, 2010; WALLIS, 2011).

Diversos métodos de combinação são encontrados na literatura, inicialmente Bates e Granger (1969) propuseram a realização de combinações lineares entre os preditores individuais, com pesos atribuídos de acordo com os erros gerados pelos modelos. Em estudos recentes são realizadas combinações de técnicas de previsão por meio de modelos de Cópulas, como uma alternativa não-linear para combinação de preditores individuais. Os resultados obtidos demonstraram que a utilização de tal modelo também obteve resultados mais acurados quando comparado a modelos individuais (OLIVEIRA et al., 2017; ASSIS, 2017; OLIVEIRA et al., 2016; OLIVEIRA et al., 2013).

Portanto, esta pesquisa se propõe a combinar previsões individuais obtidas dos modelos de Holt-Winters, Box-Jenkins e RNA por meio dos métodos lineares clássicos de combinação, assim como por aplicação de modelos de Cópulas. Para tanto, são propostos dois estudos, o primeiro aborda uma revisão sistemática de literatura acerca do desenvolvimento e aplicações de modelos de previsão em processos industriais. O segundo utilizará séries de produção industrial provenientes de um sistema portuário integrado, de uma indústria de grande porte do setor de mineração e logística.

1.1 JUSTIFICATIVA

Os estudos acerca dos métodos de previsões, constantemente são direcionados ao desenvolvimento de novas técnicas e modelos que possam reduzir a incerteza, sobretudo no contexto das séries temporais (FIRMINO; MATTOS NETO; FERREIRA, 2014). Nesse sentido, pesquisadores têm se desafiado a buscar novas abordagens na modelagem de séries temporais, sendo a combinação de previsões uma alternativa atrativa, a partir da integração de diversos modelos ajustados a mesma série, com o objetivo de promover uma previsão com acurácia superior (WALLIS, 2011; MARTINS; WERNER, 2014).

Dentre as alternativas de combinações encontradas na literatura, a aplicação por Média Simples é um dos métodos mais utilizados pois, apesar de ser pouco sofisticado, sua implementação tem baixo custo e considerável eficiência (FLORES; WHITE, 1989; OLIVEIRA et al., 2017). Outra abordagem consolidada na literatura é o método da Variância Mínima, proposto por Bates e Granger (1969), consistindo na combinação linear de previsores individuais com adoção de pesos baseados nos erros das previsões. Pesquisas correlatas recentes, como Doganis, Aggelogiannaki e Sarimoveis (2008), Wallis (2011), Martins e Werner

(2012), Aye et al. (2015) e Azevedo e Campos (2016), suportam a utilização da combinação de previsões como uma forma eficaz de melhorar a acurácia.

A utilização de modelos de Cópulas em séries temporais tem sido discutida em diversos estudos recentes, como Morettin et al. (2011), Bessa et al. (2012), Patton (2012), Liu (2015), Smith (2015), Lahiri e Yang (2016). Dentre as aplicações encontradas, modelos de Cópulas são adotados na combinação não-linear de previsões nos estudos: Oliveira et al. (2013), Assis (2017) e Oliveira et al. (2017), entretanto não é visto na literatura aplicações dessa abordagem em estudos de casos com séries reais, sobretudo no setor industrial, neste sentido esta pesquisa se justifica pois possibilita uma abordagem nova para modelagem de séries temporais com combinações nesse setor.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Esta pesquisa tem como objetivo geral combinar previsões por meio de técnicas lineares e não-lineares, possibilitando verificar a acurácia e ganhos em termos de redução de erros para séries do setor industrial.

1.2.2 Objetivos específicos

Realizar uma revisão sistemática sobre métodos para combinação de previsão, a fim de verificar o estado da arte na qual a temática se encontra, permitindo ao fim comparar os resultados encontrados com a discussão já existente na literatura.

Ajustar modelos de previsões às séries temporais do setor industrial a partir dos modelos de Holt-Winters, da modelagem ARIMA com a aplicação da metodologia de Box-Jenkins, assim como por modelos de RNA à realização das previsões individuais.

Realizar a combinação das previsões individuais a partir da aplicação de Média Simples, da combinação linear pelo método da Variância Mínima e por modelos de Cópulas, gerando novas previsões.

Verificar qual método de previsão individual ou combinado apresenta maior acurácia para as séries do setor industrial consideradas nesta pesquisa. Para tanto, será realizado um estudo com série reais, a partir da análise das medidas de acurácia recorrentes na literatura.

1.3 ESTRUTURA DO TRABALHO

Para atender os propósitos da pesquisa, este trabalho está dividido em cinco capítulos, apresentados a seguir:

O **capítulo 1** aborda a introdução ao tema, a justificativa da pesquisa, apresenta o objetivo geral do trabalho, assim como os específicos, e a estrutura do trabalho.

O **capítulo 2** apresenta uma revisão de literatura sobre modelos de previsões para séries temporais e sobre combinação de previsões. Na primeira parte desse capítulo é introduzido o conceito de previsão, assim como a classificação das técnicas e as etapas do processo de previsão. São abordadas as técnicas preditoras individuais que suportarão a realização das combinações: os modelos de Holt-Winters, a metodologia de Box-Jenkins e os modelos de previsão baseados em Redes Neurais Artificiais.

Ainda nesse capítulo é apresentado o conceito de combinação de previsões, aborda uma revisão de literatura dos principais métodos existentes, assim como uma revisão atualizada das abordagens recentes baseadas em combinações lineares e não-lineares. Nesse capítulo são discutidos os métodos de combinação por média simples, variância mínima e combinação por modelos de Cópulas.

O **capítulo 3** apresenta a metodologia proposta, é realizada a classificação da pesquisa quanto à natureza, à abordagem, aos objetivos e aos procedimentos, são descritas as variáveis consideradas no estudo e, por fim, a apresentada das etapas metodológicas adotadas.

O **capítulo 4** apresenta, na forma de artigo, o resultado da revisão sistemática de literatura realizada acerca do desenvolvimento e aplicações de modelos de previsão em processos industriais.

O **capítulo 5** apresenta, na forma de artigo, o resultado da aplicação da combinação de previsões com séries reais de produção industrial.

O **capítulo 6** apresenta a discussão dos resultados dos artigos de forma integrada.

O **capítulo 7** apresenta as conclusões finais da pesquisa.

2 REVISÃO DE LITERATURA

Nesse capítulo será abordada a revisão de literatura a respeito do tema de estudo desta pesquisa. A primeira parte dessa seção trata dos modelos para previsão de séries temporais, apresentando os modelos de Holt-Winters, a metodologia de Box-Jenkins e os modelos de previsão baseados em Redes Neurais Artificiais. Enquanto na segunda, parte é abordado a combinação de modelos previsão, apresentando os métodos de combinação por média simples, variância mínima e combinação por modelos de cópulas.

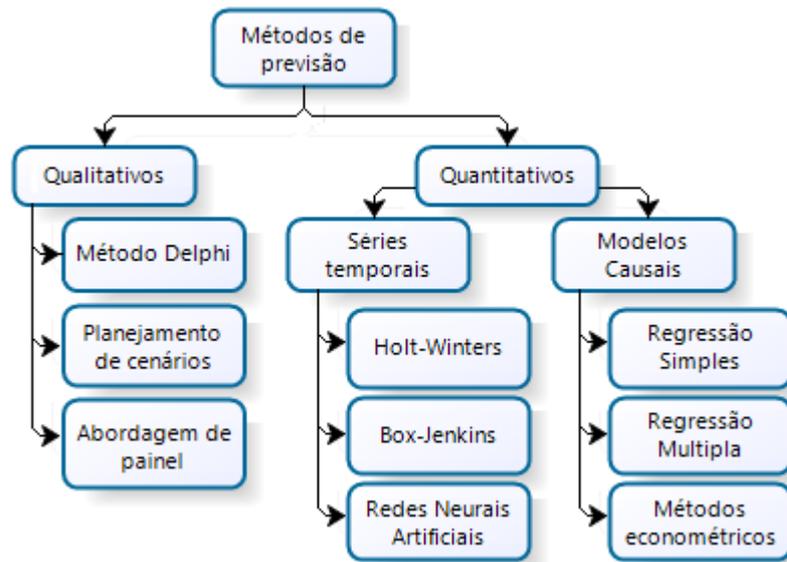
2.1 MODELOS PARA PREVISÃO DE SÉRIES TEMPORAIS

Realizar previsões é uma atividade indispensável no planejamento de atividades e nos processos de tomada decisão (WERNER, 2005; WANG; CHANG, 2010). A previsão pode ser entendida como a busca de informações sobre o comportamento futuro de uma variável a partir de um processo racional envolvendo incertezas. Nesse contexto, a previsão consiste em um processo metodológico que objetiva definir os dados futuros com base em modelos estatísticos, matemáticos, econométricos e/ou subjetivos (MARTINS; LAUGENI, 2009; MOREIRA, 2014).

Dessa forma, comumente os modelos de previsão são divididos em duas classes genéricas: qualitativas e quantitativas (LAWRENCE; KLIMBERG; LAL, 2009). Técnicas qualitativas são largamente utilizadas em diversos contextos, devido a facilidade de aplicação e de apresentarem baixos custos relativos. Tais métodos normalmente são utilizados em situação de escassez de dados históricos, sendo, de uma forma geral, menos robustos quando comparados a métodos quantitativos. Dentre os métodos qualitativos se destacam a abordagem de painel, o método Delphi, o planejamento de cenários, dentre outros (ROSIENKIEWICZ; CHLEBUS; DETYNA, 2017).

As técnicas quantitativas utilizam dados históricos para a realização de previsões, podendo utilizar modelos baseados em séries temporais ou modelos causais. Enquanto modelos causais buscam incluir variáveis explicativas para predizer o comportamento da variável estudada, os modelos de séries temporais utilizam o comportamento dos dados ao longo do tempo para extrair um padrão que possa explicar o comportamento futuro da variável estudada (ROSIENKIEWICZ; CHLEBUS; DETYNA, 2017). Na Figura 1 ilustra-se a classificação dos métodos de previsão, assim como os modelos utilizados em cada caso.

Figura 1 – Classificação dos métodos de previsão



Fonte: Adaptado de Lustosa et al. (2008)

Conforme Souza (2016), uma série temporal pode ser definida como uma sequência de observações sobre uma variável em diferentes instantes de tempo em que os dados são observados em pontos temporais discretos, usualmente equidistantes. A análise de séries temporais consiste em dois objetivos básicos: (i) identificar as características e propriedades da série e/ou (ii) realizar previsões. As séries temporais são compostas por quatro elementos:

- a) Tendência: verifica o sentido de deslocamento da série temporal ao longo do tempo;
- b) Ciclo: movimento ondulatório da série temporal, que ao longo de vários anos tende a ser periódico;
- c) Sazonalidade: movimento ondulatório de curta duração, normalmente inferior a um ano, que, em geral, está associado a mudanças climáticas;
- d) Ruído aleatório ou erro: compreende a variabilidade intrínseca à série temporal, não podendo ser modelado.

Os erros oriundos do modelo ajustado são definidos pela diferença entre os valores reais da série temporal modelada e os valores previstos. De acordo com Bueno (2008), para um modelo ser adequado, a sequência de ruídos gerados deve ser não autocorrelacionada, possuir média zero e variância constante, sendo que, os ruídos quando atendem esses requisitos são denominados de ruído branco, cuja representação é $RB \sim (0, \sigma^2)$.

Parte-se, então, do pressuposto que exista um “mecanismo gerador” para os dados estudados, dessa forma, procura-se construir um modelo que represente razoavelmente bem tal mecanismo. A abordagem clássica parte da ideia de que uma série estudada Z é passível de ser decomposta por meio das seguintes generalizações (SOUZA, 2016):

$$Z_t = T + S + C + \varepsilon_t \quad (1)$$

Onde: T representa a tendência; S a sazonalidade; C o ciclo; ε_t o erro. Desta forma, uma série temporal pode ser estudada como uma combinação de seus componentes, além da estrutura aditiva a série pode ser multiplicativa dada pelo produto de seus componentes.

Para previsões de séries temporais alguns modelos estão consolidados na literatura. Dentre os mais utilizados se destacam os métodos de suavização, também conhecidos como modelos de Holt-Winters, e a metodologia de Box-Jenkins (MAKRIDAKIS; STEVEN; HYNDMAN, 1998). Recentemente métodos baseados em redes neurais passaram a ser amplamente utilizados para previsões em séries temporais (WERNER, 2005).

De acordo com Montgomery, Jennings e Kulahci (2007), o processo de realização de previsões é composto de diversas etapas estruturadas, na Figura 2 é apresentado um sistema de previsão estruturado composto por seis passos conectados.

Figura 2 – O processo de previsão



Fonte: Adaptado de Montgomery, Jennings e Kulahci (2007)

A primeira etapa consiste em definir qual o objetivo para a realização da previsão, assim como definir a forma que essa previsão será utilizada, comumente a definição do problema advém da necessidade de prever demandas, controlar um determinado processo, mensurar riscos, oferecer subsídios a tomada de decisão, dentre outros. A etapa seguinte, coleta de dados, consiste na obtenção dos dados históricos que serão utilizados para prever o comportamento futuro da variável estudada. Nessa etapa é importante definir quais dados serão relevantes ao estudo (WERNER, 2005).

Após a coleta dos dados, se faz necessário analisá-los a fim de definir qual técnica de previsão será empregada. Na literatura existem diversas abordagens, técnicas e modelos previsores para séries temporais, variando de acordo a capacidade de acurácia, o objetivo, o horizonte de previsão e os custos envolvidos. Portanto, a obtenção de uma previsão acurada depende da utilização de uma técnica de previsão adequada aos dados estudados, sendo que a seleção entre os modelos ou técnicas de previsão dependerá principalmente da acurácia da previsão (MAKRIDAKIS; STEVEN; HYNDMAN, 1998).

A validação de um modelo foi realizada pela análise do ajuste do modelo aos dados reais, sendo calculada por meio de medidas de acurácia. Segundo Montgomery, Jennings e Kulahci (2007) quando duas ou mais técnicas se mostram razoáveis para realizar previsões, as medidas de acurácia podem ser usadas para discriminar entre os modelos concorrentes aquele que possui melhor ajuste.

Após validado, se faz necessário o monitoramento do modelo, pois com o passar do tempo as condições costumam mudar, deteriorando a capacidade preditiva e a performance do modelo. Monitorar os erros de previsão é uma parte essencial do processo, em muitos casos a aplicação de gráficos de controle é uma forma simples e eficaz de monitorar a performance de um modelo de previsão (MONTGOMERY; JENNINGS; KULAHCI, 2007).

Nesta pesquisa foram utilizados como modelos previsores os modelos de Holt-Winters, a metodologia de Box-Jenkins, assim como modelos de Redes Neurais Artificiais. A seguir apresentam-se as técnicas de previsão que suportaram este estudo.

2.1.1 Métodos de Suavização Exponencial, Holt e Holt-Winters

Os métodos denominados de Métodos de Suavização Exponencial constituem uma família de modelos matemáticos que objetivam ajustar uma curva adequada aos dados históricos de uma série temporal, utilizados amplamente em muitas áreas, como negócios e economia (GUJARATI; PORTER, 2011). Tais modelos apresentam como vantagem a fácil compreensão da modelagem e baixo custo de aplicação, podendo ser desenvolvidos em planilhas eletrônicas com o auxílio de métodos de otimização para o ajuste dos parâmetros (MORETTIN; TOLOI, 2006).

Aborda-se nessa seção o Método de Suavização Exponencial, o Método Linear de Holt para séries com características de tendência e o Método de Holt-Winters para séries com características de tendência e sazonalidade.

O Método de Suavização Exponencial consiste em obter o valor de Z_t a partir dos valores passados ponderados, de forma que os pesos decaem geometricamente. Em sua representação mais simples, cada previsão é obtida a partir da previsão anterior somada do erro cometido corrigido por um coeficiente de ponderação “ α ” (TUBINO, 2009).

$$\tilde{Z}_t = \tilde{Z}_{t-1} + \alpha(Z_{t-1} - \tilde{Z}_{t-1}) \quad (2)$$

Onde: \tilde{Z}_t corresponde a previsão no período “t”; Z_t é o valor real no período “t”; α representa o coeficiente de ponderação em uma faixa entre 0 e 1.

O Método Linear de Holt (também conhecido como suavização exponencial dupla) é utilizado quando os dados apresentam tendência linear crescente ou decrescente, em séries reais tal característica é comumente encontrada, sobretudo no setor industrial (MARTINS, 2011). O método utiliza duas constantes de suavização “ α ” e “ β ”, sendo “ α ” proveniente do primeiro ajuste exponencial e “ β ” o coeficiente de ponderação da tendência. São utilizadas as equações (3), (4) e (5):

$$\tilde{Z}_{t+m} = L_t + b_t m \quad (3)$$

$$L_t = \alpha Z_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (4)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (5)$$

Onde: L_t representa o valor estimado do nível; b_t representa a estimativa de tendência; α e β são as constantes de suavização no intervalo de 0 a 1; \tilde{Z}_{t+m} corresponde a previsão no período “t+m”, em que “m” representa quantos passos à frente se deseja prever.

Já o método denominado de Holt-Winters, destina-se a modelagem de série que apresentem tendência e sazonalidade, tais modelos foram desenvolvidos por Holt (1957) e Winters (1960), possuindo duas abordagens distintas: multiplicativa, no caso da amplitude sazonal aumentar em relação ao tempo; e aditiva, quando a série estudada possui uma amplitude constante ao longo de seus ciclos (MAKRIDAKIS; STEVEN; HYNDMAN, 1998). A Tabela 1 contém as equações das duas abordagens do modelo.

Tabela 1 – Equações dos modelos de Holt-Winters Aditivo e Multiplicativo

Modelo	Equações	
	$\tilde{Z}_{t+m} = (L_t + b_t m) S_{t-s+m}$	(6)
Modelo de Holt-Winters (Método multiplicativo)	$L_t = \alpha (Z_t / S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$	(7)
	$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$	(8)
	$S_t = \gamma (Z_t / L_t) + (1 - \gamma)S_{t-s}$	(9)
	$\tilde{Z}_{t+m} = (L_t + b_t m) + S_{t-s+m}$	(10)
Modelo de Holt-Winters (Método aditivo)	$L_t = \alpha(Z_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$	(11)
	$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$	(12)
	$S_t = \gamma(Z_t - L_t) + (1 - \gamma)S_{t-s}$	(13)

Fonte: Adaptado de Morettin e Toloi (2006)

Onde: L_t representa o valor estimado do nível; b_t representa a estimativa de tendência; α , β e γ são as constantes de suavização no intervalo de 0 a 1; \tilde{Z}_{t+m} corresponde a previsão no período “t+m”, em que “m” representa quantos passos à frente se deseja prever; S_t o índice sazonal da série temporal.

A atribuição de um valor específico para os coeficientes de ponderação (α , β e γ) costuma ser realizado por simulação computacional utilizando otimização linear, em que o valor é ajustado de forma a minimizar o erro de previsão (TUBINO, 2009).

2.1.2 Metodologia de Box-Jenkins

A metodologia de Box-Jenkins (1970) é uma abordagem bastante difundida para a realização de previsão em séries temporais, foi proposta inicialmente na publicação “*Time Series Analysis: Forecasting and Control*”. A abordagem metodológica ficou conhecida popularmente como metodologia de Box-Jenkins, mas tecnicamente como metodologia ARIMA, conduzindo a uma nova perspectiva para a realização de previsões, em que a ênfase está na análise das propriedades da própria série temporal, sob a filosofia “*deixem os dados falarem por si mesmos*”. Tal metodologia permite que Z_t seja explicado por seus próprios valores passados, ou defasados, do próprio Z , assim como em termos de seu erro estocástico (GUJARATI; PORTER, 2011).

Tal método é utilizado com o intuito de análise e realização de previsões para séries de médio comprimento, sendo caracterizado por capturar a correlação entre os valores da série ao longo do tempo (SOUZA, 2016). Os modelos de Box-Jenkins resultam da combinação de três filtros: o componente Autorregressivo (AR), o filtro de Integração (I) e o componente de Médias Móveis (MA). Uma série temporal pode ser modelada pela combinação dos três filtros, ou somente por um ou dois deles, resultando em diversos modelos com características diferentes (WERNER, 2005).

2.1.2.1 Modelos Estacionários

Um pressuposto básico para utilização da metodologia de Box-Jenkins é da estacionariedade da série temporal estudada, garantindo a significância dos parâmetros estimados ao longo dos períodos. Dessa forma, modelos estacionários assumem que o processo gerador da série é “equilibrado”, com sua média e variância constante ao longo do tempo (MONTGOMERY; JENNINGS; KULAHCI, 2007).

2.1.2.1.1 Modelo Autorregressivo (AR)

Um modelo denominado autorregressivo, de uma série temporal Z_t , é aquele descrito por seus valores passados do período “t”, adicionados de um erro ε_t no mesmo instante (GUJARATI; PORTER, 2011). Dessa forma, o modelo é denominado autorregressivo de ordem “p”, denotado $AR(p)$, sendo representado pela equação (14):

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + \varepsilon_t \quad (14)$$

Onde: ϕ_p é o parâmetro autorregressivo de ordem “p”; ε_t representa o erro ou ruído aleatório $\sim (0, \sigma^2)$; \tilde{Z}_t corresponde ao valor Z_t subtraído a média do processo (μ):

$$\tilde{Z}_t = Z_t - \mu \quad (15)$$

O modelo é considerado estacionário para todo $|\phi| < 1$. Essa condição é denominada de condição de estacionariedade, estabelecendo que todas as raízes devem estar fora do círculo unitário para um processo de ordem finita. A identificação do modelo autorregressivo é feita

por meio das funções de autocorrelação e autocorrelação parcial, que indicam a ordem do modelo a ser ajustado (BUENO, 2008).

A função de autocorrelação em um processo autorregressivo decai exponencialmente podendo alternar de sinal. Para a função de autocorrelação parcial o decaimento ocorre de forma abrupta em um *lag* significativo “*p*”, indicando a ordem do modelo a ser ajustado (MORETTIN, 2011).

2.1.2.1.2 Modelo de Médias Móveis (MA)

Um modelo denominado de médias móveis (*moving average*), de uma série temporal Z_t , é descrito em termos de seus erros ε_t do período atual juntamente com os erros de períodos defasados “*t*” (GUJARATI; PORTER, 2011). Dessa forma, o modelo é chamado de médias móveis de ordem “*q*”, denotado $MA(q)$, dado pela equação (16):

$$\tilde{Z}_t = \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (16)$$

Onde: θ_q é o parâmetro de médias móveis de ordem “*q*”; ε_t representa o erro ou ruído aleatório $RB \sim (0, \sigma^2)$; \tilde{Z}_t corresponde ao valor Z_t subtraído a média do processo (μ).

Para o modelo de médias móveis o parâmetro estimado deve assumir $|\theta| < 1$. Tal restrição é denominada de condição de inversibilidade, dessa forma as raízes da equação devem estar fora do círculo unitário em um processo de ordem finita. A identificação do modelo é realizada por meio funções de autocorrelação e autocorrelação parcial, que indicam a ordem do modelo a ser ajustado (BUENO, 2008).

A função de autocorrelação de um modelo de médias móveis decai abruptamente no *lag* significativo, indicando a ordem “*q*” do modelo a ser ajustado. Para a função de autocorrelação parcial o decaimento ocorre de forma exponencial, podendo ocorrer em forma de uma senoide amortecida (MORETTIN, 2011).

2.1.2.1.3 Modelo Autorregressivo de Médias Móveis (ARMA)

Em um modelo denominado de autorregressivo de médias móveis, ocorrerá a combinação dos filtros AR e MA, pois em determinados casos as séries temporais não se ajustam a modelos puramente AR ou MA (GUJARATI; PORTER, 2011). Assim como nos modelos puros, o modelo ARMA se ajustará somente quando à série Z_t apresentar

estacionariedade. Dessa forma, o modelo é denominado de autorregressivo de médias móveis de parâmetros “ p ” e “ q ”, denotado ARMA(p,q), expresso pela equação (17):

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (17)$$

Onde: ϕ_p é o parâmetro autorregressivo de ordem “ p ”; θ_q é o parâmetro de médias móveis de ordem “ q ”; ε_t representa o erro ou ruído aleatório $\sim (0, \sigma^2)$; \tilde{Z}_t corresponde ao valor Z_t subtraído a média do processo (μ).

O modelo ARMA assume a mesma condição de estacionariedade de um modelo AR, isto é, $|\phi| < 1$, assim como a condição de invertibilidade de um modelo MA, isto é, $|\theta| < 1$. Assim como nos modelos puros, a identificação do modelo ARMA é realizada por meio das funções de autocorrelação e autocorrelação parcial, com ambas apresentando decaimento exponencial e/ou senoidal, o que torna a identificação dos parâmetros relativamente mais difícil (MONTGOMERY; JENNINGS; KULAHCI, 2007; BUENO, 2008)

2.1.2.2 Modelos Não-Estacionários

Em aplicações reais, raramente as séries temporais são estacionárias, isto é, com a média e a variância não constantes dependentes do tempo. A não estacionariedade de uma série temporal pode estar relacionada: (i) a existência de tendência nos dados estudados, com ausência de oscilação em torno de uma média constante e/ou (ii) a variabilidade dos dados não se mantem constante ao longo do tempo, indicando que a variância dos dados está se alterando (WERNER, 2005).

A verificação da estacionariedade se dá a priori por análise gráfica, sendo confirmada pela aplicação de testes de raízes unitárias. Os testes Augmented Dick-Fuller – ADF (DICKEY, 1984) e Kwiatkowski, Phillips, Schmidt e Shin – KPSS (KWIATKOWSKI et al., 1992) comumente são utilizados a fim de verificar a estacionariedade em séries temporais, sendo sugerido a utilização conjunta de ambos para obter resultados mais acurados sobre o grau de estacionariedade dos dados (SOUZA, 2016). Maiores detalhes sobre teste de estacionariedade em séries temporais podem ser vistos em Morettin (2011) e Bueno (2008).

Dessa forma, caso a série possua tendência, não sendo estacionária, se faz necessária a aplicação de diferenças entre os valores a fim de torná-la estacionária (GUJARATI; PORTER, 2011). A forma mais comum de realizar transformações em séries temporais, consiste em

realizar diferenças entre os valores da série sucessivamente até a mesma se tornar estacionária, a primeira diferença é dada pela equação (18):

$$\Delta Z_t = Z_t - Z_{t-1} \quad (18)$$

A segunda diferença é dada pela equação (19):

$$\Delta^2 Z_t = \Delta(Z_t - Z_{t-1}) = Z_t - 2Z_{t-1} + Z_{t-2} \quad (19)$$

Comumente é suficiente a aplicação de uma ou duas diferenças para que a série se torne estacionária. Dessa forma, o número de “ d ” diferenças realizadas é denominada de ordem de integração, portanto o modelo é denominado de autorregressivo integrado de médias móveis de parâmetros “ p ”, “ d ” e “ q ” denotado ARIMA(p,d,q), dado pela equação (20):

$$w_t = \phi_1 w_{t-1} + \dots + \phi_p w_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (20)$$

Onde: $w_t = \Delta^d Z_t$; ϕ_p é o parâmetro autorregressivo de ordem “ p ”; θ_q é o parâmetro de médias móveis de ordem “ q ”; ε_t representa o erro ou ruído aleatório $\sim (0, \sigma^2)$

2.1.2.3 Modelos Sazonais

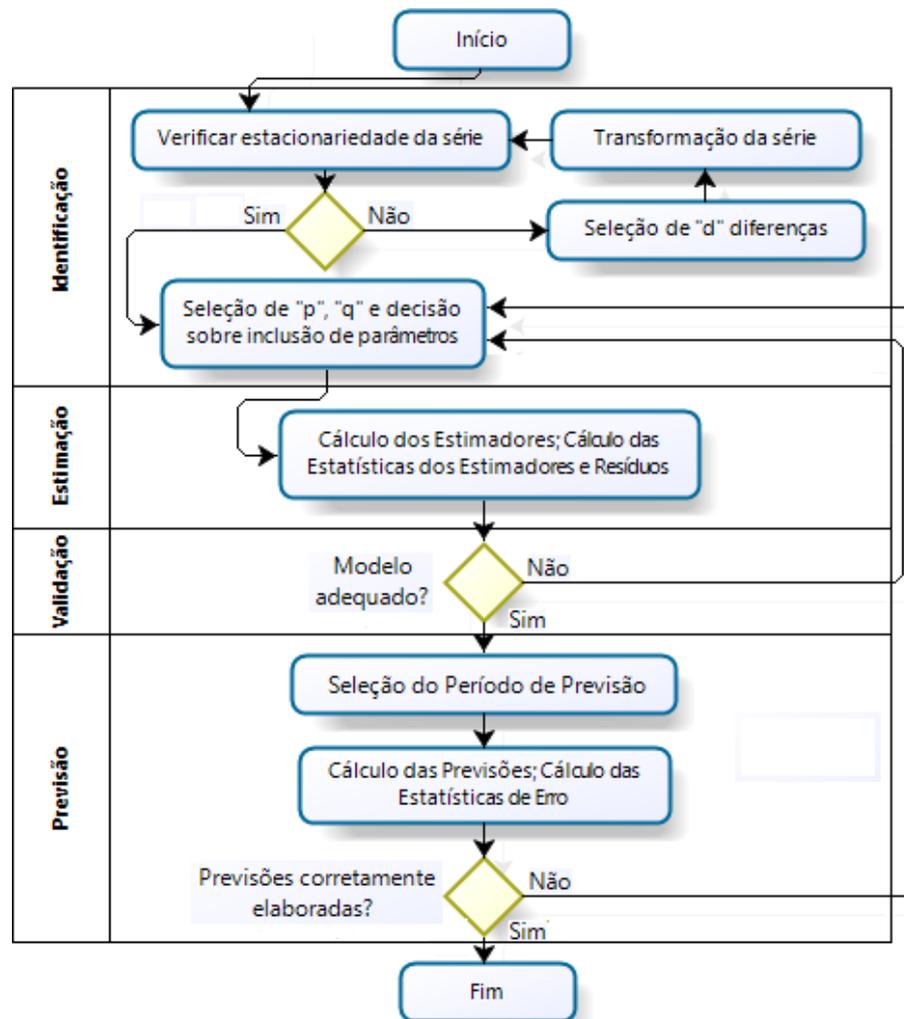
Além dos filtros autorregressivos e de médias móveis, a investigação da autocorrelação pode indicar correlação entre os períodos da série analisada, apontando presença de sazonalidade. Nesse caso os modelos com componentes sazonais são chamados de SARIMA (*Seasonal Autoregressive Integrated Moving Average*). Os modelos denominados SARIMA são compostos da parte não sazonal, com parâmetros iguais aos modelos ARIMA (p,d,q) e de uma parte com os parâmetros sazonais (P, D, Q) $_s$, em que o “ s ” indica a ordem da sazonalidade. Dessa forma, a descrição genérica do modelo é denotada SARIMA (p, d, q) (P, D, Q) $_s$ (WERNER; RIBEIRO, 2003).

A parte sazonal do modelo pode ser detectada a partir das funções de autocorrelação e autocorrelação parcial, em que a função decaí de forma senoidal. Uma sazonalidade de ordem 12 apresentará uma autocorrelação significativa nas defasagens “12, 24, 36 ...” (WERNER; RIBEIRO, 2003).

2.1.2.4 Etapas da Metodologia de Box-Jenkins

A modelagem de Box-Jenkins se constitui de um ciclo iterativo, permitindo ao fim determinar o melhor modelo predictor com base nas características de autocorrelação da série estudada (BOX; JENKINS, 1976). Na Figura 3 ilustra-se a metodologia.

Figura 3 – Etapas da Metodologia de Box-Jenkins



Fonte: Adaptado de Pereira e Requeijo (2008)

Inicialmente é verificado a estacionariedade da série e realizada as devidas transformações, se necessárias. Nesta etapa também é determinado o modelo para representar a série por meio da análise da função de autocorrelação (FAC) e autocorrelação parcial (FACP), utilizando os critérios previamente discutidos na seção 2.2, resumidos no Quadro 1.

Quadro 1 – padrões teóricos da FAC e FACP para seleção de filtros

Tipo de Modelo	Padrão Teórico da FAC	Padrão Teórico da FACP
AR(p)	A função de autocorrelação com decaimento exponencial e/ou senoidal	A função de autocorrelação parcial decai de forma abrupta no <i>lag</i> significativo “ p ”
MA(q)	A função de autocorrelação decai de forma abrupta no <i>lag</i> significativo “ q ”	A função de autocorrelação parcial com decaimento exponencial e/ou senoidal
ARMA(p, q)	Declínio exponencial e/ou senoidal	Declínio exponencial e/ou senoidal

Fonte: Elaborado a partir de Souza (2016), Gujarati e Porter (2011), Morettin (2011)

Após selecionados os filtros para compor o modelo, parte-se para a estimação dos parâmetros “ p ” e “ q ”. A estimação dos parâmetros é realizada por meio do método dos mínimos quadrados ou pela função de máxima verossimilhança, embora ambos os métodos sejam eficazes, o método da máxima verossimilhança é mais utilizado pois é mais eficiente. Maiores detalhes sobre tais métodos, consultar Gujarati e Porter (2011) e Bueno (2008).

De acordo com Box e Jenkins (1976), a com a inclusão de muitos parâmetros no modelo ajustado pode ser prejudicial, pois o mesmo deve ser o mais parcimonioso possível. Para decidir sobre a inclusão ou não de parâmetros, os critérios *Akaike Information Criteria* – AIC (AKAIKE, 1973) e *Bayesian Information Criteria* – BIC (SCHWARZ, 1978) são utilizados. Tais critérios são considerados penalizadores visto que levam em consideração o número de parâmetros dos modelos e a variância dos erros gerados, dessa forma o modelo que apresentar menores valores para os critérios e AIC e BIC terá o melhor ajuste (MORETTIN, 2008). Os critérios de AIC e BIC são definidos pelas equações (21) e (22):

$$AIC(p, q) = \ln \sigma_{p,q}^2 + \frac{2(p+q)}{n} \quad (21)$$

$$BIC(p, q) = \ln \sigma_{p,q}^2 + (p+q) \frac{\ln(n)}{n} \quad (22)$$

Onde: p e q são os parâmetros conhecidos, n é o tamanho da amostra, \ln o logaritmo neperiano e σ^2 a variância estimada dos erros.

A validação do modelo consiste em verificar o ajuste ao comportamento real da série. A sequência de erros pelo modelo ajustado deve possuir características de ruído branco, ou seja, não autocorrelacionados, com média zero e variância constante $RB \sim (0, \sigma^2)$ (BUENO, 2008). Além disso, medidas de acurácia podem ser usadas para discriminar entre os modelos concorrentes aquele que possui melhor ajuste (MONTGOMERY; JENNINGS; KULAHCI, 2007). As principais medidas de acurácia são descritas no Quadro 2.

Quadro 2 – Medidas de acurácia

Sigla	Descrição	Equação
MAE	Erro Médio Absoluto	$\frac{\sum_{t=1}^n \varepsilon_t }{n} \quad (23)$
MAPE	Erro Percentual Médio Absoluto	$\frac{\sum_{t=1}^n \varepsilon_t / Z_t * 100}{n} \quad (24)$
RMSE	Raiz do Erro Quadrático Médio	$\frac{\sqrt{\sum_{t=1}^n (\varepsilon_t)^2}}{n} \quad (25)$
U-Theil	Coefficiente U de Theil	$\frac{\sqrt{\sum_{t=1}^n (\varepsilon_t)^2}}{\sqrt{\sum_{t=1}^n (Z_t - Z_{t-1})^2}} \quad (26)$

Fonte: Adaptado de Bueno (2008)

Onde: ε_t = Erro de previsão no instante t ; n = Número de observações; Z_t = Valor real no tempo t e $t = 1, 2, \dots, n$.

A última etapa consiste comumente em um dos objetivos principais da aplicação da metodologia de Box-Jenkins: a realização de previsões. A definição do horizonte de previsão, assim como os métodos de verificação da acurácia das previsões dependem da natureza do estudo realizado. Segundo Johnson e King (1988), se a previsão abrange até três passos à frente, é considerado curto prazo. Se o horizonte for maior que 20 períodos é considerado longo prazo. Se for realizada em algum período intermediário entre os citados, a previsão é considerada de médio prazo.

2.1.3 Redes Neurais Artificiais

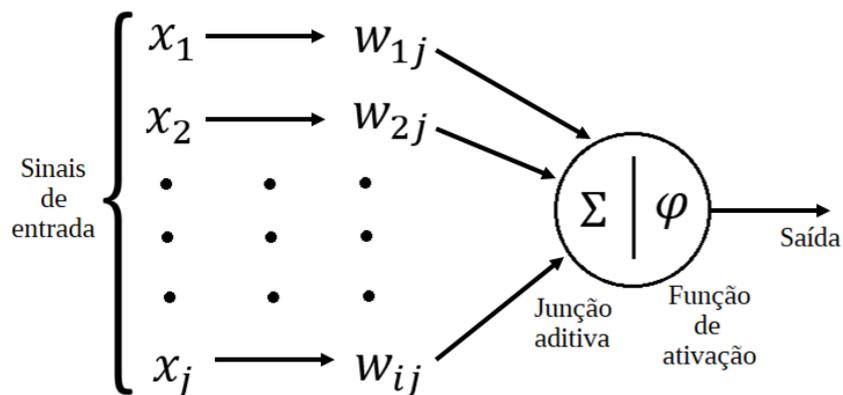
Modelos de Redes Neurais, ou também denominados de Redes Neurais Artificiais (RNA) possuem diversas aplicações práticas, amplamente utilizadas na modelagem de sistemas dinâmicos por sua capacidade de reconhecer e aprender padrões complexos e não-lineares

(HAYKIN, 2001). Tal abordagem foi desenvolvida inspirada no processo de informação do cérebro humano, por meio de algoritmos de treinamentos, sendo também uma abordagem bastante difundida para realização de previsões em séries temporais, sobretudo com padrões não-estacionários (MONTGOMERY; JENNINGS; KULAHCI, 2007).

A publicação de McCulloch e Pitts (1943) denominada “*A Logical Calculus of the Ideas Immanent in Nervous Activity*” é considerado o trabalho seminal para o desenvolvimento do conceito de RNA, abrindo uma nova área científica de estudo. Contribuições fundamentais para o desenvolvimento da RNA são creditadas a: Hebb (1949), que instituiu a capacidade de aprendizagem às RNA; Widrow (1957), desenvolveu o princípio que deu origem ao algoritmo *backpropagation*, sendo um dos mais utilizados no treinamento de uma RNA; Rosenblatt (1962), desenvolveu o modelo *perceptron*, contendo múltiplos neurônios em rede (JACOBS, 2014; KOVÁCS, 2006).

A generalização de um modelo Redes Neurais Artificiais é descrita por quatro classificações principais: neurônios, tipo de modelo, redes e aprendizado. A estrutura básica de um neurônio artificial compõe quatro componentes: conexões, junção aditiva, função de ativação e o viés ou *bias* (MARTINS; WERNER, 2014). Na Figura 4 ilustra-se um modelo teórico de um neurônio artificial.

Figura 4 – Modelo de um neurônio artificial



Fonte: Hair et al. (2005)

As conexões realizadas entre os elos são denominadas de sinapses, dessa forma a junção aditiva combina os sinais de entrada x_j com os pesos w_{ij} , sendo i o índice do neurônio e j o índice do sinal de entrada da sinapse conectada a um neurônio. A junção aditiva constitui uma combinação linear dos sinais de x_j com os respectivos pesos w_{ij} . O viés funciona como um

regulador de entrada, aumentando ou reduzindo o seu valor (JACOBS, 2014; MARTINS, 2011; HAIR et al., 2005). A função aditiva pode ser representada pela equação (27):

$$h_i = \sum_{j=1}^N w_{ij}x_j + b_i \quad (27)$$

Onde: h_i representa a saída da junção aditiva; x_j os sinais de entrada; w_{ij} os pesos atribuídos a cada sinal de entrada; b_i representa o viés; e N o total de sinais de entradas no modelo.

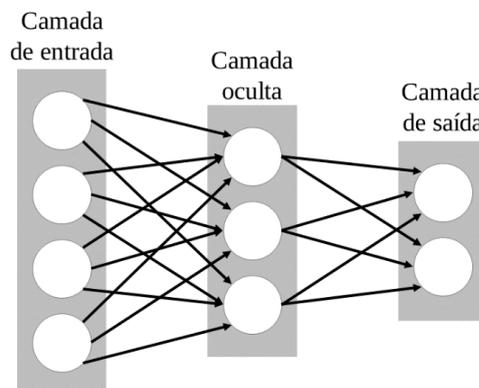
O elemento seguinte é a função de ativação cujo objetivo é limitar a amplitude do sinal de saída de um neurônio. A família de funções mais utilizadas são as funções sigmóides, sendo aplicada em cada somatório resultante da junção aditiva (TSENG; YU; TZENG, 2002). A equação (28) representa a função de ativação:

$$\varphi = f(h_i) = 1/(1 + e^{-h_i}) \quad (28)$$

Onde: φ representa a saída da função de ativação; e h_i é a saída da junção aditiva.

Os modelos de RNA são subdivididos em classes de acordo com o formato de funcionamento, sendo as redes alimentadas por múltiplas camadas consideradas as mais conhecidas e utilizadas, tendo superior capacidade preditiva em modelos temporais (QI; ZHANG, 2001). Tal classe se diferencia pela presença de camadas ocultas, permitindo captar comportamentos temporais mais complexos, como não-estacionariedade e sazonalidade. A configuração de uma RNA com múltiplas camadas é representada na Figura 5.

Figura 5 – Rede neural com múltiplas camadas



A notação adotada neste estudo para representar uma rede de múltiplas camadas, segue a nomenclatura: $A - B - C$, em que A representa o número de neurônios na camada de entrada, B representa o número de neurônios na camada oculta, e C representa o número de neurônios na camada de saída. Dessa forma, a Figura 5 teria a notação 4-3-2, com quatro neurônios de entrada, três na camada oculta e dois neurônios na saída (JACOBS, 2014; FLORES, 2009).

Dentre as aplicações possíveis, a realização de previsões a partir de RNA, especificamente com a utilização do modelo *Multilayer Perceptron* (MLP) é a mais difundida por permitir a realização de previsões com modelos univariados, utilizando os períodos defasados da própria série na camada de entrada. O modelo considera a utilização de funções não-lineares de acordo com a estruturação da rede construída, podendo ser considerado um modelo genérico autorregressivo não-linear (ZHANG; PATUWO; HU, 2001; JACOBS, 2014), conforme a equação (29):

$$\hat{Z}_t = f(Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}) \quad (29)$$

Onde: Z_t corresponde ao valor da série no período “t”; “p” o número de camadas de entrada na RNA; “f” a função linear ou não-linear.

Assim como em modelos clássicos de previsão, o erro em um modelo de RNA é calculado pela equação (30):

$$\varepsilon_t = Z_t - \hat{Z}_t \quad (30)$$

Onde: ε_t representa o erro de previsão no instante t ; Z_t o valor real da série no período t e \hat{Z}_t o valor estimado pela RNA no período t .

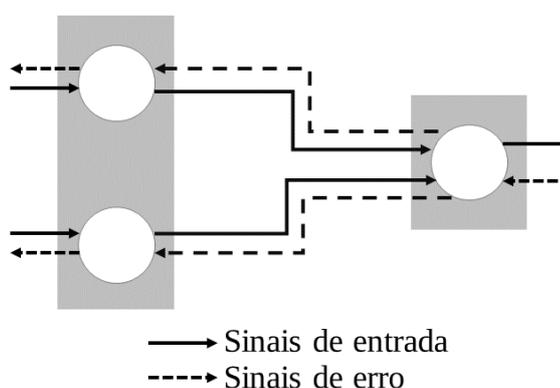
O erro gerado pelo modelo, também comumente chamado na literatura de sinal e erro, é propagado de volta as camadas de entrada fazendo o caminho inverso. Durante esse percurso os pesos das sinapses são reajustados otimizando o novo erro a fim de minimizar esse sinal. Tal procedimento é conhecido como retropropagação do erro ou *backpropagation*, sendo um dos algoritmos mais utilizados no treinamento de RNA (HAYKIN, 2001). Dessa forma os parâmetros de uma RNA são ajustados minimizando a função da soma dos erros quadráticos, conforme a equação (31):

$$SEQ = \sum_t^n (Z_t - \hat{Z}_t)^2 \quad (31)$$

Onde: SEQ representa a soma dos erros quadráticos; Z_t o valor real da série no período t e \hat{Z}_t o valor estimado pela RNA no período t .

Assim, em uma rede totalmente conectada o sinal segue na direção dos neurônios de saída, enquanto os sinais de erros percorrem o caminho contrário reajustando os parâmetros a cada novo ciclo de treinamento, conforme a Figura 6. O algoritmo é semelhante ao método dos mínimos quadrados médios (MQM), de acordo com Haykin (2001), a retropropagação pode ser considerada uma generalização do MQM, sendo um dos métodos de treinamento mais difundidos na literatura. Maiores detalhes sobre o método *backpropagation* podem ser encontrados em Ripley (1996) e Kovács (2006).

Figura 6 – Fluxos de sinais de uma RNA com múltiplas camadas



Fonte: Adaptado de Haykin (2001)

O modelo MPL apresenta como limitação a interpretação dos modelos ajustados, assim como restrições de uso quanto a pequenas amostras. A dificuldade de interpretação de um modelo MPL é chamado de efeito caixa preta, pois apesar de ser possível identificar as camadas ocultas presentes em um modelo, seu exato funcionamento é de difícil interpretação, assim como os parâmetros e pesos, tornando o modelo comumente não interpretável. Entretanto o foco principal do modelo é a realização de previsões, não inviabilizando seu uso por suas limitações (HAYKIN, 2001; FLORES, 2009).

A previsão de séries temporais utilizando modelos de RNA considera a divisão da série estudada em duas partes distintas, comumente denominadas de período de treino (*in sample*) e de teste (*out sample*), em que o período de treino é utilizado para o ajuste dos parâmetros e o período de teste para a validação do modelo a partir da análise das medidas de acurácia. Desta forma, as etapas para a utilização do modelo MPL são: (i) definição dos períodos de treino e teste; (ii) definição do número de camadas; (iii) definição dos parâmetros iniciais; (iv)

treinamento da RNA; (v) escolher modelo melhor ajustado de acordo com as medidas de acurácia; (iv) realização de previsões (JACOBS, 2014; FLORES, 2009; TSENG; YU; TZENG, 2002).

A definição da estrutura a ser utilizada em uma RNA para realização de previsões não segue uma regra única, havendo diversas abordagens na literatura. Zhang, Patuwo e Hu (2001) sugerem a construção da estrutura da RNA baseada na estrutura de autocorrelação da série temporal a ser modelada. Na prática, uma das abordagens mais difundidas é treinar diversos modelos de RNA com diferentes estruturas ajustadas a mesma série de dados, e decidir por aquela que apresentar menores erros.

2.2 COMBINAÇÃO DE MODELOS DE PREVISÕES

Na busca por modelos cada vez mais acurados, pesquisadores têm colocado esforços em desenvolver métodos capazes de aumentar a precisão de previsões em diversas áreas (FIRMINO; MATTOS NETO; FERREIRA, 2014). Com a disponibilidade de diversos modelos, selecionar o mais adequado pode ser um grande desafio visto que as técnicas variam de acordo com acurácia, horizonte, custos, complexidade e disponibilidade de dados (ZOU; YANG, 2004).

Nesse contexto, Clemem (1989) argumenta que a combinação de previsões é uma abordagem atraente, uma vez que, ao contrário de se preocupar em selecionar o melhor modelo para a série estudada, o pesquisador deve buscar quais modelos podem contribuir com o aumento de acurácia, uma vez combinados. Nesse mesmo sentido, Rausser e Oliveira (1976) comentam que comumente no processo de realização de previsões, em que são ajustados 2 ou 3 modelos, utiliza-se alguma medida de acurácia para selecionar o melhor e os demais são descartados, muitas vezes perdendo alguma informação capturada pelos modelos não selecionados.

Wallis (2011) afirma que uma forma atrativa de obter previsões acuradas é combinar diferentes modelos de previsão, pois os métodos de previsão combinados podem melhorar a precisão, assim como reduzir a variância dos erros. Isso se deve ao fato da escolha de um modelo em detrimento de outro não abranger todas as particularidades que cada técnica contempla, visto que cada abordagem captura algum tipo de informação que influencia na previsão realizada (MARTINS; WERNER, 2014). Dessa forma, a previsão combinada é uma técnica a ser considerada na busca de um modelo mais preciso (SOUZA et al., 2011).

Para realização da combinação de modelos, Flores e White (1989) sugerem uma estrutura dividida em duas etapas: (i) seleção dos modelos de previsão, que tratará da tarefa de selecionar métodos que se adequem corretamente à série estudada pelos critérios de: acurácia, horizonte, custos, complexidade e dados disponíveis; (ii) consiste na seleção do método de combinação, em que a preocupação estará em definir a forma que as previsões serão combinadas, existindo diversos métodos propostos.

2.2.1 Estudos Recentes com Combinação de Previsões

Com o objetivo de compor um portfólio de estudos recentes sobre métodos para combinação de previsões, na Tabela 2 são apresentadas as principais informações acerca de pesquisas recentes dentro dessa temática. Como critério de seleção foram considerados artigos publicados em periódicos, nos últimos 10 anos, que abordavam o desenvolvimento ou aplicação de métodos de combinação de previsões, tanto em contextos práticos, como teóricos.

Tabela 2 – Estudos de combinação de previsões de séries temporais

(continua)

Autor	Ano	Preditores individuais	Método de Combinação	Periódico
Oliveira; Assis; Firmino; Ferreira	2017	ARIMA; RNA	Modelo de Cópulas; Média Simples; Variância Mínima	Information Sciences
Rosienkiewicz; Chlebus; Detyna	2017	Regressão; RNA	AIC; BIC	Applied Mathematical Modelling
Pang; Gebka	2017	Holt-Winters; ARIMA; VEC	Variância Mínima	Int. Journal of Production Research
Yin; Liu; Hou	2016	-	Componentes Principais	Information Sciences
Azevedo; Campos	2016	Suavização Exponencial; ARIMA	Regressão Múltipla	Int. Journal of Production Research
Jacobs; Souza; Zanini	2016	Box-Jenkins; RNA	Inverse Mean Square Error	IEEE Latin America
Xiao; Shao; Liang; Wang	2016	Regressão; RNA	Otimização	Applied Energy
Santos; Vellasco	2015	Holt-Winters; ARIMA	Neural Expert Weighting (NEW)	Expert system with applications
Aye; Balcilar; Gupta; Majumdar	2015	Holt-Winters; ARIMA; RNA	Média Simples; Componentes Principais; Discounted Mean-Square	Int. J. Production Economics
Firmino; Mattos Neto; Ferreira	2014	ARIMA; RNA	Máxima Verossimilhança	Neural Networks

Tabela 2 – Estudos de combinação de previsões de séries temporais

(conclusão)

Autor	Ano	Preditores individuais	Método de Combinação	Periódico
Rodrigues; Stevenson	2013	Regressão Logística; RNA	KK Combination	Int. Journal of Forecasting
Martins; Werner	2012	ARIMA; RNA	Média Simples; Variância Mínima	Expert system with applications
Asadi; Tavakoli; Hejazi	2012	ARIMA; PSO	Otimização	Expert system with applications
Wan; Lou; Ji; Yan	2012	Holt-Winters; Decomposição	Partial Least Square (PLS)	American Journal of Operations Research
Lee; Tong	2011	ARIMA; RNA	Genetic Programming	Knowledge-Based Systems
Wang; Chang	2010	Holt-Winters; ARIMA	Fuzzy Neural Network (FNN)	Expert system with applications
Doganis; Aggelogiannaki; Sarimveis	2008	Holt-Winters; ARIMA; RNA	Model Predictive Control (MPC)	Int. Journal of Production Research

Fonte: Elaborado pelo autor

O estudo realizado por Oliveira et al. (2017) argumenta que a utilização de combinação de previsões é superior em termos estatísticos quando comparado às previsões individuais, neste estudo os autores propõem uma forma de combinação baseada em modelos de cópulas, utilizando com preditores individuais os modelos ARIMA e de RNA. O estudo compara a eficácia do modelo proposto em relação à combinação pelo método da variância mínima e por meio de média simples. Ao fim do estudo, o modelo proposto se mostra superior quando as distribuições dos erros das previsões individuais divergem, tal resultado é obtido por meio de um estudo simulado com 1027 séries, assim como pela modelagem de duas séries reais.

O estudo seguinte, realizado por Rosienkiewicz, Chlebus e Detyna (2017), aborda um modelo híbrido para previsão de demanda dedicado a indústria de mineração, os autores utilizam modelos de regressão e de RNA combinados a partir dos critérios de AIC e BIC. Para verificar a eficácia do método proposto é realizado um estudo simulado, chegando à conclusão que o modelo proposto é superior quando comparado à modelos tradicionais.

Nessa mesma perspectiva, Pang e Gebka (2017) utilizam modelos de suavização exponencial e a modelagem ARIMA, juntamente com um Modelo Vetorial de Correções de Erros (VEC), combinados através do método da variância mínima. Os autores aplicam a metodologia proposta para prever a taxa de transferência de containers em um porto localizado na Indonésia. Os resultados demonstram, que para o caso estudado, o método de Holt-Winters

multiplicativo foi superior para prever o comportamento geral do sistema, e o modelo VEC proveu os melhores resultados modelando os terminais portuários individualmente, porém ao combinar as previsões os resultados foram superiores.

Yin, Liu e Hou (2016) propuseram combinar previsões a partir de um modelo multivariado, com o objetivo de avaliar a qualidade de produtos em um processo industrial. O método desenvolvido pelos autores é baseado em regressão por componentes principais, o qual testa o modelo proposto com um exemplo numérico e um estudo de caso em uma indústria de vinhos. Os autores não abordam como foi obtido as previsões individuais, focando no desenvolvimento e aplicação do modelo partindo do pressuposto que tais previsões já existam e que estão adequadamente ajustadas. Ao fim do estudo o método utilizado se mostrou superior as previsões individuais.

O estudo de Azevedo e Campos (2016) utiliza os modelos de suavização exponencial e a modelagem ARIMA combinados por regressão linear múltipla para prever o preço do óleo bruto no mercado *spot*. Os autores utilizam séries de janeiro de 1994 a junho de 2012 para estimar os modelos, e de julho de 2012 a junho de 2013 para validá-los. Os resultados encontrados demonstraram que o modelo ajustado de suavização exponencial foi superior ao ARIMA, porém o modelo combinado foi mais acurado quando comparado aos individuais.

Outro estudo, realizado por Jacobs, Souza e Zanini (2016), avaliou diversos métodos de combinação para prever a demanda agregada de uma indústria de lácteos, utilizando um modelo sazonal ARIMA juntamente com um modelo de RNA para obter as previsões individuais. Os resultados encontrados pelos autores demonstraram, que para o caso estudado, o método *inverse mean square* obteve a melhor acurácia, sendo 56% superior ao modelo SARIMA e 66,5% ao modelo de RNA.

O estudo realizado por Xiao et al. (2016) combina modelos de previsão por meio de um algoritmo de otimização, utilizando RNA em conjunto com um modelo de regressão para obtenção das previsões. Os autores propõem o modelo de combinação baseado na otimização dos pesos de ponderação, utilizando inteligência artificial com o objetivo de minimizar o erro médio percentual absoluto (MAPE). O estudo foi realizado a partir de um experimento numérico, permitindo concluir que o modelo proposto se mostrou superior aos demais, apresentando menor MAPE.

Santos e Vellasco (2015) apresentam em seu estudo uma nova abordagem para combinação de previsões, de forma não-linear e dinâmica. Os autores utilizam os modelos de Holt-Winters e Box-Jenkins combinados por meio do modelo proposto denominado de *“Neural expert weighting”*. A proposta dos autores baseia-se nos modelos de RNA, visando otimizar os

pesos de modo não-fixo ao longo da combinação. O estudo apresenta aplicações reais em dois estudos de caso, permitindo ao fim constatar a eficácia do modelo proposto.

Aye et al. (2015) abordam 26 modelos para prever o preço das ações das redes varejistas da África do Sul, sendo 23 deles provenientes das famílias de modelos autorregressivos, de suavização exponencial e baseados em RNA, e outros 3 modelos de combinação: por média simples, por componentes principais e o por *Discounted Mean-Square*, que atribui pesos maiores para as observações mais recentes. Ao fim do estudo é argumentado pelos autores que os modelos não-lineares se mostraram superiores comparados aos lineares, devido à volatilidade presente neste tipo de série, sendo o modelo de combinação *Discounted Mean-Square* o que produziu melhores resultados para o estudo.

O estudo de Firmino, Mattos Neto e Ferreira (2014) utiliza os modelos ARIMA e de RNA combinados por um algoritmo proposto pelos autores que, baseado no critério AIC como decisor, a partir da função de Máxima Verossimilhança para combinar os preditores individuais. Os autores utilizam quatro séries reais, provenientes de índices de ações para ilustrar a aplicabilidade do modelo proposto, chegando a resultados satisfatórios ao fim do estudo.

Rodrigues e Steveson (2013) utilizam um modelo de regressão logística combinado com RNA, por meio do modelo conhecido como *KK Combination*, baseado em uma estrutura flexível com função de regressão logística, sendo o modelo resultante baseado em um vetor combinado das previsões por atribuição de pesos. Os autores aplicam a abordagem proposta em um portfólio de investimentos objetivando reduzir os erros de previsão e consequentemente aumentar o retorno dos investidores.

Outro estudo abordado é o de Martins e Werner (2012). Os autores modelam uma amostra de séries industriais provenientes do banco de dados da *M3 competition* (MAKRIDAKIS; HIBON, 2000), que contém séries reais de vários setores da economia. A abordagem proposta utiliza a metodologia de Box-Jenkins e RNA combinadas através de média simples e pelo método da Variância Mínima, levando em consideração a correlação entre os erros de previsão. Ao fim do estudo a combinação de previsões se mostrou superior as previsões individuais, sendo o método da Variância Mínima o que obteve melhor desempenho.

Asadi, Tavakoli e Hejazi (2012) utilizam os modelos ARIMA e *Particle Swarm Optimization* (PSO) combinados por meio de otimização. A modelagem PSO é uma técnica de otimização oriunda de simulação de modelos sociais. Os autores denominam o modelo proposto de PSOARIMA, e apresentam como principal vantagem a capacidade de acurácia em pequenas amostras, demonstrando este resultado em um estudo com uma série real com 35 observações

mensais, referentes ao preço do ouro, obtendo maior acurácia que um modelo ARIMA convencional.

Wan et al. (2012) aplicam um método de combinação de previsão baseado no conceito de *Partial Least Square*. Tal técnica é considerada em problemas estatísticos multivariados, desenvolvida a partir do conceito de componentes principais com o objetivo de solucionar problemas de múltipla correlação entre as variáveis modeladas. Os autores aplicam o modelo proposto a partir da combinação de previsões de Holt-Winters e por meio de decomposição, utilizando um conjunto de séries de vendas da indústria do cigarro da província de Anhui, na China. Ao fim da pesquisa os autores demonstraram que, para o caso estudado, o modelo proposto foi superior em relação as previsões individuais.

O estudo realizado por Lee e Tong (2011), utilizou os modelos ARIMA e de RNA combinados através de um modelo não-linear utilizando algoritmo de programação genética. O estudo utiliza algumas séries reais para exemplificar o modelo proposto, permitindo demonstrar a eficácia do modelo e melhorando a acurácia em relação aos preditores individuais.

Wang e Chang (2010) realizam um estudo propondo a combinação dos modelos ARIMA e de Holt-Winters por meio de um modelo de RNA baseado na lógica *fuzzy*, nomeado *Fuzzy Neural Network* (FNN). Os autores aplicam a abordagem para prever a demanda de fabricação de painéis de energia em Taiwan, obtendo menores valores para a estatística MAPE comparados aos outros modelos considerados.

Doganis, Aggelogiannaki e Sarimveis (2008) utilizam a abordagem *Model Predictive Control* (MPC) para propor um modelo de controle de inventários a partir de previsões provenientes dos modelos de Holt-Winters, ARIMA e RNA. O MPC é apresentado como um método de controle para variáveis em sistemas dinâmicos que utiliza métodos de otimização. Os autores testam a abordagem proposta em um estudo de caso utilizando dados reais do setor industrial. O modelo composto se mostrou mais acurado que os resultados individuais, contribuindo positivamente para o gerenciamento e controle do sistema de suprimentos estudado.

Entre todos os estudos discutidos, não é observado a aplicação única de um modelo ótimo para realizar previsões, assim como não é visto a adoção de uma estratégia única para realizar combinações. Como já abordado no início deste capítulo, Flores e White (1989) argumentam que a seleção de modelos adequados as características dos dados estudados, e a estratégia correta para combinar tais modelos é de grande importância para obtenção de resultados acurados.

Nas diversas abordagens vistas nos trabalhos, os modelos ARIMA são utilizados como previsores individuais na maioria dos estudos, seguidos por modelos de RNA e de Holt-Winters, o que já era esperado devido a consolidação da modelagem ARIMA e de Holt-Winters na literatura de séries temporais (GUJARATI; PORTER, 2011), assim como pela crescente popularidade dos modelos de RNA em diversos contextos de incerteza, sobretudo em casos de não-linearidade (AGAMI et al., 2009).

Quanto a combinação, vários métodos são utilizados com abordagens distintas, conforme discutido ao longo desta seção. Grande parte dos estudos abordados tratam do desenvolvimento de novas formas de combinar preditores, evidenciando a constante busca dos pesquisadores da área por meios mais acurados de realizar previsões (FIRMINO; MATTOS NETO; FERREIRA, 2014). As combinações pela média simples e pelo método da variância mínima são observadas com maior frequência e, mesmo quando não utilizados, são citados em grande parte dos trabalhos como abordagens difundidas e consolidadas.

2.2.2 Método da Variância Mínima

O método da Variância Mínima foi proposto por Bates e Granger (1969), tal método consiste em combinar previsões de forma linear e objetiva, atribuindo um peso “ w ” para a primeira previsão, e um peso complementar ($1-w$) para a segunda previsão, conforme pode ser visto na equação (32):

$$F_c = wF_1 + (1 - w)F_2 \quad (32)$$

Onde: F_c é a previsão combinada; w é o peso atribuído à previsão e F_1 e F_2 são as previsões originais a serem combinadas.

Para obtenção do valor dos pesos (w) descrito na equação (32), baseia-se na observação das variâncias dos erros das previsões a serem combinadas. Dessa forma, à previsão com maior variabilidade nos erros deve ser atribuída menor peso, a fim de obter-se maior acurácia. A seguir, é apresentada a equação (33) para a minimização da variância com erros das previsões individuais correlacionados, em que se realiza a diferenciação da variação da previsão combinada em relação à “ w ” e iguala-se o resultado a zero. Portanto, esse método ficou conhecido como método da variância mínima justamente por buscar a minimização da variância dos erros (BATES; GRANGER, 1969).

$$w = \frac{\sigma_2^2 - \rho\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2} \quad (33)$$

Onde: w é o peso atribuído à previsão; ρ corresponde ao coeficiente de correlação linear de Pearson entre os erros oriundos das previsões; σ_1^2 e σ_2^2 o valor da variância dos erros das previsões F_1 e F_2 .

Quando os erros observados não são correlacionados ($\rho = 0$) o cálculo de “ w ” é obtido de forma simplificada por meio da equação (34), pelo método da variância mínima com erros das previsões individuais não correlacionados.

$$w = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} \quad (34)$$

Onde: σ_1^2 e σ_2^2 representam a variância dos erros das previsões individuais.

Uma abordagem simplificada sugerida por Makridakis e Winkler (1983) é da utilização da média simples das previsões, pois segundo os autores a média pode prover maior acurácia da previsão, reduzindo sua variabilidade, pois não existindo informações de dependência entre as previsões, torna-se razoável sua utilização, podendo dar origem a resultados melhores que métodos mais sofisticados (STOCK; WATSON, 2004; KONIG et al., 2005).

A média aritmética é um dos mais populares métodos empregados na combinação de previsões (OLIVEIRA et al., 2017; MARTINS; WERNER, 2014). Dessa forma, a combinação por média com pesos iguais e fixos pode ser considerado um caso particular ou uma simplificação do Método da Variância Mínima, conforme equação (35):

$$F_c = 0,5F_1 + 0,5F_2 \quad (35)$$

Onde: F_c é a previsão combinada; F_1 e F_2 são as previsões individuais.

Outra abordagem sugerida por Granger e Ramanathan (1984), trata de combinar previsões em casos da existência de mais de dois preditores individuais, a partir de uma combinação linear sem restrição para os pesos, sendo estes estimados por Mínimos Quadrados em relação a série original. Tal método é equivalente ao Método da Variância Mínima, porém admite combinar mais de duas previsões, conforme a equação:

$$F_c = w_1F_1 + w_2F_2 + \dots + w_pF_p \quad (36)$$

Onde: F_c é a previsão combinada; w_p é o peso atribuído à cada previsão, sujeito à $\sum_{i=1}^p w_i = 1$; F_p são as previsões originais a serem combinadas.

Como já discutido, diversos estudos encontrados na literatura utilizam o Método da Variância Mínima e suas variações, sendo considerado uma técnica de combinação consolidada entre os pesquisadores para combinar previsões.

2.2.3 Modelos de Cópulas Para Combinação de Previsões

A utilização de modelos de Cópulas em séries temporais tem se intensificado como uma abordagem não-linear para modelagem em diversos problemas. Estudos realizados por Morettin et al. (2011), Bessa et al. (2012), Patton (2012), Liu (2015), Smith (2015), Lahiri e Yang (2016) abordam aplicações de modelos de Cópulas em séries temporais de diversos contextos. Entre as possíveis aplicações, os modelos de Cópulas podem ser adotados como uma abordagem para combinação não-linear de previsões individuais, sendo encontrada aplicações nos trabalhos de Oliveira et al. (2013), Assis (2017) e Oliveira et al. (2017).

Cópulas podem ser definidas como funções que medem a dependência entre variáveis, a partir das suas respectivas distribuições (MORETTIN, 2011), genericamente definida pela equação (37):

$$F(x, y) = C(F_1(x), F_2(y)) \quad (37)$$

Onde: F representa distribuição das variáveis; C o modelo de Cópula; x e y as variáveis modeladas.

A utilização de modelos de Cópulas para combinação de previsões em séries temporais segue três etapas: modelagem individual, em que consiste na realização das previsões por meio dos modelos já discutidos na seção 2.1; modelagem dos erros, em que se verifica os erros cometidos em cada modelo; combinação das previsões, em que se utiliza as distribuições dos erros para combinar as previsões através do modelo de Cópula ajustado (OLIVEIRA et al., 2017).

Os modelos de Cópulas permitem descrever dependências locais, ou seja, para todo par de variáveis x e y consideradas, diferentes das medidas clássicas de dependência que

consideram um único valor para todo conjunto de dados. Desta forma é possível avaliar de forma não-linear a dependência entre variáveis (GENEST; FAVRE, 2007; MORETTIN, 2011). Para o caso da combinação de previsões tais variáveis serão as previsões individuais, utilizando o modelo de Cópula para estimar a dependência em cada período de tempo da previsão.

Entre os diversos modelos existentes foi considerado neste trabalho a Cópula de Gumbel, pois a mesma não possui restrições quanto as distribuições das variáveis modeladas (NELSEN, 2006), a equação (38) representa a função da Cópula de Gumbel bivariada.

$$C(x, y) = \exp \left\{ - \left[(-\ln(x)^\theta) + (-\ln(y)^\theta) \right]^{\frac{1}{\theta}} \right\} \quad (38)$$

Onde: C representa o modelo de Cópula; x e y as variáveis modeladas; θ o parâmetro de dependência entre as variáveis.

A principal abordagem utilizada para a estimação dos parâmetros de uma Cópula é por meio do método denominado *Inference Function for Margins* (IFM). Esse método sugere a estimação dos parâmetros separadamente realizada em duas etapas: inicialmente são estimados os parâmetros das variáveis modeladas, para este estudo serão as previsões individuais, e em seguida estimado os parâmetros de dependência da Cópula, por exemplo, θ para o modelo de Gumbel e δ para a Copula Normal (OLIVEIRA et al., 2017).

Nesse método se adota a estimação por máxima verossimilhança, em que são otimizados os parâmetros das funções de forma reduzir o erro quadrático (YAN, 2007). Para mais detalhes sobre IFM consultar Joe e Xu (1996).

A combinação das previsões será realizada considerando os parâmetros de dependência local ajustados para cada Cópula, em que a previsão combinada resultará de uma ponderação local utilizando a equação (39):

$$F_c = \left(\frac{\sigma_2^2 - \rho\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2} F_1 \right) + \left(1 - \left(\frac{\sigma_2^2 - \rho\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2} \right) \right) F_2 \quad (39)$$

Onde: F_c é a previsão combinada; ρ corresponde ao parâmetro de dependência local, que pode assumir diferentes valores em instantes diferentes de tempo; σ_1^2 e σ_2^2 o valor da variância dos erros das previsões F_1 e F_2 . Dessa forma, a utilização de modelos de Cópulas para combinar previsões ocorrerá de forma não-linear, uma vez que os pesos de ponderação assumirão diferentes valores, capturando o efeito de dependência entre os preditores.

A abordagem proposta nesta pesquisa contempla tanto métodos de previsão (Suavização Exponencial, Box-Jenkins) e de combinação (média simples, variância mínima) já consolidados na literatura, assim como métodos emergentes de previsão (RNA) e de combinação (modelos de Cópulas) encontrados em pesquisas recentes, conforme discutido na seção 2.2.1. Desta forma, espera-se conseguir capturar de forma eficaz o comportamento temporal, assim como ajustar modelos acurados para as aplicações propostas.

No capítulo seguinte serão apresentados os aspectos metodológicos deste estudo, no qual é descrito a classificação da pesquisa quanto à natureza, à abordagem, os objetivos e os procedimentos, são descritas as variáveis consideradas e, por fim, apresentadas as etapas metodológicas adotadas.

3 MATERIAIS E MÉTODOS

Neste capítulo são apresentados os aspectos metodológicos adotados neste trabalho. Inicialmente é realizada a classificação da pesquisa quanto à natureza, à abordagem, os objetivos e aos procedimentos, posteriormente são descritas as variáveis consideradas no estudo e, por fim, apresentadas as etapas metodológicas adotadas.

3.1 ESTRUTURA E CLASSIFICAÇÃO DA PESQUISA

Prodanov e Freitas (2013) afirmam que uma pesquisa pode ser classificada em categorias, sendo estas: natureza da pesquisa; abordagem ao problema; objetivos; e procedimentos adotados. No Quadro 3 apresenta-se a classificação do presente trabalho de acordo com as categorias descritas acima.

Quadro 3 – Classificação da pesquisa

Categoria	Classificação
Natureza	Pesquisa aplicada
Abordagem	Pesquisa quantitativa
Objetivos	Pesquisa exploratória
Procedimentos	Bibliográfico/Estudo de caso

Fonte: Elaborado a partir de Prodanov e Freitas (2013) e Gil (2010)

Quanto à natureza, este estudo se caracteriza como aplicado pois visa a utilização de conceitos teóricos em casos práticos com o objetivo de resolver problemas específicos. A abordagem adotada é quantitativa visto que apresenta resultados quantificáveis, centrados na objetividade, em que as informações são transformadas em números, com a aplicação de métodos matemáticos. Quanto aos objetivos a abordagem adotada foi exploratória, pois visa explicar e gerar hipóteses sobre o problema em estudo, esse tipo de pesquisa é adotado em casos de pesquisas bibliográficas e estudos de caso (PRODANOV; FREITAS, 2013; GIL, 2010).

Por fim, quanto aos procedimentos, o presente estudo se classifica inicialmente como bibliográfico, pois busca analisar uma problemática através de referenciais teóricos já existentes (livros, artigos científicos, teses, dentre outros). Posteriormente a pesquisa adota como procedimento técnico o estudo de caso, em que o estudo proposto apresenta poucos objetivos e

é realizado a partir de um caso particular de modo a permitir o seu conhecimento amplo e detalhado (GIL, 2010).

A presente pesquisa será estruturada na forma de dois artigos:

Artigo I – O primeiro artigo aborda uma revisão sistemática de literatura acerca do desenvolvimento e aplicações de modelos de previsão em processos industriais. Nesse estudo foi realizada a busca nas bases Web of Science, Scopus e IEE, compondo um portfólio de artigos publicados em periódicos científicos nos últimos 10 anos. A análise da literatura foi realizada em três etapas: classificação detalhada do portfólio de estudos; análise de cocitação, de acoplamento bibliográfico e análise de similitude da coocorrência dos termos nos estudos; elaboração de um framework unificado para classificação das aplicações de métodos de previsão em processos industriais. Pretende-se submeter o artigo para publicação no periódico *Expert Systems With Applications* (ISSN: 0957-4174), o periódico publica estudos que abordam sistemas inteligentes, assim como estudos de revisão sobre tais temáticas. O periódico é atualmente classificado com Qualis A1 na área de avaliação Engenharia III, conforme a última classificação de periódicos (quadriênio 2013-2016).

Artigo II – O segundo artigo tem como objetivo a aplicação da combinação de métodos de previsões a partir de um estudo de caso realizado em uma empresa de grande porte do setor de mineração e logística, com séries de produção industrial provenientes de um sistema portuário integrado. Neste estudo o objetivo geral será ajustar um modelo de previsão combinada acurado, utilizando técnicas lineares e não-lineares. Pretende-se submeter o artigo para publicação no periódico *International Journal of Production Research* (ISSN: 0020-7543), que publica estudos originais que abordam problemas complexos de decisão no contexto de gerenciamento e controle de sistemas produtivos. O periódico é atualmente classificado com Qualis A2 na área de avaliação Engenharia III, conforme a última classificação de periódicos (quadriênio 2013-2016).

3.2 DESCRIÇÃO DAS VARIÁVEIS UTILIZADAS

A variável considerada no segundo artigo representa o Tempo Médio de Descarga (TMD) de *commodities* minerais, em um sistema de 8 viradores de vagões em uma planta industrial portuária, parte de um sistema logístico integrado de movimentação minério de ferro (contendo mina, ferrovia e porto), escoando toda a produção da mina de Carajás (Brasil), que atualmente é considerada a maior mina a céu aberto do mundo.

Os dados foram coletados a partir do banco de dados de apontamentos do sistema de automação industrial, sendo o principal sistema de controle de produção da organização. Dessa forma, os dados são referentes a um mês de operação, com observações a cada hora, gerando 8 séries temporais com 720 observações. O indicador é representado pela equação (40):

$$TMD = TTD/N^{\circ} \text{ Lotes} \quad (40)$$

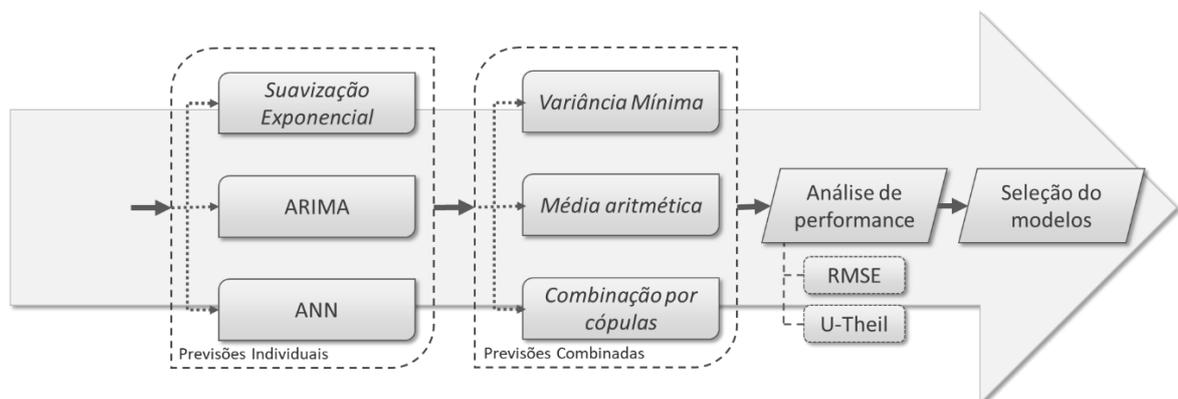
Onde: *TTD* representa o tempo total de descarga; *N° Lotes* representa o número total de lotes operados no período, sendo cada lote constituído de 110 vagões.

A variável TMD é considerada um indicador chave de produção, sendo o principal parâmetro de controle do sistema de descarga portuário. Devido ao processo de descarga ser fornecedor dos processos portuários posteriores de empilhamento e embarque, o controle sobre a variável TMD torna-se um importante fator a ser abordado nos processos decisórios, tais como o dimensionamento de produção e o planejamento de rotinas de manutenção, desta forma o modelo ajustado será utilizado como predictor do comportamento futuro da variável, servindo como uma ferramenta de apoio à tomada de decisão.

3.3 PROCEDIMENTOS DE MODELAGEM E ANÁLISE DOS DADOS

Para atingir os objetivos propostos, o estudo foi executado em três etapas: (i) modelagem individual das séries temporais; (ii) combinação das previsões; (iii) comparação das medidas de acurácia de cada previsão e seleção do melhor modelo, conforme ilustrado. O detalhamento de cada etapa é apresentado na sequência.

Figura 7 – Etapas de análise dos dados



Etapa 1 – Modelagem e previsões individuais: As séries temporais serão divididas em duas partes, sendo a primeira fase correspondente ao período de treino com cerca de 80% das observações e segunda a fase de teste com cerca de 20% das observações. A fase de treino foi utilizada para o ajuste dos modelos, enquanto a de teste para a avaliação das medias de acurácia na etapa 3. As previsões individuais foram obtidas a partir dos modelos de Suavização Exponencial, Box-Jenkins e de RNA, sendo selecionado como melhores modelos em cada previsão aqueles que apresentarem os melhores ajustes. As etapas de cada modelagem individual foram as seguintes:

(i) Suavização Exponencial: verificação da presença de componentes de tendência e sazonalidade; identificação do modelo (Suavização simples, linear de Holt, Holt-Winters); estimação dos parâmetros; realização da previsão e cálculo das medidas de acurácia.

(ii) Box-Jenkins: verificação da estacionariedade da série (teste ADF e KPSS); identificação do modelo (p, d, q); estimação dos parâmetros; validação do modelo (verificação dos ruídos e parâmetros); Realização da previsão e cálculo das medidas de acurácia.

(iii) RNA: definição do número de neurônios na camada de entrada; treinamento de um conjunto de RNA; escolha da melhor RNA de acordo com critérios de acurácia; realização da previsão e cálculo das medidas de acurácia.

Etapa 2 – Combinação das previsões: Após obtenção das previsões individuais, foram realizadas as combinações de três formas distintas: pelo método da variância mínima, por meio de média aritmética simples e por meio do modelo de cópula de Gumbel. Para a combinação das previsões foram considerados os dois previsores individuais que apresentarem menores erros quadráticos.

Etapa 3 – Comparação das medidas de acurácia: a análise de desempenho dos modelos propostos, tanto individuais quanto combinados, foi realizada pela comparação das medidas de acurácia RMSE e U-Theil, conforme apresentadas no capítulo 2 (Quadro 2). Foi selecionado como modelo predictor aquele que apresentar menores erros para as medidas propostas na fase de teste das séries modeladas. A utilização do RMSE como medida de avaliação de modelos é sugerida por Makridakis, Steven e Hyndman (1998) quando analisadas previsões na mesma unidade de medida.

Dessa forma, ao fim da pesquisa foi possível avaliar a aplicação dos modelos de previsões individuais, assim como dos modelos combinados, permitindo uma comparação e discussão da aplicabilidade dos métodos propostos em séries temporais do setor industrial. A metodologia disposta nesse capítulo permitirá uma avaliação objetiva e quantitativa, a partir de

critérios científicos, possibilitando uma discussão das evidências empíricas resultante deste estudo.

Como recurso computacional para tratamento, análise e modelagem dos dados foi utilizado o software livre 'R'. Para as análises bibliométricas foram utilizados os softwares livres Gephi 0.9.2 e Iramuteq versão 0.7 alpha 2.

A seguir são apresentados os resultados da pesquisa na forma de artigos, foram adotadas as estruturas e formatações definidas pelos periódicos a serem submetidos os estudos, conforme sugerido pelo Manual de Teses e Dissertações vigente.

ARTIGO I

Modelos de Previsão na Indústria: Revisão Sistemática da Literatura Recente e Direções de Pesquisa

Ícaro Agostino^a e Adriano Mendonça Souza^a

^a Universidade Federal de Santa Maria – UFSM, Av. Roraima, nº 1000, Santa Maria, Rio Grande do Sul, Brazil.

Resumo

O objetivo deste artigo é apresentar o resultado de uma revisão sistemática de literatura (RSL) acerca da aplicação e desenvolvimento de modelos de previsão no contexto industrial, sobretudo no contexto de processos de manufatura e gestão de operações. A pesquisa foi realizada levando em consideração a elaboração de um protocolo de pesquisa estabelecido objetivando conhecer, discutir e analisar as principais abordagens adotadas por pesquisadores da área. Foram revisados 354 artigos publicados em periódicos, no período compreendido entre 2008 e 2018, que constavam nas bases Web of Science, Scopus e IEEE Xplore. A RSL foi conduzida em três etapas: a classificação detalhada do *corpus* de pesquisa; a análise de coocorrência de citações, de coocorrência de termos textuais em conjunto com a análise de acoplamento bibliográfico; e a identificação de um *framework* unificado identificando as principais abordagens para a realização de previsões no contexto industrial e os enfoques de aplicações. Como resultado constatou-se que os três principais periódicos que vinculam as pesquisas nessa temática são *International Journal of Production Research*, *Computers and Industrial Engineering* e *Expert System With Applications*, foi identificado um crescimento do número de publicações ao longo do período, assim como demonstrada a relevância de importantes autores como George Box, Charles Holt e como mais central Guoqiang Zhang. Demonstrou-se uma predominância de abordagens envolvendo métodos estatísticos e de inteligência artificial com um grande direcionamento de aplicação em contextos de modelagem de processos de manufatura, previsão de demanda, planejamento, previsão de consumo energético e otimização de inventários. Por fim, foi proposto um *framework* relacionando os métodos aplicados com os contextos industriais analisados.

Palavras-chave: Revisão Sistemática de Literatura, Modelos de Previsão, Indústria, Gestão de Operações, Manufatura.

1. Introdução

A tomada de decisão em processos produtivos se apresenta como um problema complexo para decisores, enfrentando ambientes cada vez mais dinâmicos e voláteis, em que sistemas produtivos comumente estão sujeitos a efeitos estocásticos, como variações em tempos de processamento e falhas operacionais (Terkaj, Tolio e Urgo, 2015; Frazzon, Kück e Freitag, 2018, Agostino et al., 2019). Uma alternativa para subsidiar decisões em processos de produção é a utilização de modelos de previsão, apresentado por uma família de modelos estatísticos, econométricos e computacionais utilizados para prever o comportamento futuro de variáveis (Montgomery, Jennings e Kulaçci, 2015).

Realizar previsões é uma atividade indispensável no planejamento de atividades e nos processos de tomada de decisão (Werner, 2005; Wang e Chang, 2010), sendo amplamente utilizadas na modelagem de processos produtivos, no planejamento da produção e na previsão de demanda (Wang e Chang, 2010; Scholz-Reiter, Kück e Lappe, 2014; Rosienkiewicz, Chlebus e Detyna, 2017). A previsão pode ser entendida como a busca de informações sobre o comportamento futuro de uma variável a partir de um processo racional envolvendo incertezas. Nesse contexto, a previsão consiste em um processo metodológico que objetiva definir os dados futuros com base em modelos matemáticos e/ou subjetivos (Martins e Laugeni, 2009; Moreira, 2017).

Alguns estudos de revisão são encontrados na literatura atual abordando métodos de previsão em diversos contextos. Nenni, Giustiano e Pirolo (2013) analisaram modelos de previsão na indústria da moda, destacando a utilização de modelos tradicionais de suavização, modelos estatísticos e modelos de Redes Neurais Artificiais. Weron (2014) analisou a aplicação de modelos de previsão para o preço da eletricidade, destacando a aplicação de modelos multiagentes, modelos estatísticos e modelos de inteligência artificial. Cheng et al. (2015) analisaram a utilização de modelos de séries temporais em contextos de não linearidade e não estacionariedade aplicados a dados reais de manufatura e saúde. Não foram encontradas evidências na literatura pesquisada de estudos de revisão que aborde a utilização de modelos de previsão no contexto de sistemas produtivos de forma ampla, não limitando a um setor específico da indústria.

Diante do exposto, este estudo tem por objetivo realizar uma Revisão Sistemática de Literatura (RSL) abrangendo artigos publicados em periódicos, nos últimos 10 anos, que abordam o desenvolvimento ou aplicação de métodos previsão, aplicados a sistemas produtivos, permitindo conhecer, discutir e analisar as principais abordagens adotadas por pesquisadores da área.

Foi elaborado um protocolo de pesquisa condizente com o rigor metodológico exigido na condução de uma RSL visando o mapeamento e análise de pesquisas relevantes, apoiada nos protocolos de Tranfield, Denyer e Smart (2003), Kitchenham (2004) e Biolchini et al. (2005), o que resultou na composição do *corpus* de pesquisa. Dessa forma, as seguintes questões de pesquisa nortearam o desenvolvimento deste estudo:

- Quais as principais abordagens para a realização de previsões no contexto de sistemas produtivos?
- Quais autores são os principais contribuintes no desenvolvimento de pesquisas envolvendo métodos de previsão em sistemas produtivos?
- Quais países e periódicos concentram maior número de publicações? Existe uma evolução temporal da quantidade de publicações da temática?
- Quais são os principais contextos de aplicação de modelos de previsão em sistemas produtivos?

Este estudo apresenta um corte temporal apenas abrangendo o período compreendido entre 2008 e 2018, justificado pelo alto volume de publicações encontrados, impossibilitando uma análise mais profunda ao não considerar um limite de tempo específico, entretanto tal escolha permitiu apresentar um panorama atualizado das pesquisas e identificar de forma mais consistente direções e lacunas atuais.

Este estudo é o primeiro a apresentar o atual estado da arte tratando da temática de aplicações de modelos de previsões em um contexto amplo envolvendo processos industriais a partir de uma RSL. Como contribuições três pontos principais podem ser relacionados: (i) o presente artigo apresenta um portfólio atualizado dos modelos de previsão no contexto industrial, provendo um ponto de referência para pesquisadores e gestores industriais; (ii) é apresentada a caracterização do campo de pesquisa a partir da identificação dos veículos de publicações, frequência, principais autores e países relacionados ao desenvolvimento de pesquisas sobre a temática; (iii) é proposto um *framework* unificado relacionando características dos modelos de previsão com seus respectivos contextos de aplicações, identificando as direções atuais de pesquisa com a intenção de fornecer subsídios teóricos para o desenvolvimento de novas abordagens para previsão na indústria.

Além dessa introdução, o artigo está organizado da seguinte forma: na seção 2 são apresentados os aspectos metodológicos, abrangendo a descrição detalhada do protocolo de pesquisa desenvolvido, os critérios de seleção dos estudos, assim como recursos computacionais utilizados. Na seção 3 são apresentados e discutidos os resultados. Por fim na seção 4 são dispostas as conclusões e oportunidades de pesquisa encontradas.

2. Metodologia da pesquisa

A Revisão Sistemática de Literatura (RSL) foi conduzida a partir dos protocolos de pesquisa de Tranfield, Denyer e Smart (2003), Kitchenham (2004) e Biolchini et al. (2005), guiada pelas questões de pesquisa definidas na seção 1. Não é objetivo deste estudo entrar em detalhes a respeito do modelo de processo para a realização da RSL, mas utilizá-lo como um instrumento metodológico, dessa forma inicialmente foi construída uma *string* de busca a partir da inclusão de termos relacionados ao tema de pesquisa envolvendo as áreas de modelos de previsão e processos produtivos e/ou industriais. As versões finais das *strings* construídas para as bases de periódicos Web of Science, Scopus e IEEE Xplorer são apresentadas na Tabela 1, assim como a quantidade de resultados em termo do número de publicações em cada uma das bases. Três critérios de inclusão foram considerados nesse estudo: apenas artigos publicados em periódicos, artigos na língua inglesa, artigos publicados no período compreendido entre 2008 e 2018.

Tabela 1 – *Strings* de Busca

Database	String de busca	Resultados
Web of Science	<i>TS=(("industrial process" OR manufactur* OR "operations management") AND (forecast*))</i>	1051
Scopus	<i>(TITLE-ABS(("industrial process" OR manufactur* OR "operations management") AND (forecast*)) OR AUTHKEY(("industrial process" OR manufactur* OR "operations management") AND (forecast*)))</i>	1511
IEEE	<i>(("industrial process" OR manufactur* OR "operations management") AND (forecast*))</i>	117
Total		2679

Fonte: Elaborado pelos autores.

Foi encontrado um total de 2.679 artigos, sendo 1.051 da base Web of Science, 1.511 da Scopus e 117 da IEEE Xplorer, os termos utilizados para o primeiro constructo foram “*industrial process*”, “*manufactur**” e “*operations management*” e para o segundo “*forecast**” sendo a busca aplicada no título, resumo e palavras chave. Para a validação da *string* de busca foram utilizados os artigos da Tabela 2 como grupo de controle, conforme sugerido por Kitchenham (2004), dessa forma garantiu-se a abrangência dos termos ao considerar artigos já previamente conhecidos que abordavam a temática e continham diferentes termos correlatos, sendo a *string* validada quando foi capaz de encontrar todos os estudos do grupo de controle.

Tabela 2 – Estudos de Controle

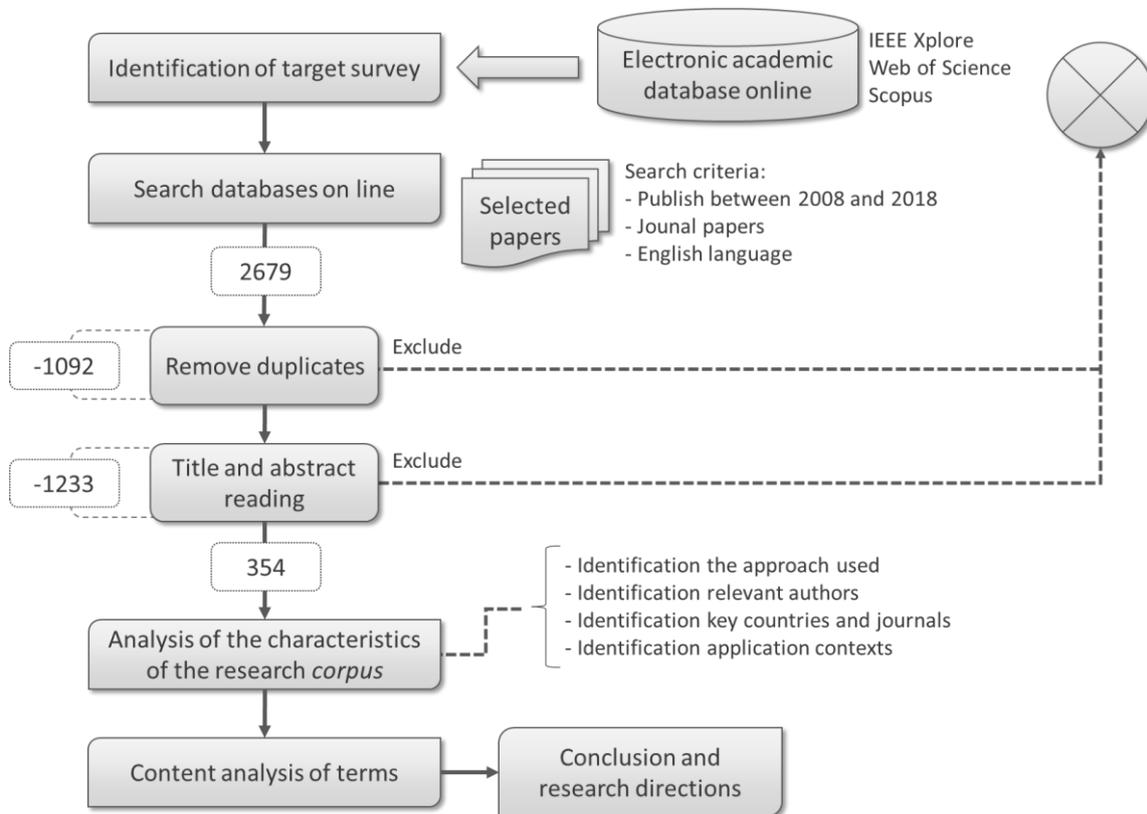
Referência	Título	Indexação
Wang e Chang (2010)	<i>Adaptive neuro-fuzzy inference system for combined forecasts in a panel manufacturer</i>	Web of Science, Scopus
Scholz-Reiter, Kück e Lappe (2014)	<i>Prediction of customer demands for production planning Automated selection and configuration of suitable prediction methods</i>	Web of Science, Scopus
Albey et al. (2015)	<i>Demand Modeling With Forecast Evolution: An Application to Production Planning</i>	Web of Science, Scopus, IEEE
Zurita et al. (2018)	<i>Multimodal Forecasting Methodology Applied to Industrial Process Monitoring</i>	Web of Science, Scopus, IEEE

Fonte: Elaborado pelos autores.

O protocolo de pesquisa foi então construído conforme o modelo de processo apresentado na Figura 1, o principal propósito desse estudo foi selecionar apenas artigos que claramente tratavam da aplicação e/ou desenvolvimento de modelos de previsão no contexto de sistemas produtivos e/ou industriais, dessa forma, a taxonomia de classificação incluindo todas as etapas foi composta da seguinte forma: (i) identificação do problema de pesquisa; (ii) a busca nas bases em conjunto com os critérios de exclusão; (iii) a remoção de artigos duplicados, que ao mesmo tempo foram encontrados em mais de uma base; (iv) a leitura do título e resumos dos artigos após remoção das duplicatas a fim de identificar o alinhamento do estudo com as questões de pesquisa e temática definida; (v) a análise

detalhada das características do corpus de pesquisa; (vi) por fim, a análise de termos visando identificar focos de aplicações, direcionamentos das pesquisas e lacunas teóricas.

Figura 1 – Processo metodológico da pesquisa



Fonte: Elaborado pelos autores.

A análise da RSL foi conduzida em três etapas: (i) a classificação detalhada do *corpus* de pesquisa, incluindo a identificação dos principais periódicos que vinculam pesquisas da temática abordada, análise da evolução temporal da frequência de publicação, a identificação dos artigos mais relevantes do *corpus* de acordo com o número de citações e a identificação dos países relacionados às publicações; (ii) a análise de coocorrência de citações com o objetivo de identificar os principais autores contribuintes da área, assim como a formação de grupos de citação, a análise de coocorrência de termos textuais a partir da frequência de termos e análise de similitude objetivando identificar o direcionamento dos estudos, ainda nessa etapa foi realizada a análise de acoplamento bibliográfico com o objetivo de verificar a consistência da área de pesquisa; (iii) por fim realizou-se a construção de um *framework* teórico a partir da identificação das principais abordagens para a realização de previsões no contexto industrial e os enfoques de aplicações.

Como recurso computacional foram utilizados os *softwares* Gephi 0.9.2 (Bastian, Heymann e Jacomy, 2009), e Iramuteq versão 0.7 alpha 2 (Ratinaud e Déjean, 2009; Vizeu Camargo e Justo, 2013; Vanz e Stumpf, 2010).

3. Resultados e discussões

Nesta seção são apresentados os resultados em três etapas, incluindo a classificação do *corpus* de pesquisa, a análise de redes e de coocorrência de termos e a construção de um *framework* unificado das técnicas e contextos de aplicações.

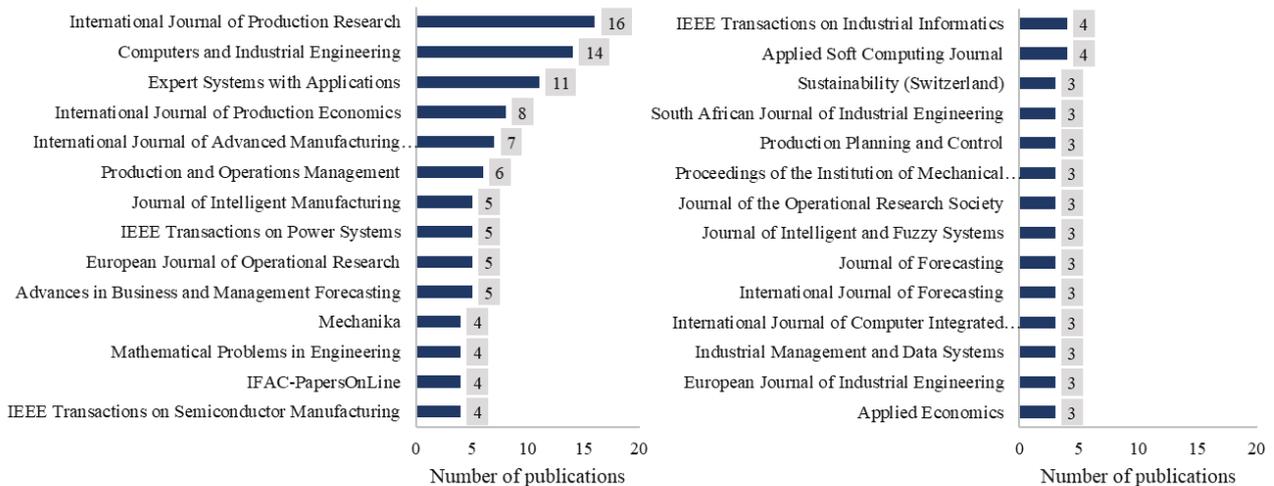
3.1 Classificação detalhada do corpus de pesquisa

O objetivo desta seção é responder, de forma gráfica, os seguintes questionamentos: Quais periódicos vinculam pesquisas relacionando modelos de previsão no contexto industrial? Qual

frequência anual das publicações? Quais países mais desenvolvem pesquisas sobre a temática? Quais os estudos mais citados do *corpus* de pesquisa analisado?

Na Figura 2 apresenta-se o conjunto de periódicos que vinculam os artigos constituintes do *corpus* analisado que apresentaram três ou mais artigos publicados, assim como a frequência de publicação de cada periódico. Ao todo, 210 periódicos diferentes foram computados, sendo que 28 concentram 3 ou mais publicações, representando cerca de 13% do total de periódicos com cerca de 40% das publicações vinculadas. Os três principais periódicos, em termos de frequência foram o *International Journal of Production Research*, *Computers and Industrial Engineering* e *Expert System With Applications*.

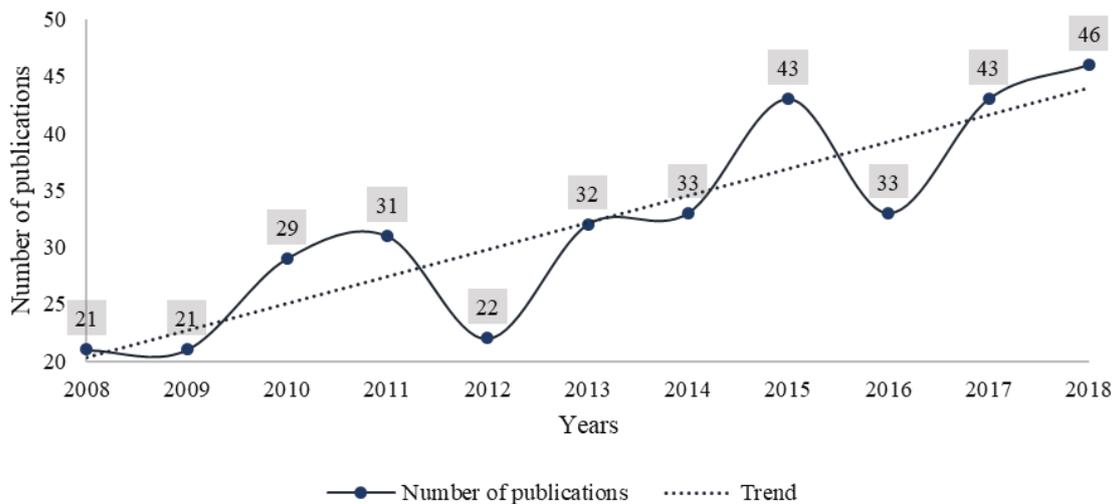
Figura 2 – Quantidade de artigos publicados por periódicos do *corpus* analisado



Fonte: Elaborado pelos autores.

A evolução temporal da frequência de publicações é apresentada na Figura 3. É possível evidenciar um crescimento da área de pesquisa, com um aumento de cerca 119% entre 2008 e 2018, apresentando uma tendência de crescimento com flutuações ao longo do período.

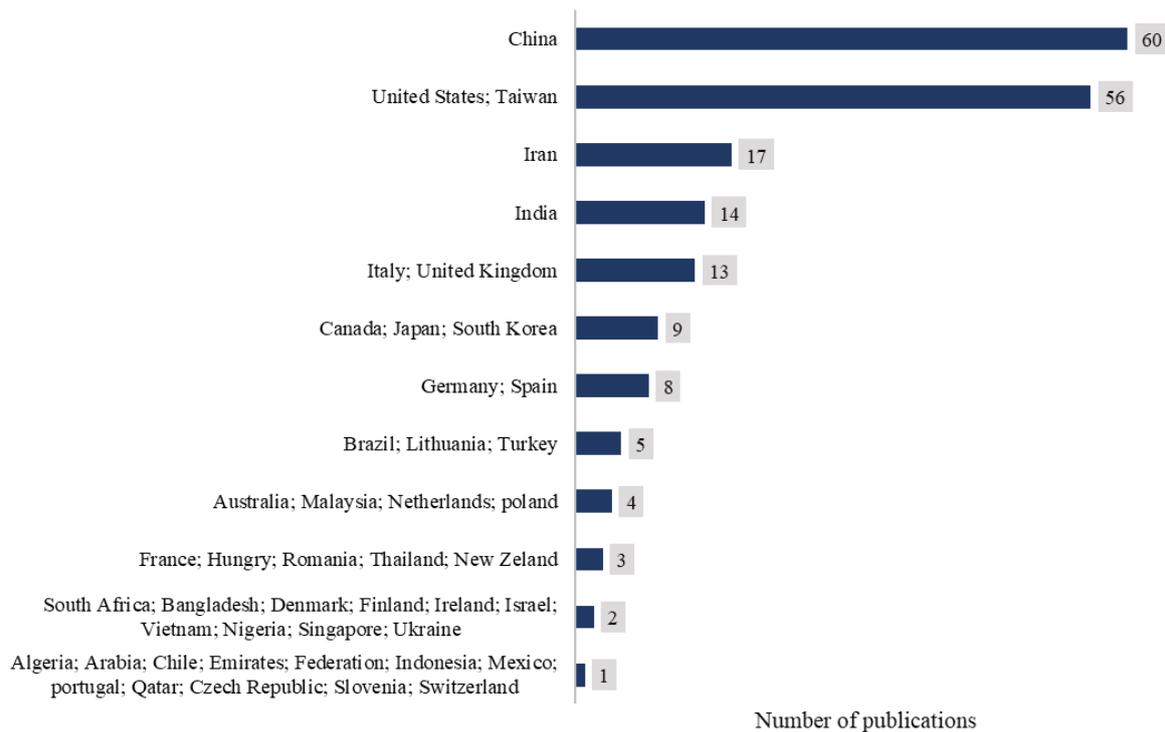
Figura 3 – Evolução temporal do número de publicações



Fonte: Elaborado pelos autores.

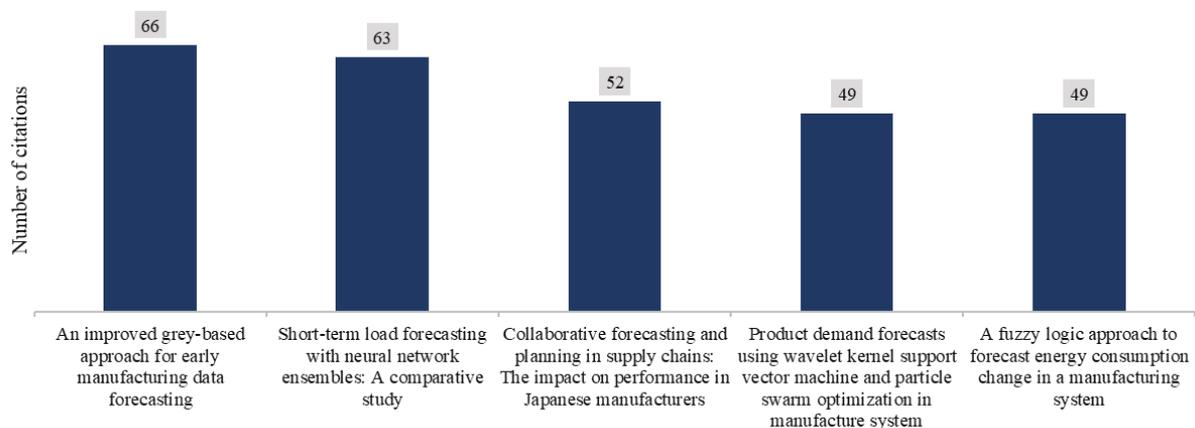
A distribuição do número de publicações por país ao qual os autores afirmam pertencer é apresentada na Figura 4. Foram identificados 46 países diferentes, com grande concentração das publicações relacionadas à China (60), United States (56) e Taiwan (56), concentrando cerca de 49% do total de publicações.

Figura 4 – Quantidade de artigos publicados por países



Fonte: Elaborado pelos autores.

Na Figura 5 apresenta-se os cinco artigos mais citados do *corpus* analisado, utilizando as citações indexadas na base Scopus. O artigo desenvolvido por Li, Yeh e Chang (2009) é o mais citado, o estudo trata do desenvolvimento da abordagem *adaptive grey prediction model* (AGM) aplicado a pequenas amostras em processos de manufatura. O segundo estudo mais citado, desenvolvido por Felice e Yao (2011) trata da realização de previsões de curto prazo para demanda de energia por sistemas industriais comparando diversas abordagens baseadas em modelos de Redes Neurais Artificiais (ANN). Na sequência, Nakano (2009) trata do impacto de previsões colaborativas em cadeias de suprimentos e processos de produção no setor de manufatura do Japão. Wu (2010) apresenta uma abordagem híbrida combinando *wavelet kernel support vector machine* e *swarm optimization* para produção de demanda industrial. Por fim, o quinto estudo mais citado foi desenvolvido por Lau et al. (2008), os autores apresentam uma abordagem a partir da lógica *fuzzy* para previsão de consumo energético em uma indústria baseado na análise de fatores de produção.

Figura 5 – Artigos com maior número de citações do *corpus* analisado

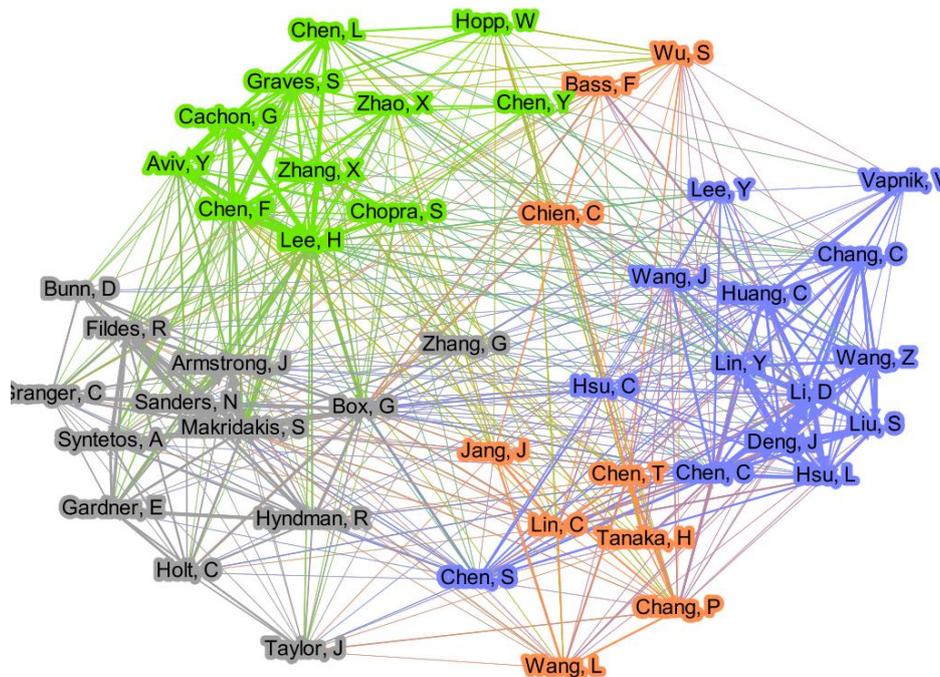
Fonte: Elaborado pelos autores.

3.2 Análise de redes e de cocorrência de termos

O objetivo desta seção é responder, de forma gráfica, os seguintes questionamentos: Quais autores são mais cocitados nos estudos? Quais estudos possuem maior grau de acoplamento? Quais termos são mais recorrentes? Quais os padrões de investigações dos estudos de acordo com a cocorrência de termos?

A análise de cocitação é apresentada na Figura 6, para a construção do gráfico foram considerados todos os autores com 10 ou mais ocorrências de cocitação. A distribuição da rede foi realizada pelo algoritmo de Fruchterman e Reingold (1991) e agrupados pela estatística “*Modularity Class*” (Newman, 2006), sendo o tamanho dos vértices proporcionais à estatística *Eingvector Centrality* (Prell, 2012). Dessa forma, percebe-se a formação de quatro grupos de autores, com destaque (em cinza) para o grupo formado pelos autores com maior ocorrência de cocitação, nesse grupo é possível identificar importantes autores relacionados a temática de previsão, como George Box, Charles Holt, Cliver Granger, Spyros Makridakis, Robin Hyndman entre outros. O autor com maior centralidade foi Guoqiang Zhang, indicando forte influência na área de pesquisa para o período considerado, sendo que os trabalhos mais citados do autor no *corpus* analisado são direcionados para a realização de previsões com modelos de ANN (Zhang, Patuwo e Hu, 1998; Zhang, 2003; Zhang e Qi, 2005).

Figura 6 – Rede de cocitação dos autores citados nas publicações

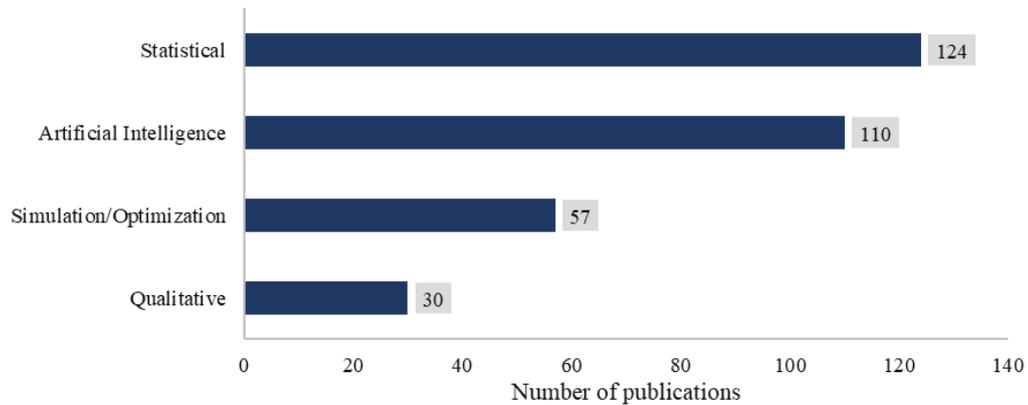


Fonte: Elaborado pelos autores.

Na Figura 7 é apresentada a análise de acoplamento bibliográfico realizada com o objetivo de identificar a formação de grupos de similaridade entre os estudos com o maior número de citações do *corpus* analisado, a partir da ocorrência de referências em comum (Egghe e Rousseau, 2002). Para a construção da rede foram considerados todos os estudos com 10 ou mais citações. Assim como na análise de cocitação, distribuição da rede foi realizada pelo algoritmo de Fruchterman e Reingold (1991) e agrupados pela estatística “*Modularity Class*” (Newman, 2006), sendo o tamanho dos vértices proporcionais à estatística *Eingvector Centrality* (Prell, 2012). Quatro grupos são identificados a partir da rede formada, sendo: vermelho: formado por estudos que predominantemente abordam modelos de inteligência artificial; azul: estudos utilizam abordagens híbridas; amarelo: estudos com abordagens de otimização; verde: modelos estatísticos de séries temporais; cinza: abordagens de combinações. A análise de acoplamento permite inferir que os estudos apresentam três abordagens teóricas principais: (i) modelagem por inteligência artificial; (ii) modelagem por modelos

apresentam grande abrangência de aplicação com enfoque quantitativo, tal fato pode ser explicado pela maior disponibilidade de dados. Peres e Fogliatto (2018) argumentam que nas últimas décadas, devido aos avanços tecnológicos, a disponibilidade de variáveis industriais aumentou significativamente, possibilitando a utilização de modelos mais robustos na modelagem de processos.

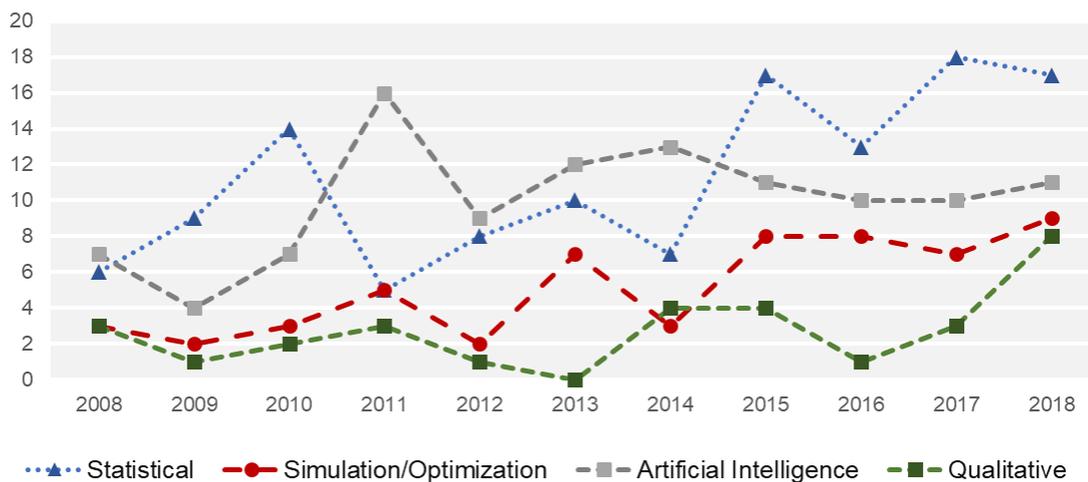
Figura 10 – Categorização dos métodos aplicados



Fonte: Elaborado pelos autores.

Com o objetivo de investigar tendências e direções de pesquisas, a Figura 11 apresenta a distribuição das categorias apresentadas anteriormente distribuídas de forma temporal ao longo do período considerado. Para o *corpus* analisado, é possível evidenciar que abordagens de inteligência artificial tiveram grande ocorrência entre os anos de 2011 e 2014, superando métodos estatísticos, que voltaram a ser mais recorrentes nos últimos quatro anos considerados. Nesse sentido o estudo de Makridakis, Spiliotis e Assimakopoulos (2018) que comparou modelos de aprendizado de máquina com modelos clássicos estatísticos, observando uma maior eficiência de modelos estáticos na ausência de grande quantidade de dados. Grande parte dos estudos encontrados lidavam com a limitação da baixa quantidade de informações disponíveis, não viabilizando aplicação de modelos de aprendizado.

Figura 11 – Evolução temporal dos métodos aplicados

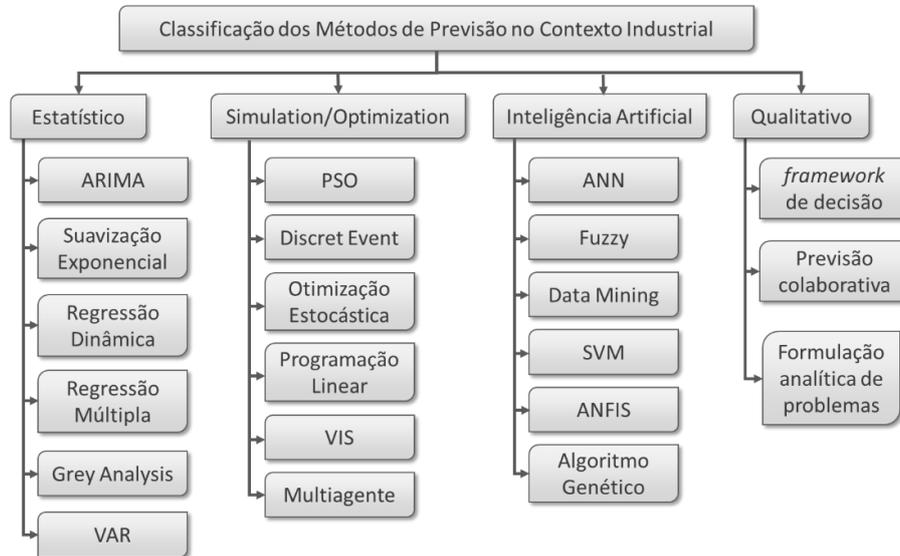


Fonte: Elaborado pelos autores.

Na Figura 12 é exibido uma estrutura de classificação das técnicas de previsão encontradas nos estudos analisados, categorizadas de acordo com os grupos definidos anteriormente, os métodos estatísticos a parecem de forma mais diversificada, comumente relacionados a dados do tipo série temporal. Entre os modelos de simulação e otimização os estudos se concentram em dois enfoques, o primeiro relacionado a realização de previsões simulando cenários futuros, e a segundo caso com a

utilização de otimização com técnicas de programação. O grupo relacionado a inteligência artificial apresenta técnicas principalmente relacionados a modelo de aprendizado de máquina em contextos de disponibilidade de grandes volumes de dados. Por fim, as abordagens qualitativas consistiam principalmente na construção de metodologias de previsão baseados no conhecimento de especialistas e modelos analíticos.

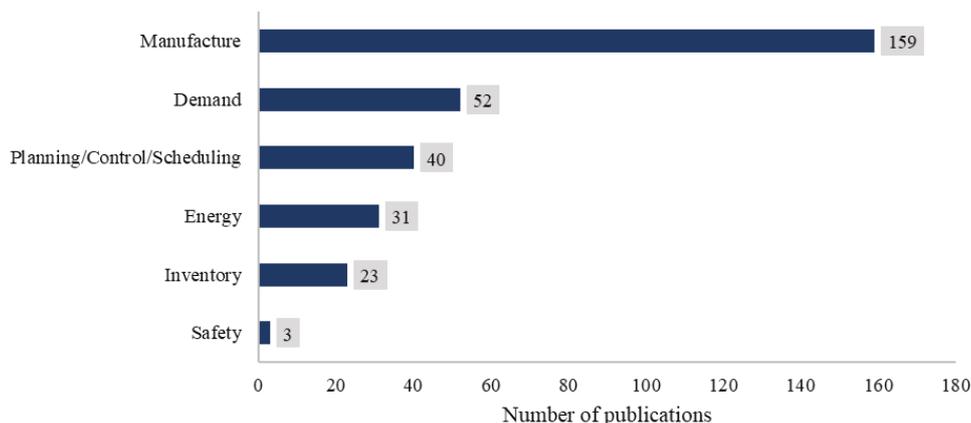
Figura 12 – Classificação dos métodos



Fonte: Elaborado pelos autores.

A investigação dos contextos de aplicação foi categorizada em seis grupos: (i) *Manufacture*: nesse grupo foram incluídos estudos que focavam na modelagem de processos, de indicadores de produção, custos de produção, dentre outros contextos correlatos. (ii) *Demand*: foram incluídos estudos que tratavam do problema de previsão de demanda. (iii) *Planning/Control/Scheduling*: foram incluídos estudos com enfoque na utilização de modelos de previsão como subsídios para o planejamento, controle e *scheduling*, esse grupo possui similaridade com o anterior, uma vez que a previsão de demanda é complementar a esses casos, porém decidiu-se separar em diferentes categorias devido aos estudos relacionados ao grupo (ii) se limitarem a previsão de demanda sem o enfoque de desdobramento nas demais funções gerenciais. (iv) *Energy*: nesse grupo foram incluídos estudos que tratavam da previsão de consumos energético por processos industriais. (v) *Inventory*: foram incluídos estudos que tratavam da previsão de inventários e estoque em processos de produção. Por fim, (vi) *Safety*: foram incluídos estudos que tratavam de previsão de acidentes no contexto industrial. A Figura 13 exibe a frequências das aplicações dos estudos.

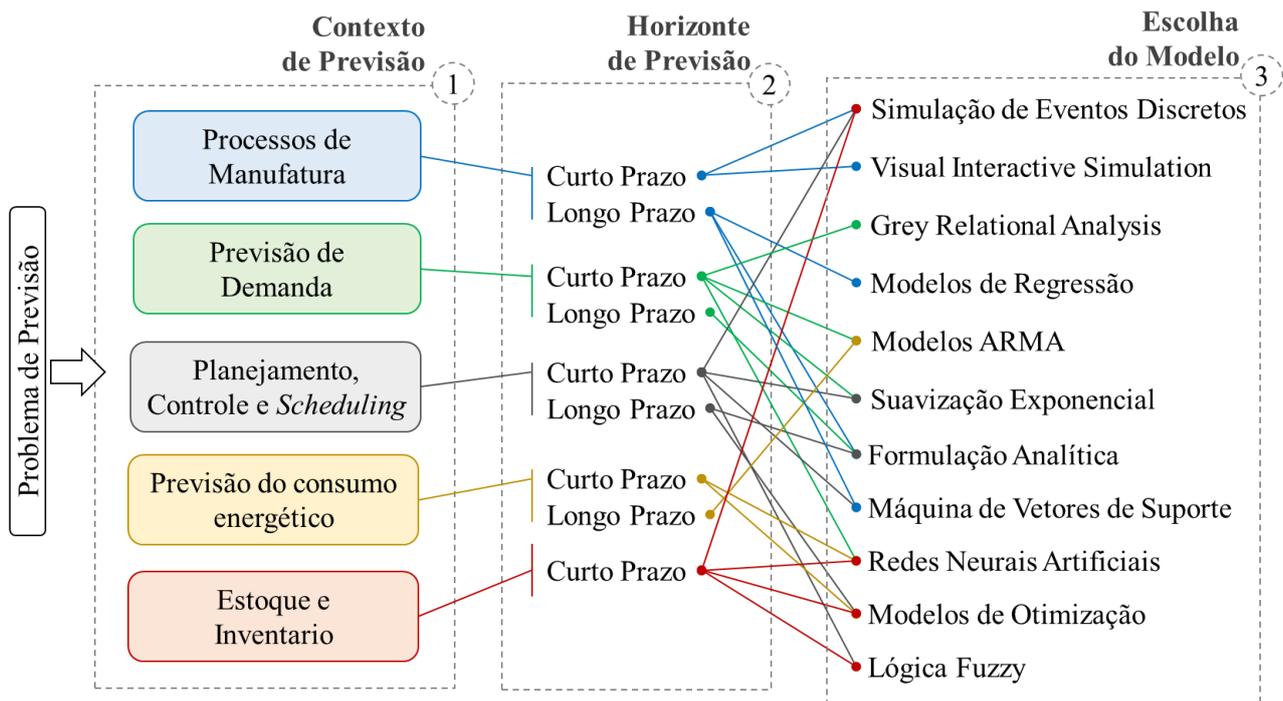
Figura 13 – Contextos de aplicação dos estudos



Fonte: Elaborado pelos autores.

A construção final do *framework* relacionando os contextos de aplicação com os modelos de previsão encontrados nos estudos constituídos do *corpus* é proposto na Figura 14. Foram identificadas três principais fatores associados a utilização de métodos de previsão no contexto industrial: (i) o contexto de aplicação, em que foram consideradas as categorias identificadas anteriormente com a exclusão do categoria “*safety*” pela baixa ocorrência, impedindo de realizar identificações mais profundas; (ii) horizonte de previsão, em que percebeu-se que modelos de simulação e de inteligência artificial são preferidos no curto prazo, e no longo prazo modelos de regressão e formulação analítica são mais recorrentes. (iii) escolha do modelo, em que ao final foram mantidas 11 diferentes opções envolvendo os modelos mais recorrentes dentro das categorias já apresentadas.

Figura 14 – *Framework* de aplicação de modelos de previsão no contexto industrial



Fonte: Elaborado pelos autores.

O *framework* proposto, suportado pela análise dos estudos encontrados no processo sistemático de revisão, possibilitou relacionar os métodos de previsão com os contextos mais frequentes verificados nos estudos analisados, provendo um ponto inicial de referência para pesquisadores e engenheiros na utilização de modelos de previsão relacionado ao gerenciamento de sistemas produtivos.

4. Conclusões

Esse estudo revisou um escopo da literatura entre 2008 e 2018 para aplicação de modelos de previsão no contexto industrial, 354 estudos foram considerados a partir de uma busca sistematizada nas bases Web of Science, Scopus e IEEE Xplorer, utilizando critérios específicos de inclusão. A partir das análises realizadas cinco pontos emergem desse estudo, possibilitando responder as questões de pesquisa propostas inicialmente:

- Métodos quantitativos são claramente dominantes nesse campo de pesquisa, com ênfase em três categorias: (i) modelos estatísticos; (ii) modelos de inteligência artificial e (iii) modelos de simulação e otimização.
- Entre os principais autores, a partir da análise de cocitação realizada, estão George Box, Charles Holt, Spyros Makridakis, Robin Hyndman e como mais central Guoqiang Zhang.
- Os três principais periódicos que vinculam pesquisa nessa temática são *International Journal of production Research*, *Computers and Industrial Engineering* e *Expert Systems With*

Applications. E os principais países onde são desenvolvidas as pesquisas são China, Estados Unidos e Taiwan.

- Identificou-se um aumento geral do número de publicação ao longo do tempo, indicando o amadurecimento da área de estudo nos últimos 10 anos.
- Por fim, identificou-se cinco principais contextos de aplicações de modelos de previsão no setor industrial: (i) processos de manufatura; (ii) previsão de demanda; (iii) planejamento, controle e *scheduling*; (iv) previsão de consumo energético e (v) previsão de estoques.

Referências

- Agostino, I., Sousa, S., Frota, P., Daher, R., & Souza, A. M. (2019). Modeling and Simulation of Operations: A Case Study in a Port Terminal of Vale S/A. In *New Global Perspectives on Industrial Engineering and Management* (pp. 91-99). Springer, Cham.
- Albey, E., Norouzi, A., Kempf, K. G., & Uzsoy, R. (2015). Demand modeling with forecast evolution: an application to production planning. *IEEE Transactions on Semiconductor Manufacturing*, 28(3), 374-384.
- Bastian, M., Heymann, S., & Jacomy, M. (2009). Gephi: an open source software for exploring and manipulating networks. *Icwsn*, 8(2009), 361-362.
- Biolchini, J., Mian, P. G., Natali, A. C. C., & Travassos, G. H. (2005). Systematic review in software engineering. *System Engineering and Computer Science Department COPPE/UFRJ, Technical Report ES*, 679(05), 45.
- Cheng, C., Sa-Ngasoongsong, A., Beyca, O., Le, T., Yang, H., Kong, Z., & Bukkapatnam, S. T. (2015). Time series forecasting for nonlinear and non-stationary processes: a review and comparative study. *IIE Transactions*, 47(10), 1053-1071.
- Felice, M., & Yao, X. (2011). Short-term load forecasting with neural network ensembles: A comparative study [application notes]. *IEEE Computational Intelligence Magazine*, 6(3), 47-56.
- Egghe, L., & Rousseau, R. (2002). Co-citation, bibliographic coupling and a characterization of lattice citation networks. *Scientometrics*, 55(3), 349-361.
- Frazzon, E. M., Kück, M., & Freitag, M. (2018). Data-driven production control for complex and dynamic manufacturing systems. *CIRP Annals*.
- Fruchterman, T. M., & Reingold, E. M. (1991). Graph drawing by force-directed placement. *Software: Practice and experience*, 21(11), 1129-1164.
- Kitchenham, B. (2004). Procedures for performing systematic reviews. Keele, UK, Keele University, 33(2004), 1-26.
- Lau, H. C., Cheng, E. N. M., Lee, C. K., & Ho, G. T. (2008). A fuzzy logic approach to forecast energy consumption change in a manufacturing system. *Expert Systems with Applications*, 34(3), 1813-1824.
- Li, D. C., Yeh, C. W., & Chang, C. J. (2009). An improved grey-based approach for early manufacturing data forecasting. *Computers & Industrial Engineering*, 57(4), 1161-1167.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PloS one*, 13(3), e0194889.
- Martins, P. G., & Laugeni, F. P. (2009). *Administração da produção*. Saraiva.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction to time series analysis and forecasting*. John Wiley & Sons.
- Moreira, D. A. (2017). *Administração da produção e operações*. Editora Saraiva.

- Nakano, M. (2009). Collaborative forecasting and planning in supply chains: The impact on performance in Japanese manufacturers. *International Journal of Physical Distribution & Logistics Management*, 39(2), 84-105.
- Nenni, M. E., Giustiniano, L., & Pirolo, L. (2013). Demand forecasting in the fashion industry: a review. *International Journal of Engineering Business Management*, 5(Godište 2013), 5-36.
- Newman, M. E. (2006). Modularity and community structure in networks. *Proceedings of the national academy of sciences*, 103(23), 8577-8582.
- Peres, F. A. P., & Fogliatto, F. S. (2018). Variable selection methods in multivariate statistical process control: A systematic literature review. *Computers & Industrial Engineering*, 115, 603-619.
- Prell, C. (2012). *Social network analysis: History, theory and methodology*. Sage.
- Ratinaud, P., & Déjean, S. (2009). IRaMuTeQ: implémentation de la méthode ALCESTE d'analyse de texte dans un logiciel libre. *Modélisation appliquée aux sciences humaines et sociales MASHS*, 8-9.
- Rosienkiewicz, M., Chlebus, E., & Detyna, J. (2017). A hybrid spares demand forecasting method dedicated to mining industry. *Applied Mathematical Modelling*, 49, 87-107.
- Scholz-Reiter, B., Kück, M., & Lappe, D. (2014). Prediction of customer demands for production planning—Automated selection and configuration of suitable prediction methods. *CIRP Annals-Manufacturing Technology*, 63(1), 417-420.
- Terkaj, W., Tolio, T., & Urgo, M. (2015). A virtual factory approach for in situ simulation to support production and maintenance planning. *CIRP Annals*, 64(1), 451-454.
- Tranfield, D., Denyer, D., & Smart, P. (2003). Towards a methodology for developing evidence-informed management knowledge by means of systematic review. *British journal of management*, 14(3), 207-222.
- Vanz, S. A. D. S., & Stumpf, I. R. C. (2010). Scientific collaboration: theoretical and conceptual review. *Perspectivas em Ciência da Informação*, 15(2), 42-55.
- Vizeu Camargo, B., & Justo, A. M. (2013). IRAMUTEQ: um software gratuito para análise de dados textuais. *Temas em psicologia*, 21(2).
- Wang, F. K., & Chang, K. K. (2010). Adaptive neuro-fuzzy inference system for combined forecasts in a panel manufacturer. *Expert Systems with Applications*, 37(12), 8119-8126.
- Werner, L. (2005). Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião.
- Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International journal of forecasting*, 30(4), 1030-1081.
- Wu, Q. (2010). Product demand forecasts using wavelet kernel support vector machine and particle swarm optimization in manufacture system. *Journal of Computational and Applied Mathematics*, 233(10), 2481-2491.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.
- Zhang, G. P., & Qi, M. (2005). Neural network forecasting for seasonal and trend time series. *European journal of operational research*, 160(2), 501-514.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*, 14(1), 35-62.
- Zurita, D., Delgado, M., Carino, J. A., & Ortega, J. A. (2018). Multimodal Forecasting Methodology Applied to Industrial Process Monitoring. *IEEE Transactions on Industrial Informatics*, 14(2), 494-503.

ARTIGO II

Modelagem e previsão de indicadores operacionais: Uma abordagem combinada baseada em modelos lineares e não-lineares

Ícaro Romolo Sousa Agostino^a e Adriano Mendonça Souza^a

^a Universidade Federal de Santa Maria

(Recebido em XXXX; aceito em XXXX)

Neste artigo é proposto um modelo de previsão combinado para prever o comportamento de um sistema de descarga de minério em um terminal portuário a partir dos modelos de Suavização Exponencial, ARIMA e dos modelos de Redes Neurais Artificiais (ANN). A combinação das previsões foi realizada por três abordagens distintas: a combinação por média aritmética, pelo método da Variância Mínima, consistindo em uma combinação linear a partir da variância dos erros de previsão, e a partir de modelos de cópulas, sendo esta uma abordagem não linear baseada no grau de dependência das previsões individuais. Como medidas de avaliação dos modelos propostos foram utilizados os critérios RMSE e U-Theil. O estudo foi desenvolvido em uma gerência de operação portuária responsável pelo escoamento de toda a produção da mina de Carajás (Brasil) que atualmente é considerada a maior mina a céu aberto do mundo. As variáveis modeladas representam o Tempo Médio de Descarga (TMD) do sistema contendo oito viradores de vagões, com dados referentes a um mês de operação, gerando oito séries temporais com 720 observações cada. Os resultados encontrados demonstraram que os modelos ARIMA e ANN foram superiores em termos de acurácia em relação as previsões individuais, e os métodos de combinação por modelo de cópula produziram previsões mais acuradas em relação às demais abordagens de combinações adotadas.

Palavras-chave: Combinação de previsões; ARIMA; ANN; Holt-Winters; Modelos de cópulas.

1. Introdução

Decisões de curto prazo desempenham um importante papel no contexto organizacional, sobretudo no planejamento de operações e na alocação de recursos em processos produtivos (Wang e Petropoulos, 2016; Rashed et al., 2017). Nesse cenário, terminais portuários se apresentam como ambientes dinâmicos, dependendo de ferramentas que auxiliem no planejamento e no controle de operações, objetivando a minimização de esforços e o aumento da produtividade (Pani et al., 2014; Gómez, Camarero e Molina, 2015; Goedhals-Gerber, 2016; Agostino et al., 2019).

Nesse contexto, técnicas de previsão são apresentadas com o intuito de solucionar problemas diversos envolvendo riscos, pois possibilitam gerar subsídios que auxiliem os decisores na formulação de estratégias nos processos produtivos (Wang e Chang, 2010; Slack, Brandon-Jones e Johnston, 2013). Em geral, a realização de previsões no contexto organizacional utiliza métodos quantitativos, baseados na existência de registros de dados históricos. Entre os modelos quantitativos existentes para a realização de previsões, se destacam os modelos de séries temporais (Montgomery, Jennings e Kulahci, 2015).

Entre os trabalhos encontrados na literatura, Fung (2002) desenvolveu um modelo estruturado de correções de erros para prever taxa de transferência de containers nos terminais do porto de Hong Kong. Vlahogianni, Karlaftis e Golias (2005) utilizaram uma abordagem não linear com aplicação de modelos de redes neurais artificiais (ANN) para previsão de curto prazo do fluxo e ocupação de transporte. Schulze e Prinz (2009) analisaram a movimentação de containers nos portos da Alemanha utilizando os modelos SARIMA e o modelo de Holt-Winters, encontrando resultados superiores para o modelo SARIMA ajustado. Pang e Gebka (2017) utilizaram os modelos de Holt-Winters, modelos sazonais ARIMA e o modelo de Vetores de Correção de Erros (VEC) para prever a taxa de transferência de containers do porto de Tanjung Priok na Indonésia, encontrando resultados superiores para abordagem de combinação dos modelos.

Estudos envolvendo modelos quantitativos de previsão empregam em sua maioria os modelos de suavização exponencial, modelagem ARIMA e modelos de ANN (Hyndman e Athanasopoulos, 2018; Martins e Werner, 2012). Uma alternativa para obtenção de previsões mais eficazes consiste em combinar técnicas individuais de previsão, resultando em previsões estatisticamente superiores em termos de acurácia, comparadas às técnicas individuais (Hibon e Evgeniou, 2005). Diversos estudos apresentam resultados demonstrando que diferentes métodos de combinações obtiveram resultados mais acurados em relação a previsões individuais (Clemem, 1989; Makridakis e Hibon, 2000; Stock e Watson, 2004; Amendola e Storti, 2008; Doganis, Aggelogiannaki e Sarimveis, 2008; Jeong e Kim, 2009; Costantini e Pappalardo, 2010; Wallis, 2011; Azevedo e Campos, 2016; Wang e Petropoulos, 2016; Makridakis, Spiliotis e Assimakopoulos, 2018).

Entre os métodos de combinação de previsões, a média aritmética é um dos mais populares métodos empregados, trazendo resultados satisfatórios na redução da variabilidade das previsões (Stock e Watson, 2004; Koning et al., 2005; Martins e Werner, 2012). Outra abordagem bastante difundida é o método da mínima variância, consistindo na combinação linear de previsores individuais com adoção de pesos baseados nos erros das previsões para realizações das combinações (Bates e Granger, 1969; Timmermann, 2006; Martins e Werner, 2012).

Uma abordagem não linear para combinação de previsões proposta por Oliveira et al. (2017) utiliza o modelo de Cópula de Gumbel–Hougaard para combinação de previsões, obtendo resultados satisfatórios em relação às demais abordagens difundidas na literatura. A utilização de modelos de Cópulas em séries temporais tem sido discutida em diversos estudos recentes, como Morettin et al. (2011), Bessa et al. (2012), Patton (2012), Liu (2015), Smith (2015), Lahiri e Yang (2016) e Oliveira et al (2017), entretanto não é visto na literatura aplicações dessa abordagem em estudos de casos com séries reais com o objetivo de previsão, sobretudo no setor industrial.

Esta pesquisa propõe a combinação dos modelos de Holt-Winter, ARIMA e ANN para prever o comportamento de curto prazo do tempo médio de descarga de um sistema de descarga de minério composto por oito linhas de produção, sendo um indicador chave de desempenho do terminal portuário estudado. Para combinação das previsões foram utilizados os métodos da média aritmética, variância mínima e pelo modelo de cópulas de Gumbel–Hougaard.

Portanto, este estudo contribui com a área de pesquisa, pois apresenta uma abordagem robusta para previsão de curto prazo, não havendo na literatura atual consultada estudos semelhantes que englobem abordagens não lineares para combinação de previsões aplicadas aos indicadores chave de desempenho em terminais portuários. Além disso, a abordagem proposta é facilmente replicável a diversos contextos que envolvem problemas complexos de decisão.

O artigo está organizado da seguinte forma: na seção 2 é apresentada uma revisão de literatura dos modelos de suavização exponencial, ARIMA e ANN, assim como dos métodos de combinação de previsões. Na seção 3 são descritos os procedimentos metodológicos adotados. Na seção 4 é apresentado o estudo de caso. Na seção 5 são apresentados os resultados. Por fim, na seção 6 é apresentada a discussão e as considerações finais do artigo.

2. Revisão de Literatura

A revisão de literatura aborda os métodos de previsão utilizados neste estudo que darão suporte à aplicação empírica proposta. Foram abordados os modelos de suavização exponencial, ARIMA e ANN, assim como os métodos de combinação de previsões adotados: média aritmética, variância mínima, combinação baseada em cópulas.

2.1 Modelos de previsão

Nesta seção são apresentados os aspectos teóricos dos modelos de previsão adotados.

2.1.1 Suavização Exponencial

Entre os modelos de previsões existentes, os Métodos de Suavização Exponencial popularizados por Holt (1957) e Winters (1960) constituem uma família de modelos matemáticos que objetivam ajustar uma curva adequada aos dados históricos de uma série temporal, utilizados amplamente em muitas áreas, como negócios e economia (Gujarati e Porter, 2008; Montgomery, Jennings e Kulahci, 2015). O método denominado de Holt-Winters possui duas abordagens distintas: a multiplicativa, no caso da amplitude sazonal aumentar em relação ao tempo; e aditiva, quando a série estudada possui uma amplitude constante ao longo de seus ciclos (Makridakis, Steven e Hyndman, 1998).

O método aditivo é representado pela Equação (1):

$$Z_{t+m} = (L_t + b_t m) + S_{t-s+m} \quad (1)$$

Onde:

$$L_t = \alpha(Z_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

$$S_t = \gamma(Z_t - L_t) + (1 - \gamma)S_{t-s}$$

O método multiplicativo é representado pela Equação (2):

$$Z_{t+m} = (L_t + b_t m) S_{t-s+m} \quad (2)$$

Onde:

$$L_t = \alpha (Z_t / S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

$$S_t = \gamma (Z_t / L_t) + (1 - \gamma)S_{t-s}$$

Em ambas as equações: L_t representa o valor estimado do nível; b_t representa a estimativa de tendência; α , β e γ são as constantes de suavização no intervalo de 0 até 1; Z_{t+m} corresponde a previsão no período “t+m”, em que “m” representa quantos passos à frente se deseja prever; S_t o índice sazonal da série temporal.

2.1.2 Modelo Autorregressivo Integrado de Médias Móveis

Os modelos autorregressivos integrados de médias móveis (ARIMA) foram desenvolvidos por Box e Jenkins (1970), sendo caracterizados por captar o comportamento da correlação seriada entre os valores da série temporal, e assim realizar previsões futuras (Montgomery, Jennings e Kulahci, 2015). A modelagem ARIMA segue quatro etapas: (i) identificação, consistindo na determinação do modelo que melhor descreve o comportamento da série, por meio da análise das funções de autocorrelação (FAC) e autocorrelação parcial (FACP); (ii) estimação, realizando a estimação dos parâmetros autorregressivos, assim como de médias móveis; (iii) validação, consistindo na análise da adequação do modelo ajustado ao comportamento real da série, em que são analisados os resíduos do modelo; (iv) previsão, que somente é realizada, quando as etapas anteriores forem satisfatórias (Gujarati e Porter, 2008; Enders, 2008).

Usualmente os modelos ARIMA (p, d, q) são representados pela equação (3):

$$\phi(B) \Delta^d Z_t = \theta(B) \varepsilon_t \quad (3)$$

Onde: Z_t representa a série temporal modelada, B representa o operador retroativo, d a ordem de integração, ϕ é termo que representa o parâmetro autoregressivo de ordem p , θ representa o parâmetro de médias móveis de ordem q e ε_t representa a sequência de erros, denotado ruído branco quando a média dos erros é zero e a variância é constante com homocedasticidade $\sim (0, \sigma^2)$. O modelo com melhor ajuste, selecionado pelo critério de Akaike (AIC) (Akaike, 1974) é selecionado para realização de análises e previsões.

2.1.2 Redes Neurais Artificiais

Os modelos de redes neurais artificiais (ANN) foram desenvolvidos inspirados no processo de informação do cérebro humano, por meio de algoritmos de treinamentos, sendo considerados uma poderosa abordagem para modelagem de séries temporais, capazes de capturar padrões complexos e não lineares. A estrutura de uma ANN é composta por quatro elementos: neurônios, tipo de modelo, redes e aprendizado, sendo os neurônios o principal elemento de uma ANN (Hayati e Shirvany, 2007; Agami et al., 2009; Guresen, Kayakutlu e Daim, 2011).

Entre os principais modelos de arquiteturas utilizados para realização de previsões a partir de ANN, o modelo *Multilayer Perceptron* (MLP) é o mais difundido por permitir a realização de previsões com modelos univariados, utilizando os períodos defasados da própria série na camada de entrada (Agami et al., 2009; Ahmed et al., 2010; Jacobs, Souza e Zanini, 2016). O modelo utiliza funções não lineares sigmoide de acordo com a estruturação da rede construída, podendo ser considerado um modelo genérico autorregressivo não linear (Hyndman e Athanasopoulos, 2018; Zhang, Patuwo e Hu, 2001).

O modelo genérico MLP/ANN pode ser representado pela Equação (4):

$$Z_t = f(h_i) \quad (4)$$

Onde a saída de cada neurônio é dada por:

$$h_i = \sum_{j=1}^N w_{ij}x_j + b_i$$

Onde: x_j representa os sinais de entrada; w_{ij} os pesos atribuídos a cada sinal de entrada; b_i representa o viés; e N o total de sinais de entradas no modelo.

A definição da estrutura a ser utilizada em uma ANN para realização de previsões não segue uma regra única, havendo diversas abordagens na literatura. Zhang, Patuwo e Hu (2001) sugerem a construção da estrutura da ANN baseada na estrutura de autocorrelação da série temporal a ser modelada.

2.2 Combinação de previsões

Nesta seção são apresentados os aspectos teóricos das abordagens para a combinação das previsões adotadas.

2.2.1 Variância mínima e média aritmética

O método da Variância Mínima foi proposto por Bates e Granger (1969), sendo uma das abordagens mais difundidas para combinação de previsões (Timmerman, 2006; Martins e Werner, 2012). Tal método consiste em combinar previsões de forma linear e objetiva, atribuindo um peso “w” para a primeira previsão e um peso complementar (1-w) para a segunda previsão. O valor dos pesos baseia-se na observação das variâncias dos erros das previsões a serem combinadas. Dessa forma, a previsão com maior variabilidade nos erros deve ser atribuída menor peso, a fim de obter-se maior acurácia, conforme pode ser visto na Equação (5):

$$F_c = wF_1 + (1 - w)F_2 \quad (5)$$

Onde: F_c é a previsão combinada; w é o peso atribuído à previsão e F_1 e F_2 são as previsões originais a serem combinadas.

Os pesos são calculados por meio da Equação (6):

$$w = \frac{\sigma_2^2 - \rho\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2} \quad (6)$$

Onde: w é o peso atribuído à previsão; ρ corresponde ao coeficiente de correlação linear de Pearson entre os erros oriundos das previsões; σ_1^2 e σ_2^2 o valor da variância dos erros das previsões F_1 e F_2 .

Uma abordagem simplificada sugerida por Makridakis e Winkler (1983) refere-se à utilização da média simples das previsões, pois segundo os autores a média pode prover maior acurácia da previsão, reduzindo sua variabilidade, pois não existindo informações de dependência entre as previsões, torna-se razoável sua utilização, podendo dar origem a resultados melhores que métodos mais sofisticados (Stock e Watson, 2004; Koning et al., 2005).

A combinação por média aritmética é dada pela Equação (7):

$$F_c = 0,5F_1 + 0,5F_2 \quad (7)$$

Onde: F_c é a previsão combinada; F_1 e F_2 são as previsões individuais.

A média aritmética é um dos mais populares métodos empregados na combinação de previsões (Oliveira et al., 2017; Martins e Werner, 2012). Dessa forma, a combinação por média com pesos iguais e fixos pode ser considerado um caso particular ou uma simplificação do Método da Variância Mínima.

2.2.2 Método baseado em cópulas

A utilização de modelos de Cópulas em séries temporais tem se intensificado como uma abordagem não linear para modelagem em diversos problemas. Estudos realizados por Morettin et al. (2011), Bessa et al. (2012), Patton (2012), Liu (2015), Smith (2015), Lahiri e Yang (2016) abordam aplicações de modelos de cópulas em séries temporais de diversos contextos. Entre as possíveis aplicações, os modelos de cópulas podem ser adotados como uma abordagem para combinação não linear de previsões individuais (Oliveira et al, 2017).

Cópuas podem ser definidas como funções que medem a dependência entre variáveis, a partir das suas respectivas distribuições (Nelsen, 2006), genericamente definida pela Equação (8).

$$F(x, y) = C(F_1(x), F_2(y)) \quad (8)$$

Onde: F representa distribuição das variáveis; C o modelo de Cópula; x e y as variáveis modeladas.

Os modelos de Cópulas permitem descrever dependências locais, ou seja, para todo par de variáveis x e y consideradas, diferentes das medidas clássicas de dependência que consideram um único valor para todo conjunto de dados. Desta forma é possível avaliar de forma não linear a dependência entre variáveis (Genest e Favre, 2007; Morettin et al., 2011). Para o caso da combinação de previsões tais variáveis serão as previsões individuais, utilizando o modelo de Cópula para estimar a dependência em cada período de tempo da previsão.

Entre os diversos modelos existentes foi considerado neste trabalho o modelo de Cópula de Gumbel, pois não possui restrições quanto às distribuições das variáveis modeladas (Nelsen, 2006). A Equação (9) representa a função da cópula de Gumbel bivariada.

$$C(x, y) = \exp \left\{ - \left[(-\ln(x)^\theta) + (-\ln(y)^\theta) \right]^{\frac{1}{\theta}} \right\} \quad (9)$$

Onde: C representa o modelo de Cópula; x e y as variáveis modeladas; θ o parâmetro de dependência entre as variáveis.

A abordagem adotada nesta pesquisa para combinação das previsões por modelos de cópulas segue o modelo proposto por Oliveira et al (2017), seguindo as seguintes etapas: modelagem individual, em que consiste na realização das previsões por meio dos modelos de previsão; modelagem dos erros, em que se verifica os erros cometidos em cada modelo; combinação das previsões, em que se utiliza as distribuições dos erros para combinar as previsões a partir do modelo de cópula ajustado (Oliveira et al., 2017).

3. Metodologia

A metodologia está dividida em 2 seções: (1) descrição dos dados da pesquisa; (2) apresentação da abordagem proposta para a modelagem individual, combinação das previsões, comparação das medidas de acurácia de cada previsão e seleção do melhor modelo.

3.1 Dados da pesquisa

Os dados utilizados para modelagem foram coletados a partir do banco de informações de apontamentos do sistema de automação industrial de uma empresa brasileira de grande porte do setor de mineração e logística, sendo o principal sistema de controle de produção da organização. Os dados são referentes a um mês de operação, com observações a cada hora, gerando oito séries temporais com 720 observações cada. Foi aplicada uma transformação logarítmica nas séries temporais com o objetivo de estabilizar a variância dos dados, conforme sugerido por Montgomery, Jennings e Kulahci (2015) e Hyndman e Athanasopoulos (2018) em casos de séries com variâncias não constantes ao longo do tempo.

As séries temporais foram divididas em duas partes, a primeira correspondente ao período de treino com cerca de 80% das observações e segunda a fase de teste com cerca de 20% das observações. A fase de treino foi utilizada para o ajuste dos modelos, enquanto a de teste, para a avaliação das medidas de acurácia.

3.2 Modelagem individual e combinação das previsões

As previsões individuais foram obtidas a partir dos modelos de Suavização Exponencial, Box-Jenkins e de ANN, sendo selecionado como melhores modelos em cada previsão aqueles que apresentaram os melhores ajustes. As etapas de cada modelagem individual são descritas a seguir:

Suavização Exponencial: verificação da presença de componentes de tendência e sazonalidade; identificação do modelo (Suavização simples, linear de Holt, Holt-Winters); estimação dos parâmetros; realização da previsão e cálculo das medidas de acurácia.

Box-Jenkins: verificação da estacionariedade da série pelos testes ADF (Said e Dickey, 1984) e KPSS (Kwiatkowski, Phillips, Schmidt e Shin, 1992) ambos utilizando o nível de significância de 5%; identificação do modelo (p, d, q); estimação dos parâmetros; validação do modelo (verificação dos ruídos e parâmetros); realização da previsão e cálculo das medidas de acurácia.

ANN: definição do número de neurônios na camada de entrada; treinamento de um conjunto de ANN; escolha da melhor ANN de acordo com critérios de acurácia; realização da previsão e cálculo das medidas de acurácia.

Após a obtenção das previsões individuais, foram realizadas as combinações de três formas distintas: pelo método da variância mínima, por meio de média aritmética simples e por meio dos modelos de cópulas de Gumbel, utilizando a abordagem proposta por Oliveira et al (2017). Para todas as combinações foram utilizados os dois previsores individuais que apresentaram menores erros quadráticos. A Figura 1 ilustra a abordagem proposta.

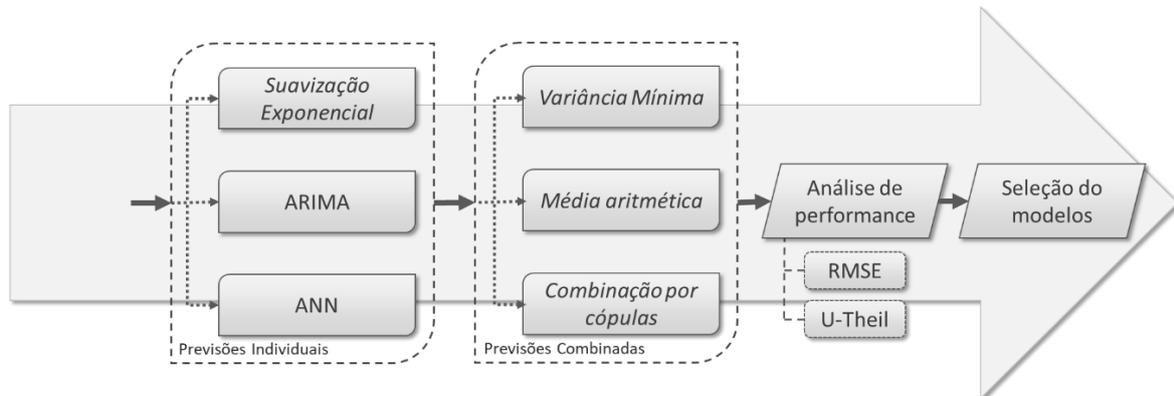


Figura 1. Abordagem proposta

A análise de desempenho dos modelos propostos, tanto individuais quanto combinados, foram realizadas pela comparação das medidas de acurácia *root mean squared errors* (RMSE) e o coeficiente de U-Theil. A utilização do RMSE como medida de avaliação de modelos é sugerida por Chai e Draxler (2014) e Hyndman e Athanasopoulos (2018) quando analisadas previsões na mesma unidade de medida.

RMSE pode ser calculado pela Equação (10):

$$RMSE = \frac{\sqrt{\sum_{t=1}^n (\varepsilon_t)^2}}{n} \quad (10)$$

Onde: ε_t representa o erro de previsão no instante t ; n refere-se ao número de observações.

O coeficiente de U-Theil é uma importante medida para avaliação de previsões, a medida avalia o desempenho da previsão em relação à previsão ingênua ou trivial (Hyndman e Koehler, 2006; Thiel, 1966). Um modelo é considerado adequado quando $U < 1$, indicando que o erro do modelo ajustado é menor que de uma previsão ingênua, quando $U \geq 1$, o erro do modelo ajustado é maior ou igual que de uma previsão ingênua. O coeficiente de U-Theil pode ser calculado pela Equação (11):

$$U = \frac{\sqrt{\sum_{t=1}^n (\varepsilon_t)^2}}{\sqrt{\sum_{t=1}^n (Z_t - Z_{t-1})^2}} \quad (11)$$

Onde: ε_t representa o erro de previsão no instante t ; n o número de observações; Z_t o valor real no tempo t .

Será selecionado como modelo predictor aquele que apresentar menores erros para as medidas propostas na fase de teste das séries modeladas. Dessa forma, foi possível ao fim da pesquisa avaliar a aplicação dos modelos de previsões individuais, assim como dos modelos combinados, permitindo uma comparação e discussão da aplicabilidade dos métodos propostos em séries temporais. A metodologia disposta neste artigo permitiu uma avaliação objetiva e quantitativa a partir de critérios científicos, possibilitando uma discussão das evidências empíricas resultante deste estudo.

Como recurso computacional para tratamento, análise e modelagem dos dados foi utilizado o software livre 'R' (R Core Team, 2017) juntamente com os pacotes 'tseries' (Trapletti et al., 2018), 'forecast' (Hyndman e Khandakar, 2008), 'copula' (Yan, 2007).

4. Estudo de caso

O estudo foi desenvolvido em uma gerência de operação portuária, em que foi modelado parte de um sistema logístico integrado de movimentação de minério de ferro (contendo mina, ferrovia e porto), responsável pelo escoamento de toda a produção da mina de Carajás (Brasil), que atualmente é considerada a maior mina a céu aberto do mundo (<http://www.transportes.gov.br/>, recuperado em 21, junho, 2018). O transporte do material, após extração, é realizado via

sistema ferroviário por composição de três lotes de 110 vagões formando uma composição de 330 vagões. Tal composição é desmembrada via Terminal Ferroviário e cada lote é manobrado e posicionado em um Virador de Vagões para realizar a descarga do minério. A Figura 2 ilustra o processo de movimentação estudado.

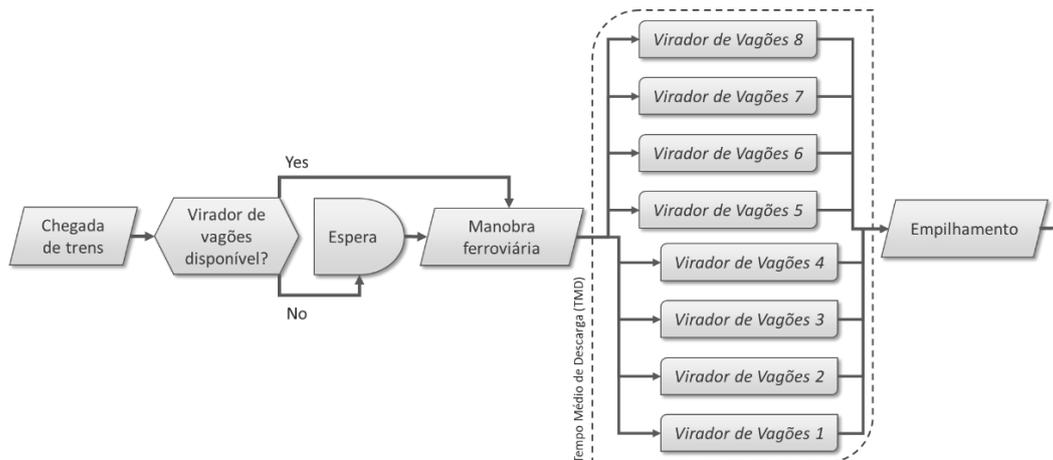


Figura 2. Sistema de descarga de minério por viradores de vagões

O processo inicial portuário se caracteriza pela descarga do minério utilizando oito Viradores de Vagões (VV), em que cada equipamento industrial gira um par de vagões por vez, direcionando o material para um sistema de correias transportadoras. O modelo proposto contempla a operação de descarga de minério. A variável modelada representa o Tempo Médio de Descarga (TMD) do sistema de viradores de vagões a cada hora, o indicador é representado pela Equação (12):

$$TMD = TTD / N^{\circ} \text{ Lotes} \quad (12)$$

Onde: TTD representa o tempo total de descarga; N° Lotes representa o número total de lotes operados no período, sendo cada lote constituído de 110 vagões.

A variável TMD é considerada um indicador chave de produção, sendo o principal parâmetro de controle do sistema de descarga portuário. Devido ao processo de descarga atender aos processos portuários posteriores de empilhamento e embarque, o controle sobre a variável TMD torna-se um importante fator a ser abordado nos processos decisórios, tais como o dimensionamento de produção e o planejamento de rotinas de manutenção, dessa forma o modelo ajustado será utilizado como predictor do comportamento futuro da variável, servindo como uma ferramenta de apoio à tomada de decisão.

5. Resultados e discussões

Os resultados estão apresentados em 3 etapas: (1) análise descritiva das séries; (2) ajuste dos modelos individuais; (3) combinação das previsões e comparação da performance dos modelos fora da amostra.

5.1 Série de dados

São apresentadas na Tabela 1 as estatísticas descritivas das séries temporais. Entre as linhas de descarga, o VV8 apresenta maior média (119.177), assim como maior mediana (119.177), enquanto a menor média foi obtida pelo VV3 (111.486), assim como mediana (111.486). Quanto à dispersão, o VV2 apresentou menor desvio padrão (6.721) e coeficiente de variação (6.0%), enquanto a maior variabilidade foi observada no VV8 (desvio padrão de 15.106 e coeficiente de variação de 12.7%). Na Figura 3 representa-se o comportamento do indicador TMD, a FAC e FACP para cada linha de descarga, coletadas durante um mês de operação com observações a cada hora, gerando oito séries temporais com 720 observações.

Tabela 1. Estatísticas descritivas das séries de TMD

Séries	Média	Mediana	Máximo	Mínimo	Desvio padrão	Coefficiente de variação
VV1	115.508	115.508	149.443	92.927	9.107	7.9%
VV2	112.406	112.383	158.026	94.145	6.721	6.0%
VV3	111.486	111.486	164.284	91.974	8.393	7.5%
VV4	112.970	112.929	183.919	92.523	10.531	9.3%
VV5	113.581	113.255	156.554	93.538	8.664	7.6%
VV6	113.911	113.911	152.193	91.492	11.231	9.9%
VV7	114.489	114.489	180.934	91.661	9.455	8.3%
VV8	119.177	119.177	198.432	92.995	15.106	12.7%

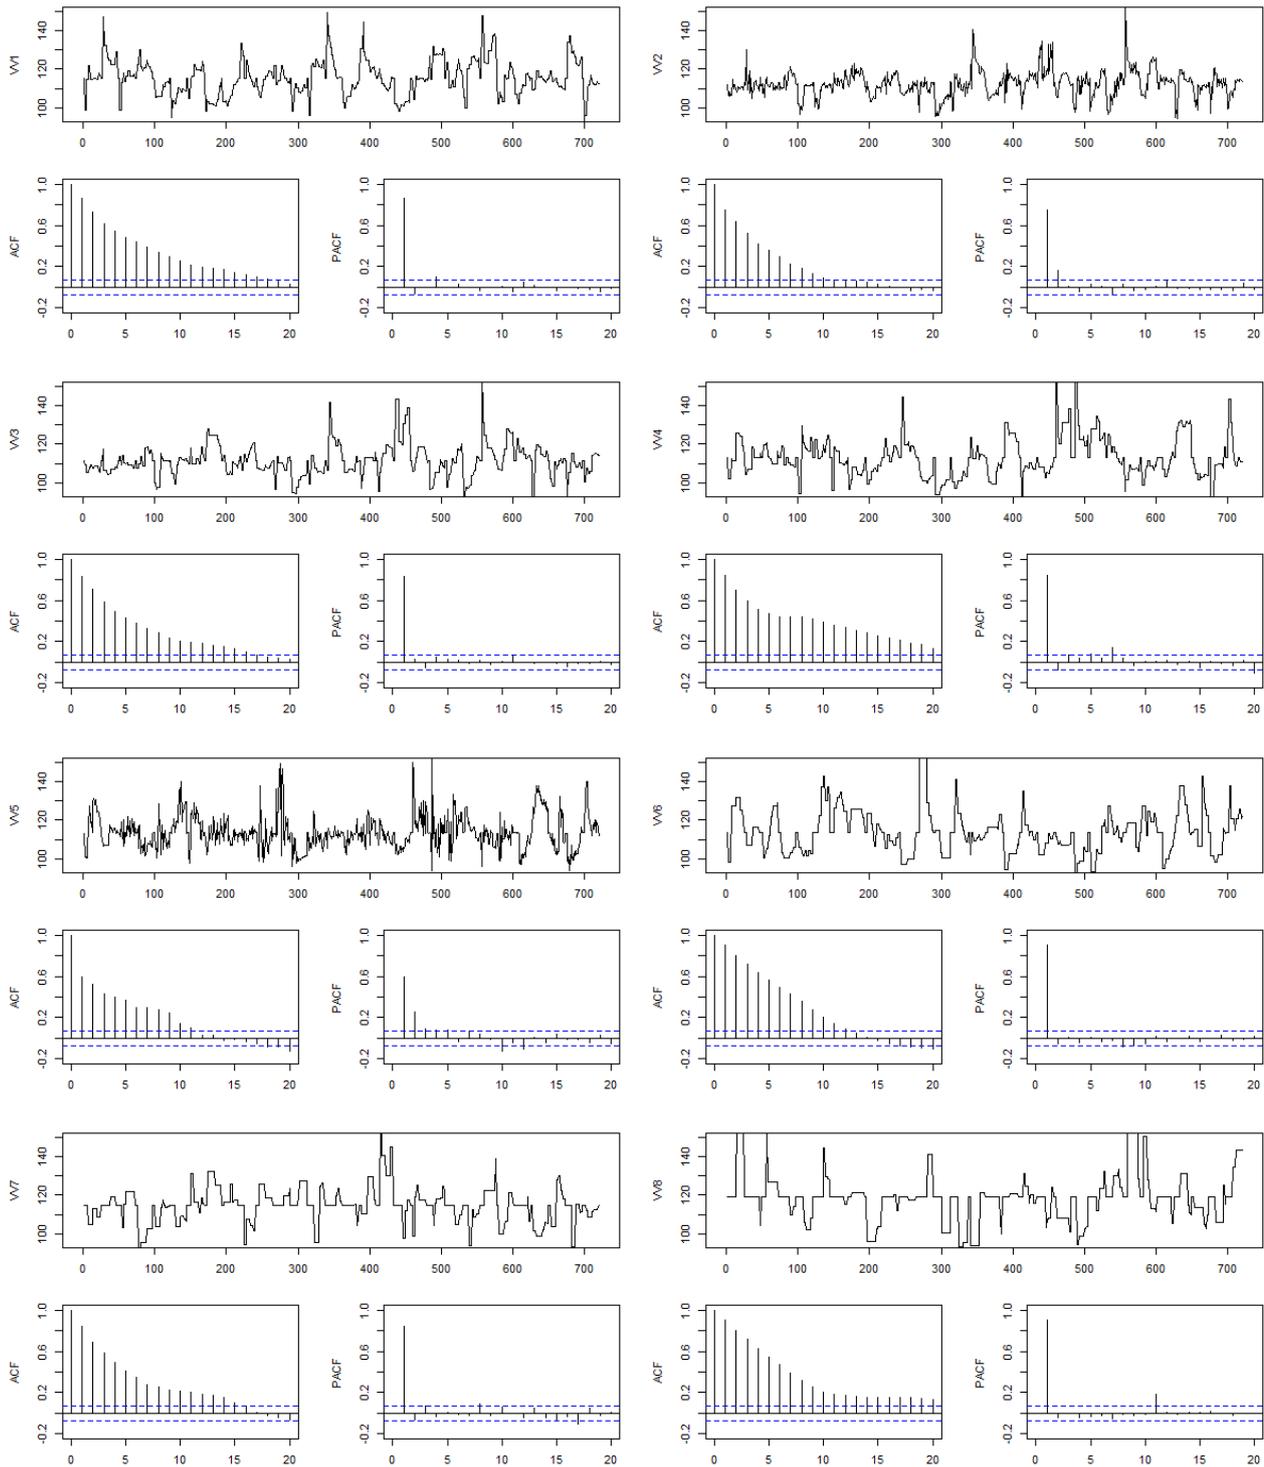


Figura 3. Séries temporais FAC e FACP.

Na Figura 3, a partir das FAC é possível observar presença de autocorrelação em todas as séries entre os períodos Y e Y_{t-1} indicando uma dependência de curto prazo entre períodos. Nas FACP é possível identificar autocorrelação entre os resíduos, predominantemente entre os períodos ε_t e $\varepsilon_{t-1}, \dots, \varepsilon_{t-10}$. Como mencionado na seção 3.1, neste estudo foi aplicada transformação logarítmica com o objetivo de estabilizar a variância dos dados reduzindo problemas com heterocedasticidade, nas próximas etapas foram utilizados os dados transformados para ajustar os modelos.

5.2 Modelos individuais

A Tabela 2 contém os modelos de suavização exponencial ajustados.

Para o ajuste dos modelos foi utilizado o critério de AIC, para as séries VV1, VV2, VV3, VV4, VV5, VV6 e VV7 em que o modelo de suavização exponencial com apenas um parâmetro de suavização obteve melhor desempenho, isso ocorreu devido às séries serem estacionárias e não apresentarem comportamento sazonal. Apenas o VV8 se ajustou melhor ao modelo aditivo de Holt-Winters, sem presença de tendência.

Tabela 2. Modelos de suavização exponencial

Séries	Modelo	Parameters	Inicial states	AIC	MSE
VV1	Suavização Exponencial simples	α 0.995	115.507	2.927	18.622
VV2	Suavização Exponencial simples	α 0.685	111.229	2.848	17.211
VV3	Suavização Exponencial simples	α 0.942	111.265	3.012	20.278
VV4	Suavização Exponencial simples	α 0.993	112.684	3.123	22.642
VV5	Suavização Exponencial simples	α 0.395	109.648	3.682	39.597
VV6	Suavização Exponencial simples	α 1.000	113.702	3.506	33.236
VV7	Suavização Exponencial simples	α 0.986	114.246	3.169	23.729
		α 0.995	113.090		
VV8	Holt-Winters aditivo	β 0.000	-	3.284	26.472
		γ 0.965	5.946		

Entre os modelos de Suavização exponencial ajustados, o modelo ajustado à série VV2 apresentou menor MSE, assim como menor valor para o critério de AIC. A razão para a performance superior desse modelo pode ser atribuída à menor variabilidade da série, pois a mesma apresentou menor coeficiente de variação (6.0%), indicando a menor performance dos modelos de suavização exponencial para séries com maior variabilidade.

Para o ajuste dos modelos ARIMA foi utilizado o critério de AIC, além de apresentarem características de ruído branco. Todas as séries foram consideradas estacionárias em nível ($d = 0$) pelos testes ADF e KPSS para um nível de significância de 5%, não necessitando da aplicação de diferenças. A Tabela 3 contém os modelos ARIMA ajustados. Todos os modelos apresentaram parâmetros autorregressivos e apenas os modelos ajustados às séries VV3, VV7 e VV8 não apresentaram parâmetros de médias móveis, todos os parâmetros dos modelos ajustados foram significativos (p -value $< 0,05$). Em todos os casos, os modelos confirmam a dependência de curto prazo entre os períodos das séries.

Tabela 3. Modelos ARIMA

Séries	Modelo	(p) AR	P-value (AR)	(q) MA	P-value (MA)	AIC	MSE
VV1	ARIMA (3,0,1)	ϕ_1 -0.060 ϕ_2 0.854 ϕ_3 -0.085	<0.01 <0.01 <0.01	θ_1 0.099	<0.01	2.808	16.396
VV2	ARIMA (4,0,2)	ϕ_1 0.887 ϕ_2 0.744 ϕ_3 -0.504 ϕ_4 -0.126	<0.01 <0.01 <0.01 <0.01	θ_1 -0.244 θ_2 -0.754	<0.01 <0.01	2.753	15.428
VV3	ARIMA (1,0,0)	ϕ_1 0.841	<0.01	-	-	2.924	18.506
VV4	ARIMA (3,0,2)	ϕ_3 0.616	<0.01	θ_1 0.887 θ_2 0.762	<0.01 <0.01	3.088	21.696
VV5	ARIMA (1,0,1)	ϕ_1 0.874	<0.01	θ_1 -0.476	<0.01	3.616	36.870
VV6	ARIMA (2,0,1)	ϕ_2 0.811	<0.01	θ_1 0.926	<0.01	3.431	30.657
VV7	ARIMA (2,0,0)	ϕ_1 0.981 ϕ_2 0.018	<0.01 <0.01	-	-	3.170	23.683
VV8	ARIMA (1,0,0)	ϕ_1 0.903	<0.01	-	-	3.241	25.423

Em relação aos modelos de suavização exponencial, a modelagem ARIMA apresentou performance superior, pois os modelos ajustados produziram menores erros quadráticos, assim como se mostraram mais parcimoniosos de acordo com

o critério AIC, demonstrando que a relação entre qualidade e complexidade dos modelos ajustados pode justificar a utilização de modelos mais robustos.

Os modelos de ANN, assim como os demais, foram ajustados e avaliados utilizando o critério de AIC para cada variável foram treinadas dez ANN, totalizando 80 modelos ajustados. A estrutura e escolha das redes para cada modelo foi definida de acordo com a periodicidade das variáveis, utilizando o ciclo de 24 períodos, e a estrutura de autocorrelação das mesmas. A Tabela 4 contém os modelos ANN finais ajustados. Para a camada de entrada os modelos obtiveram melhor performance utilizando entre 4 e 8 períodos defasados, para a camada intermediária houve maior variabilidade, o VV3 apresentou apenas um neurônio enquanto os VV2, VV4, VV5 e VV7 apresentaram 24 neurônios.

Tabela 4. Modelos ANN

Séries	Modelo	AIC	MSE
VV1	ANN (6,05)	2.899	17.909
VV2	ANN (5,24)	2.701	14.690
VV3	ANN (5,01)	2.921	18.306
VV4	ANN (6,24)	3.111	22.067
VV5	ANN (8,24)	3.657	37.906
VV6	ANN (4,06)	3.444	30.951
VV7	ANN (4,24)	3.066	21.211
VV8	ANN (5,02)	3.236	25.073

Em relação aos modelos individuais de suavização exponencial e ARIMA, a modelagem ANN apresentou performance superior para as séries VV2, VV3, VV7 e VV8, tanto em termos de acurácia, produzindo menores erros quadráticos, quanto menores valores para o critério de AIC.

Para a etapa seguinte de combinação das previsões foram utilizadas as previsões dos modelos ARIMA e ANN, pois foi observada uma performance superior das previsões produzidas por esses modelos, apresentando menores erros quadráticos, conforme proposto na seção 3.2.

5.6 Combinação das previsões e comparação out of sample

Os resultados das previsões dos modelos individuais, assim como das combinações das previsões pelos métodos da média aritmética, variância mínima e por modelos de cópulas estão dispostos na Tabela 5.

Nas etapas anteriores foi utilizado o critério de AIC como uma medida de avaliação de performance para selecionar os modelos. O critério de AIC é baseado na relação entre complexidade e qualidade do modelo ajustado, porém não necessariamente identifica o modelo mais acurado, capaz de produzir menores erros (Azevedo e Campos, 2016). Dessa forma, para comparar modelos de diferentes classes, foram utilizadas as medidas de acurácia RMSE e U-Theil para as seis previsões finais obtidas.

Tabela 5. Comparação das previsões (out of sample)

	Modelos individuais			Modelos combinados		
	Suavização Exponencial	ARIMA	ANN	Média aritmética	Variância Mínima	Combinação por copulas
VV1						
RMSE	4.753730	4.511952	4.446045	4.438198	4.439137	4.434637
U-Theil	0.020514	0.019483	0.019191	0.019159	0.019163	0.019143
VV2						
RMSE	4.532623	4.387700	4.361616	4.351346	4.351005	4.349307
U-Theil	0.020129	0.019507	0.019365	0.019332	0.019330	0.019319
VV3						
RMSE	4.788464	4.607970	4.585916	4.588482	4.588376	4.584688
U-Theil	0.021416	0.020625	0.020489	0.020518	0.020517	0.020495
VV4						
RMSE	5.791635	5.542214	5.471289	5.474927	5.475237	5.466590
U-Theil	0.025523	0.024449	0.024119	0.024144	0.024145	0.024104
VV5						

RMSE	6.851115	6.682222	6.568798	6.586439	6.587198	6.572575
U-Theil	0.030091	0.029357	0.028815	0.028910	0.028914	0.028843
VV6						
RMSE	4.904011	4.784239	4.756972	4.749200	4.749182	4.748941
U-Theil	0.021423	0.020917	0.020774	0.020751	0.020751	0.020753
VV7						
RMSE	5.286164	5.292926	5.084330	5.094601	5.088796	5.068938
U-Theil	0.023008	0.023040	0.022215	0.022218	0.022195	0.022120
VV8						
RMSE	6.670583	6.488616	6.585766	6.516742	6.516494	6.506803
U-Theil	0.027740	0.027027	0.027424	0.027140	0.027139	0.027099

Os resultados encontrados para as previsões *out of sample* demonstraram que a combinação das previsões obteve resultado superior em seis das oito variáveis modeladas. Para todas as previsões realizadas o coeficiente de U-Theil apresentou valores menores que 1, indicando que os modelos possuem melhor desempenho que as previsões ingênuas. Entre as abordagens de combinação das previsões utilizadas, o modelo de cópulas obteve performance superior em relação as demais abordagens de combinação para a medida RMSE, conseguindo reduzir até 6.71% do erro para a série VV1 em relação à pior previsão obtida pelo modelo de suavização exponencial.

Entre os modelos de previsão individuais, os modelos de suavização exponencial obtiveram menor performance no período *out of sample* em relação aos demais. Os modelos ARIMA apresentaram performance superior para os indicadores VV4 e VV8 em relação às demais previsões individuais. Os modelos ANN foram superiores em performance para os demais indicadores, evidenciando que, para os dados modelados, a abordagem ANN apresentou maior acurácia na maioria dos casos para as previsões individuais.

Em relação à combinação das previsões, o modelo ANN ajustado ao VV5 também apresentou melhor performance no período *out of sample*, isso pode ser parcialmente explicado pelo número de camadas, pois entre os modelos ANN ajustados o VV5 obteve melhor ajuste com o maior número de parâmetros, indicando um alto nível de ajustamento do modelo à série. Entretanto, a análise mais robusta do modelo é limitada pois, apesar de ser possível identificar as camadas ocultas, a interpretação de seus parâmetros e de seus coeficientes é de difícil interpretação prática, tal efeito denominado na literatura de “*black box*”. Entretanto o foco principal do modelo é a realização de previsões, não inviabilizando seu uso por suas limitações (Haykin, 1994).

Para o VV8 o modelo individual ARIMA ajustado apresentou melhor desempenho no período *out of sample*, tanto comparado as previsões individuais quanto combinadas, o modelo ajustado ARIMA (1,0,0) indica que a série é influenciada principalmente pelo período imediatamente anterior defasado, indicando uma memória de curto prazo no indicador. Para essa variável a combinação das previsões não foi capaz de reduzir o erro de previsão, tal fato pode ser explicado pela maior variabilidade da série em relação as demais, tornando instável a realização da combinação das previsões.

Entre os métodos de combinação adotados, à combinação por cópulas obteve melhor desempenho, pois sua performance foi superior para a medida RMSE em relação às demais combinações. Quando comparadas todas as previsões obtidas em seis a combinação por cópulas foi superior, evidenciando o método como uma abordagem atrativa na redução dos erros de previsões individuais. A seleção final dos modelos para a previsão dos indicadores chave de desempenho considerou os modelos mais acurados de acordo com a medida RMSE indicados na Tabela 6.

Tabela 6. Modelos finais selecionados

	Modelo	RMSE	U-Theil
VV1	Combinação por copulas ARIMA (3,0,1) and ANN (6,05)	4.435	0.019
VV2	Combinação por copulas ARIMA (4,0,2) and ANN (5,24)	4.349	0.019
VV3	Combinação por copulas ARIMA (1,0,0) and ANN (5,01)	4.585	0.020
VV4	Combinação por copulas ARIMA (3,0,2) and ANN (6,24)	5.467	0.024
VV5	ANN (8,24,1)	6.569	0.029
VV6	Combinação por copulas ARIMA (2,0,1) and ANN (4,06)	4.749	0.020
VV7	Combinação por copulas ARIMA (2,0,0) and ANN (4,24)	5.069	0.022
VV8	ARIMA (1,0,0)	6.489	0.027

Entre todas as abordagens adotadas o método de suavização exponencial apresentou maiores erros em comparação aos demais modelos no período *out of sample*, seguido da modelagem ARIMA e dos modelos ANN. De uma forma geral, a combinação das previsões foi capaz de reduzir os erros produzidos pelas previsões individuais, aumentando assim a

precisão das previsões combinadas, sendo o método de combinação por cópulas o que apresentou melhores resultados na maioria dos casos.

6. Conclusões

A combinação de previsões é uma abordagem difundida para o aumento da precisão de acurácia de previsões. A realização de combinação por média aritmética é considerada um dos mais populares métodos empregados na literatura, assim como o método da variância mínima é apresentado como uma das abordagens mais acuradas para a realização de combinação de previsões. Esta pesquisa teve como objetivo ajustar modelos de previsões acurados para oito indicadores chave de desempenho de um terminal portuário, utilizando como abordagem a combinação dos modelos de suavização exponencial, ARIMA e ANN por meio dos métodos já difundidos da média aritmética e da variância mínima juntamente com uma abordagem recente proposta na literatura através de modelos de cópulas. Os modelos individuais foram ajustados utilizando o período *in sample* contendo 80% das observações coletadas, sendo aplicada nos dados uma transformação por logaritmo natural para estabilizar a variância. A avaliação final dos modelos foi realizada pela comparação das medidas RMSE e U-Theil para as previsões no período *out of sample*.

Este trabalho apresentou uma contribuição original para literatura por ser um dos poucos estudos a considerar os modelos de suavização exponencial, ARIMA e ANN assim como suas combinações por três abordagens distintas aplicadas em um estudo de caso em um terminal portuário de grande porte localizado no Brasil, obtendo resultados empíricos ainda não encontrados na literatura com a mesma abordagem.

Os resultados encontrados demonstraram que entre as seis previsões finais obtidas para cada indicador, os modelos individuais ARIMA e ANN foram superiores em termos de acurácia em relação às previsões individuais em dois dos oito casos e os métodos de combinação foram superiores nos seis dos demais indicadores modelados, destacando-se o modelo de cópula em relação às demais abordagens de combinação adotadas.

Tais resultados são corroborados pela literatura, como no estudo realizado por Martins e Werner (2012) que comparou previsões individuais e combinadas para 50 séries reais do setor industrial, obtendo resultados superiores com previsões combinadas. O estudo realizado por Pang e Gekba (2016) que utilizaram a combinação de previsões para obter resultados mais acurados aplicados à transferência de containers em um porto localizado na Indonésia encontrando resultados superiores em relação às previsões individuais. Outro estudo recente realizado por Jacobs, Souza e Zanini (2016) que utilizaram modelos baseados em ANN, assim como a modelagem ARIMA em conjuntos com diversos métodos de combinação para prever a demanda agregada de uma indústria de laticínios, os resultados encontrados pelos autores demonstraram, que para o caso estudado, a combinação das previsões obteve a melhor acurácia, apresentando menores erros para as estatísticas de erro médio absoluto e relativo. Outro estudo recente realizado por Makridakis, Spiliotis e Assimakopoulos (2018), considerando cem mil séries temporais reais de vários setores, demonstrou que modelos de previsão com abordagens de combinação, que utilizam conjuntamente métodos computacionais e estatísticos tendem a ter uma performance superior em termos de acurácia. Quanto a utilização de modelos de cópulas para a combinação de previsões, Oliveira et al. (2017) aplicou essa abordagem com séries simuladas encontrando resultados superiores em relação às previsões individuais. Dessa forma, os resultados corroboram com a literatura confirmando a importância da combinação de previsões.

Apesar dos modelos finais ajustados apresentarem resultados acurados, a gestão dos indicadores exigirá o constante exercício de modelagem e previsão ao longo do tempo para capturar a natureza variável dos dados analisados, entretanto, a amostra considerada permitiu concluir que os modelos em período de curto prazo se apresentam como previsores acurados dos indicadores. Além disso, a abordagem proposta pode ser replicada em outros estudos que envolvem problemas complexos de decisão necessitando prever o comportamento de variáveis com precisão. Como direcionamento para futuros trabalhos sugere-se a utilização de modelos multivariados para previsão de indicadores de desempenho, permitindo incorporar a interrelação entre as variáveis como a modelagem por vetores autorregressivos e vetores de correção de erros. Outro aspecto importante a ser investigado é quanto à aplicabilidade da combinação de previsão por meio de outros modelos de cópulas em diversos contextos e horizontes diferentes de previsão.

Agradecimentos

Os autores agradecem ao Laboratório de Análise e Modelagem Estatística LAME – UFSM pela disponibilização de infraestrutura técnica e computacional e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, pelo apoio financeiro, o que incluiu uma bolsa de pesquisa.

Declaração de Divulgação

Nenhum potencial conflito de interesse foi relatado pelos autores.

Referências

- Agami, N., Atiya, A., Saleh, M., & El-Shishiny, H. (2009). A neural network based dynamic forecasting model for Trend Impact Analysis. *Technological Forecasting and Social Change*, 76(7), 952-962.
- Agostino, I., Sousa, S., Frota, P., Daher, R., & Souza, A. M. (2019). Modeling and Simulation of Operations: A Case Study in a Port Terminal of Vale S/A. In *New Global Perspectives on Industrial Engineering and Management* (pp. 91-99). Springer, Cham.
- Ahmed, N. K., Atiya, A. F., Gayar, N. E., & El-Shishiny, H. (2010). An empirical comparison of machine learning models for time series forecasting. *Econometric Reviews*, 29(5-6), 594-621.
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE transactions on automatic control*, 19(6), 716-723.
- Amendola, A., & Storti, G. (2008). A GMM procedure for combining volatility forecasts. *Computational Statistics & Data Analysis*, 52(6), 3047-3060.
- Azevedo, V. G., & Campos, L. M. (2016). Combination of forecasts for the price of crude oil on the spot market. *International Journal of Production Research*, 54(17), 5219-5235.
- Bates, J. M., & Granger, C. W. (1969). The combination of forecasts. *Journal of the Operational Research Society*, 20(4), 451-468.
- Bessa, R. J., Miranda, V., Botterud, A., Zhou, Z., & Wang, J. (2012). Time-adaptive quantile-copula for wind power probabilistic forecasting. *Renewable Energy*, 40(1), 29-39.
- Box, G. E. P., and GM Jenkins (1970) *Time Series Analysis, Forecasting, and Control*. Francisco Holden-Day.
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. *Geoscientific model development*, 7(3), 1247-1250.
- Clemen, R. T. (1989). Combining forecasts: A review and annotated bibliography. *International journal of forecasting*, 5(4), 559-583.
- Costantini, M., & Pappalardo, C. (2010). A hierarchical procedure for the combination of forecasts. *International journal of forecasting*, 26(4), 725-743.
- Doganis, P., Aggelogiannaki, E., & Sarimveis, H. (2008). A combined model predictive control and time series forecasting framework for production-inventory systems. *International Journal of Production Research*, 46(24), 6841-6853.
- Enders, W. (2008). *Applied econometric time series*. John Wiley & Sons.
- Fung, M. K. (2002). Forecasting Hong Kong's container throughput: An error-correction model. *Journal of Forecasting*, 21(1), 69-80.
- Genest, C., & Favre, A. C. (2007). Everything you always wanted to know about copula modeling but were afraid to ask. *Journal of hydrologic engineering*, 12(4), 347-368.
- Goedhals-Gerber, L. L. (2016). Predicting the throughput of grain products at the multipurpose terminal at the Port of Cape Town. *Journal of Transport and Supply Chain Management*, 10(1), 1-10.
- Gómez, R., Camarero, A., & Molina, R. (2015). Development of a Vessel-Performance Forecasting System: Methodological Framework and Case Study. *Journal of Waterway, Port, Coastal, and Ocean Engineering*, 142(2), 04015016.
- Gujarati, D. N., & Porter, D. C. (2008). *Basic Econometric* (Edisi Kelima).
- Guresen, E., Kayakutlu, G., & Daim, T. U. (2011). Using artificial neural network models in stock market index prediction. *Expert Systems with Applications*, 38(8), 10389-10397.
- Hayati, M., & Shirvany, Y. (2007). Artificial neural network approach for short term load forecasting for Illam region. *World Academy of Science, Engineering and Technology*, 28, 280-284.
- Haykin, S. (1994). *Neural networks: a comprehensive foundation*. Prentice Hall PTR.
- Hibon, M., & Evgeniou, T. (2005). To combine or not to combine: selecting among forecasts and their combinations. *International Journal of Forecasting*, 21(1), 15-24.
- Holt C. (1957), *Forecasting Trends and Seasonals by Exponentially Weighted Averages*, Carnegie Institute of Technology, Pittsburgh Office of Naval Research memorandum no. 52.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice*. OTexts.
- Hyndman, R. J., & Khandakar, Y. (2007). *Automatic time series for forecasting: the forecast package for R* (No. 6/07). Monash University, Department of Econometrics and Business Statistics.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International journal of forecasting*, 22(4), 679-688.
- Jacobs, W., Souza, A. M., & Zanini, R. R. (2016). Combination of Box-Jenkins and MLP/RNA models for forecasting. *IEEE Latin America Transactions*, 14(4), 1870-1878.
- Jeong, D. I., & Kim, Y. O. (2009). Combining single-value streamflow forecasts—A review and guidelines for selecting techniques. *Journal of Hydrology*, 377(3-4), 284-299.
- Koning, A. J., Franses, P. H., Hibon, M., & Stekler, H. O. (2005). The M3 competition: Statistical tests of the results. *International Journal of Forecasting*, 21(3), 397-409.

- Kwiatkowski, D., Phillips, P. C., Schmidt, P., & Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?. *Journal of econometrics*, 54(1-3), 159-178.
- Lahiri, K., & Yang, L. (2016). A non-linear forecast combination procedure for binary outcomes. *Studies in Nonlinear Dynamics & Econometrics*, 20(4), 421-440.
- Liu, X. (2015). Modeling time-varying skewness via decomposition for out-of-sample forecast. *International Journal of Forecasting*, 31(2), 296-311.
- Makridakis, S., & Hibon, M. (2000). The M3-Competition: results, conclusions and implications. *International journal of forecasting*, 16(4), 451-476.
- Makridakis, S., & Winkler, R. L. (1983). Averages of forecasts: Some empirical results. *Management Science*, 29(9), 987-996.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). The M4 Competition: Results, findings, conclusion and way forward. *International Journal of Forecasting*.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting methods and applications*. John Wiley & sons.
- Martins, V. L. M., & Werner, L. (2012). Forecast combination in industrial series: A comparison between individual forecasts and its combinations with and without correlated errors. *Expert Systems with Applications*, 39(13), 11479-11486.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction to time series analysis and forecasting*. John Wiley & Sons.
- Morettin, P. A., Toloi, C. M., Chiann, C., & de Miranda, J. C. (2011). Wavelet estimation of copulas for time series. *Journal of Time Series Econometrics*, 3(3).
- Nelsen, R. B. (2006). *An introduction to copulas*, 2nd. New York: SpringerScience Business Media.
- Oliveira, R. T., de Assis, T. F. O., Firmino, P. R. A., & Ferreira, T. A. (2017). Copulas-based time series combined forecasters. *Information Sciences*, 376, 110-124.
- Pang, G., & Gebka, B. (2017). Forecasting container throughput using aggregate or terminal-specific data? The case of Tanjung Priok Port, Indonesia. *International Journal of Production Research*, 55(9), 2454-2469.
- Pani, C., Fadda, P., Fancello, G., Frigau, L., & Mola, F. (2014). A data mining approach to forecast late arrivals in a transshipment container terminal. *Transport*, 29(2), 175-184.
- Patton, A. J. (2012). A review of copula models for economic time series. *Journal of Multivariate Analysis*, 110, 4-18.
- Rashed, Y., Meersman, H., Van de Voorde, E., & Vanelslender, T. (2017). Short-term forecast of container throughput: an ARIMA-intervention model for the port of Antwerp. *Maritime Economics & Logistics*, 19(4), 749-764.
- R Core Team (2017). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- Said, S. E., & Dickey, D. A. (1984). Testing for unit roots in autoregressive-moving average models of unknown order. *Biometrika*, 71(3), 599-607.
- Schulze, P. M., & Prinz, A. (2009). Forecasting container transshipment in Germany. *Applied Economics*, 41(22), 2809-2815.
- Slack, N., Brandon-Jones, A., & Johnston, R. (2013). *Operations management*. Pearson.
- Smith, M. S. (2015). Copula modelling of dependence in multivariate time series. *International Journal of Forecasting*, 31(3), 815-833.
- Stock, J. H., & Watson, M. W. (2004). Combination forecasts of output growth in a seven-country data set. *Journal of Forecasting*, 23(6), 405-430.
- Theil, H. (1966). *Applied economic forecasting*. Chicago, IL: Rand McNally.
- Timmermann, A. (2006). Forecast combinations. *Handbook of economic forecasting*, 1, 135-196.
- Trapletti, A., Hornik, K., LeBaron, B., & Hornik, M. K. (2018). Package 'tseries'.
- Vlahogianni, E. I., Karlaftis, M. G., & Golias, J. C. (2005). Optimized and meta-optimized neural networks for short-term traffic flow prediction: A genetic approach. *Transportation Research Part C: Emerging Technologies*, 13(3), 211-234.
- Wallis, K. F. (2011). Combining forecasts—forty years later. *Applied Financial Economics*, 21(1-2), 33-41.
- Wang, F. K., & Chang, K. K. (2010). Adaptive neuro-fuzzy inference system for combined forecasts in a panel manufacturer. *Expert Systems with Applications*, 37(12), 8119-8126.
- Wang, X., & Petropoulos, F. (2016). To select or to combine? The inventory performance of model and expert forecasts. *International Journal of Production Research*, 54(17), 5271-5282.
- Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management science*, 6(3), 324-342.
- Yan, J. (2007). Enjoy the joy of copulas: with a package copula. *Journal of Statistical Software*, 21(4), 1-21.
- Zhang, G. P., Patuwo, B. E., & Hu, M. Y. (2001). A simulation study of artificial neural networks for nonlinear time-series forecasting. *Computers & Operations Research*, 28(4), 381-396.

6 DISCUSSÃO

Os resultados encontrados e apresentados na forma de dois artigos convergiram quanto aos seus achados, a revisão sistemática de literatura (RSL) realizada evidenciou que métodos quantitativos são claramente dominantes nesse campo de pesquisa com predominância de modelos estatísticos e computacionais, direcionados à previsão de processos de manufatura, previsão de demanda, planejamento, controle, previsão de consumo energético e previsão de estoques.

As abordagens encontradas na RSL foram utilizadas na aplicação proposta na forma de estudo de caso, sendo aplicadas às principais classes de modelos de previsão predominantes na literatura, assim como o contexto de aplicação abordado modelando um sistema de produção a partir de seus indicadores operacionais. Dessa forma, os métodos aplicados estão de acordo com a atual literatura, garantindo o correto direcionamento da pesquisa tanto em termos metodológicos quanto ao contexto de aplicação.

Os resultados provenientes da aplicação dos modelos de previsão no artigo II demonstraram que entre as seis previsões finais obtidas para cada indicador, os modelos individuais ARIMA e ANN foram superiores em termos de acurácia em relação às previsões individuais em dois dos oito casos, e os métodos de combinação foram superiores nos seis dos demais indicadores modelados, destacando-se o modelo de cópula em relação às demais abordagens de combinação adotadas.

Tais resultados são corroborados pela literatura, como nos estudos realizado por Martins e Werner (2012), Pang e Gekba (2016), Jacobs, Souza e Zanini (2016) e Rosienkiewicz, Chlebus e Detyna (2017). Todos os autores citados encontraram resultados em que a combinação de previsões proveu aumento de acurácia em diversos contextos, com principal direcionamento ao setor industrial. Dessa forma, os resultados confirmam a importância da combinação de previsões como uma alternativa viável e cientificamente evidenciada.

7 CONCLUSÃO

Esta pesquisa teve como objetivo principal ajustar modelos de previsões acurados para séries do setor industrial. Foi realizado uma investigação exaustiva da atual literatura por meio de uma revisão sistemática considerando um escopo de 354 artigos publicados em periódicos no período compreendido entre 2008 e 2018, assim como uma aplicação de métodos combinados de previsão em um indicador de desempenho de um terminal portuário de grande porte.

As principais contribuições originais a literatura foram: (i) um mapeamento do atual estado da arte quanto a aplicação de modelos de previsão na indústria; (ii) a construção de um *framework* unificado relacionando métodos e previsão e contextos de aplicação, (iii) uma abordagem original considerando modelos de suavização exponencial, ARIMA e ANN e suas combinações por três métodos distintos, obtendo resultados empíricos ainda não encontrados na literatura com a mesma abordagem.

Como principais conclusões da presente pesquisa, quatro pontos principais emergem, possibilitando responder aos objetivos propostos:

— Métodos quantitativos são claramente dominantes nesse campo de pesquisa, com ênfase em três categorias: modelos estatísticos, modelos de inteligência artificial e modelos de simulação e otimização.

— Os principais contextos de aplicações de modelos de previsão no setor industrial são: processos de manufatura, previsão de demanda, planejamento, controle e *scheduling*, previsão de consumo energético e previsão de estoques.

— Os modelos individuais ARIMA e ANN foram superiores em termos de acurácia em relação às previsões individuais para o estudo de caso realizado.

— Os métodos de combinação proveram aumento de acurácia com destaque a abordagem não-linear por modelo de cópula.

REFERÊNCIAS

- ABRAHAM, B.; LEDOLTER, J. **Statistical Methods for Forecasting**. New Jersey: John Wiley & Sons, 2005.
- AGAMI, N. et al. A neural network based dynamic forecasting model for Trend Impact Analysis. **Technological Forecasting & Social Change**, v. 76, p. 952-962, 2009.
- AKAIKE, H. Information theory and an extension of the maximum likelihood principle. **2nd International Symposium on Information Theory**, Tsahkadsor, Armenia, USSR, 1973.
- AMENDOLA, A.; STORTI, G. A GMM procedure for combining volatility forecasts. **Computational Statistics & Data Analysis**, v. 52, p. 3047-3060, 2008.
- ASADI, S. I.; TAVAKOLI, A.; HEJAZI, S. R. A new hybrid for improvement of auto-regressive integrated moving average models applying particle swarm optimization. **Expert Systems with Applications**, v. 39, p. 5332-5337, 2012.
- ASSIS, T. F. O. CÓPULAS PARA COMBINAÇÃO DE MODELOS DE SÉRIES TEMPORAIS. **Tese (Doutorado) - Universidade Federal Rural de Pernambuco**, Recife, 2017.
- AYE, G. C. et al. Forecasting Aggregate Retail Sales: The Case of South Africa. **International Journal of Production Economics**, v. 160, p. 66-79, 2015.
- AZEVEDO, V. G.; CAMPOS, L. M. S. Combination of forecasts for the price of crude oil on the spot market. **International Journal of Production Research**, v. 54, p. 5219-5235, 2016.
- BATES, J. M.; GRANGER, C. W. J. The Combination of Forecasts. **Operational Research Society**, v. 20, p. 451-468, 1969.
- BESSA, R. J. et al. Time-adaptive quantile-copula for wind power probabilistic forecasting. **Renewable Energy**, v. 40, p. 29-39, 2012.
- BOX, G.; JENKINS, G. **Time Series Analysis, forecast and control**. San Francisco: Holden-Day, 1970.
- BOX, G.; JENKINS, G. **Time Series Analysis, forecast and control**. Revisada. ed. San Francisco: Holden-Day, 1976.
- BUENO, R. L. S. **Econometria de séries temporais**. São Paulo: Cengage Learning, 2008.
- CLEMEM, R. T. Combining forecasts: A review and annotated bibliography. **International Journal of Forecasting**, v. 5, p. 559-583, 1989.
- COSTANTINI, M.; PAPPALARDO, C. A hierarchical procedure for the combination of forecasts. **International Journal of Forecasting**, v. 26, p. 725-743, 2010.
- DICKEY, D. A. Power of Unit Root Tests. **Proceedings of business and economic statistics Sections**, v. 74, p. 427-431, 1984.

- DOGANIS, P.; AGGELOGIANNAKI, E.; SARIMVEIS, H. A combined model predictive control and time series forecasting framework for production-inventory systems. **International Journal of Production Research**, v. 24, p. 6841-6853, 2008.
- FIRMINO, P. R. A.; MATTOS NETO, P. S. G.; FERREIRA, T. A. E. Correcting and combining time series forecasters. **Neural Networks**, v. 50, p. 1-11, 2014.
- FLORES, B. E.; WHITE, E. M. Combining forecasts: why, when and how. **Journal of Business Forecasting Methods & Systems**, v. 8, p. 2-5, 1989.
- FLORES, J. H. F. Comparação de modelos de MLP/RNA e modelos Box-Jenkins em séries temporais não lineares. **Dissertação (Mestrado) - Universidade Federal do Rio Grande do Sul**, Porto Alegre, 2009.
- GENEST, C.; FAVRE, A.-C. Everything You Always Wanted to Know about Copula Modeling but Were Afraid to Ask. **Journal of Hydrologic Engineering**, v. 12, p. 347-368, 2007.
- GIL, A. C. **Como elaborar projetos de pesquisa**. São Paulo: Atlas, v. 5, 2010.
- GRANGER, C. W. J.; RAMANATHAN, R. Improved Methods of Combining Forecasts. **Journal of Forecasting**, v. 3, p. 197-204, 1984.
- GUJARATI, D. N.; PORTER, D. C. **Econometria Básica**. 5. ed. Porto Alegre: AMGH, 2011.
- HAIR, J. F. et al. **Análise multivariada de dados**. 5. ed. Porto Alegre: Bookman, 2005.
- HAYKIN, S. **Redes Neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.
- HEBB, D. O. **The Organization of Behavior: A Neuropsychological Theory**. New York: Wiley & Sons, 1949.
- HIBON, M.; EVGENIOU, T. To combine or not to combine: selecting among forecasts and their combinations. **International Journal of Forecasting**, v. 21, p. 15-24, 2005.
- HOLT, C. C. Forecasting seasonals and trends by exponentially weighted moving averages. **ONR Memorandum**, 1957.
- JACOBS, W. Combinação das previsões dos modelos de Box-Jenkins e MLP/RNA para a previsão de demanda no planejamento da produção. **Dissertação (Mestrado) - Universidade Federal de Santa Maria**, Santa Maria, 2014.
- JACOBS, W.; SOUZA, A. M.; ZANINI, R. R. Combination of Box-Jenkins and MLP/RNA models for forecasting. **IEEE Latin America Transactions**, v. 14, p. 1870-1878, 2016.
- JEONG, D. I.; KIM, Y.-O. Combining single-value streamflow forecasts – A review and guidelines for selecting techniques. **Journal of Hydrology**, v. 377, p. 284-299, 2009.
- JOE, H.; XU, J. J. The Estimation Method of Inference Functions for Margins for Multivariate Models. **R. Faculty Research and Publications**, v. 166, p. 1-22, 1996.
- JOHNSON, D.; KING, M. **Basic Forecast Techniques**. London: Butterworth & Co., 1988.

KONIG, A. J. et al. The M3 competition: Statistical tests of the results. **International Journal of Forecasting**, v. 21, p. 397–409, 2005.

KOVÁCS, Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações**. 4. ed. São Paulo: Livraria da Física, 2006.

KWIATKOWSKI, D. et al. Testing the null hypothesis of stationarity against the alternative of a unit root. **Journal of Econometrics**, v. 54, p. 159-178, 1992.

LAHIRI, K.; YANG, L. A non-linear forecast combination procedure for binary outcomes. **Stud. Nonlinear Dyn**, v. 20, p. 421-440, 2016.

LAWRENCE, K. D.; KLIMBERG, R. K.; LAL, T. Using data envelopment analysis (DEA) to forecast bank performance. **Advances in Business and Management Forecasting**, 2009.

LEE, Y.-S.; TONG, L.-I. Forecasting time series using a methodology based on autoregressive integrated moving average and genetic programming. **Knowledge-Based Systems**, v. 24, p. 66-72, 2011.

LIU, X. Modeling time-varying skewness via decomposition for out-of-sample forecast. **International Journal of Forecasting**, v. 31, p. 296-311, 2015.

LUSTOSA, L. et al. **Planejamento e Controle da Produção**. Rio de Janeiro: Elsevier, 2008.

MAKRIDAKIS, S.; HIBON, M. The M3-Competition: results, conclusions and implications. **International Journal of Forecasting**, v. 16, p. 451-476, 2000.

MAKRIDAKIS, S.; STEVEN, W.; HYNDMAN, R. **Forecasting: Methods and Applications**. 3. ed. New Jersey: John Wiley & Sons, 1998.

MAKRIDAKIS, S.; WINKLER, R. L. Averages of Forecasts: Some Empirical Results. **Management Science**, v. 29, p. 987-996, 1983.

MARTINS, P. G.; LAUGENI, F. P. **Administração da Produção**. 2. ed. São Paulo: Saraiva, 2009.

MARTINS, V. L. M. Comparação de combinação de previsões correlacionadas e não correlacionadas com as suas previsões individuais : um estudo com séries industriais. **Dissertação (Mestrado) - Universidade Federal do Rio Grande do Sul**, Porto Alegre, 2011.

MARTINS, V. L. M.; WERNER, L. Forecast combination in industrial series: A comparison between individual forecasts and its combinations with and without correlated errors. **Expert Systems with Applications**, v. 39, p. 11479-11486, 2012.

MARTINS, V. L. M.; WERNER, L. Comparação de previsões individuais e suas combinações: um estudo com séries industriais. **Production**, v. v. 24, n. 3, p. 618-627, 2014.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of mathematical biophysics**, v. 5, p. 115-133, 1943.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting**. New Jersey: John Wiley & Sons, 2007.

MOREIRA, D. A. **Administração da Produção e Operações**. 2. ed. São Paulo: Cengage Learning, 2014.

MORETTIN, P. A. **Econometria Financeira - um curso em séries temporais financeiras**. 1. ed. São Paulo: Blucher, 2008.

MORETTIN, P. A. **Econometria financeira - Um curso em séries temporais financeiras**. 2. ed. São Paulo: Blucher, 2011.

MORETTIN, P. A. et al. Wavelet Estimation of Copulas for Time Series. **Journal of Time Series Econometrics**, v. 3, 2011.

MORETTIN, P. A.; TOLOI, C. M. C. **Previsão de séries temporais**. 2. ed. São Paulo: Atual, 2006.

NELSEN, R. B. **An Introduction to Copulas**. Portland: Springer, v. 2, 2006.

OLIVEIRA, R. T. A. et al. Combining Time Series Forecasting Models Via Gumbel-Hougaard Copulas. **BRICS Congress on Computational Intelligence & 11th Brazilian Congress on Computational Intelligence**, 2013.

OLIVEIRA, R. T. A. et al. Copulas-Based Ensemble of Artificial Neural Networks for Forecasting Real World Time Series. **International Joint Conference on Neural Networks (IJCNN)**, 2016.

OLIVEIRA, R. T. A. et al. Copulas-based time series combined forecasters. **Information Sciences**, v. 376, p. 110-124, 2017.

PANG, G.; GEBKA, B. Forecasting container throughput using aggregate or terminal-specific data? The case of Tanjung Priok Port, Indonesia. **International Journal of Production Research**, v. 55, p. 2454-2469, 2017.

PATTON, A. J. A review of copula models for economic time series. **Journal of Multivariate Analysis**, v. 110, p. 4-18, 2012.

PEREIRA, L. P.; REQUEIJO, G. J. **Qualidade: Planejamento e Controlo Estatístico de Processos**. Lisboa: FCT/UNL, 2008.

PRODANOV, C. C.; FREITAS, E. C. **Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico**. 2. ed. Novo Hamburgo: Universidade Feevale, 2013.

QI, M.; ZHANG, G. P. An investigation of model selection criteria for neural network time series forecasting. **European Journal of Operational Research**, v. 132, p. 666-680, 2001.

RAUSSER, G. C.; OLIVEIRA, R. A. An econometric analysis of wilderness area use. **Journal of the American Statistical Association**, v. 71, p. 276-285, 1976.

RIPLEY, B. D. **Pattern Recognition and Neural Networks**. Cambridge: Cambridge University Press, 1996.

RODRIGUES, B. D.; STEVENSON, M. J. Takeover prediction using forecast combinations. **International Journal of Forecasting**, v. 29, p. 628-641, 2013.

ROSENBLATT, F. **Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms**. Washington D. C.: Spartan Books, 1962.

ROSIENKIEWICZ, M.; CHLEBUS, E.; DETYNA, J. A Hybrid Spares Demand Forecasting Method Dedicated to Mining Industry. **Applied Mathematical Modelling**, v. 49, p. 87-107, 2017.

SANTOS, R. O.; VELLASCO, M. B. A NEW framework for dynamic forecast combination. **Expert Systems with Applications**, v. 42, p. 8625-8636, 2015.

SCHWARZ, G. E. Estimating the dimension of a model. **Annals of Statistics**, v. 6, p. 461-464, 1978.

SLACK, N.; BRANDON-JONES, A.; JOHNSTON, R. **Administração da Produção**. São Paulo: Atlas, 2015.

SMITH, M. S. Copula modelling of dependence in multivariate time series. **International Journal of Forecasting**, 2015.

SOUZA, A. M. et al. Electrical energy supply for Rio Grande do Sul, Brazil, using forecast combination of weighted eigenvalues. **GEPROS: Gestão da Produção, Operações e Sistemas**, v. 6, p. 23, 2011.

SOUZA, F. M. **Modelos de Previsão: aplicações à energia elétrica - ARIMA - ARCH - AI e ACP**. Curitiba: Appris, 2016.

STOCK, J. W.; WATSON, M. W. Combination Forecasts of Output Growth in a Seven-Country Data Set. **Journal of Forecasting**, v. 23, p. 405-430, 2004.

TSENG, F.-M.; YU, H.-C.; TZENG, G.-H. Combining neural network model with seasonal time series ARIMA models. **Technological Forecasting & Social Change**, v. 69, p. 71-87, 2002.

TUBINO, D. F. **Planejamento e controle da produção: teoria e prática**. 2. ed. São Paulo: Atlas, 2009.

WALLIS, K. F. Combining forecasts – forty years later. **Applied Financial Economics**, v. 21, p. 33-41, 2011.

WAN, L. et al. A Type of Combination Forecasting Method Based on Time Series Method and PLS. **American Journal of Operations Research**, v. 2, p. 467, 2012.

WANG, F.-K.; CHANG, K.-K. Adaptive neuro-fuzzy inference system for combined forecasts in a panel manufacturer. **Expert Systems with Applications**, v. 37, p. 8119-8126, 2010.

WERNER, L. Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião. **Tese (Doutorado) - Universidade Federal do Rio Grande do Sul**, Porto Alegre, 2005.

WERNER, L.; RIBEIRO, J. L. D. Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais. **Gestão & Produção**, v. 10, p. 47-67, 2003.

WIDROW, B. Propagation of Statistics in Systems. **IRE WESCON Western Electronics Show and Convention Record**, v. 2, p. 114-121, 1957.

WINTERS, P. R. Forecasting Sales by Exponentially Weighted Moving Averages. **Management Science**, p. 324-342, 1960.

XIAO, L. et al. A combined model based on multiple seasonal patterns and modified firefly algorithm for electrical load forecasting. **Applied Energy**, v. 167, p. 135-153, 2016.

YAN, J. Enjoy the Joy of Copulas: With a Package copula. **Journal of Statistical Software**, v. 21, p. 1-21, 2007.

YIN, S.; LIU, L.; HOU, J. A multivariate statistical combination forecasting method for product quality evaluation. **Information Sciences**, v. 355, p. 229-236, 2016.

ZHANG, G. P.; PATUWO, B. E.; HU, M. Y. A simulation study of artificial neural networks for nonlinear time-series forecasting. **Computers & Operations Research**, v. 28, p. 381-396, 2001.

ZOU, H.; YANG, Y. Combining time series models for forecasting. **International journal of Forecasting**, v. 20, p. 69-84, 2004.