

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ
MARIANA DE SIQUEIRA GUERSOLA

**PROPOSTA DE UMA METODOLOGIA PARA ANÁLISE E PREVISÃO DE
INDICADORES-CHAVE DE DESEMPENHO DE EMPRESAS DO SETOR
PRODUTIVO**

CURITIBA
2017

MARIANA DE SIQUEIRA GUERSOLA

**PROPOSTA DE UMA METODOLOGIA PARA ANÁLISE E PREVISÃO DE
INDICADORES-CHAVE DE DESEMPENHO DE EMPRESAS DO SETOR
PRODUTIVO**

Tese apresentada como requisito parcial à obtenção de grau de Doutora em Engenharia de Produção e Sistemas, Programa de Pós-Graduação em Engenharia de Produção e Sistemas, Pontifícia Universidade Católica do Paraná.

Orientadora: Prof.^a Dr.^a Maria Teresinha
Arns Steiner

CURITIBA

2017

Dados da Catalogação na Publicação
Pontifícia Universidade Católica do Paraná
Sistema Integrado de Bibliotecas – SIBI/PUCPR
Biblioteca Central

G935p
2017

Guersola, Mariana de Siqueira
Proposta de uma metodologia para análise e previsão de indicadores-chave de desempenho de empresas do setor produtivo / Mariana de Siqueira Guersola ; orientadora: Maria Teresinha Arns Steiner. – 2017.
241 f. : il. ; 30 cm

Tese (doutorado) – Pontifícia Universidade Católica do Paraná, Curitiba, 2017
Bibliografia: f. 107-117

1. Engenharia de produção. 2. Padrões de desempenho. 3. Indicadores.
4. Redes neurais. I. Steiner, Maria Teresinha Arns. II. Pontifícia Universidade Católica do Paraná. Programa de Pós-Graduação em Engenharia de Produção e Sistemas. III. Título.

CDD 22. ed. – 670

TERMO DE APROVAÇÃO

Mariana de Siqueira Guersola

PROPOSTA DE UMA METODOLOGIA PARA ANÁLISE E PREVISÃO DE INDICADORES-CHAVE DE DESEMPENHO DE EMPRESAS DO SETOR PRODUTIVO.

Tese aprovada como requisito parcial para obtenção do grau de Doutora no Curso de Doutorado em Engenharia de Produção e Sistemas, Programa de Pós-Graduação em Engenharia de Produção e Sistemas, da Escola Politécnica da Pontifícia Universidade Católica do Paraná, pela seguinte banca examinadora:

Presidente da Banca
Prof^a. Dr^a. Maria Teresinha Arns Steiner
(Orientadora)

Prof. Dr. Fernando Deschamps
(Membro Interno)

Prof. Dr. Marcelo Gechele Cleto
(Membro Externo)

Prof. Dr. Paulo Henrique Siqueira
(Membro Externo)

Prof. Dr. Pedro José Steiner Neto
(Membro Externo)

Curitiba, 15 de dezembro de 2017.

RESUMO

Realizar avaliações constantes do desempenho é uma maneira eficaz para as empresas se manterem competitivas. Uma revisão sistemática de literatura sobre indicadores de desempenho de manufatura levantou diversas necessidades de pesquisa nessa área, entre as quais está a necessidade de desenvolver métodos quantitativos para analisar as relações existentes entre os diferentes indicadores e, também, a necessidade de prever o comportamento futuro dos mesmos. Este trabalho objetiva cobrir estas necessidades, propondo uma metodologia que possa ser utilizada como uma ferramenta de auxílio à gestão das empresas. A metodologia proposta consiste em três fases. A primeira fase diz respeito à coleta e análise dos dados. A segunda fase visa calcular as correlações estatísticas entre os indicadores, organizá-las de forma hierárquica e analisá-las. A terceira fase foca em realizar previsões para os indicadores utilizando redes neurais MLP (*Multiple Layer Perceptron* ou Perceptron de Múltiplas Camadas) e RBF (*Radial Basis Function* ou Função de Base Radial). A metodologia foi aplicada a três empresas, de portes e áreas de atuação distintos, como forma de avaliar a sua adaptabilidade a diferentes situações. Os resultados indicam que as hierarquias de correlações entre indicadores podem ser úteis tanto para gerir o conjunto de indicadores (identificando indicadores que possam ser eliminados ou incluídos), quanto para gerir a própria empresa, ampliando as percepções das relações entre os diferentes fenômenos que influenciam os resultados das empresas. A previsão futura dos indicadores-chave atingiu resultados satisfatórios para 17 das 18 situações previstas, e as redes neurais MLP superaram as RBF. A maior limitação da metodologia proposta é a necessidade de ter registros históricos dos indicadores, impossibilitando a sua implementação em empresas novas ou em empresas que não tenham implementado indicadores de desempenho há pelo menos três anos.

Palavras-chave: Desempenho; Indicadores; Correlação; Previsão; Redes neurais.

ABSTRACT

Conducting regular performance assessments is an effective way for companies to remain competitive. A systematic literature review on manufacturing performance indicators raised several research gaps, among which are the need for non-empirical methods to analyze the relationships between different indicators and the need to predict future behavior of indicators. This work aims to cover these gaps by proposing a methodology which can be used as a tool to improve company's management. The proposed methodology consists of three phases. The first phase concerns the data collection and analysis. The second phase aims to calculate the statistical correlations between indicators, organize them hierarchically and analyze the result. The third phase focuses on predicting indicators future values, implementing MLP (multi layer perceptron) and RBF (radial basis function) neural networks. The methodology was applied to three companies, of different sizes and expertise areas, in order to assess its adaptability to different situations. Results indicate that correlation hierarchies between indicators can be useful both to manage the indicators set, identifying indicators which can be removed or added, and to manage the company, expanding the perceptions on the relationship between the different phenomena influencing results. The performance indicators forecast achieved satisfactory results for 17 out of 18 test situations, and MLP neural networks outperformed RBF networks. The proposed methodology's biggest limitation is the need for indicators historical data, which makes implementation impossible for new enterprises and companies without performance indicators implemented for at least 3 years.

Keywords: Performance; Indicators; Correlation; Forecasting; Neural Networks.

LISTA DE FIGURAS

Figura 2.1 Localização das pesquisas na área de indicadores	24
Figura 2.2. Modelo de Neurônio de uma RNA	35
Figura 2.3. Exemplo de rede MLP com três camadas	36
Figura 2.4 Padrão espacial da rede RBF	41
Figura 2.5: Explicação vetorial da RBF	41
Figura 2.6: Função gaussiana	42
Figura 3.1. Exemplo de padrões de dados de entrada e saída	58
Figura 4.1: Gráfico linear Empresa A: Indicador “Reclamação do cliente geral”	64
Figura 4.2: Outlier por gráfico linear da Empresa A: Indicador “Consumo de óleo combustível Fábrica 01”	65
Figura 4.3: Outlier por gráfico boxplot da Empresa A: Indicador “Consumo de óleo combustível Fábrica 01”	65
Figura 4.4: Nova série da Empresa A: Indicador “Consumo de óleo combustível Fábrica 01”	66
Figura 4.5: Gráfico linear da Empresa B: Indicador “Ativos: Todos os ramos”	67
Figura 4.6: Outlier por gráfico linear Empresa B: Indicador “Despesas administrativas”	67
Figura 4.7: Outlier por gráfico bloxplot Empresa B: Indicador “Despesas administrativas”	68
Figura 4.8: Nova série da Empresa B: Indicador “Despesas administrativas”	68
Figura 4.9. Inconsistência por gráfico linear Empresa C: Indicador “Despesas comerciais”	69
Figura 4.10. Empresa C. Indicador “Despesas comerciais” ajustado	70
Figura 4.11. Outlier por gráfico linear Empresa C: Indicador “Despesas de exportação”	70
Figura 4.12. Outlier por gráfico boxplot Empresa C: Indicador “Despesas de exportação”	71
Figura 4.13. Nova série da Empresa C: Indicador “Despesas de Exportação”	71
Figura 4.14. Empresa A. Hierarquia do indicador “Scrap consolidado do produto A total”	73

Figura 4.15. Empresa A. Hierarquia do indicador “Produtividade por funcionário da fábrica 2”	75
Figura 4.16. Empresa B. Hierarquia do indicador “Endividamento total”	76
Figura 4.17. Empresa B. Hierarquia do indicador “Rentabilidade dos ativos”	77
Figura 4.18. Empresa C. Hierarquia do indicador “EBITDA”	78
Figura 4.19. Empresa C. Hierarquia “Custo médio dos produtos vendidos”	79
Figura 4.20. Empresa C. Hierarquia indicador “quantidade produzida fábrica”	81
Figura 4.21 Dados Empresa A: Indicador “Produtividade por funcionário da fábrica 2”	83
Figura 4.22 Dados Empresa A: Indicador “Scrap consolidado do produto A total”	83
Figura 4.23 Dados Empresa B: Indicador “Endividamento total”	84
Figura 4.24 Dados empresa B: Indicador “Rentabilidade dos Ativos”	84
Figura 4.25 Dados empresa C: Indicador “Custo médio dos produtos vendidos”	85
Figura 4.26 Dados empresa C: Indicador “EBITDA”	85
Figura 4.27 Percentual de redes RBF com bom desempenho por Spread	96
Figura 4.28 Porcentagem das redes (MLP) que tiveram erro máximo menor do que 5% por meio da análise da quantidade de neurônios escondidos	97

LISTA DE TABELAS

Tabela 4.1 Características das Empresas Analisadas	62
Tabela 4.2: Resumo da fase 1: coleta e análise dos dados	63
Tabela 4.3 Melhores RNAs encontradas para a previsão dos indicadores-chave.....	89
Tabela 4.4 Análise dos dados de entrada das RNA considerando as três redes com	94
Tabela 4.5 Porcentagem das redes (MLP e RBF) com erro máximo menor do que 5%	95
Tabela 4.6 Porcentagem das redes (MLP) que tiveram erro máximo menor do que 5% por meio da análise da taxa de aprendizagem.....	96
Tabela 4.7 Porcentagem das redes (MLP) que tiveram erro máximo menor do que 5% por meio da análise da função de ativação	97
Tabela 4.8 Porcentagem das redes (MLP) que tiveram erro máximo menor do que 5% por meio da análise de avaliação do treinamento	98
Tabela 4.9 Exemplo de escolha de RNA para implementação (Empresa A; Indicador: “Produtividade por funcionário da fábrica 2”)	99

LISTA DE QUADROS

Quadro 2.1 Protocolo de pesquisa para revisão sistemática da literatura	22
Quadro 2.2 Palavras-chave mais utilizadas nos artigos revisados	25
Quadro 2.3 Funções de Ativação para RNAs.....	38
Quadro 2.4 Trabalhos Correlatos	50
Quadro 3.1 Metodologia de Resolução de Problemas aplicada aos Problemas de Pesquisa.....	54
Quadro 3.2: Metodologia Proposta: 3 Fases e 12 Passos.....	54

LISTA DE ABREVIATURAS E SIGLAS

AFSA	Artificial fish swarm algorithm / Algoritmo de cardume peixes artificiais
AHP	Analytic hierarchy process / Processo de hierarquia analítica
BNDES	Banco Nacional de Desenvolvimento Econômico e Social
BSC	Balanced Scorecard / Indicadores Balanceados de Desempenho
CDI	Certificado de Depósito Interbancário
CUB	Custos Unitários Básicos de Construção
DEA	Data envelopment analysis / Análise envoltória de dados
EBITDA	Earnings before interest, taxes, depreciation and amortization / Lucros antes de juros, impostos, depreciação e amortização
IBGE	Instituto Brasileiro de Geografia e Estatística
ICEI	Índice de Confiança do Empresário Industrial
IGP-DI	Índice geral de preços disponibilidade interna
IGP-M	Índice Geral de Preços do Mercado
INCC-DI	Índice Nacional de Custo de Construção, Disponibilidade Interna
INEC	Índice nacional de expectativa do consumidor Brasil.
IPA-DI	Índice de preços por atacado
IPC	Índice de Preços ao Consumidor
IPCA	Índice Nacional de Preços ao Consumidor Amplo
ISM	Interpretive structural modeling / Modelagem estrutural interpretativa
KPI	Key performance indicators / Indicadores chave de desempenho
MATLAB	Matrix laboratory / Laboratório de matriz
MIWI	Mutual information based weight initialization / Inicialização de peso baseada em informações mútuas
MLP	Multilayer perceptron / Perceptron de múltiplas camadas
MSE	Mean square error / Erro médio quadrado
OEE	Overall equipment effectiveness / Eficiência geral de equipamento
ProMES	Productivity measurement and evaluation system / Sistema de medição e avaliação de produtividade
RBF	Radial basis function / Função de base radial
RNA	Rede Neural Artificial / Rede neural artificial
SELIC	Sistema Especial de Liquidação e de Custódia

SPSS	Statistical Package for the Social Sciences / Pacote estatístico para as ciências sociais
UNIDO	United Nations Industrial Development Organization / Organização de desenvolvimento industrial das Nações Unidas

SUMÁRIO

1.	Introdução	15
1.1.	Objetivos	17
1.2.	Metodologia da pesquisa	18
1.3.	Contribuições	18
1.4.	Organização do trabalho	19
2.	Referencial Teórico	21
2.1.	Indicadores de desempenho	21
2.1.1.	Análise descritiva	23
2.1.2.	Análise temática	26
2.1.3.	Temas para pesquisa	30
2.2.	Correlação entre indicadores de desempenho.....	31
2.3.	Previsão de séries temporais	32
2.4.	Redes Neurais Artificiais	34
2.4.1.	Rede Perceptron de Múltiplas Camadas (MLP)	36
2.4.2.	Redes neurais RBF	40
2.4.3.	RNAs e a utilização dos dados.....	42
2.5.	Análise e limpeza de dados	44
2.6.	Trabalhos correlatos	45
3.	Metodologia Proposta	53
3.1.	Coleta e análise dos dados	55
3.2.	Correlação entre indicadores de desempenho.....	56
3.3.	Previsão de indicadores-chave de desempenho.....	56
3.3.1.	Preparação dos dados de entrada	57
3.3.2.	Testes com diferentes redes neurais para a previsão	58
3.3.3.	Definição da rede com melhor desempenho	59
4.	Resultados	61
4.1.	Fase 1: Coleta e análise dos dados	61
4.1.1.	Empresa A.....	64
4.1.2.	Empresa B.....	66
4.1.3.	Empresa C	69
4.2.	Fase 2: Correlação entre indicadores de desempenho.....	72

4.2.1.	Empresa A.....	72
4.2.2.	Empresa B.....	76
4.2.3.	Empresa C	78
4.3.	Fase 3: Previsão futura dos indicadores-chave.....	82
4.3.1.	Preparação dos dados	82
4.3.2.	Testes com as RNA.....	87
4.3.3.	Análise das melhores configurações de RNAs.....	94
4.3.4.	Escolha da rede a ser implementada	98
5.	Discussão.....	100
5.1.	Fase 1: Coleta e análise dos dados	101
5.2.	Fase 2: Correlação entre indicadores de desempenho	102
5.3.	Fase 3: Previsão futura dos indicadores-chave.....	103
6.	Conclusões	105
6.1.	Limitações	107
6.2.	Sugestões de trabalhos futuros.....	107
	Referências	109
	APÊNDICE A. Indicadores de desempenho identificados na revisão sistemática da literatura	120
	APÊNDICE B. Indicadores de desempenho da Empresa A.....	132
	APÊNDICE C. Indicadores de desempenho da Empresa B.....	134
	APÊNDICE D. Indicadores de desempenho da Empresa C.....	138
	APÊNDICE E. Proposta de Lista reduzida de indicadores da Empresa B	142

1. INTRODUÇÃO

Condições econômicas e políticas desfavoráveis e sem precedentes, as quais tornam o ambiente atual de negócios instável, repleto de turbulências e incertezas, estão presentes no mundo, e especialmente no Brasil, desde a crise financeira de grandes proporções no final da década de 2000. Isto, segundo Psomas e Kafetzopoulos (2014), representa uma ameaça significativa para as empresas, que estão lutando para sobreviver e precisam adaptar o seu estilo de gestão e suas perspectivas estratégicas para lidar com estes desafios.

Além das mudanças econômicas, o rápido desenvolvimento tecnológico também mudou as necessidades dos clientes e os padrões de concorrência comercial (Yang *et al.*, 2009). A fabricação existe para criar valor, mas esse valor sofre alterações com o decorrer do tempo (Plehn *et al.*, 2012). Segundo Olivella e Gregorio (2015) um sistema de medição de desempenho pode ser usado para concentrar as organizações na cadeia de valor, melhorando a percepção sobre o que irá gerar valor para o cliente.

Os fabricantes devem ter um método eficaz de medir e avaliar o desempenho de seus processos de fabricação, a fim de melhorar o desempenho operacional e reduzir os custos. Um desempenho superior, como colocado por Amrina e Yusof (2011), leva a uma maior competitividade e, por este motivo, para que se mantenham competitivas, é vital que as empresas de manufatura realizem avaliações regulares de desempenho. Medição de desempenho eficaz é, então, uma questão primordial para as empresas de hoje (Jain *et al.*, 2011).

É necessário estabelecer uma métrica apropriada para identificar os problemas presentes nas empresas e melhorar os seus desempenhos (Eswaramurthi e Mohanram, 2013). Desta forma, o primeiro passo na criação de um sistema para a medição do desempenho, conforme apresentado por Dočekalová (2013), é determinar os indicadores de desempenho considerados chaves (*Key Performance Indicators - KPI*). KPIs são definidos por Zhu *et al.* (2014) como “medidas quantificáveis e estratégicas que refletem os fatores críticos de sucesso do processo de manufatura”; são muito úteis para a compreensão, *benchmarking* e melhoria do desempenho.

O processo de seleção de medidas de desempenho é um processo subjetivo, o qual frequentemente envolve o alto escalão administrativo “sentado a uma mesa”

para escolher uma medida a partir de uma série de alternativas (Folan e Browne, 2005). Os gerentes têm a tendência de medir o que é fácil, e não o que é necessário, o que leva a maioria das empresas a utilizar medidas erradas ou medidas corretas de maneiras erradas (Gomes *et al.*, 2004; El Mola e Parsaei, 2010). El Mola e Parsaei (2010) afirmam que "pouco tem sido feito para identificar as dimensões críticas de desempenho, para enumerar as medidas que existem e para definir como selecionar as medidas adequadas". Uma revisão da literatura sobre os indicadores de desempenho, incluindo uma lista dos mesmos e classificações encontradas na literatura, pode ajudar a escolher as medidas adequadas ao projetar ou atualizar os sistemas de gestão de desempenho. Desta forma, a primeira questão de pesquisa deste trabalho é: quais são os indicadores de desempenho utilizados pelas organizações e quais são as indicações quanto à melhor maneira de selecioná-los?

Além de escolher indicadores individualmente relevantes para a organização, é preciso analisar e compreender o grupo de indicadores como um todo, uma vez que uma variação em um indicador pode gerar outra variação, positiva ou negativa, em outro indicador. Como exemplos dessas influências, Macchi (2008) cita que uma melhoria na eficiência dos equipamentos deverá beneficiar o tempo de escoamento, enquanto Sueyoshi e Goto (2010) afirmam que diversos estudos mostram que uma redução da poluição pode levar a um ganho financeiro.

Diferentes métricas fornecem avaliações diferentes e possivelmente conflitantes, o que torna difícil, para os tomadores de decisão, controlar e melhorar o desempenho global (Jain *et al.*, 2011). As decisões devem, de acordo com Zhu *et al.* (2014), equilibrar indicadores conflitantes, considerando as restrições e as necessidades reais, buscando um ponto de operação para obter o máximo benefício possível. Assim, entender como os diferentes indicadores estão correlacionados pode auxiliar tanto na escolha adequada do conjunto de KPIs a ser utilizado, quanto na gestão desse conjunto, dando subsídios para decisões mais bem embasadas. A partir disso, a segunda questão de pesquisa deste trabalho é: Como identificar as relações entre os indicadores de desempenho e utilizá-las para melhorar a compreensão dos processos e a gestão das empresas?

Os indicadores de desempenho tradicionais são criticados por medirem o passado em vez de "olharem" para o futuro. Jusoh *et al.* (2008a) destacam que as métricas são, na maioria dos casos, obsoletas e atrasadas, refletindo o resultado de uma decisão do passado. Olivella e Gregorio (2015) complementam colocando que a

análise dos indicadores deve ter ênfase sobre o futuro, não sobre o passado, e que o foco deve ser mantido nos indicadores de desempenho chave. Procedimentos para estimar com precisão as medidas de desempenho podem ajudar a tomar decisões mais consistentes, especialmente no que diz respeito à alocação de recursos (Damodaran e Hulett, 2012; Hulett e Damodaran, 2011). A terceira, e última, questão de pesquisa deste trabalho é: Como realizar previsões futuras dos indicadores-chave das empresas para auxiliar a tomada de decisão?

1.1. Objetivos

O objetivo geral deste trabalho é propor e testar, por meio de múltiplos estudos de caso, uma metodologia que, utilizando técnicas da área de Pesquisa Operacional, possa auxiliar a gestão dos indicadores de desempenho dentro de empresas, melhorando o processo de tomada de decisão.

Os objetivos específicos deste trabalho são:

- a) Identificar, a partir da literatura, e classificar, uma lista de indicadores de desempenho de manufatura, assim como quais são as indicações quanto à melhor maneira de selecioná-los.
- b) Coletar e analisar os dados dos indicadores de desempenho das empresas objeto do estudo de múltiplos casos;
- c) Estabelecer as correlações estatísticas entre os principais indicadores, utilizá-las para organizar os KPIs de forma hierárquica, e propor modificações no conjunto de indicadores e na gestão das empresas com base na análise das hierarquias;
- d) Testar diferentes tipos de redes neurais para prever os valores futuros dos indicadores-chave das empresas e definir qual é a melhor rede a ser implantada em cada uma das empresas analisadas.

O objetivo específico “a” visa responder à primeira questão de pesquisa levantada, identificando os indicadores de desempenho utilizados pelas empresas e as indicações quanto à melhor maneira de selecioná-los. O objetivo “b” provê as informações necessárias para que os objetivos posteriores possam ser alcançados. O objetivo “c” responde à segunda questão de pesquisa, identificando as relações entre os indicadores e utilizando-as para melhorar a compreensão dos processos e a gestão dos indicadores e da empresa. O objetivo “d” procura responder à terceira

questão de pesquisa, realizando previsões futuras dos indicadores-chave das empresas a serem utilizadas para auxiliar a tomada de decisão.

1.2. Metodologia da pesquisa

Existem maneiras distintas de classificar trabalhos científicos. De acordo com Gil (2010), este trabalho pode ser classificado como:

- a) Quanto à finalidade: pesquisa aplicada, já que busca resolver problemas e é voltada “à aquisição de conhecimento com vistas à aplicação numa situação específica”.
- b) Quanto ao objetivo: pesquisa exploratória, uma vez que busca identificar relações entre variáveis e deixar o tema em estudo mais familiar.
- c) Quanto aos métodos empregados, estão incluídos: pesquisa bibliográfica, baseada em outros materiais publicados e com o propósito de fornecer fundamentação ao trabalho assim como identificar o estágio do conhecimento; pesquisa experimental, aquela na qual é realizado o controle de alterações das variáveis envolvidas como forma de analisar as variações nos resultados; e estudo de caso, caracterizado como um estudo profundo de um ou poucos objetos, que considera o contexto em que estão inseridos.

A adequação da proposta metodológica deste trabalho é percebida na colocação de Martins *et al.* (2014), quando os autores afirmam que os principais métodos de pesquisa científica utilizados em engenharia de produção são: pesquisa experimental, método de modelagem e simulação, *survey*, estudo de caso e pesquisa-ação. Os mesmos autores, porém, chamam a atenção para a maior limitação do estudo de caso, que consiste na necessidade de ter muito cuidado com a generalização, uma vez que este método não é utilizado para estudo de populações.

1.3. Contribuições

A medição do desempenho das empresas, incluindo as diferentes maneiras de realizá-la com precisão, é um campo de importância crescente, tanto para o ambiente empresarial quanto para o acadêmico, conforme colocado em concordância pelos trabalhos de El Mola e Parsaei (2010) e Parthiban e Goh (2011). O presente estudo de múltiplos casos aproxima a indústria da academia ao estudar um tema relevante para ambas, colocando a teoria em prática.

Como já citado na introdução, a escolha de indicadores de desempenho é geralmente baseada em experiências do gestor; há uma falta de métodos quantitativos para apoiar ou executar a escolha e a avaliação do conjunto de indicadores adequado. Aplicar técnicas da área de Pesquisa Operacional pode potencialmente melhorar a qualidade da gestão de desempenho das empresas, além de aproximar diferentes áreas importantes para a Engenharia de Produção, as quais podem ser beneficiadas por trabalhos em conjunto.

A melhora na gestão do desempenho pode ajudar as indústrias brasileiras a sobreviverem durante os momentos de turbulência política e econômica, tornando-as mais competitivas. Os países que mais investem em pesquisas sobre medição de desempenho estão entre os industrialmente mais evoluídos, como mostra a revisão de literatura e, assim sendo, trabalhos como o aqui apresentado podem ter impacto no desenvolvimento da indústria nacional.

A originalidade deste trabalho, ou seja, sua diferença em relação a outros trabalhos acadêmicos, encontra-se nos seguintes tópicos, que estão explicados em detalhes no decorrer do trabalho:

- Proposta de uma nova forma de classificação de indicadores de desempenho baseada no modelo *input-transformação-output* (ou entrada-transformação-saída);
- Proposta de uma nova forma de analisar as interferências entre diferentes indicadores, construindo uma hierarquia de importância e de correlação entre eles, a partir dos indicadores-chave;
- Proposta de uma nova forma de escolher os dados de entrada para as redes neurais de previsão de indicadores-chave, utilizando dados internos e externos à empresa, além de dados históricos associados a dados de prospecção;
- Proposta de uma nova metodologia completa, que integra a adequação de indicadores, sua análise e previsão, de forma a respaldar uma melhor tomada de decisão.

1.4. Organização do trabalho

O capítulo 2 concentra a revisão da literatura, a qual inclui as técnicas de análise de dados e de correlação de variáveis que são utilizadas; algumas

informações sobre previsão de séries temporais e redes neurais artificiais aplicadas à previsão de séries temporais, além de uma revisão sistemática de literatura sobre indicadores de desempenho.

O capítulo 3 apresenta a metodologia proposta, composta de três etapas principais: coleta e análise dos dados, cálculo e análise das correlações estatísticas entre os indicadores e previsão futura de indicadores-chave.

O capítulo 4 apresenta detalhes sobre as empresas que fazem parte do estudo de caso, além dos resultados obtidos com a aplicação da metodologia proposta. O capítulo 5 contém as discussões sobre a metodologia e os resultados, envolvendo vantagens, dificuldades encontradas e sugestões para implementação futura.

E, finalmente, o capítulo 6 apresenta as conclusões e inclui sugestões para trabalhos futuros.

2. REFERENCIAL TEÓRICO

A pesquisa de literatura inicia com uma revisão sistemática sobre indicadores de desempenho, a qual inclui uma análise da área de pesquisa, uma análise de temas importantes relativos aos indicadores de desempenho e uma lista de temas levantados para pesquisas futuras. O referencial teórico aborda também as correlações estatísticas e a previsão de séries temporais. O método das redes neurais artificiais aplicado à previsão também é estudado, assim como algumas técnicas estatísticas para a análise e limpeza dos dados, necessárias para que as demais técnicas apresentem melhores resultados. A revisão de literatura é encerrada com a busca por trabalhos correlatos ao aqui desenvolvido.

2.1. Indicadores de desempenho

Uma revisão sistemática da literatura sobre indicadores de desempenho de manufatura foi realizada. A revisão foi feita de acordo com a proposta de Tranfield *et al.* (2003), a qual foi aplicada com sucesso por diversos pesquisadores (Kamal and Irani, 2014), e consiste em planejar a revisão, desenvolvendo um protocolo de pesquisa, e realizando a pesquisa, o que inclui identificação e seleção de artigos a serem analisados e extração e sintetização de informações. Diferente da revisão de literatura convencional, a revisão sistemática aumenta o rigor metodológico, fazendo com que a informação sintetizada seja menos tendenciosa (Kitchenham, 2004 e Tranfield *et al.*, 2003).

O protocolo de pesquisa utilizado está apresentado no Quadro 2.1. Os termos de busca foram os termos exatos “manufactur* performance measur*” ou “manufactur* performance indicato*” a serem buscados no título, resumo e palavras-chave dos artigos, ou qualquer combinação desses termos a ser procurado apenas no título. A importância de aceitar qualquer combinação dos termos no título consiste em incluir artigos com títulos como, por exemplo, “measures for manufacturing performance” ou “performance indicators applied to manufacturing”.

Utilizar o operador “*” permite a inclusão de diferentes termos de pesquisa parecidos, por exemplo, utilizar “measur*” incluiria termos que iniciam com “measur” porém terminam de qualquer maneira, tais como “measure”, “measures” e “measurement”.

Quadro 2.1 Protocolo de pesquisa para revisão sistemática da literatura.

Termos de pesquisa	Grupo 1: "manufactur* performance measur*" Grupo 2: "manufactur* performance indicato*" Grupo 3: manufactur* performance measur* Grupo 4: manufactur* performance indicato*
Operador booleano	Ou entre os grupos
Mecanismo de busca	Título, resumo e palavras-chave para os grupos 1 e 2, título para os grupos 3 e 4.
Bases de dados	Scopus, Web of Science e Science Direct
Língua	Inglês
Janela de tempo	2000 até 2015
Tipo de publicação	Artigos de revistas e eventos científicos
Critério de exclusão	<ul style="list-style-type: none"> • Artigos que não apresentam indicadores de desempenho • Artigos que não são sobre manufatura, mas sim sobre outras aplicações como serviços ou agricultura • Artigos focados em metrologia • Artigos focados apenas em cadeia de suprimentos, sem preocupação com desempenho interno das empresas • Artigos que apresentam apenas indicadores voltados a um produto específico, mas não à manufatura como um todo

Fonte: a autora.

De acordo com Kitchenham (2004), resultados positivos são mais aceitos para publicação que negativos, o que pode deixar uma revisão de literatura tendenciosa, e uma forma de evitar que isto aconteça é incluir publicações de eventos científicos, e não apenas de revistas. O protocolo de pesquisa inclui, então, artigos tanto de revistas quanto de eventos científicos, publicados entre 2000 e 2015, em inglês.

Tranfield *et al.* (2003) observa que apenas estudos que atentem a todos os critérios de inclusão e não manifestam critérios de exclusão, são incorporados na literatura. Excluindo artigos duplicados, ou seja, que apareceram em mais de uma base de dados, 224 trabalhos foram identificados, dos quais 128 puderam ter o texto completo acessado. Após a aplicação dos critérios de exclusão, 87 artigos foram escolhidos para a realização do estudo.

Os dados coletados devem ser analisados em duas etapas, como indicado por Tranfield *et al.* (2003): uma análise descritiva da área de pesquisa e uma análise temática, identificando os tópicos emergentes e questões de pesquisa que ainda necessitam de resposta. As análises são detalhadas a seguir.

2.1.1. Análise descritiva

No total 193 autores diferentes participaram dos 87 artigos analisados, sendo que 170 estão em um artigo, 19 em dois artigos, 4 em três artigos e nenhum autor compartilhou a pesquisa em quatro ou mais artigos. Esta análise mostra a falta de maturidade temática, já que áreas de pesquisa maduras tendem a ter pesquisadores com histórico relevante de pesquisa. A análise temporal das publicações, porém, mostrou um aumento significativo na quantidade de trabalhos ao longo dos anos, indicando que a área está em desenvolvimento.

Os setores industriais pesquisados foram os mais diversos, tais como as indústrias automotiva, química, eletrônica, mecânica, de plástico e de madeira. Quanto às fontes dos trabalhos, foi possível identificar a multidisciplinaridade do tema, uma vez que os artigos foram publicados em periódicos de diversas áreas, tais como administração, contabilidade, economia, engenharia, ciências da computação, matemática e econometria.

A análise dos métodos de pesquisa aplicados nos artigos mostrou que os métodos empíricos representam quase 60% de todas as metodologias de investigação. Trabalhos teóricos e propostas de modelos e métodos têm tido menos espaço entre os artigos pesquisados. Chofreh *et al.* (2014) enumera quatro fases para a investigação científica: introdução, crescimento, maturidade e declínio. De acordo com Spina *et al.* (2013), a fase inicial tem o principal objetivo de observar fenômenos e descrevê-los, e é caracterizada pela exploração empírica e observação; a segunda etapa combina a observação empírica com a reflexão teórica, buscando a construção da teoria; e a terceira fase da investigação visa testar a teoria. As pesquisas sobre medição de desempenho carecem de estudos teóricos e desenvolvimento de metodologias menos subjetivas, podendo-se inferir, então, que o campo entrou na fase de crescimento, mas ainda não está perto do nível de maturidade.

A Figura 2.1 apresenta, em vermelho, as diferentes regiões em que as pesquisas estudadas foram realizadas. O relatório de desempenho industrial 2012/2013 publicado pela UNIDO (2013) classifica os países através de uma análise comparativa relativa à competitividade industrial. De acordo com esta classificação, 52% dos países identificados na revisão da literatura estão entre os 25 países mais industrializados do mundo, e 88% se encontram entre os 50 mais industrialmente competitivos. Isto indica que pesquisas sobre medição de desempenho estão sendo

realizadas principalmente em países desenvolvidos. Investir mais neste campo de pesquisa poderia, então, ser uma oportunidade, para os países em desenvolvimento, como o Brasil, de ganhar competitividade.

Figura 2.1 Localização das pesquisas na área de indicadores



Fonte: A autora, elaborado com matadornetwork.com/travel-map/

A diversidade de autores pesquisando o tema, de diferentes áreas de atuação e em tantos países diferentes, destaca a importância da área de pesquisa. A quantidade de áreas de pesquisa influenciadas pela medição de desempenho também explica a grande variedade de palavras-chave identificadas. As palavras-chave mais citadas, assim como os trabalhos que as citaram, guiaram a análise temática, e estão descritas no Quadro 2.2.

As palavras-chave estão principalmente relacionadas com os papéis desempenhados pela medição de desempenho (ex: estratégia e *benchmarking*), técnicas utilizadas para gerenciar os indicadores (ex: *balanced scorecard* e *data envelopment analysis*) e tendências recentes envolvendo o que avaliar com a medição de desempenho (sustentabilidade e satisfação do consumidor).

Os resultados descritivos mostram o estágio atual da área de pesquisa e indicam as direções para as quais os trabalhos sobre medição de desempenho estão caminhando. É esperado um crescimento da área. Gomes *et al.* (2004) realizou uma revisão de literatura similar, porém utilizando artigos até o ano 2000, e concluiu que acadêmicos e práticos precisavam combinar esforços para validar o que já é sabido sobre indicadores de desempenho de manufatura e construir novos conhecimentos a partir disto, levando ao desenvolvimento de filosofias práticas, sistemas e medidas,

que as indústrias tanto precisam. Mais de 15 anos depois, pode-se afirmar que a área de pesquisa evoluiu, mas ainda são necessárias mais abordagens quantitativas aplicáveis para deixar o processo de tomada de decisão menos baseado em tentativa e erro.

Quadro 2.2 Palavras-chave mais utilizadas nos artigos revisados

Palavra-chave	Nº de aparições	Artigos
Data envelopment analysis (DEA)	7	Düzakin e Düzakin (2007); Jain <i>et al.</i> (2011); Rezaie <i>et al.</i> (2009); Sueyoshi e Goto (2010); Triantis e Otis (2004); Tseng <i>et al.</i> (2009); Zaim (2004).
Manufacturing System	7	Efthymiou <i>et al.</i> (2014); El Mola e Parsaei (2010); Garbie (2014); Hon (2005); Plehn <i>et al.</i> (2012); Rezazadeh <i>et al.</i> (2011); Yang <i>et al.</i> (2009).
Analytic hierarchy process (AHP)	6	Amrina e Vilsa (2015); Bansia <i>et al.</i> (2014); Mohammadzadeh <i>et al.</i> (2011); Parthiban e Goh (2011); Tseng <i>et al.</i> (2009); Yang <i>et al.</i> (2009).
Sustainability	6	Amrina e Vilsa (2015); Amrina e Yusof (2011); Dočekalová (2013); Dočekalová <i>et al.</i> (2015); O'Driscoll <i>et al.</i> (2013); Verrier <i>et al.</i> (2014).
Balanced Scorecard (BSC)	5	Bansia <i>et al.</i> (2014); Chompu-Inwai <i>et al.</i> (2013); Gosselin (2005); Jusoh <i>et al.</i> (2008a, 2008b)
Lean Manufacturing	5	Fullerton e Wempe (2009); Metternich <i>et al.</i> (2013); Olivella e Gregorio (2015); Ribeiro <i>et al.</i> (2011); Verrier <i>et al.</i> (2014).
Environmental Performance or Green manufacturing	5	Digalwar <i>et al.</i> (2013); Henri e Journeault (2008); Sueyoshi e Goto (2010); Triantis e Otis (2004); Verrier <i>et al.</i> (2014).
Decision Making	4	Chan <i>et al.</i> (2002); Gomes <i>et al.</i> (2007); Rezazadeh <i>et al.</i> (2011); Tseng <i>et al.</i> (2009).
Performance Management	4	Gosselin (2005); Nenadál (2008); O'Kane (2004); Parthiban e Goh (2011).
Benchmarking	3	Grando e Belvedere (2006); Herzog <i>et al.</i> (2009); Triantis e Otis (2004).
Customer Satisfaction	3	Chen e Cheng (2007); Chen (2008); Setijono (2008).
Fuzzy Set	3	Chan <i>et al.</i> (2002); Mohammadzadeh <i>et al.</i> (2011); Rezazadeh <i>et al.</i> (2011).
Manufacturing Network	3	Lin e Chang (2013a, 2013b); Manupati <i>et al.</i> (2013).
Strategy	3	Henri e Journeault (2008); Herzog <i>et al.</i> (2009); Jusoh <i>et al.</i> (2008a).

Fonte: a autora.

2.1.2. Análise temática

A análise temática inclui os papéis desempenhados pela medição de desempenho, as indicações quanto às melhores formas de escolher os indicadores de desempenho, como classificar e descrever os indicadores, e outros tópicos importantes relacionados ao tema, provenientes das palavras-chave mais citadas nos artigos analisados.

Foram identificadas cinco funções principais desempenhadas pelos indicadores de desempenho. O primeiro papel é influenciar o comportamento dos funcionários. Uyar (2009) afirma que os indicadores traduzem a estratégia em comportamentos desejados, comunicando as expectativas, fornecendo *feedback*, e embasando recompensas e sanções. O segundo papel é o de orientar o comportamento dos gestores, direcionando a sua atenção para áreas importantes, como observado por Joiner *et al* (2009). O terceiro e mais difundido papel das medidas de desempenho é o monitoramento e controle das atividades das empresas. As medidas são úteis para acompanhar os progressos (Uyar, 2009) e controlar a eficiência operacional (Amrina e Yusof, 2011). A quarta função é o *benchmarking*. Como O'Driscoll *et al.* (2013) observam, indicadores são um ponto de referência com os quais comparações podem ser feitas, permitindo que uma Empresa Compare o seu desempenho com o de indústrias similares. O último papel dos indicadores de desempenho é operacionalizar a estratégia, uma vez que, como defende Uyar (2009), medidas de desempenho podem traduzir estratégias em resultados desejados.

Para que os indicadores de desempenho possam cumprir seu papel, é preciso que eles sejam escolhidos adequadamente. El Mola e Parsaei (2010) afirmam que a literatura em geral não é boa em indicar como selecionar medidas de desempenho, apesar de indicar possíveis diferentes indicadores. Wang e Li (2009) colocam que se os indicadores utilizados não forem os corretos, o controle e o melhoramento dos processos não será satisfatório.

Existem muitas recomendações na literatura, muitas das quais contraditórias, quanto à melhor maneira de escolher os indicadores, sendo que elas podem acabar “atrapalhando” a escolha ao invés de ajudar. Como exemplo, Gomes *et al.* (2011) e El Mola e Parsaei (2010) mostram que os indicadores sejam simples e fáceis de compreender, enquanto Senkuvienė *et al.* (2014) afirmam que os indicadores não podem ser escolhidos apenas pela simplicidade. Alguns autores, tais como Yang *et*

al. (2009), defendem que os indicadores sejam mensuráveis, já outros como Bansi *et al.* (2014) acreditam que as empresas devem utilizar tanto indicadores quantitativos quanto qualitativos. São expostos aqui alguns dos consensos encontrados sobre os indicadores:

- não devem ser isolados uns dos outros;
- devem ser derivados das estratégias;
- devem ser balanceados em número e conteúdo;
- devem cobrir todas as dimensões críticas do desempenho;
- devem ser ajustados para cada empresa, respeitando os diferentes cenários como tamanho, tipo de processo e nível de automação.

Quanto à classificação dos indicadores de desempenho de manufatura, Amrina e Yusof (2011) e Yang *et al.* (2009) concordam que as dimensões de classificação mais comuns são qualidade, custo, flexibilidade e tempo. Senkuvienė *et al.* (2014) explicam que o custo define o quão cara ou barata a produção é, qualidade indica se esta produção satisfaz as expectativas dos usuários finais, flexibilidade indica a capacidade da organização de ajustar seu processo produtivo e tempo denota a habilidade de produzir e entregar a produção no prazo necessário. El Mola e Parsaei (2010), Tseng *et al.* (2009), e Yang *et al.* (2009) acrescentam outras dimensões: satisfação do cliente, tecnologia, inovação, produtividade, estoque, segurança e meio ambiente, moral dos funcionários, educação e treinamento, competição, finanças, capacidade e cadeia de suprimentos. Pintzos *et al.* (2012) classificam os indicadores com base nos 4M's: *man, machine, material and method* (recursos humanos, equipamentos, materiais e métodos).

De acordo com Slack *et al.* (2010), todas as operações de manufatura podem ser descritas pelo modelo entrada-transformação-saída. Propõe-se então uma classificação de indicadores baseada neste modelo, que pode ser utilizada por qualquer tipo de indústria. As dimensões a serem utilizadas são: consumidor (entrada), equipamentos (entrada) funcionários (entrada), materiais (entrada), produtos (saída), processo produtivo (transformação) e medidas corporativas (transformação). A seguir está exposta a importância de cada uma destas classes e como alguns dos principais indicadores de desempenho utilizados pelas indústrias seria classificado.

Indicadores de consumidores: Chen (2008) avalia que orientação para o mercado significa que a empresa foca seus esforços em identificar, analisar, entender e responder às necessidades dos clientes. Jusoh *et al.* (2008a) defende que medir o desempenho em relação aos clientes permite uma estratégia de criação de valor e diferenciação da concorrência. O Anexo A apresenta 42 indicadores de desempenho relativos aos consumidores identificados nesta revisão de literatura.

Indicadores de produtos: Psomas e Kafetzopoulos (2014) coloca que o aumento da competitividade no mercado gera demandas por melhores produtos e serviços, de forma que ter produtos melhores significa aumentar a fatia de mercado controlada. Bai *et al.* (2007) afirmam que o ciclo de vida dos produtos está cada vez mais curto, fazendo com que as empresas dependam cada vez mais da sua capacidade de desenvolver novos produtos, então medir o desempenho dos projetos de produtos torna-se cada vez mais importante. O Anexo A apresenta 50 indicadores relativos a produtos identificados.

Indicadores de equipamentos: Zhu *et al.* (2014) explicam que os equipamentos influenciam diretamente os rendimentos produtivos e os lucros das empresas, de forma que é necessário avaliar seu desempenho para garantir a estabilidade e eficiência do processo produtivo. Lin e Chang (2013) explicam que as falhas de equipamentos levam a produtos defeituosos e à queda de produtividade. Chompu-Inwai *et al.* (2013) alega que indicadores de manutenção também devem ser considerados. O Anexo A contém os 27 indicadores de equipamentos identificados nos artigos analisados.

Indicadores de funcionários: Abdel-Maksoud *et al.* (2010) defendem que atitudes positivas dos empregados geram resultados favoráveis para as empresas, e que adotar indicadores de avaliação de desempenho dos funcionários pode levar à adoção de medidas que melhorem a satisfação e a confiança dos trabalhadores. Wang e Li (2009) complementam, afirmando que indicadores de performance encorajam um melhor comportamento. Os 56 indicadores de desempenho de funcionários identificados na pesquisa estão no Anexo A.

Indicadores de materiais: Mahmood *et al.* (2014) coloca que matérias-primas frequentemente são os maiores contribuintes dos problemas de qualidade dos produtos fabricados. Triantis e Otis (2004) afirmam que o controle dos materiais também é importante para o impacto ambiental, sendo que o objetivo deve ser

produzir a mesma saída utilizando menos material na entrada. Foram identificados e incluídos no Anexo A 31 indicadores de matérias.

Indicadores de processo (relacionados ao chão de fábrica): algumas das medidas importantes são tempo de ciclo, flexibilidade, capacidade produtiva, confiabilidade, e qualidade, e, para Ribeiro *et al.* (2011), a maior parte dos indicadores desta categoria dependem de outros fatores críticos, como exemplo o tempo de setup de máquina depende diretamente dos equipamentos. O Anexo A apresenta 118 indicadores de processo identificados nesta pesquisa.

Indicadores corporativos ou organizacionais: cobrem medidas de desempenho importantes e não relacionadas às outras categorias. Dočekalová (2013) salienta a importância de controlar o desempenho global em termos econômicos, ambientais e sociais. Verrier *et al.* (2014) defendem que utilizar indicadores de desempenho ambiental gera redução de desperdícios de energia e materiais. Foram identificados e estão apresentados no Anexo A 114 indicadores de desempenho corporativos.

Os indicadores mais citados, aparecendo em pelo menos 15 dos artigos analisados, foram: tempo de entrega ao cliente, reclamações de clientes, taxa de defeitos, tempo de ciclo, *time-to-market* (tempo para o lançamento) de novos produtos, nível de sucata, índice de retrabalho, nível de utilização dos equipamentos e taxa de retorno dos investimentos.

Não há padronização, entre os trabalhos pesquisados, para a terminologia dos indicadores. A fim de gerar a lista de indicadores apresentada foi necessário unificar medidas, tais como número de unidades produzidas, quantidade produzida e volume de produção. Não há consenso a respeito das fórmulas também. Tempo de *setup*, por exemplo, pode ser medido como o tempo total de preparo do equipamento para produzir um produto diferente, tal como apresentado por Mohammadzadeh *et al.* (2011) e Rezazadeh *et al.* (2011), ou pode ser calculado como uma porcentagem do tempo de preparo do equipamento em relação ao tempo total, como apontado por Yang *et al.* (2009). De acordo com Pintzos *et al.* (2012), essas diferenças tornam difícil a comparação dos desempenhos, não só de diferentes indústrias, mas também dentro das próprias organizações.

Além da padronização, outro tópico recorrente nos trabalhos é a ponderação dos indicadores, uma vez que nem todos influenciam igualmente o desempenho geral da empresa. Estabelecer a importância relativa de cada indicador pode ajudar a definir quais KPIs utilizar, como defende Tseng *et al.* (2009), e também ajuda a priorizar os

indicadores mais importantes, dentro do conjunto escolhido, como complementam Amrina e Vilsa (2015). O método *Analytical Hierarchy Process* (AHP) é o mais utilizado na literatura para determinar os pesos de cada indicador. O processo é realizado por meio de entrevistas com os gestores, visando realizar comparações par a par usando uma escala de preferência, como explica Temur *et al.* (2007).

Outro tema recorrente nos trabalhos é a sustentabilidade. De acordo com Amrina e Yusof (2011), produção sustentável é a criação de produtos que têm valor para a sociedade, enquanto minimizam os impactos ambientais negativos, tanto durante a fabricação quanto durante o uso, conservam energia e recursos naturais, são seguros para os funcionários, comunidades e consumidores e são economicamente viáveis. Dočekalová (2013) defende que a incorporação da sustentabilidade pode representar gastos sem retorno de curto prazo, mas no longo prazo pode ter um impacto positivo sobre o desempenho global da empresa, incluindo o desempenho financeiro. Laurent *et al.* (2010) acrescentam que a integração das questões de sustentabilidade nos sistemas de gestão pode ter efeitos potenciais nas cadeias produtivas inteiras.

2.1.3. *Temas para pesquisa*

Os artigos analisados apresentam diversas sugestões de temas para pesquisas futuras, entre os quais alguns foram identificados como recorrentes:

- Como garantir uma melhoria simultânea do desempenho das dimensões social, ambiental e econômica?
- Como os sistemas de informação e a tecnologia podem facilitar a medição de desempenho sem representarem muita despesa?
- Como implementar e manter sistemas de medição de desempenho em pequenas e médias empresas?
- Como incluir indicadores externos, não apenas relacionados à cadeia de suprimentos, mas também ao mercado?
- Como determinar numericamente as medidas de desempenho que são relevantes com base na estratégia?
- Como avaliar a utilidade dos indicadores ao longo do tempo para que os mesmos possam ser alterados de forma flexível de acordo com a sua relevância?

- Como determinar as relações, as dependências e os conflitos entre os indicadores e estabelecer seus valores ótimos?
- Como prever valores futuros de indicadores de desempenho, considerando as incertezas, a fim de ajudar na tomada de decisões?
- Qual é a diferença, em termos de práticas de medição de desempenho, entre empresas que estão sendo afetadas pela crise financeira e empresas que não estão sofrendo com ela?
- É possível criar um conjunto específico de medidas de desempenho para serem utilizadas como *benchmarking*, para segmentos industriais específicos?
- É possível propor uma abordagem padrão de nomenclatura e fórmulas dos indicadores de desempenho para facilitar as comparações entre empresas?

2.2. Correlação entre indicadores de desempenho

A correlação mede o relacionamento entre variáveis. Duas variáveis podem estar positivamente relacionadas (quando uma aumenta a outra também aumenta), negativamente relacionadas (quando uma aumenta a outra diminui) ou não relacionadas. Algumas das estatísticas para medir a correlação são o Coeficiente de Correlação de Pearson, o Coeficiente de Correlação de Spearman e o Tau de Kendall. O primeiro é uma estatística paramétrica que assume a normalidade dos dados, enquanto que os demais são não-paramétricos e podem ser aplicados a dados não-normais (Field, 2005). De acordo com Agbedeyi e Igweze (2014), o teste Tau de Kendall possui propriedades estatísticas melhores que o teste de Spearman, e apresenta resultados melhores para conjuntos de dados pequenos. Estudos de correlação exigem, segundo Rovai *et al.* (2013), uma amostra mínima de 30 dados para serem realizados.

Os valores resultantes do teste Tau de Kendall devem estar no intervalo de $[-1, 1]$, sendo que o valor “-1” identifica um relacionamento negativo perfeito; o valor “+1”, um relacionamento positivo perfeito, e o valor “0” indica não haver relação entre as variáveis. A interpretação desses valores, segundo Field (2005), é a seguinte: de 0 até $\pm 0,1$ não existe correlação; de $\pm 0,1$ até $\pm 0,3$ a correlação tem um efeito pequeno; de $\pm 0,3$ até $\pm 0,5$ o efeito é médio e de $\pm 0,5$ até ± 1 a correlação apresenta efeito

grande. O mesmo autor afirma que o valor da significância do teste deve ser valor $p \leq 0,05$ para garantir que a correlação seja realmente significativa e não tenha ocorrido apenas por acaso.

Ao interpretar os coeficientes de correlação é preciso ter cuidado com duas questões, como explica Field (2005). A primeira questão diz respeito à direção da causalidade, ou seja, o coeficiente de correlação, sozinho, não informa qual variável causa alteração na outra. A segunda questão diz respeito ao problema da terceira variável, isto é, à possibilidade de as duas variáveis não se influenciarem diretamente, mas sim estarem sob influência de uma terceira variável.

2.3. Previsão de séries temporais

A previsão do comportamento de variáveis é pré-requisito para muitas atividades de planejamento, apoiando, assim, as decisões estratégicas das organizações (Wong *et al.*, 2010). O objetivo de realizar previsão de séries temporais é prever o comportamento de variáveis com base somente nos padrões passados (registros históricos) do mesmo fenômeno (Donate *et al.*, 2013).

Os métodos tradicionais de análise de séries temporais, provenientes da estatística, incluem a análise fatorial, regressão, a suavização exponencial e o modelo auto-regressivo integrado de média móvel (ARIMA), sendo que todos eles assumem relações lineares entre os valores passados da variável (Wong *et al.*, 2010). No entanto, especialmente no atual momento econômico, dados de séries temporais geralmente têm características não lineares (Wang *et al.*, 2015). Alguns métodos alternativos foram desenvolvidos para melhorar a previsão de séries temporais com características não lineares, entre os quais estão os modelos heterocedásticos (ARCH), que tendem a ser específicos para aplicações particulares (Gomes e Ludermir, 2013).

Adhikari (2015) lista mais algumas limitações dos modelos estatísticos utilizados para a previsão:

- uma série temporal raramente é independente e igualmente distribuída, propriedade fundamental dos processos estatísticos realistas, desta forma, um modelo com ótimo desempenho para um conjunto de dados de teste pode não oferecer as melhores previsões para os valores futuros;

- como o modelo de previsão deve estar relacionado à natureza da série temporal, considerando, por exemplo, se os dados contêm tendência ou sazonalidade, um grande número de observações históricas faz-se necessário, porém, na prática, é comum que exista apenas uma pequena amostra dos dados, o que pode tornar o ajuste do modelo inadequado;
- a série temporal é um processo dinâmico, com alto grau de incerteza e taxa de mudanças, assim, quando novas observações são incluídas, a validade do modelo passa a ser questionável.

O método das Redes Neurais Artificiais (RNAs) é considerado uma ferramenta útil para a previsão de séries temporais (Yolcu *et al.*, 2013). Kourentzes *et al.* (2014) citam que RNAs superam os modelos estatísticos na imensa maioria dos casos estudados na literatura. Os motivos encontrados para a preferência pelas RNAs são:

- estes modelos podem acompanhar as mudanças contínuas e súbitas nas séries de dados (Gomes *et al.*, 2011);
- eles acomodam melhor séries temporais não-lineares, não-aleatórias e não-estacionárias (Wong e Versace, 2012);
- são capazes de lidar com problemas que têm uma relação funcional desconhecida (Maia e De Carvalho, 2011);
- apresentam propriedades de adaptabilidade e de tolerância a ruído (Adhikari e Agrawal, 2014);
- não necessitam de conhecimentos prévios quanto à distribuição da séries temporal (YangG *et al.*, 2014);
- resultados experimentais indicam alta capacidade para realizar a aproximação de funções com boa precisão (Gomes e Ludermir, 2013);
- apresentam grande flexibilidade na modelagem de dados (Kourentzes *et al.*, 2014);
- apresentam habilidades de aprendizagem e permitem computação em paralelo, diminuindo o tempo de processamento (Wang *et al.*, 2015)

A próxima seção aborda as RNAs com mais detalhes, explicando seu funcionamento, especialmente para a previsão de séries temporais.

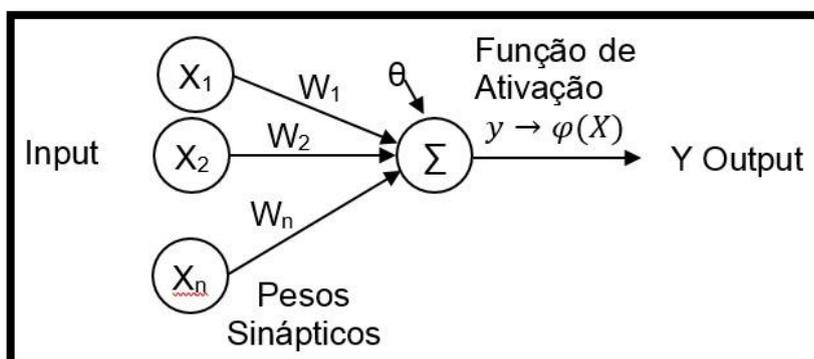
2.4. Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) copiam a inteligência humana na aprendizagem por observação ou dedução (Yu e Huarng, 2010). O cérebro humano é um sistema de decisão que contém milhões de unidades, os neurônios, distribuídos em múltiplas camadas interagindo paralelamente (Bataineh, 2015). As RNAs são grupos interconectados de neurônios artificiais que utilizam modelos matemáticos ou computacionais para processar informação (Sharma, 2011). Grant (2014) cita algumas das propriedades que as RNAs incorporam dos neurônios biológicos:

- Os neurônios de processamento recebem muitos sinais;
- Os sinais podem ser modificados por pesos nas sinapses receptoras;
- Os neurônios de processamento realizam a soma das entradas ponderadas;
- Os neurônios de processamento transmitem uma única saída, uma vez que tenham entradas suficientes;
- A saída de cada neurônio de processamento pode ir a muitos outros neurônios;
- O processamento da informação é local;
- A memória é distribuída: a de longo prazo reside nas sinapses ou pesos dos neurônios, enquanto a de curto prazo corresponde aos sinais enviados pelos neurônios;
- A força das sinapses pode ser modificada pela experiência;
- Neurotransmissores para as sinapses podem ser excitadores ou inibidores;
- Tolerância a falhas.

Em resumo, uma RNA contém uma grande quantidade de elementos de processamento chamados de neurônios, interconectados pelas sinapses, cada uma com um peso (bias) ou nível de importância associado (Grant, 2014). O processamento dentro de cada neurônio se dá através de uma função de ativação, e os parâmetros são modificados durante a operação, já que o sistema é adaptativo (Sharma, 2011). A Figura 2.2, adaptada do trabalho de Matijaš (2013), mostra, de forma lógica, o modelo de um neurônio.

Figura 2.2. Modelo de Neurônio de uma RNA



Fonte: adaptado de Matijaš (2013)

O cálculo realizado pelo processamento do neurônio pode ser expresso pela equação 2.1, onde Y é a saída; X_i é o valor de entrada i ; W_i é o valor do peso da entrada i ; θ corresponde ao bias, n é o número de entradas e φ é a função de ativação escolhida.

$$Y = \varphi\left(\sum_{i=1}^n X_i W_i + \theta\right) \quad (2.1)$$

As RNAs são desenvolvidas para cumprir duas funções principais, reconhecimento de padrões (classificação) e aproximação de funções, sendo que a previsão de séries temporais se enquadra na segunda opção (Sharma, 2011). Para aplicar redes neurais à previsão de séries temporais, o *output* deve representar o valor da previsão para o próximo período, enquanto os *inputs* são os dados das observações passadas da série temporal ou de outras variáveis explicativas (Kourentzes *et al.*, 2014).

Gomes, G. da S. *et al.* (2011) explicam que uma rede neural pode ser caracterizada por três aspectos principais, relacionados:

- A arquitetura, que corresponde ao padrão de conexão utilizado entre os neurônios;
- O algoritmo de treinamento ou de aprendizagem, que corresponde ao método de determinação dos pesos das sinapses;
- A função de ativação.

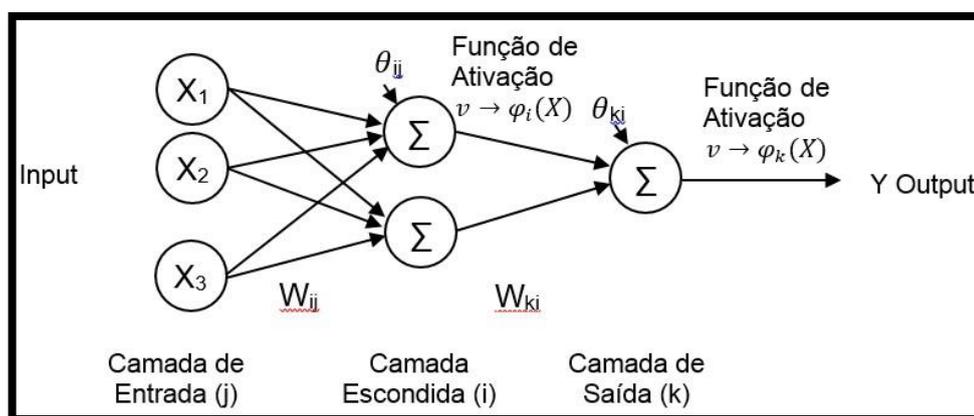
As RNAs mais utilizadas para a previsão de séries temporais são as *multilayer perceptron* (MLP) e as de função de base radial (RBF) (Kourentzes *et al.*, 2014), as quais estão apresentadas nas próximas seções, assim como esses aspectos importantes aplicados à elas.

2.4.1. Rede Perceptron de Múltiplas Camadas (MLP)

De acordo com Adhikari e Agrawal (2014), a rede MLP apresenta, basicamente, uma arquitetura do tipo *feed-forward*, com uma camada de entrada (*input*), uma ou mais camadas escondidas e uma camada de saída (*output*). Os mesmos autores colocam que uma única camada escondida costuma ser suficiente para resolver problemas práticos e que, em termos de requisitos computacionais, são preferíveis as mais simples. Uma rede que não é suficientemente complexa pode deixar de detectar totalmente o sinal em um conjunto de dados, já uma rede muito complexa pode captar não só o sinal, mas também muito ruído (Wong *et al.*, 2010). A quantidade de neurônios na camada de entrada, que corresponde à quantidade de informações que irão alimentar a rede; a quantidade de neurônios na camada de saída, que corresponde à quantidade de respostas diferentes esperadas da rede; e a quantidade de neurônios na camada escondida devem ser avaliadas, escolhendo-se o número que minimiza o erro (Kourentzes *et al.*, 2014).

O algoritmo de aprendizagem *back-propagation* otimiza a rede ajustando os pesos sinápticos de forma a minimizar o erro para trás, enquanto a informação é transmitida para a frente (Wang *et al.*, 2015). A Figura 2.3 exemplifica uma rede MLP com três neurônios na camada de entrada, dois na camada escondida e um na camada de saída.

Figura 2.3. Exemplo de rede MLP com três camadas



Fonte: baseado em Grant (2014)

Grant (2014) explica como o processo acontece: a cada passagem de um padrão t realizada pela rede, o erro $e(t)$ é calculado a partir da resposta da rede $Y(t)$

e do valor desejado para esta resposta $d(t)$. Então, utilizando a teoria de aprendizagem do gradiente descendente, cada peso na rede é adaptado através da correção com um termo proporcional ao erro. Em resumo, a aplicação da rede MLP de três camadas, contendo n neurônios na camada de entrada, m na camada escondida e h na camada de saída, segue a seguinte ordem:

A cada exemplo de treinamento a ser passado pela rede:

Para cada neurônio i da camada escondida é aplicada uma função de ativação φ_i ao somatório (ponderado pelos pesos sinápticos W_{ij}) dos dados de entrada da rede X_j , gerando um valor de saída V_i , conforme a equação 2.2.

$$V_i = \varphi_i(\sum_{j=1}^n X_j W_{ij} + \theta_{ij}) \quad (2.2)$$

Em seguida, para cada neurônio da camada de saída é aplicada uma função de ativação φ_h , que não precisa ser a mesma função utilizada na camada escondida, ao somatório ponderado dos dados provenientes da camada escondida, de forma a gerar um valor de saída para a rede, conforme a equação 2.3.

$$Y_k = \varphi_k(\sum_{i=1}^m V_i W_{ki} + \theta_{ki}) \quad (2.3)$$

Calcula-se, então, o erro da camada de saída e ajustam-se os pesos da mesma camada segundo as fórmulas:

$$\delta_k(t) = (d_k(t) - Y_k(t))\varphi'_k(\sum_{i=1}^m V_i W_{ki} + \theta_{ki}) \quad (2.4)$$

$$w_{ki}(t+1) = w_{ki}(t) + \alpha(w_{ki}(t-1)) + \eta\delta_k(t)Y_k(t) \quad (2.5)$$

onde $d_k(t)$ é o valor esperado para o neurônio k na passagem t , $\varphi'_k(\cdot)$ é a derivada da função de ativação da camada de saída, η é a taxa de aprendizagem e α é a constante de *momentum*, usualmente chamados de parâmetros livres.

Calcula-se, finalmente, o erro da camada oculta e ajustam-se seus pesos, de acordo com as equações:

$$\delta_i(n) = \varphi'_i(\sum_{j=1}^n X_j W_{ij} + \theta_{ij}) \sum_{k=1}^h \delta_k(n) W_{ki}(n) \quad (2.6)$$

$$W_{ij}(n+1) = W_{ij}(n) + \alpha(W_{ij}(n-1)) + \eta\delta_j(n)V_i(n) \quad (2.7)$$

onde $\phi'_j(\cdot)$ é a derivada da função de ativação da camada oculta.

Ao final de cada iteração (quando todos os padrões de treinamento passaram pela rede), deve-se calcular, utilizando os últimos pesos calculados, o erro médio quadrático global para todos os exemplos de treinamento. Quando o critério de parada for atingido as iterações podem parar e os pesos obtidos pela rede podem ser aplicados ao conjunto de testes.

As funções de ativação utilizadas nas RNAs influenciam fortemente a sua complexidade e desempenho, impactando muito na convergência dos algoritmos de aprendizagem (Gomes e Ludermir, 2013). É desejável que as funções sejam não-lineares e diferenciáveis (Maia e Carvalho, 2011). A função de ativação de cada neurônio costuma ser a mesma em uma mesma camada, sendo que as funções sigmoide logística e tangente hiperbólica são frequentemente usadas (Wang *et al.*, 2015).

O quadro 2.3 apresenta, conforme apresentado por Grant (2014), as funções de ativação mais utilizadas em redes MLP e suas derivadas.

Quadro 2.3 Funções de Ativação para RNAs

Função de Ativação	Fórmula $a = f(u)$	Derivadas $\frac{df(u)}{du}$
Sigmoide	$f(u) = \frac{1}{1 + e^{-u/T}}$ T = Parâmetro de Temperatura	$\frac{f(u)[1 - f(u)]}{T}$
Tangente Hiperbólica	$f(u) = \tanh\left(\frac{u}{T}\right)$	$\frac{(1 - [f(u)]^2)}{T}$
Tangente Inversa	$f(u) = \frac{2}{\pi} \tan^{-1}\left(\frac{u}{T}\right)$	$\frac{2}{\pi T} \cdot \frac{1}{1 + \left(\frac{u}{T}\right)^2}$
Limiar	$f(u) = \begin{cases} 1, & u > 0; \\ -1, & u < 0; \end{cases}$	Sem derivada em $u = 0$
Linear	$f(u) = au + b$	a

Fonte: adaptado de Grant (2014).

Gomes e Ludermir (2013) citam que uma MLP, com uma única camada escondida, utilizando funções de ativação sigmoide, é capaz de aproximar qualquer

função mensurável. Matijaš (2013) afirma que a função sigmoide estabiliza bem as RNAs, porém mapeia os resultados no intervalo $[0, 1]$, o que é mais adequado para resolver problemas de classificação. Segundo o autor, para a maior parte das redes neurais, os resultados são melhor mapeados no intervalo $[-1, 1]$. Por este motivo Matijaš (2013) sugere a utilização da função de ativação de transferência sigmoide tangente (*tansig*), a qual realiza o mapeamento no intervalo $[-1, 1]$, definida como:

$$tansig(u) = \frac{2}{1+e^{-2u}} - 1 \quad (2.8)$$

A aprendizagem das RNAs acontece quando a rede, respondendo a um estímulo, se ajusta em um esforço para produzir uma resposta válida (Grant, 2014). Aprendizagem é a capacidade de aproximar o comportamento da rede aos dados de saída (resposta), a partir dos dados de treinamento, e o tipo de aprendizagem é determinado pela forma como os parâmetros (pesos sinápticos e parâmetros livres) são alterados (Sharma, 2011). Algoritmos de aprendizagem podem facilmente ficar presos em ótimos locais, e uma maneira de minimizar este problema é reiniciar as redes diversas vezes, com diferentes modelos (Kourentzes et al., 2014). Sharma (2011) explica que um algoritmo de aprendizagem é um conjunto predeterminado de regras para a solução de um problema de aprendizagem, e cita alguns exemplos:

- Aprendizagem por correção do erro: os algoritmos de formação fazem uso da diferença entre o produto desejado e o sinal de saída produzido pela rede neural, realizando ajustes de correção do erro do sinal nos pesos sinápticos;
- Aprendizagem baseada em memória: todas as experiências passadas são armazenadas, classificando exemplos de entrada-saída. Um critério é utilizado para definir a vizinhança do padrão de teste e a regra de aprendizagem é aplicada aos exemplos de treinamento nesta vizinhança. Uma das regras de aprendizagem mais utilizadas é a regra do vizinho mais próximo;
- Aprendizagem Hebbian: se dois neurônios são ativados simultaneamente, então a força da sinapse é aumentada de forma seletiva; já se os dois neurônios são ativados de forma assíncrona, a ligação é enfraquecida ou eliminada seletivamente;

- Aprendizagem Competitiva: múltiplos neurônios da camada de saída competem entre si para produzir a saída mais próxima ao objetivo desejado, permanecendo assim ativos, sendo que apenas um neurônio de saída pode ser ativado por vez.

Os algoritmos de aprendizagem também podem ser classificados por aprendizagem forçada por um “professor” ou aprendizagem não forçada (Sharma, 2011). Grant (2014) explica esta classificação:

- Aprendizagem não supervisionada: a rede não tem uma saída esperada. Os sinais de entrada são interpretados e classificados e, quando um novo sinal chega, este é comparado aos já classificados. Este método precisa de uma predefinição das categorias a serem utilizadas;
- Aprendizagem supervisionada: a rede tem uma saída esperada. Quando a saída da rede é diferente do requerido, os pesos são ajustados objetivando convergir a saída da rede para o valor esperado;
- Aprendizagem reforçada: a rede tem uma saída esperada. Difere do método supervisionado por não considerar a convergência, em vez disso utiliza uma indicação binária (verdadeiro ou falso) para classificar se o padrão de entrada corresponde à saída esperada. Se a resposta é incorreta, a rede modifica seus parâmetros.

O algoritmo *back-propagation* pode ser considerado um algoritmo de aprendizagem (Stasinakis, 2013) supervisionada por correção do erro.

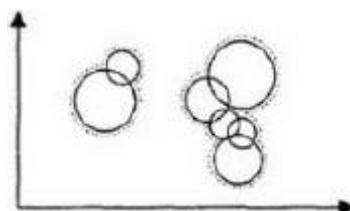
2.4.2. Redes neurais RBF

As redes neurais de base radial (RBFs), assim como as MLPs, geram aproximações universais de funções, porém são sempre construídas em três camadas (Kriesel, 2007). Hagan *et al.* (2014) afirmam que existem duas diferenças básicas entre estes dois tipos de rede neural: ao invés de multiplicar os pesos pelos valores de entrada, na RBF calculamos a distância entre o vetor de entrada e os vetores de pesos, sendo que cada linha da matriz de pesos corresponde a um centro, um ponto no qual o valor da rede será zero; e ao invés de adicionar o bias, ele deve ser multiplicado, pois tem a função de escalonar a função, aumentando ou comprimindo.

Hagan *et al.* (2014) explica ainda que as funções de ativação utilizadas na primeira camada das redes RBF diferem das utilizadas nas redes MLP por

apresentarem propriedades locais, ou seja, quando o input tende ao infinito, o output fica próximo de zero, ao contrário da função sigmoideal, por exemplo, onde nas mesmas condições o output tenderia a 1. A Figura 2.4 demonstra um exemplo de padrão de aproximação dos dados de uma RBF.

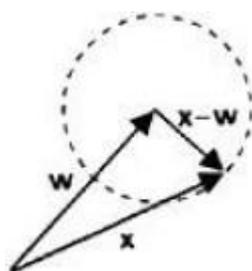
Figura 2.4 Padrão espacial da rede RBF



Fonte: Gurney (2004)

Para Gurney (2004), a diferença $|x-w|$, entre os pesos w e o vetor de entradas x , indica o grau de alinhamento entre os dois vetores, conforme indicado na Figura 2.5, que enfatiza a simetria radial da situação, já que diferentes padrões que estejam a uma mesma distância do vetor de pesos ficam em um círculo com centro em w . Precisa-se então de uma função que gere uma saída que diminua conforme as distâncias aumentem, e a mais utilizada é a função gaussiana, que pode ser vista em duas e três dimensões na Figura 2.6.

Figura 2.5: Explicação vetorial da RBF

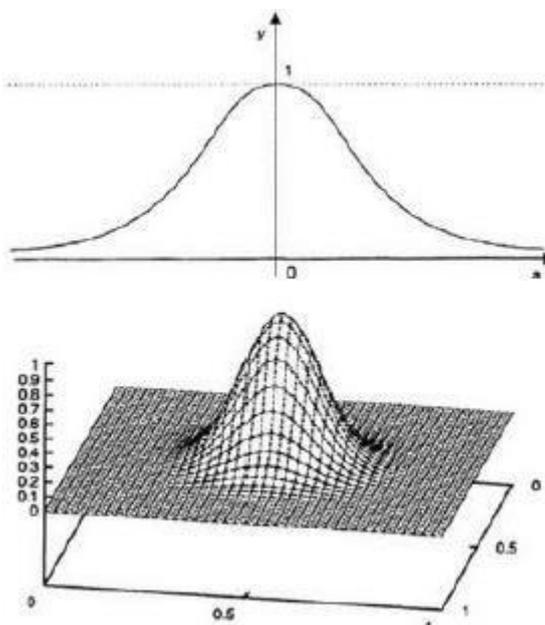


Fonte: Gurney (2004)

Hagan *et al.* (2014) afirmam que as redes RBF geram aproximações robustas mesmo quando os dados são limitados ou apresentam ruído, pois a ênfase desta rede é ter bom poder de generalização para novas situações. Já Gurney (2004) coloca que a maneira mais simples para treinar redes RBF é escolher alguns centros aleatoriamente entre os dados de treinamento e treinar os pesos para alcançar o

output desejado, resolvendo um conjunto de equações lineares que minimiza a soma dos erros entre o resultado da rede e o resultado desejado.

Figura 2.6: Função gaussiana



Fonte: Gurney (2004)

2.4.3. RNAs e a utilização dos dados

As RNAs apresentam capacidade de aprendizagem e devem apresentar a capacidade de generalização ao final de um treinamento. Aprendizagem é a capacidade de aproximar o comportamento da rede aos dados de saída (resposta), adaptativamente a partir dos dados de treinamento (Sharma, 2011). Generalização é a capacidade da rede de fornecer previsão adequada para casos novos, que nunca tenham sido usadas para treinamento (Bataineh, 2015).

Para avaliar a capacidade da RNA de generalização, o conjunto de dados deve ser dividido em três partes: dados de treinamento, dados de validação e dados de teste, segundo Stasinakis (2013). O conjunto de treinamento, como o próprio nome já diz, é utilizado para treinar a rede, o conjunto de validação é utilizado para validar a performance do modelo a ser utilizado, e o modelo validado é utilizado, então, para realizar as previsões do conjunto de teste (Matijaš, 2013). O conjunto de validação é, muitas vezes, utilizado como critério de parada para o treinamento pois, a partir dele, verifica-se como o erro da rede evolui para sinais desconhecidos, e, se este erro aumenta por muitas iterações seguidas, é um sinal de que a rede já está

superajustada (*overfitting*) à amostra de treinamento, o que diminui sua capacidade de generalização (Kourentzes *et al.*, 2014).

Não existe um padrão específico na literatura quando à divisão ideal dos dados. É comum que o conjunto de validação tenha a mesma quantidade de padrões que o conjunto de teste, e que os demais dados sejam utilizados para treinamento (Gomes, G. da S. *et al.*, 2011). Donate *et al.* (2013) utilizam 30% dos dados para testes, Wong e Versace (2012) utilizam 25%, Wang *et al.* (2015) utilizam 13%, Wong *et al.* (2010) utilizam 8%, e Gomes e Ludermir (2013) utilizam de 7% à 17% dos dados como conjunto de testes, dependendo da aplicação.

Muitos autores dividem os dados em apenas dois conjuntos, um para treinamento e um para teste, especialmente quando as séries são muito curtas, pois a utilização de um conjunto de validação reduziria muito a quantidade de informações disponíveis para realizar o treinamento (Gheyas e Smith, 2011). Usualmente, para a aplicação de previsão de séries temporais, o conjunto de testes compreende os dados mais recentes da série, os dados de validação são os dados imediatamente anteriores a esses e os dados de treinamento são primeiros, ou mais antigos.

Outra questão importante diz respeito à normalização ou padronização dos dados. Guo *et al.* (2012) afirmam que normalizar os dados antes de realizar o treinamento, ou seja, deixá-los com média zero e desvio padrão um, evita problemas computacionais e facilita a aprendizagem da rede. Uma das formas mais usuais de realizar a normalização é conhecida como *z-score*, e consistem em calcular a diferença entre cada valor e o valor médio da série, e então dividi-la pelo desvio padrão (Matijaš, 2013), conforme a equação 2.9.

$$X' = \frac{X - \bar{X}}{\sigma_X} \quad (2.9)$$

onde \bar{X} é a média dos dados, σ_X é o desvio-padrão dos dados, X é o valor a ser modificado e X' é o novo valor calculado.

A padronização, também citada por muitos autores como normalização, é outra alternativa de tratamento dos dados, mais utilizada que a normalização por preparar os dados para qualquer tipo de função de ativação. Donate *et al.* (2013) explicam que a padronização dos dados é realizada, antes do treinamento da rede, transformando-os para o intervalo [0, 1], e que os mesmos devem ser revertidos para a escala original

após as previsões para que seja feita a análise. Wang *et al.* (2015) apontam que a maior vantagem deste processo é evitar que atributos em intervalos numéricos maiores dominem aqueles que apresentam intervalos numéricos menores. O mesmo autor sugere que os dados sejam escalados linearmente, conforme a equação 2.10, na qual X_{min} e X_{max} correspondem, respectivamente, aos valores mínimo e máximo da série temporal, X é o valor a ser modificado e X' é o novo valor calculado.

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2.10)$$

A qualidade e a quantidade dos dados que alimentam as redes também são um tópico crucial (Donate *et al.*, 2013). É preciso selecionar cuidadosamente os dados de entrada, pois incluir muitos dados não filtrados pode introduzir informações irrelevantes ou conflitantes que prejudicam o desempenho da rede (Wong e Versace, 2012). O resultado de previsão nem sempre é preciso e tal fato poderá ocorrer por diversos motivos; por exemplo, quando os dados de treinamento são muito diferentes dos dados de validação (Wong *et al.*, 2010). A utilização de séries temporais muito curtas, ou seja, que apresentam poucos elementos, torna a qualidade dos dados ainda mais relevante, já que, com menos padrões de treinamento é mais difícil realizar o aprendizado da RNA e, conseqüentemente, obter a sua generalização (Donate *et al.*, 2013).

2.5. Análise e limpeza de dados

Para que as correlações entre os indicadores e as previsões de séries temporais tenham melhores desempenhos, é preciso realizar previamente a análise e limpeza dos dados coletados. Esta seção aborda as técnicas estatísticas que podem ser utilizadas com este intuito, são elas:

- O teste de normalidade;
- As estatísticas descritivas e
- A reposição de dados via regressão.

O teste de normalidade é necessário, pois a escolha de muitos outros testes depende do resultado relativo à normalidade. Field (2005) aponta o teste de Kolgomorov-Smirnov como opção para avaliar a normalidade, e explica que se o

resultado do teste é significativo, ou seja, se $p < 0,05$, então a distribuição não pode ser considerada normal.

As estatísticas descritivas, as quais podem ser tabulares, gráficas ou numéricas, resumem as informações contidas em conjuntos de dados, tornando-os mais fáceis de interpretar (Sweeney *et al.*, 2013). Entre as opções de gráficos estão o linear e o boxplot. O linear é aplicado à séries temporais e ajuda a explorar as tendências nos dados (Levine *et al.*, 2011). O boxplot, por sua vez, pode ser utilizado para identificar valores discrepantes, também chamados *outliers*, os quais devem ser eliminados ou substituídos da base de dados (Field, 2005). Entre as estatísticas numéricas, também utilizadas tanto para obter uma compreensão melhor dos dados quanto para identificar *outliers*, Field (2005) apresenta média, mediana, variância, desvio padrão, *skewness* (simetria da distribuição) e *kurtosis* (nível de concentração da distribuição).

De acordo com Tsiriktsis (2005), dados faltantes podem resultar em estimativas tendenciosas e podem “puxar” coeficientes de correlação para valores mais baixos que a realidade. O mesmo autor sugere a utilização do método baseado em regressão para a reposição de dados quando o percentual de faltantes é menor que 10% e os valores faltantes não seguem um padrão, ou seja, são randômicos. O método baseado em regressão inicialmente calcula a relação entre as variáveis e então utiliza os coeficientes de regressão para estimar os valores faltantes.

2.6. Trabalhos correlatos

Diversas buscas foram realizadas em bancos de dados científicos com o objetivo de encontrar trabalhos correlatos ao aqui desenvolvido. Foram utilizados como critérios de busca: artigos publicados em jornais e em anais de eventos, escritos em inglês, em qualquer época. Os bancos de dados pesquisados foram *Scopus* e *Web of Science*, considerados os bancos mais extensos e mais frequentemente utilizados para buscas na literatura de diferentes campos científicos (Aghaei Chadegani *et al.*, 2013). A última busca foi realizada no dia 25 de setembro de 2017.

Quatro focos principais nortearam as pesquisas. O primeiro diz respeito à utilização de RNAs para realizar a previsão de indicadores de desempenho de manufatura. Para isso foram utilizados os seguintes grupos de buscas:

- Grupo 1: "manufactur* performance measur*" (título, resumo ou palavras-chave) AND "neural network*" (título, resumo ou palavras-chave)"
- Grupo 2: "manufactur* performance indicato*" (título, resumo ou palavras-chave) AND "neural network*" (título, resumo ou palavras-chave)
- Grupo 3: manufactur* performance measur* (título) AND "neural network*" (título, resumo ou palavras-chave)
- Grupo 4: manufactur* performance indicato* (título) AND "neural network*" (título, resumo ou palavras-chave)

Os testes iniciais foram feitos buscando apenas os termos relacionados ao indicador de desempenho, sem a inclusão do termo "manufatura", porém, centenas de resultados foram encontrados. A análise superficial destes resultados mostrou que os indicadores de desempenho se referiam ao desempenho da RNA, e não à aplicação das redes para realizar a previsão do desempenho de um indicador. Optou-se, então, por realizar a busca incluindo o termo relativo à manufatura, assim como foi feito na revisão sistemática da literatura sobre os indicadores de desempenho, como forma de conduzir a busca para o tipo de indicador desejado.

Realizando as buscas dos 4 primeiros grupos nos dois bancos de dados, apenas dois artigos foram encontrados: "Environmental Performance Measurement for Green Manufacturing Program Based on BP Neural Network", de Wang e Li (2010), e "Monitoring the performance of the paper making process" de Bissessur *et al.* (1999). Os dois artigos utilizam RNAs para fins de classificação, e não para previsão futura de indicadores.

Diversos artigos foram encontrados utilizando RNAs para previsão de séries temporais, porém aplicados a outros assuntos. Wu e Liu (2012) realizaram previsões de consumo de combustível de automóveis, enquanto Shen et al. (2011) realizaram previsões de valores de índices de ações em bolsa de valores, ambos os trabalhos utilizando redes RBF. Heidari et al. (2016) visaram a previsão de viscosidade de nanofluidos, Paoli et al. (2010), por sua vez, previram a radiação solar, Szoplik (2015) realizou a previsão do consumo de gás natural, Traore et al. (2016) previram a necessidade de irrigação de plantio e Ekonomou (2010) previu o consumo de energia elétrica na Grécia, todos estes trabalhos utilizaram redes MLP.

O segundo foco principal da pesquisa diz respeito à utilização de testes de correlação como forma de escolher os dados de entrada das RNAs. Para tanto, foram utilizados os seguintes grupos de buscas:

- Grupo 5: Pearson correlation (título, resumo ou palavras-chave) AND “neural network*” (título, resumo ou palavras-chave)
- Grupo 6: Kendall Tau (título, resumo ou palavras-chave) AND “neural network*” (título, resumo ou palavras-chave)

A busca dos grupos 5 e 6 nos dois bancos de dados resultou em 208 artigos distintos, já excluindo os artigos relacionados à área médica, ou seja, aqueles que tratam de redes neurais humanas e não artificiais. Dentre os artigos levantados, quase 52% utilizam os coeficientes de correlação como forma de avaliação das RNAs, calculando a correlação entre as respostas obtidas e as esperadas da rede. Muitos artigos, cerca de 38%, utilizam a correlação para fins independentes das RNAs. Alguns artigos utilizam a correlação para relacionar os *inputs* e *outputs* das redes.

Cerca de 10% dos trabalhos encontrados utilizam as correlações relacionadas às redes neurais com o mesmo objetivo deste trabalho, ou seja, determinar quais são os melhores dados de entrada para a rede, entre eles estão: Kusiak e Li (2010) utilizam a correlação para escolher quais são as 5 turbinas de medição, a partir de um conjunto de 30, que melhor se correlacionam com o local desejado de previsão da velocidade do vento, e então utilizam os dados coletados nessas 5 turbinas como entrada para a previsão; Shi e Zhang (2012) realizam a previsão do crescimento de árvores, para isso, utilizam a correlação para reduzir, de 8 para 4, as variáveis de entrada da RNA; e Ruigar e Golian (2016) realizam a previsão de precipitação meteorológica e utilizam a correlação para definir quais são os 3 melhores conjuntos de dados a serem utilizados como entrada da RNA, entre um conjunto de 36.

O terceiro foco principal da pesquisa diz respeito à utilização de testes de correlação como forma de analisar os indicadores de desempenho. Para tanto, foram utilizados os seguintes grupos de buscas:

- Grupo 7: “manufactur* performance measur*” (título, resumo ou palavras-chave) AND Pearson correlation (título, resumo ou palavras-chave)”
- Grupo 8: “manufactur* performance indicato*” (título, resumo ou palavras-chave) AND Pearson correlation (título, resumo ou palavras-chave)

- Grupo 9: manufactur* performance measur* (título) AND Pearson correlation (título, resumo ou palavras-chave)
- Grupo 10: manufactur* performance indicato* (título) AND Pearson correlation (título, resumo ou palavras-chave)
- Grupo 11: "manufactur* performance measur*" (título, resumo ou palavras-chave) AND Kendall Tau (título, resumo ou palavras-chave)"
- Grupo 12: "manufactur* performance indicato*" (título, resumo ou palavras-chave) AND Kendall Tau (título, resumo ou palavras-chave)
- Grupo 13: manufactur* performance measur* (título) AND Kendall Tau (título, resumo ou palavras-chave)
- Grupo 14: manufactur* performance indicato* (título) AND Kendall Tau (título, resumo ou palavras-chave)

A busca pelos grupos 7 até 14 nos dois bancos de dados não apresentou resultados. Optou-se então por buscar apenas o termo “correlação”, ao invés dos nomes das correlações utilizadas, criando os seguintes novos grupos:

- Grupo 11: "manufactur* performance measur*" (título, resumo ou palavras-chave) AND correlation* (título, resumo ou palavras-chave)"
- Grupo 12: "manufactur* performance indicato*" (título, resumo ou palavras-chave) AND correlation* (título, resumo ou palavras-chave)
- Grupo 13: manufactur* performance measur* (título) AND correlation* (título, resumo ou palavras-chave)
- Grupo 14: manufactur* performance indicato* (título) AND correlation* (título, resumo ou palavras-chave)

A busca pelos grupos 11 a 14 nos dois bancos de dados apresentou 12 resultados diferentes. Nenhum dos artigos encontrados utiliza a correlação estatística como forma de analisar as relações entre os indicadores de desempenho. Os trabalhos correlacionam os indicadores com outros assuntos, tais como: correlação entre os requisitos dos clientes e os indicadores utilizados (Yiangkamolsing *et al.*, 2010), correlação entre o desempenho de diferentes empresas e a utilização de indicadores (Sarmiento *et al.*, 2009), correlação entre os tipos de indicadores utilizados e a estratégia da empresas (Jusoh *et al.*, 2008b), correlação entre a frequência de medição dos indicadores e a satisfação gerencial com o desempenho

(Coskun e Bayyurt, 2008) e correlação entre o desempenho de equipes de trabalho e o recebimento ou não de *feedback* (Jones *et al.*, 1993).

O quarto, e último foco de pesquisa foi quanto à utilização da hierarquia para analisar indicadores de desempenho de manufatura. Foram utilizados os seguintes grupos de buscas:

- Grupo 15: "manufactur* performance measur*" (título, resumo ou palavras-chave) AND hierarc* (título, resumo ou palavras-chave)"
- Grupo 16: "manufactur* performance indicato*" (título, resumo ou palavras-chave) AND hierarc* (título, resumo ou palavras-chave)
- Grupo 17: manufactur* performance measur* (título) AND hierarc* (título, resumo ou palavras-chave)
- Grupo 18: manufactur* performance indicato* (título) AND hierarc* (título, resumo ou palavras-chave)

No total, 25 artigos diferentes foram identificados, dos quais vinte utilizam o método AHP (analytical hierarchy process) e três se referem a hierarquia organizacional, e não dos indicadores. Dois artigos se aproximam mais deste trabalho, são eles: Burger *et al.* (2017) fazem uma classificação dos KPIs de forma hierárquica, qualitativamente, e Amrina e Yusof (2012) faz uma hierarquia que busca identificar a interação entre 9 diferentes indicadores, de forma qualitativa, baseada na opinião de especialistas. Não foram encontrados trabalhos que utilizem formas quantitativas para estabelecer e analisar uma hierarquia de indicadores.

Outros trabalhos realizaram revisões de literatura sobre medição de desempenho. Gomes *et al.* (2004) realizaram uma revisão de literatura de manufatura e concluíram que, entre outras coisas, pesquisas futuras deveriam aproximar a academia da prática das empresas para criar e validar filosofias, sistemas e medidas de desempenho. El Mola e Parsaei (2010) sugeriram uma forma de comparar e selecionar os indicadores adequados, os autores citam que mais de 200 indicadores existem, porém não apontam quais são eles ou como são classificados.

Folan e Browne (2005) realizaram uma revisão não sistemática, os autores não deixam claro quantos artigos foram pesquisados ou qual foi o critério de busca, e a principal sugestão após a pesquisa é o estudo da gestão de desempenho interorganizacional nas cadeias de suprimentos. Rouse e Putterill (2003) realizaram uma revisão de literatura a partir da qual fizeram a proposta de um frame work de análise de indicadores de desempenho em três etapas: medidas, análise e avaliação.

A revisão de literatura desta tese, além de ser uma atualização, já que inclui artigos de 2000 a 2015, diferencia-se dos artigos citados pois levantou uma lista de mais de 400 indicadores de desempenho que podem ser utilizados como referência nas indústrias.

Alguns artigos identificaram indicadores utilizados pelas indústrias. Gomes *et al.* (2011) identificaram 63 indicadores de desempenho de manufatura e apontaram para a necessidade de as pesquisas futuras contribuírem para facilitar a transformação das teorias criadas em práticas nas empresas e para a possibilidade de utilizar metodologias de pesquisa diferentes para identificar indicadores relevantes. Amrina e Vilsu (2015) identificaram indicadores de desempenho de sustentabilidade relevantes para a indústria de cimento com base na opinião de especialistas e aplicação do método AHP. A revisão de literatura deste trabalho também buscou levantar os indicadores relevantes, porém com base na literatura, e não em pesquisa direta com empresas, o que levou à identificação de uma quantidade maior de opções e classificações.

O quadro 2.4 condensa detalhes sobre alguns dos diversos trabalhos correlatos ao aqui realizado encontrados.

Quadro 2.4 Trabalhos Correlatos

Autores	Aplicação	Técnicas utilizadas	Indicadores e Considerações
Gomes <i>et al.</i> (2004)	Manufatura	Revisão de literatura	Mais focado nos sistemas de medição que nos indicadores em si.
El Mola e Parsaei (2010)	Manufatura.	Revisão de literatura	Sete dimensões para os indicadores identificadas: qualidade, flexibilidade, tempo, entrega, custo, finanças e satisfação dos consumidores.
Folan e Browne (2005)	Manufatura.	Revisão de literatura	Identifica na literatura algumas recomendações, frameworks e sistemas de gestão de desempenho.
Rouse e Putterill (2003)	Manufatura	Revisão de literatura e criação de Framework	Sugestão de forma teórica de avaliação holística de indicadores.
Gomes, C. F. <i>et al.</i> (2011)	Manufatura	<i>Survey</i>	O artigo identificou 63 indicadores de desempenho mais utilizados com base em uma pesquisa respondida por 69 indústrias de Portugal.
Amrina e Vilsu (2015)	Indústria de cimento	<i>Survey e AHP</i>	13 indicadores identificados e divididos no tripé da

Autores	Aplicação	Técnicas utilizadas	Indicadores e Considerações
			sustentabilidade: econômicos, ambientais e sociais. Pesos de importância dados aos indicadores.
Wang e Li (2010)	Manufatura Verde	<i>Back Propagation Neural Network</i>	São propostas 19 medidas de desempenho de 3 categorias relacionadas ao ciclo de vida do produto.
Bissessur et al. (1999)	Indústria de papel	Estatística Multivariada e Redes Neurais	São controladas características do sistema como falha de prensa e detecção de picos.
Ruigar e Golian (2016)	Meteorologia	Coeficiente de correlação de Pearson e Redes Neurais	Previsão de precipitações no Iram.
Kusiak e Li (2010)	Meteorologia	Coeficiente de correlação de Pearson e Redes Neurais	Previsão de velocidade do vento.
Shi e Zhang (2012)	Madeira	Coeficiente de correlação de Pearson e Redes Neurais	Previsão de crescimento de árvores.
Sarmiento et al. (2009)	Manufatura	<i>Data Envelopment Analysis (DEA)</i> e Correlação	Teste de diversos indicadores de manufatura como rotatividade de funcionários e eficiência.
Yiangkamolsing et al. (2010)	Manufatura	Correlação e análise fatorial	39 Indicadores de requisitos de cliente para o design de produto.
Coskun e Bayyurt (2008)	Manufatura	<i>Survey</i>	Indicadores baseados no <i>Balanced Scorecard</i> .
Jones et al. (1993)	Varejo	<i>ProMES (productivity measurement and evaluation system)</i>	Diversos indicadores considerados chave em cada departamento.
Burger et al. (2017)	Manufatura	<i>Manufacturing Value Modeling Methodology</i>	Variabilidade de produção, capacidade de expansão, programação de produção e volume produtivo.
Amrina e Yusof (2012)	Indústria Automotiva	<i>Survey e Interpretive structural modeling (ISM)</i>	Emissões, utilização de recursos, qualidade, custo, entrega, flexibilidade, funcionários, fornecedores e desperdício
Shen et al. (2011)	Bolsa de Valores	Rede Neural RBF e <i>artificial fish swarm algorithm (AFSA)</i>	Previsão de valores de índices de ações.
Heidari et al. (2016)	Química	Rede Neural MLP e <i>Levenberg-Marquardt</i>	Previsão de viscosidade de nanofluidos.

Autores	Aplicação	Técnicas utilizadas	Indicadores e Considerações
Paoli et al. (2010)	Energia	Rede Neural MLP e ARIMA	Previsão da radiação solar
Szoplik (2015)	Energia	Rede Neural MLP	Previsão de consumo de gás natural.
Traore et al. (2016)	Agricultura	Rede Neural MLP, Rede Neural Probabilística e Regressão Linear	Previsão de necessidade de irrigação de plantio.
Wu e Liu (2012)	Energia	Rede Neural RBF	Previsão de consumo de combustível de automóveis
Ekonomou (2010)	Energia	Rede Neural MLP	Previsão do consumo de energia elétrica na Grécia

Fonte: a autora.

Este capítulo apresentou a revisão de literatura sobre indicadores de desempenho, a qual levantou as questões de pesquisa do presente trabalho, assim como o embasamento teórico necessário para o desenvolvimento e aplicação da metodologia proposta. O próximo capítulo explica detalhadamente esta metodologia.

3. METODOLOGIA PROPOSTA

Com o objetivo de atender a algumas das lacunas identificadas na revisão de literatura sobre indicadores de desempenho (seção 2.1.3), este trabalho apresenta uma metodologia que busca resolver dois problemas: 1. Determinar as relações e conflitos existentes entre indicadores considerando, inclusive, indicadores externos às empresas; 2. Prever os valores futuros das séries de dados dos indicadores utilizando, para isso, RNA.

Uma técnica de resolução de problemas (RP) amplamente utilizada é a proposta por Polya (2004), que propõe quatro passos:

1. Entender o problema, quais são os dados e condições;
2. Desenhar um plano de resolução que inclui a necessidade de introduzir elementos auxiliares e os métodos a serem utilizados;
3. Executar o plano;
4. Avaliar os resultados e sua coerência.

Para que os dois problemas propostos (determinar relações e conflitos entre os indicadores e previsão de indicadores-chave) possam ser resolvidos, alguns passos são necessários. O Quadro 3.1 apresenta os passos, baseados na proposta de Polya (2004), para que cada um dos problemas seja resolvido.

Como a resolução do segundo problema é dependente da resolução do primeiro problema, optou-se então por propor uma metodologia única para a resolução conjunta dos dois problemas, juntando de forma ordenada todos os passos. Desta forma, a metodologia proposta consiste de três fases principais:

1. Coleta e análise dos dados;
2. Cálculo e análise das correlações estatísticas entre os indicadores; e
3. Previsão futura de indicadores-chave.

Cada fase é subdividida em etapas a serem realizadas, totalizando 12 passos, conforme apresentado no Quadro 3.2.

As próximas seções mostram cada passo detalhadamente.

Quadro 3.1 Metodologia de Resolução de Problemas aplicada aos Problemas de Pesquisa

Passo de RP de Polya (2004)	Problema 1	Problema 2
Entender o problema	Coletar e analisar os dados de indicadores disponíveis nas empresas	Coletar e analisar os dados de indicadores disponíveis nas empresas e os dados resultantes da resolução do problema 1, de determinação das correlações entre indicadores
Desenhar um plano	a) Determinar dados da empresa e externos a serem utilizados b) Determinar quais são os indicadores-chave de cada empresa c) Determinar qual teste de correlação deve ser utilizado a partir do teste de normalidade	a) Definir os dados de entrada das RNA b) Determinar quais RNA devem ser testadas c) Determinar quais configurações de cada RNA devem ser testadas
Executar o plano	a) Calcular as correlações entre todos os indicadores b) Criar uma hierarquia de correlações a partir dos indicadores-chave	a) Realizar os testes de previsão de indicadores-chave com RNA
Avaliar os resultados	Análise da hierarquia e proposta de como utilizá-la para melhorar a gestão de indicadores e/ou da empresa	Definir qual das redes e configurações testadas deve ser implementada por cada empresa.

Fonte: a autora.

Quadro 3.2: Metodologia Proposta: 3 Fases e 12 Passos

Coleta e Análise dos Dados	<ol style="list-style-type: none"> 1. Coleta dos dados 2. Inspeção visual dos dados 3. Análise do gráfico linear (estudo das tendências) 4. Análise do <i>boxplot</i> e demais estatísticas descritivas (busca por <i>outliers</i>) 5. Substituição dos valores faltantes 6. Teste de normalidade
Correlação entre Indicadores	<ol style="list-style-type: none"> 7. Cálculo das correlações entre todos os indicadores 8. Criação de uma hierarquia de correlações a partir dos indicadores-chave 9. Análise da hierarquia e proposta de um conjunto de indicadores a ser utilizado
Previsão Futura de Indicadores-chave	<ol style="list-style-type: none"> 10. Preparação dos dados 11. Testes com diferentes redes neurais para a previsão 12. Definição da rede com melhor desempenho a ser implementada e seus respectivos parâmetros para a previsão

Fonte: a autora.

3.1. Coleta e análise dos dados

Para que a metodologia proposta possa apresentar maiores chances de obter resultados satisfatórios, é preciso inicialmente realizar a análise e limpeza dos dados coletados, pois, como afirmam Wong e Versace (2012), incluir dados não filtrados pode introduzir informações irrelevantes ou conflitantes que podem prejudicar o desempenho das técnicas utilizadas.

A coleta dos dados (passo 1) consiste em coletar e registrar os dados históricos de todos os indicadores de desempenho que a empresa utiliza, com a maior quantidade possível de entradas de cada indicador, e adicionar aos dados da empresa os indicadores externos, como indicadores socioeconômicos, que possam impactar nos resultados alcançados nas organizações.

A inspeção visual dos dados (passo 2) consiste em buscar, nos dados de cada indicador levantado, valores incoerentes e modificá-los, trocando-os por “dados corretos”, quando possível, ou deletando o dado incorreto. Exemplos de valores que podem ser substituídos são os valores zerados, que não representam o valor zero, mas sim que correspondem à falta de medição no período. Nesta etapa deve-se eliminar do processo os indicadores que tenham sido descontinuados na empresa e aqueles que tenham sido implementados há pouco tempo, apresentando uma quantidade de dados muito baixa (inferior a 30; quantidade sugerida por Rovai *et al.* (2013)), o que prejudica a qualidade dos resultados dos métodos posteriores.

A análise do gráfico linear (passo 3) consiste em estudar as tendências de todos os indicadores levantados, individualmente, objetivando identificar mudanças bruscas de comportamento. Grandes modificações nas indústrias e nos mercados, tais como implantação de uma nova linha de produção ou mudanças em regulações comerciais, podem gerar variações grandes nos indicadores. Nesses casos deve-se considerar, para as análises seguintes de correlação e previsão, apenas os dados referentes ao período posterior à mudança, evitando a contaminação dos testes por dados relativos a outro cenário.

A análise do *boxplot* e demais estatísticas descritivas (passo 4) consiste em buscar por *outliers* em todos os conjuntos de dados, substituindo-os quando for possível, ou eliminando-os. Além disso, eliminar do processo os indicadores que, após as análises anteriores, apresentem uma quantidade de dados muito pequena, ou seja,

que tenham tido muitos dados eliminados, seja por variações de comportamento da série temporal e/ou por excesso de *outliers*.

A substituição dos valores faltantes nas séries de dados (passo 5) consiste em realizar a substituição utilizando a regressão da série com os dados existentes para completar os valores em branco.

O teste de normalidade (passo 6) consiste em realizar o teste de Kolmogorov-Smirnov para todos os indicadores. Os resultados ajudam a definir qual estatística deve ser utilizada para estabelecer a correlação entre os dados.

3.2. Correlação entre indicadores de desempenho

O cálculo das correlações entre todos os indicadores (passo 7) consiste em estabelecer as correlações fortes entre todos os indicadores utilizando o Coeficiente de Correlação de Pearson, caso os dados apresentem distribuição normal, ou o teste Tau de Kendall, caso contrário. Considerar como correlações fortes aquelas que apresentem a significância menor ou igual a 0,05 e o resultado do teste variando entre $\pm 0,5$ até ± 1 .

A hierarquia de correlações a partir dos indicadores-chave (passo 8) consiste em, para cada um dos indicadores-chave das empresas, estabelecer uma rede hierárquica. Partir do próprio indicador-chave e conectar a ele os indicadores que lhe sejam fortemente correlacionados. Para cada indicador incluído na segunda camada, incluir uma terceira camada conectando seus outros indicadores fortemente correlacionados. Continuar este processo até que a hierarquia tenha quatro camadas ou não haja mais indicadores a serem incluídos.

A análise da hierarquia e proposta de conjunto de indicadores (passo 9) consiste em, para cada uma das correlações fortes da hierarquia, analisar qual dos indicadores é gerador do outro, ou se pode existir um terceiro fenômeno que influencie os dois indicadores. A partir desta análise, e dos impactos que cada indicador tem no indicador-chave, propor uma lista de indicadores a serem acompanhados mais atentamente pelas empresas.

3.3. Previsão de indicadores-chave de desempenho

As etapas referentes à previsão de indicadores-chave, ou seja, os passos 10-Preparação dos dados de entrada, 11-Testes com diferentes RNA para a previsão, e

12-Definição da rede com melhor desempenho a ser implementada e seus respectivos parâmetros para a previsão, explicados nas subseções que seguem.

3.3.1. Preparação dos dados de entrada

O primeiro passo para a utilização de RNA para a previsão dos indicadores-chave de desempenho é a preparação dos dados para a utilização como padrões de entrada. Diferentes dados de entrada devem ser testados para alimentar as RNA. É preciso testar redes com todas as combinações possíveis entre os seguintes dados de entrada:

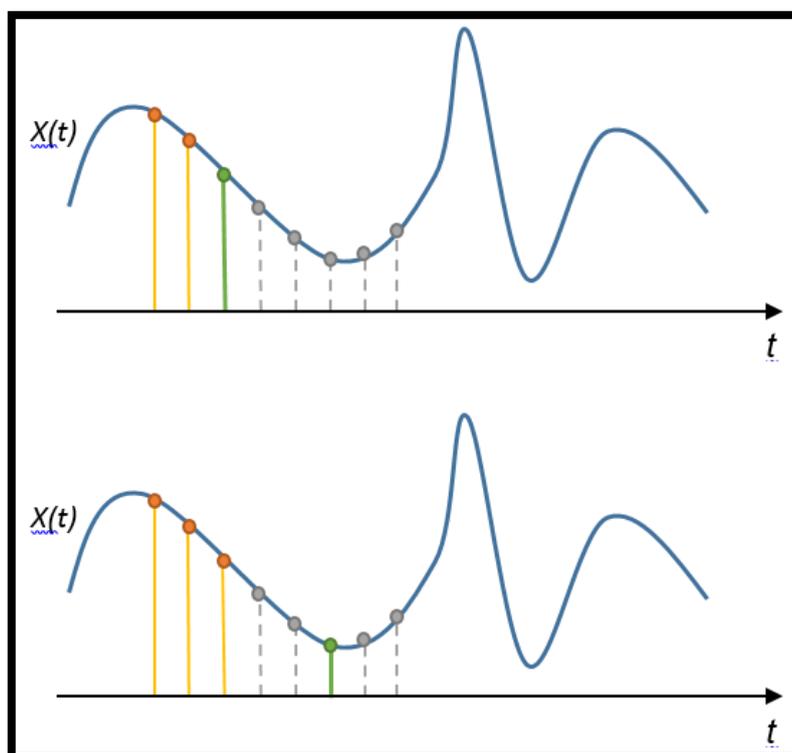
- Dados históricos do próprio indicador que se pretende prever.
- Dados históricos dos indicadores fortemente correlacionados ao indicador que se pretende prever.
- Dados que demonstrem a época do ano de que se tratam os dados, para facilitar a aprendizagem de sazonalidade.
- Dados externos de prospecção de mercado.

Wright *et al.* (2010) explicam que a previsão é amplamente apoiada por métodos quantitativos, pressupondo que o passado é um bom preditor do futuro, a prospecção, porém, considera que o futuro está sujeito a riscos e incertezas, os quais devem ser considerados em uma abordagem qualitativa. Desta forma, incluir dados de prospecção de mercado pode complementar as informações disponíveis melhorando a qualidade dos resultados.

Além de definir quais são os dados de entrada a serem testados, é preciso determinar as janelas de tempo que se pretende prever. Pode-se fazer previsões de curtíssimo prazo, para o período seguinte, previsões de curto prazo, para, por exemplo, 3 meses no futuro ou previsões de médio prazo, como um ano no futuro. A Figura 3.1 exemplifica, em sua parte superior, os dados de entrada (em vermelho) sendo utilizados para realizar a previsão do período seguinte (em verde), e, na parte inferior, os dados de entrada (em vermelho) sendo utilizados para realizar a previsão do terceiro período no futuro (em verde).

Após definir quais são as séries de dados a serem utilizadas, e como serão utilizadas para alimentar as RNA, ou seja, quais serão as janelas de tempo consideradas, deve-se então realizar a padronização das mesmas no intervalo $[0, 1]$ conforme a equação 2.10.

Figura 3.1. Exemplo de padrões de dados de entrada e saída



Fonte: a autora.

3.3.2. Testes com diferentes redes neurais para a previsão

Diferentes tipos de RNAs devem ser testadas, com diferentes parâmetros em cada uma delas. Para testes com as redes RBF, além de variar os dados de entrada e a janela de tempo, deve-se testar diferentes spreads (utilizados para calcular o bias), e o número de centros variando de 1 até o número de dados de entrada. A função de ativação utilizada é a apresentada em (3.1).

$$radbas(n) = e^{-n^2} \quad (3.1)$$

Além da rede RBF, redes MLP também devem ser testadas, utilizando três camadas e aprendizagem por *back-propagation*, com diferentes combinações dos parâmetros das redes, variando número de neurônios na camada escondida, função de ativação, conjunto de pesos iniciais, taxa de aprendizagem e forma de apresentação dos dados para a rede.

Os padrões de treinamento devem ser utilizados, em ordem aleatória, para treinar a rede. Esta ordenação aleatória da apresentação dos dados à RNA faz com

que diferentes resultados possam ser obtidos, e, por este motivo, cada conjunto de padrões deve ser aplicado a cada configuração 30 vezes, para que seja possível avaliar a consistência da qualidade da rede em questão.

Após cada iteração de treinamento, os dados de validação devem ser aplicados na rede para determinar o erro da mesma ao prever informações externas. O cálculo de erro a ser utilizado dentro das RNAs é o erro médio quadrático (MSE), apresentado na equação 3.2, por ser o cálculo de erro mais utilizado em trabalhos de comparações entre redes neurais (Kourentzes *et al.*, 2014; Wang *et al.*, 2015).

$$MSE = \frac{\sum_{t=1}^k (\hat{y}_t - y_t)^2}{k} \quad (3.2)$$

onde k é a quantidade de valores previstos pela rede, ou de períodos analisados pela rede, y_t é o valor esperado para a previsão t e \hat{y}_t é o valor obtido pela rede neural para o período t .

O critério de parada consiste em 20 iterações consecutivas sem melhoria no erro de previsão do conjunto de validação, e foi escolhido para evitar que a RNA fique superadaptada aos dados de treinamento, o que reduziria o erro da previsão dos mesmos, porém aumentaria o erro da previsão de novos dados. Após a parada do treinamento da rede, devem ser utilizados os melhores pesos obtidos (que geraram o menor erro no conjunto de validação) para prever os valores referentes ao conjunto de testes. Os erros dos padrões de teste são então utilizados para comparar a eficácia das diferentes configurações das RNAs.

Apesar de a maior parte dos trabalhos que geram a matriz de pesos iniciais aleatoriamente utilizarem pesos no intervalo $[-1;+1]$, os trabalhos de Fahlman (1988) e Nguyen e Widrow (1990) afirmam que melhores resultados são obtidos ao utilizar o intervalo $[-0,5;+0,5]$, pois a chance de os dados serem levados à saturação diminui. Por este motivo os pesos iniciais devem ser escolhidos dentro do intervalo $[-0,5;+0,5]$.

3.3.3. Definição da rede com melhor desempenho

O terceiro, e último, passo da previsão de indicadores-chave consiste na definição da melhor rede e dos parâmetros para a previsão. Deve ser escolhida uma RNA para previsão de cada indicador-chave de cada empresa.

Apesar de o erro médio quadrático ter sido utilizado internamente nas redes, a representação percentual do erro deixa a informação mais clara para utilização das empresas. Considerando que cada configuração de rede deve ser testada 30 vezes, os seguintes parâmetros devem ser utilizados para comparar o desempenho das RNAs:

- Erro % absoluto de previsão mínimo: melhor erro entre os 30 testes
- Erro % absoluto de previsão médio: erro médio entre os 30 testes
- Erro % absoluto de previsão máximo: pior erro entre os 30 testes
- Desvio padrão do erro de previsão

Escolher uma rede considerando apenas o melhor erro médio não é aconselhável pois, se o desvio padrão do erro for grande, pode ser que uma rede com bom erro médio tenha algumas poucas previsões de erro muito grande, enquanto uma segunda rede poderia ter erro médio pouco maior porém ser mais consistente. Deve ser escolhida para implementação, então, a rede neural com o menor desvio padrão do erro, entre as 3 redes com menor Erro % absoluto médio.

O próximo capítulo aborda os resultados obtidos com a aplicação desta metodologia proposta em três empresas distintas.

4. RESULTADOS

Este capítulo aborda os resultados obtidos a partir dos testes realizados, os quais englobam as etapas de 1 a 12 da metodologia proposta, apresentada no Quadro 3.1. Ou seja, são apresentados os resultados referentes às três fases: à coleta e análise de dados; às correlações entre os indicadores, além da preparação dos dados que “alimentarão” as RNA visando a previsão dos indicadores-chave.

Como forma de preservar informações sigilosas das empresas, todos os dados estão padronizados, de maneira que os gráficos terão sua escala alterada. A análise e limpeza dos dados e o cálculo das Correlações estatísticas foram realizados com o auxílio do *software* IBM® SPSS® Statistics (SPSS). Já a fase de previsão de indicadores-chave por meio de RNA foi implementada utilizando o MATLAB®.

4.1. Fase 1: Coleta e análise dos dados

A metodologia proposta neste trabalho foi aplicada a três empresas distintas, com tamanhos e áreas de atuação variados, como forma de verificar a possibilidade de implementação em diferentes cenários, ou seja, de generalizar a metodologia proposta. A Tabela 4.1 resume as informações coletadas nas empresas. Os portes das empresas foram determinados segundo o critério estabelecido na circular nº 34/2011 do BNDES (2011), a qual define como critério a receita operacional bruta anual.

A Empresa A é uma indústria de médio-grande porte, que atua no setor de bens duráveis. Foram coletados dados referentes a 81 indicadores de desempenho, dos quais 7 são corporativos, 13 são relacionados aos clientes, 23 são relativos aos funcionários, 17 são voltados aos equipamentos e 21 são relacionados ao processo produtivo. Os dados são mensais, relativos ao período de janeiro de 2011 até outubro de 2015, quando disponíveis. Alguns indicadores começaram a ser medidos mais recentemente e por isso não possuem a série de dados completa. Foram acrescentados aos indicadores internos da empresa 31 indicadores sociais e econômicos externos que, segundo a própria empresa, podem influenciar seus resultados, totalizando 112 indicadores. Entre os indicadores externos estão índices de inflação e de desemprego, variação cambial e cotação do petróleo. A Empresa A definiu os seguintes indicadores como os mais importantes, ou seja, os indicadores-

chave: “Scrap consolidado do produto A total”, ou seja, a sucata gerada na produção do produto A, e “Produtividade por funcionário da fábrica 2”.

Tabela 4.1 Características das Empresas Analisadas

Indicadores	Empresa A	Empresa B	Empresa C
Internos	81	279	194
Relativos a Clientes	13	12	54
Relativos a Funcionários	23	119	39
Relativos a Equipamentos	17	0	4
Relativos a Material	0	0	10
Relativos a Processo	21	0	38
Relativos a Produto	0	0	24
Relativos à Corporação	7	148	25
Externos	31	30	29
TOTAL	112	309	223
Frequência dos Dados	mensal	trimestral	mensal
Período de Medição	2011-2015	1995-2015	2010-2015
Atuação	Bens Duráveis	Cooperativa Agroindustrial	Indústria Alimentícia
Porte	Médio-grande	Grande	Médio

Fonte: a autora.

A Empresa B é uma cooperativa agroindustrial de grande porte. Foram coletados 309 indicadores de desempenho, dos quais 148 são corporativos, principalmente financeiros, 119 se referem à pessoal, 12 são voltados a clientes e 30 são externos à empresa. Os dados são trimestrais referentes ao período de janeiro de 1995 até outubro de 2015. Assim como acontece na Empresa A, nem todas as séries de dados estão completas. A Empresa B definiu como indicadores-chave o “Endividamento total” e a “Rentabilidade dos ativos”.

A Empresa C é uma indústria de médio porte do ramo alimentício. Foram coletados 194 indicadores internos, sendo 39 referentes aos funcionários, 38 de processo, 10 de material, 4 de equipamentos, 54 voltados aos clientes, 24 voltados aos produtos e 25 corporativos, incluindo financeiros. Foram acrescentados 29 indicadores externos pertinentes à atividade da indústria, totalizando 223 indicadores. Os dados são mensais e se referem ao período de janeiro de 2000 até outubro de

2015. Os indicadores-chave definidos pela empresa são: “EBITDA” (Lucros antes de juros, impostos, depreciação e amortização) e “Custo médio dos produtos vendidos”.

A distribuição dos indicadores de cada empresa nas diferentes categorias é um demonstrativo inicial das diferenças estratégicas de gestão. A Empresa A optou por não divulgar indicadores financeiros, os quais entrariam na categoria corporativos, apesar disso, é possível notar, a partir da falta de indicadores relativos a material e produto, que o foco se encontra na produtividade dos processos, equipamentos e funcionários.

A Empresa B apresenta apenas indicadores corporativos, principalmente financeiros e relativos à gestão de pessoas. Isso ocorre, pois somente foi possível ter acesso a esses dados, e não necessariamente porque as outras categorias não estejam sendo medidas. A Empresa C, a única a apresentar indicadores de todas as categorias, apresenta um foco maior em clientes, porém “peca” pela falta de indicadores relativos a equipamentos e materiais, deixando de controlar, por exemplo, os tempos de manutenção e produção.

A análise dos dados históricos de todos os indicadores de desempenho levantados nas três empresas está apresentada na Tabela 4.2. São apresentados, de forma resumida, o resultado das atividades de coleta dos dados; inspeção visual dos dados; análise do gráfico linear; análise do boxplot e demais estatísticas descritivas; substituição dos valores faltantes; e testes de normalidade. Detalhes das análises relativos a cada empresa são explicados na sequência.

Tabela 4.2: Resumo da fase 1: coleta e análise dos dados

Atividades da Fase 1	Empresa A	Empresa B	Empresa C
Quantidade total de indicadores analisados	112	309	222
Quantidade de indicadores excluídos por meio da inspeção visual	17	119	55
Quantidade de indicadores excluídos por meio da análise do gráfico linear	1	13	3
Quantidade total de indicadores após as devidas exclusões	94	177	164
Análise do boxplot e outras e estatísticas; percentual de valores faltantes após a exclusão de <i>outliers</i>	4,05%	1,75%	0,79%
Percentual de indicadores que apresentam distribuição normal	37,89%	25,99%	38,92%

Fonte: a autora.

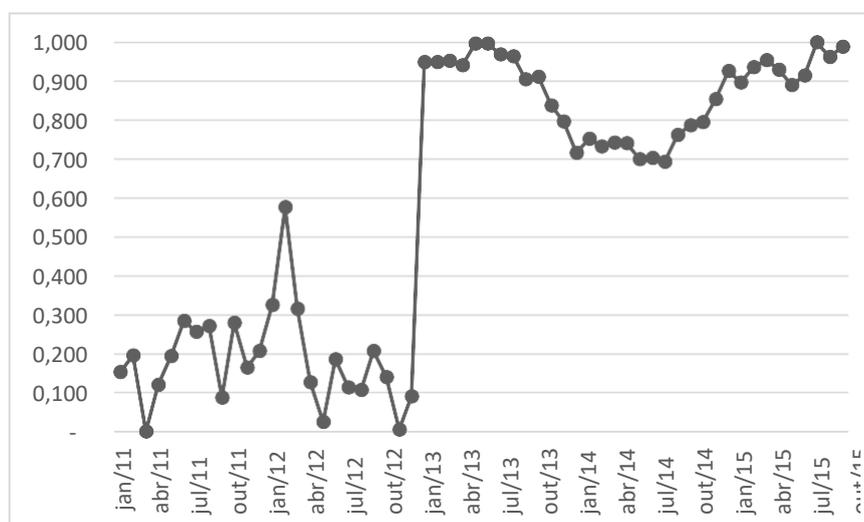
4.1.1. Empresa A

Durante o passo 1, A Empresa A teve dados de 81 indicadores de desempenho coletados, aos quais foram adicionados 31 indicadores externos à empresa, totalizando 112 séries de indicadores a serem analisadas. Após a inspeção visual dos dados, realizada no passo 2, foram eliminados 17 indicadores, incluindo os que não são mais utilizados pela empresa, e por este motivo só apresentam dados antigos e, também, os que foram implementados há pouco tempo, e por este motivo não apresentam o mínimo de 30 valores em suas séries históricas.

A análise dos gráficos lineares das séries temporais, realizada no passo 3, mostrou uma modificação grande nos padrões de comportamento de diversos indicadores no início do ano 2013. A Figura 4.1 exemplifica este fenômeno. Este fato ocorreu devido à implementação de uma nova linha de produção, responsável por outros tipos de produtos não fabricados anteriormente. Devido a esta grande mudança, os dados anteriores à implementação não são representativos da situação atual da empresa e, por isso, optou-se por utilizar apenas os dados de março de 2013 até outubro de 2015 para todos os indicadores desta empresa.

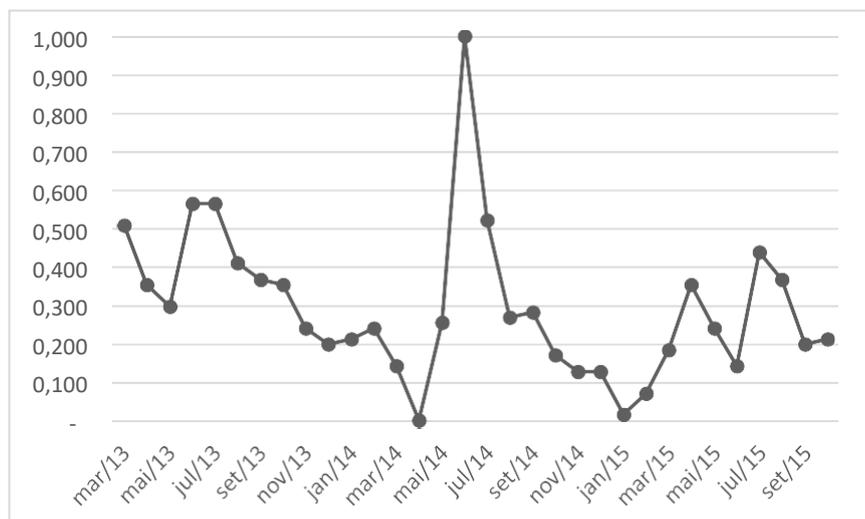
No passo 4, os gráficos *bloxplot* e as demais estatísticas descritivas foram analisados juntamente com os gráficos lineares na busca por *outliers*. As Figuras 4.2 e 4.3 mostram, como exemplo, os gráficos linear e *boxplot* referentes à série temporal de “Consumo de óleo combustível Fábrica 01”. O dado número 16, correspondente ao mês de julho de 2014, foi eliminado.

Figura 4.1: Gráfico linear Empresa A: Indicador “Reclamação do cliente geral”



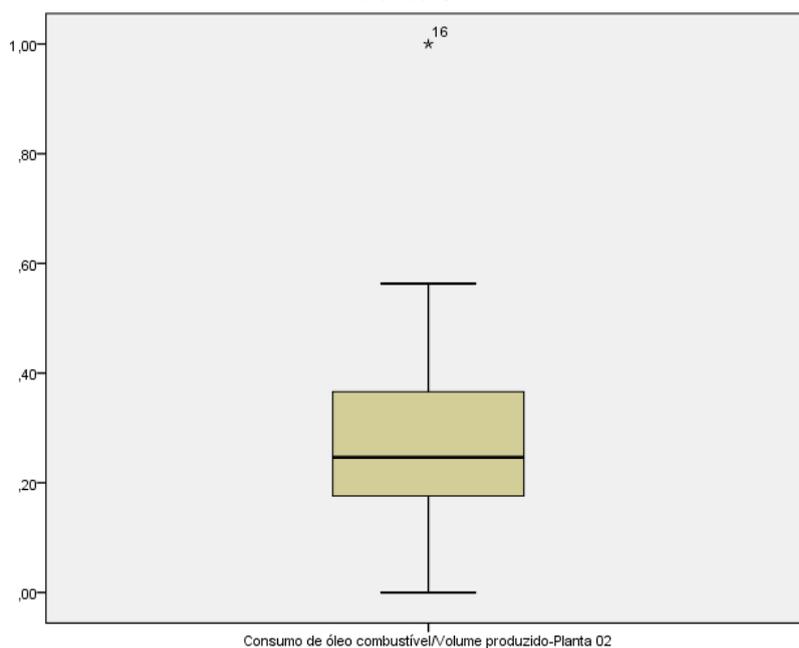
Fonte: a autora.

Figura 4.2: Outlier por gráfico linear da Empresa A: Indicador “Consumo de óleo combustível Fábrica 01”



Fonte: a autora.

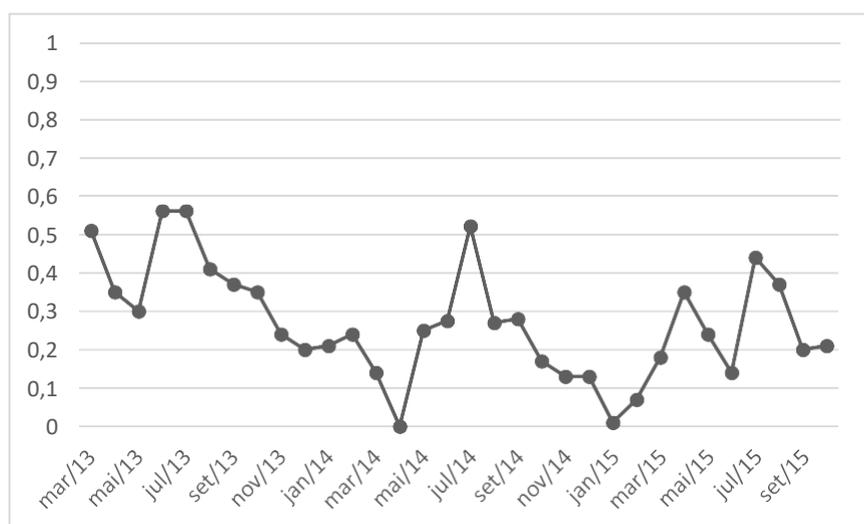
Figura 4.3: Outlier por gráfico boxplot da Empresa A: Indicador “Consumo de óleo combustível Fábrica 01”



Fonte: a autora.

Após a análise e a eliminação de *outliers* de todos os dados, a base de dados da Empresa A ficou com uma média de 4,05% de dados faltantes. Os valores faltantes foram então completados, durante o passo 5, com a utilização da função “Linear trend at point” do SPSS. A nova série para o “Consumo de óleo combustível Fábrica 01” é apresentada na Figura 4.4.

Figura 4.4: Nova série da Empresa A: Indicador “Consumo de óleo combustível Fábrica 01”



Fonte: a autora.

Durante o passo 6, último da fase de coleta e análise de dados, o teste de Kolmogorov-Smirnov foi aplicado a todos os indicadores, e apontou que apenas 37,89% dos indicadores apresentam distribuição normal. A lista final dos indicadores da Empresa A, analisados nas próximas atividades, pode ser encontrada no Anexo B.

4.1.2. Empresa B

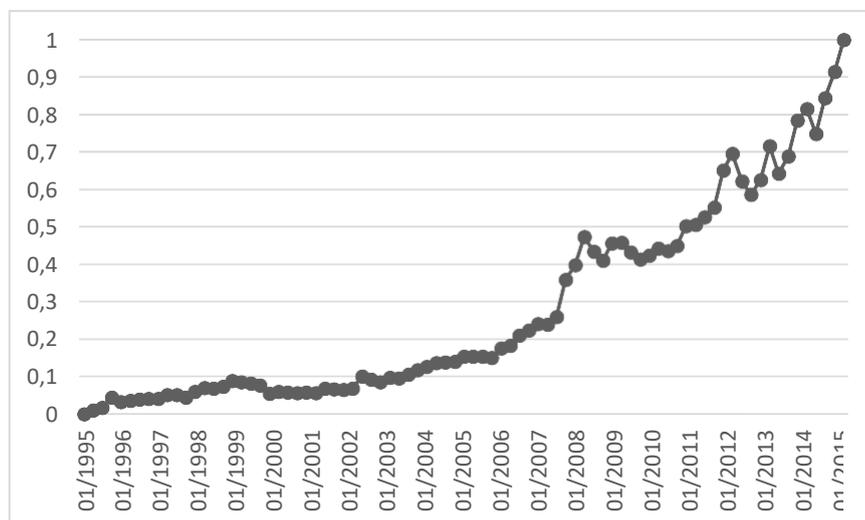
Durante o passo 1, a Empresa B teve dados de 279 indicadores de desempenho coletados, aos quais foram adicionados 30 indicadores externos à empresa, totalizando 309 séries de indicadores a serem analisadas. Após o passo 2, que consiste na inspeção visual dos dados, foram eliminados 119 indicadores. Foram eliminados, também, os dados referentes ao mês de outubro de 2015 em todas as séries temporais, uma vez que não estavam completos.

A análise das tendências dos gráficos, realizada no passo 3, mostrou que os dados muito antigos não representam a situação atual da empresa devido às diversas mudanças, internas e de mercado, que ocorreram ao longo do tempo. A Figura 4.5 exemplifica a mudança de tendência do gráfico linear dos “Ativos: Todos os ramos” da empresa. Optou-se, assim, por utilizar apenas os últimos 30 registros de cada indicador, referentes ao período de abril de 2008 até setembro de 2015.

Os gráficos *bloxplot* e as demais estatísticas descritivas foram analisados, no passo 4, juntamente com os gráficos lineares na busca por *outliers*. As Figuras 4.6 e 4.7 mostram, como exemplo, os gráficos linear e *boxplot* referentes à série temporal

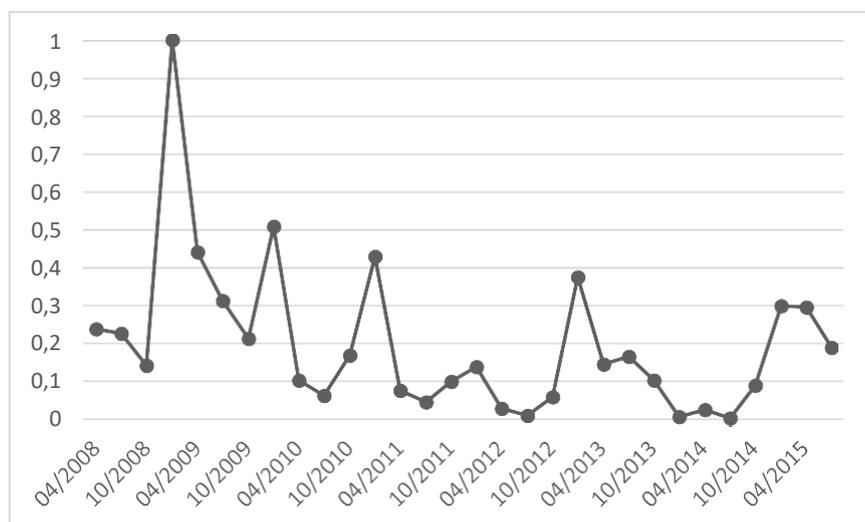
das “Despesas administrativas”. O dado número 4, correspondente ao mês de janeiro de 2009, foi eliminado.

Figura 4.5: Gráfico linear da Empresa B: Indicador “Ativos: Todos os ramos”



Fonte: a autora.

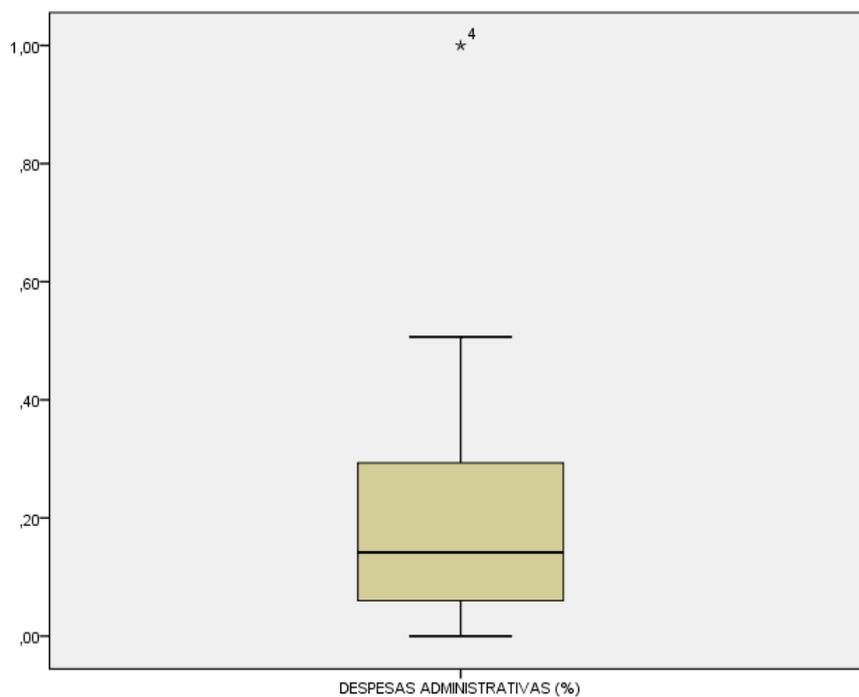
Figura 4.6: Outlier por gráfico linear Empresa B: Indicador “Despesas administrativas”



Fonte: a autora.

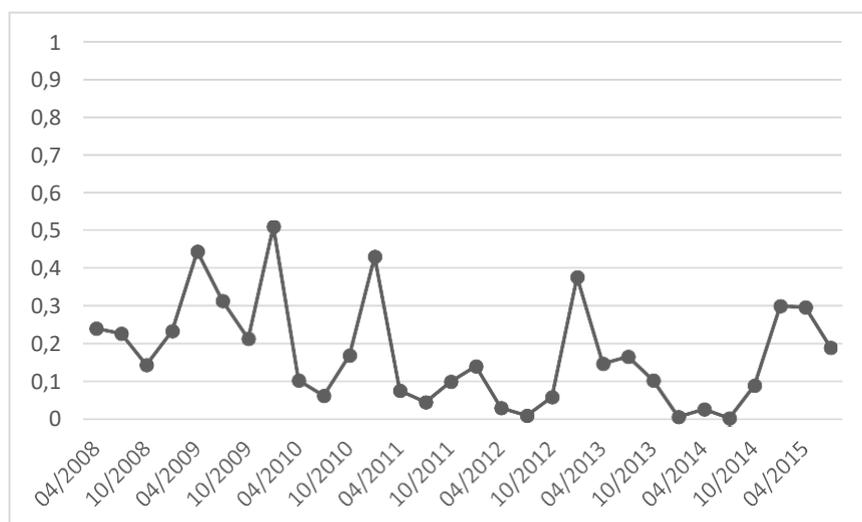
Após a análise e a eliminação de *outliers* de todos os dados da Empresa B, 13 indicadores foram eliminados. Assim, os indicadores ficaram com uma média de 1,75% de dados faltantes, os quais foram substituídos, durante o passo 5, com a utilização da função “Linear trend at point” do SPSS. A nova série para as “Despesas administrativas” pode ser visualizada na Figura 4.8.

Figura 4.7: Outlier por gráfico bloxplot Empresa B: Indicador “Despesas administrativas”



Fonte: a autora.

Figura 4.8: Nova série da Empresa B: Indicador “Despesas administrativas”



Fonte: a autora.

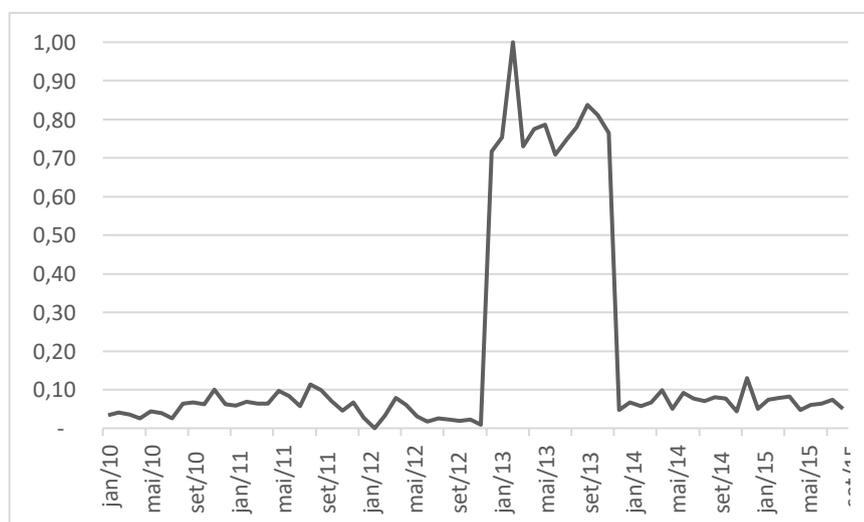
O teste de Kolmogorov-Smirnov, aplicado no passo 6, apontou que apenas 25,99% dos indicadores apresentam distribuição normal. A lista final dos indicadores da Empresa B, analisados nas próximas etapas, pode ser encontrada no Anexo C.

4.1.3. Empresa C

A Empresa C teve dados de 194 indicadores coletados durante o passo 1, aos quais foram adicionados 29 indicadores externos, totalizando 223 séries de indicadores a serem analisados. Após a inspeção visual dos dados, realizada no passo 2, foram eliminados 55 indicadores, os quais estavam com séries incompletas ou deixaram de ser utilizados pela empresa.

A análise dos gráficos lineares, no passo 3, não indicou a necessidade de excluir qualquer indicador, ou de reduzir a quantidade de dados a serem utilizados de cada série, porém, apontou inconsistências nas séries de dados de “Despesas industriais” e “Despesas comerciais”. A análise mais detalhada da situação mostrou que havia uma variação na forma de digitação dos dados de 2013, os quais não separavam com vírgula as casas decimais dos centavos. O problema foi corrigido ajustando os dados de 2013 para que tivessem o mesmo padrão dos dados dos outros anos. As Figuras 4.9 e 4.10 apresentam os dados das “Despesas comerciais” antes e após os ajustes, respectivamente.

Figura 4.9. Inconsistência por gráfico linear Empresa C: Indicador “Despesas comerciais”

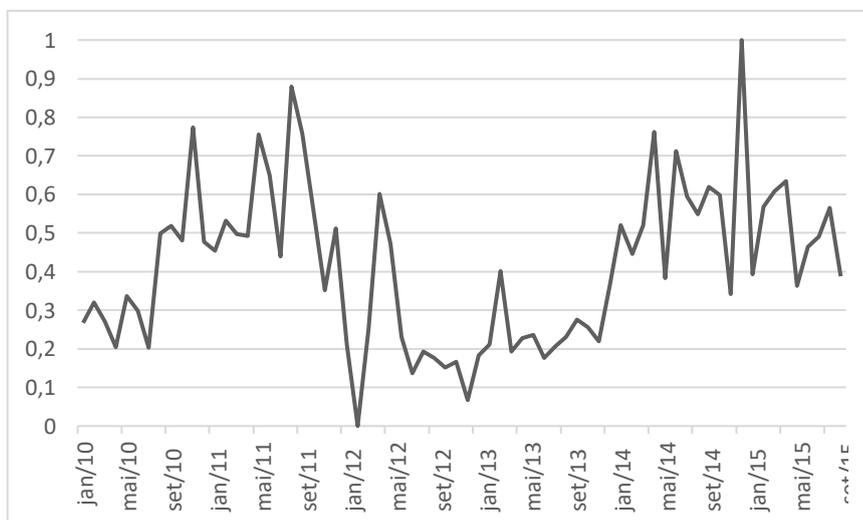


Fonte: a autora.

Durante o passo 4, os gráficos *boxplot* e as demais estatísticas descritivas foram analisados juntamente com os gráficos lineares na busca por *outliers*. Foi preciso tomar cuidado para não classificar como *outlier*, dados que são sinais claros de sazonalidade real, uma vez que as atividades da empresa são fortemente modificadas no período de Páscoa. As Figuras 4.11 e 4.12 mostram, respectivamente,

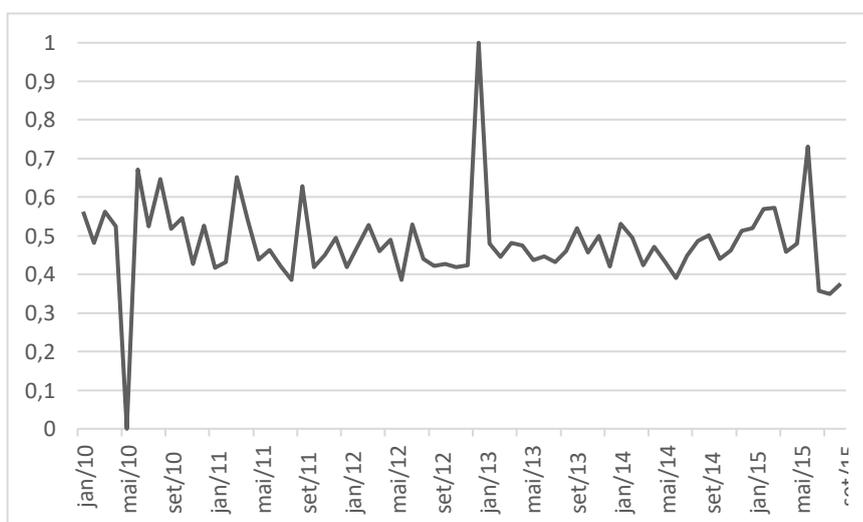
os gráficos linear e boxplot utilizados para analisar os *outliers* das “Despesas de exportação”. As entradas 5, 6, 37 e 67 foram retiradas.

Figura 4.10. Empresa C. Indicador “Despesas comerciais” ajustado



Fonte: a autora.

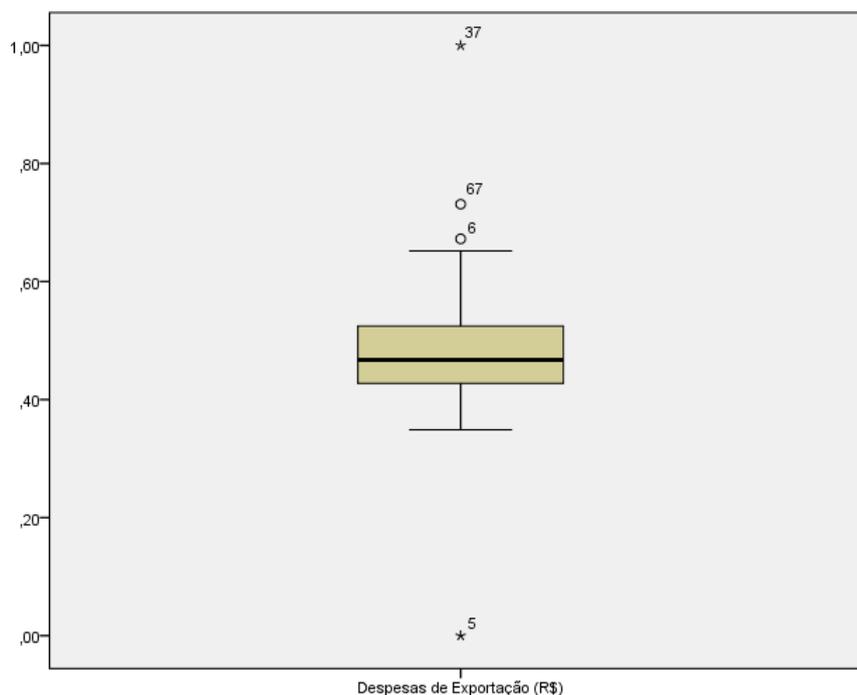
Figura 4.11. Outlier por gráfico linear Empresa C: Indicador “Despesas de exportação”



Fonte: a autora.

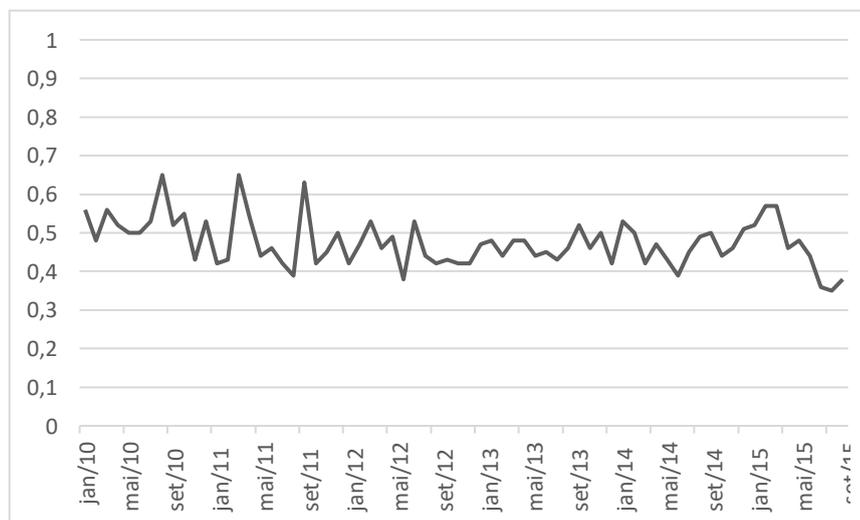
Após a análise e a eliminação de *outliers* de todos os dados da Empresa C, 3 indicadores foram eliminados. A base de indicadores da Empresa C ficou, em média, com 0,79% de dados faltantes, os quais foram substituídos, durante o passo 5, com a utilização da função “Linear trend at point” do SPSS. A nova série para as “Despesas de Exportação” pode ser visualizada na Figura 4.13.

Figura 4.12. Outlier por gráfico boxplot Empresa C: Indicador “Despesas de exportação”



Fonte: a autora.

Figura 4.13. Nova série da Empresa C: Indicador “Despesas de Exportação”



Fonte: a autora.

O passo 6 consistiu na aplicação do teste de Kolmogorov-Smirnov, o qual apontou que apenas 38,92% dos indicadores apresentam distribuição normal. A lista final dos indicadores da Empresa C, analisados nas próximas etapas, pode ser encontrada no Anexo D. A próxima seção aborda as correlações calculadas entre os indicadores (Fase 2), a partir dos dados já analisados.

4.2. Fase 2: Correlação entre indicadores de desempenho

Foram calculados, para cada empresa, os coeficientes de correlação existentes entre todos os seus indicadores, internos e externos. Para realizar este passo 7 da metodologia proposta, foi utilizado o teste Tau de Kendall, uma vez que, como visto na fase anterior, a maior parte das séries de dados não apresenta distribuição normal. Uma vez calculados todos os coeficientes de correlação, foram considerados apenas os coeficientes fortes para serem utilizados no passo 8, durante o qual foram criadas as hierarquias, a partir dos indicadores-chave. No passo 9 foram, então, analisadas estas hierarquias, e, com base nesta análise, foram propostas mudanças para as empresas. As seções seguintes apresentam, para cada empresa, as hierarquias geradas, assim como a análise das mesmas, realizadas em conjunto com as empresas.

4.2.1. Empresa A

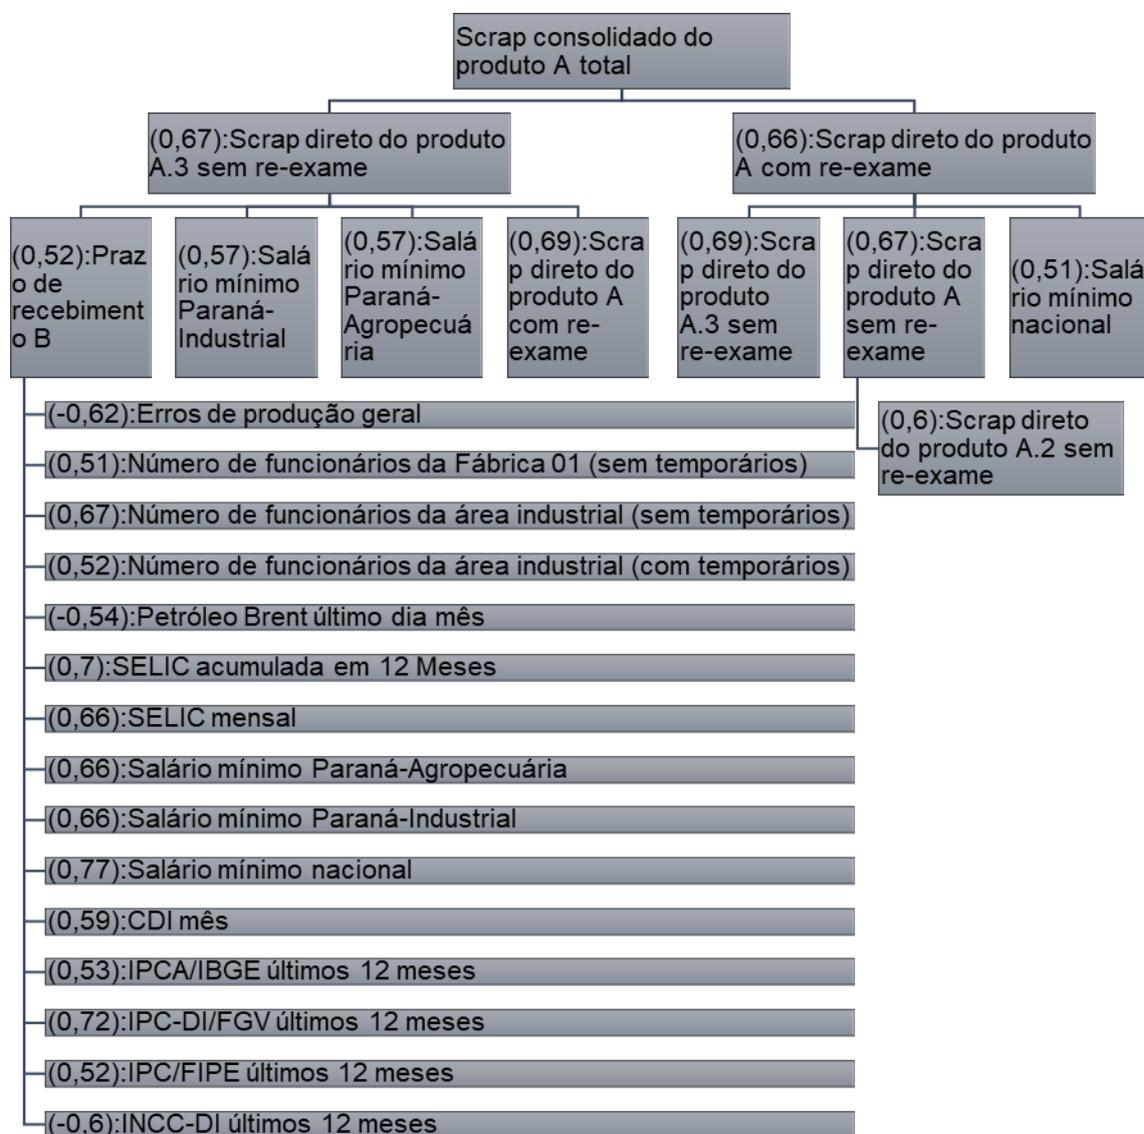
Os indicadores-chave escolhidos pela Empresa A foram “Scrap consolidado do produto A total”, ou seja, as sobras de material que acontecem durante a produção do produto A, e “Produtividade por funcionário da fábrica 2”. O primeiro tem sua hierarquia representada na Figura 4.14, enquanto o segundo tem sua hierarquia representada na Figura 4.15.

A “Produtividade por funcionário da fábrica 2” está inversamente correlacionada com a quantidade de funcionários já treinados, ou seja, sem incluir temporários, desta mesma fábrica. Isto é, quanto maior a quantidade de funcionários menor é a quantidade média produzida por funcionário. Segundo a empresa, um aumento no número de funcionários aumenta o volume de produção, porém não na mesma proporção que o aumento da mão de obra, e, isto se deve, dentre outros, ao fato de ser mais comum a realocação de funcionários para outras funções não vinculadas diretamente à produção, tais como manutenção predial, quando há mais gente disponível.

Por meio da Figura 4.14, pode-se observar que o “Scrap consolidado do produto A total” (1º. indicador-chave da Empresa A) está diretamente correlacionado com o “Scrap direto do Produto A.3 sem re-exame”. O produto A.3 representa um percentual pequeno de produção, porém, é o produto de maior volume e, por este

motivo, as perdas na sua produção têm um impacto muito grande no scrap consolidado, o qual é medido justamente em volume percentual perdido.

Figura 4.14. Empresa A. Hierarquia do indicador “Scrap consolidado do produto A total”



Fonte: a autora.

O “Scrap direto do Produto A.3 sem re-exame” apresenta, também, uma relação direta com o “prazo de recebimento B”. Os clientes que compram o produto A.3 são empresas muito grandes, que pedem um prazo maior para pagamento, porém compram em grandes quantidades. Desta forma, quando estas empresas fecham negócio, o prazo médio de recebimento aumenta, e também a quantidade de produtos a entregar em carteira. Este aumento da quantidade a ser produzida faz com que as máquinas não possam ser paradas, o que acarreta o aumento do Scrap de produção.

Este prazo de recebimento da empresa está correlacionado com diversos indicadores econômicos, pois quanto pior está a economia nacional, maior é o prazo de pagamento pedido pelos clientes. Outra correlação interessante relativa ao prazo de recebimento é a quantidade de “erros de produção geral”. Estes erros são medidos com base nas reclamações dos clientes, e esta correlação inversa pode indicar que clientes que recebem mais prazo para realizar o pagamento são menos propensos a fazer reclamações.

Além disso, observa-se que existe ainda uma correlação direta entre o “Scrap direto do Produto A.3 sem re-exame” e os salários mínimos industrial e agropecuário do Paraná. Estes dois setores são os maiores compradores do produto, e, por isto, a empresa interpreta esta correlação como sendo um aumento na produção (que aumenta o scrap) acontecendo quando estes setores estão bem (e a tendência é de aumentos maiores de salários).

Estas correlações apresentadas a partir dos indicadores-chave da Empresa A podem parecer estranhas em um primeiro momento, por representarem muitas correlações indiretas, associadas a uma terceira variável, como é o caso do volume de produção, o qual não é um indicador registrado pela empresa, porém tem impacto no Scrap e se correlaciona também com os prazos de recebimento. Apesar disto, uma vez realizada a análise, as correlações foram consideradas bastante coerentes pela empresa, e não apresentaram grandes surpresas em relação à visão que a própria empresa tem de seus processos e do mercado.

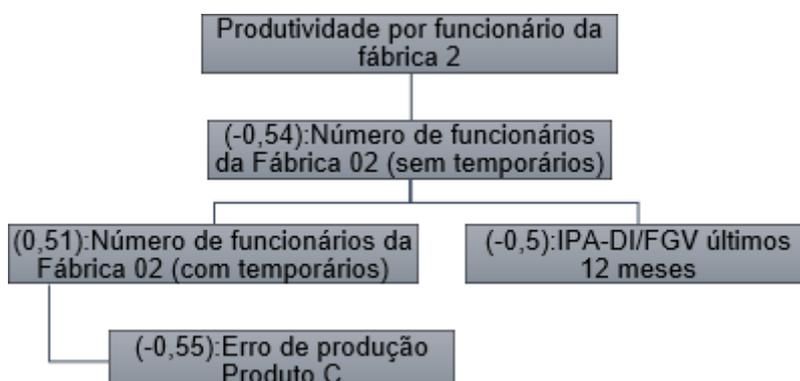
A Empresa A foi a que disponibilizou menos indicadores para este estudo, o que dificultou a obtenção de correlações diretas. Seria de se esperar, por exemplo, que o Scrap de produção fosse impactado pela qualidade da matéria prima e pelo nível de manutenção dos equipamentos, porém a empresa não possuía, até então, registros históricos destes indicadores. Estas informações eram medidas, discutidas em reunião e então descartadas. A empresa passará, a partir de agora, a registrar algumas destas informações, focando não apenas nos indicadores acompanhados à nível gerencial, mas também em alguns indicadores diretos da fábrica que possam estar impactando nos indicadores principais.

O maior ganho imediato gerencial, para a Empresa A, da análise das hierarquias, diz respeito à percepção do tamanho do impacto que o meio externo tem nos resultados da empresa. A atual crise econômica nacional, apesar de gerar uma redução nas compras em todo o país, favoreceu a Empresa A em função da alta do

Dólar ter diminuído muito a concorrência de produtos estrangeiros. Apesar das matérias primas da empresa também serem compradas em dólar, elas são, em sua grande maioria, derivadas de petróleo, o qual teve uma redução de custo nos últimos dois anos, compensando a desvalorização do Real. Se o valor do barril de petróleo voltar a subir antes que a crise econômica brasileira melhore, porém, a Empresa A ficará em uma situação bastante delicada caso não tenha efetuado mudanças para diminuir este impacto externo identificado.

Por meio da Figura 4.15, pode-se observar que a “Produtividade por funcionário da fábrica 2” (2º. indicador-chave da Empresa A), se correlaciona com o número de funcionários sem temporários. Este indicador, por sua vez, se correlaciona diretamente com o número de funcionários com temporários, o qual, exibe uma correlação inversa com os erros de produção do Produto C. Isto significa que uma diminuição da quantidade de funcionários, apesar de aumentar a produtividade média, diminui a qualidade da produção, uma vez que os equipamentos são menos assistidos.

Figura 4.15. Empresa A. Hierarquia do indicador “Produtividade por funcionário da fábrica 2”



Fonte: a autora.

A correlação inversa entre a quantidade de funcionários e o “IPA-DI/FGV últimos 12 meses” pode ser explicada, segundo a empresa, pelo fato de os períodos de instabilidade econômica, que geralmente trazem aumento da inflação, serem os períodos nos quais a empresa tende a reduzir a quantidade de empregados, evitando novas contratações e, em último caso, efetuando demissões.

4.2.2. Empresa B

As hierarquias da Empresa B apresentaram um total de mais de 10.000 linhas na última camada, tornando a análise visual inviável. Como já comentado, os indicadores-chave escolhidos pela empresa foram: o “Endividamento total” e a “Rentabilidade dos ativos” e, deste modo, a Figura 4.16 apresenta o segundo nível da hierarquia realizada a partir do “Endividamento total”, enquanto a Figura 4.17 apresenta o segundo nível para a “Rentabilidade dos ativos”.

Figura 4.16. Empresa B. Hierarquia do indicador “Endividamento total”



Fonte: a autora.

A análise inicial das hierarquias apontou que alguns dos indicadores utilizados pela empresa são muito parecidos entre si. Entre os indicadores correlacionados ao “Endividamento total”, por exemplo, encontra-se a “Liquidez corrente (IAGC-I)”, “Liquidez seca” e “Liquidez corrente”, todas relacionadas ao indicador-chave com um coeficiente de -0,51. A “Rentabilidade dos ativos” (Figura 4.17), por sua vez, está

correlacionada, com coeficientes muito próximos, aos valores de faturamento agropecuário, de crédito, de consumo, educacional e de saúde.

Figura 4.17. Empresa B. Hierarquia do indicador “Rentabilidade dos ativos”



Fonte: a autora.

Durante a análise dos resultados realizada juntamente à empresa, optou-se, então, por reduzir a quantidade de indicadores a serem acompanhados. A partir das correlações de segundo e terceiro níveis, foram determinados “blocos” de indicadores muito parecidos, e, entre os indicadores de cada bloco, a empresa escolheu aqueles que são mais relevantes. Como exemplo, percebeu-se que a “Liquidez seca” é derivada da “liquidez corrente”, e, portanto, optou-se por manter apenas a segunda.

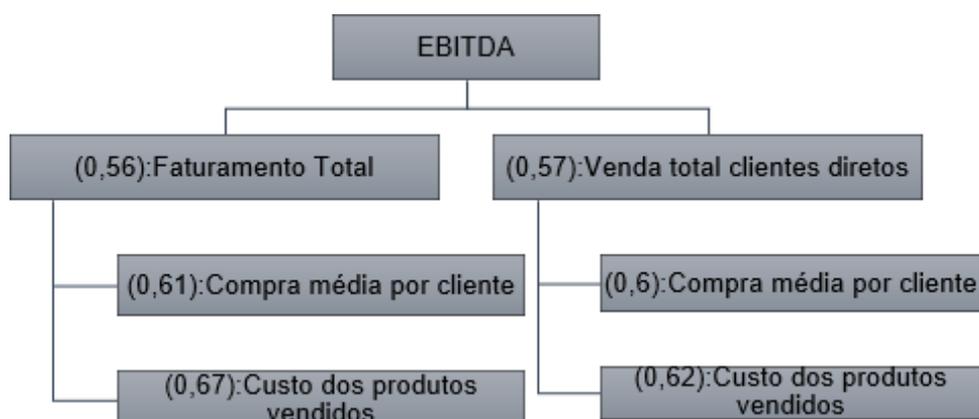
Após realizar todas as análises das correlações, a lista de indicadores foi reduzida de 177 para 59 indicadores, considerados os mais relevantes. A nova lista de indicadores para análise pode ser encontrada no Anexo E.

É importante notar que os indicadores da empresa B eram, quase na totalidade, referentes a apenas duas categorias: funcionários e corporação. As empresas A e C, apesar de terem permanecido com valores elevados de indicadores, apresentam dados de diversas categorias, de forma que não há redundância entre os indicadores como na empresa B, não justificando a redução da lista baseada neste motivo.

4.2.3. Empresa C

As hierarquias da Empresa C foram construídas para seus dois indicadores-chave: “EBITDA” e “Custo médio dos produtos vendidos”. A primeira encontra-se na Figura 4.18, enquanto a segunda é apresentada na Figura 4.19.

Figura 4.18. Empresa C. Hierarquia do indicador “EBITDA”



Fonte: a autora.

As duas hierarquias ficaram muito parecidas, o que demonstra a proximidade entre os dois indicadores-chave escolhidos. A maior preocupação da Empresa C,

durante o atual período de crise econômica nacional, é não ter prejuízo. Por este motivo, a empresa escolheu o “EBITDA” como principal indicador. O foco da empresa para enfrentamento da crise tem sido a redução dos custos e, para tanto, reduziu inclusive as operações da área industrial de três para dois turnos. Em função deste foco atual, o indicador “Custo médio dos produtos vendidos” foi escolhido como segundo indicador-chave.

A análise da hierarquia construída a partir do “EBITDA” (Figura 4.18), porém, não apresenta correlação direta entre o lucro e o “Custo médio dos produtos vendidos”. O “EBITDA” está diretamente correlacionado com o “Faturamento total” da empresa, ou seja, quanto maior é o faturamento, maior é o lucro. O “EBITDA” se correlaciona diretamente, também, com a “Venda total para clientes diretos”, ou seja, com as vendas realizadas pela empresa diretamente aos seus grandes clientes, sem intermediações de representantes. Como os representantes comerciais recebem um percentual de suas vendas, já era de se esperar que o lucro seja maior, quanto mais vendas sem intermediações a empresa fizer, como constatado.

Figura 4.19. Empresa C. Hierarquia “Custo médio dos produtos vendidos”



Fonte: a autora.

O “Faturamento total” e a “Venda total para clientes diretos”, os quais, como já observado, influenciam o lucro, estão diretamente correlacionados com o “Custo médio dos produtos vendidos”. A partir disto, pode ser constatado que o faturamento é maior nos meses em que são produzidos e vendidos os produtos mais caros.

A empresa focava sua estratégia de marketing nos produtos de “segunda linha”, os quais são mais baratos para o consumidor, acreditando que a queda do poder de compra dos brasileiros faria com que migrassem para esta categoria. Têm-se percebido, porém, que o público da empresa é bastante sensível à variação da qualidade, e que os produtos de “primeira linha” são mais conhecidos e mais bem

aceitos. A análise da hierarquia construída a partir do “Custo médio dos produtos vendidos” (Figura 4.19) corrobora com esta percepção, uma vez que apresenta uma correlação direta entre este custo e a “Compra média por cliente”. Isto significa que os clientes que compram os produtos mais caros são os que compram mais. Aliando a percepção de mercado com a análise das correlações encontradas, a empresa passa, agora, a aumentar o percentual de seus recursos de marketing alocado aos produtos de “primeira linha”.

O “Faturamento total” e a “Venda total para clientes diretos” se correlacionam diretamente, também, com a “Compra média por cliente”, ou seja, quanto mais cada cliente compra, maior é o faturamento. É interessante observar que a quantidade total de clientes, indicador que também foi considerado na análise, não apresenta uma correlação forte com o faturamento. Desta forma, a empresa opta, neste momento de crise, por colocar mais esforços em melhorar as parcerias com os clientes maiores, buscando aumentar a quantidade comprada pelos mesmos, e menos esforços em expandir seu mercado, buscando novos clientes.

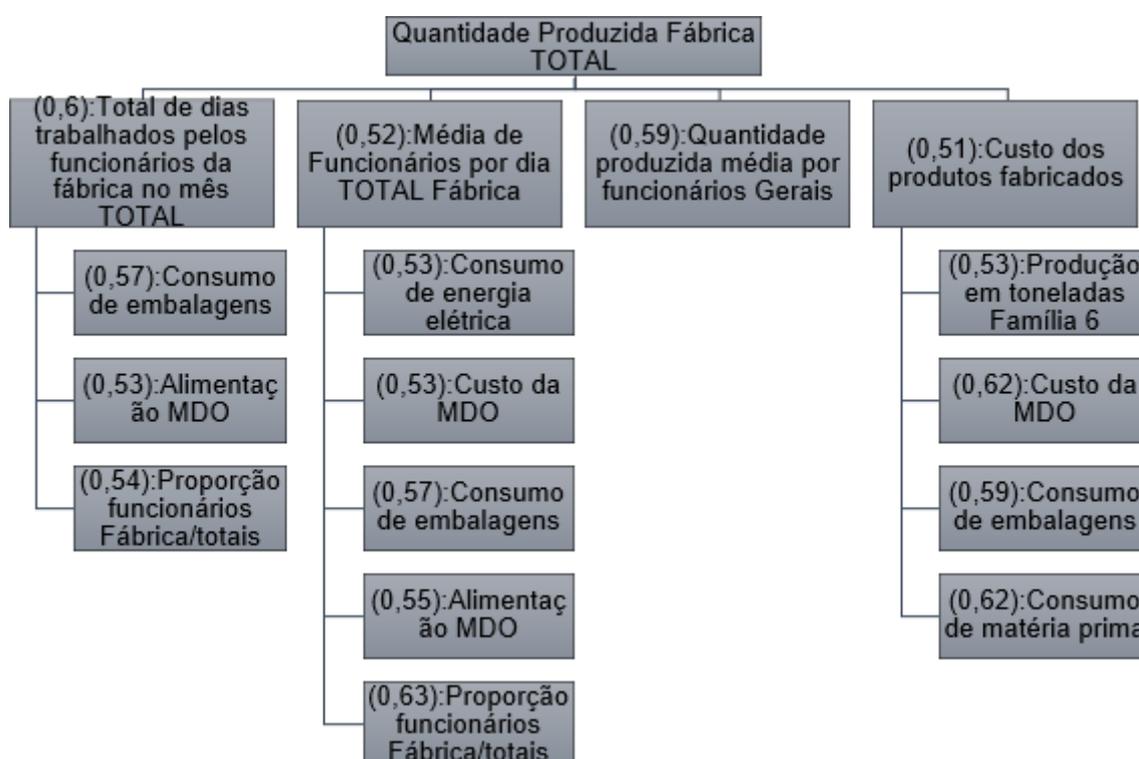
Sabendo que o lucro tem uma correlação mais forte com o faturamento que com o custo dos produtos, optou-se por realizar uma terceira hierarquia, relativa à “Quantidade total produzida na fábrica”. Este é um indicador importante, pois é comum que a fábrica não consiga produzir tudo o que foi planejado, fazendo com que a empresa, em algumas situações, deixe de faturar por falta de produtos em estoque. Esta nova hierarquia encontra-se na Figura 4.20.

A “Quantidade total produzida na fábrica” está diretamente correlacionada com a “Quantidade de dias trabalhados no mês”, isto é, nos meses com menos dias úteis se produz menos. O volume de produção também se correlaciona diretamente com a “Quantidade de funcionários trabalhando na fábrica” e com a produtividade destes funcionários, ou seja, a “Quantidade média produzida por funcionário”.

O “Custo médio total dos produtos fabricados” também se correlaciona diretamente com a quantidade fabricada, ou seja, o volume de produção é maior quando são feitos os produtos mais caros. Isto se dá em função de os produtos de “segunda linha” serem fabricados em lotes menores e em uma variedade maior. Desta forma, quanto mais produtos desta linha são produzidos, maiores são os tempos de ajuste e limpeza das máquinas, o que reduz a produtividade. Esta correlação levanta, na Empresa A, a importância de implementar indicadores relacionados às máquinas.

Com a redução dos turnos de trabalho, tornou-se muito importante manter os equipamentos trabalhando o maior tempo possível dos dois turnos disponíveis, para conseguir atender à demanda. A partir disto, a empresa iniciará um processo para implementação do OEE (Eficiência geral de equipamento), indicador que considera a disponibilidade das máquinas (apontando problemas de manutenção), a eficiência das mesmas (apontando problemas de velocidade) e a qualidade dos produtos feitos em cada máquina.

Figura 4.20. Empresa C. Hierarquia indicador “quantidade produzida fábrica”



Fonte: a autora.

Em nível de chão de fábrica será controlado também o percentual de material perdido em processo e o percentual da produção prevista que foi realizada. Em nível administrativo será adicionado um indicador para medir o percentual das vendas previstas que foi efetivado.

Duas outras ações são sugeridas a partir da análise dos dados e das hierarquias. A primeira diz respeito à alocação de um funcionário de vendas da empresa para a tarefa de contactar todos os clientes que costumavam comprar quantidades grandes e pararam nos últimos três anos. O objetivo do contato é, além de tentar reestabelecer as parcerias, entender quais são os principais fatores que

levam as empresas a pararem de comprar, tais como preços, prazos de entrega e concorrência. A partir deste levantamento a empresa poderá estabelecer planos de ação para retenção dos clientes e aumento das vendas.

As pesquisas de opinião da empresa e os investimentos em divulgação são focados nos clientes diretos, que compram os produtos da empresa. A segunda sugestão consiste no aumento da relação da empresa com os consumidores finais, que compram dos clientes diretos. A contratação de um funcionário específico para cuidar das redes sociais da empresa objetiva divulgar os produtos para estes consumidores finais. Além disso, através do contato com eles, a empresa terá uma percepção maior da visão dos mesmos sobre os seus produtos, do que os leva a escolher estes produtos ou os da concorrência.

4.3. Fase 3: Previsão futura dos indicadores-chave

Esta seção apresenta, para cada empresa, a preparação dos dados (passo 10), incluindo a padronização dos indicadores-chave e a relação dos diferentes padrões de treinamento, com as variações dos dados de entrada. São apresentados, também, os resultados obtidos com as redes MLP e RBF, descritas na metodologia, para a previsão dos indicadores-chave (passo 11), além da definição das redes a serem implementadas (passo12).

4.3.1. Preparação dos dados

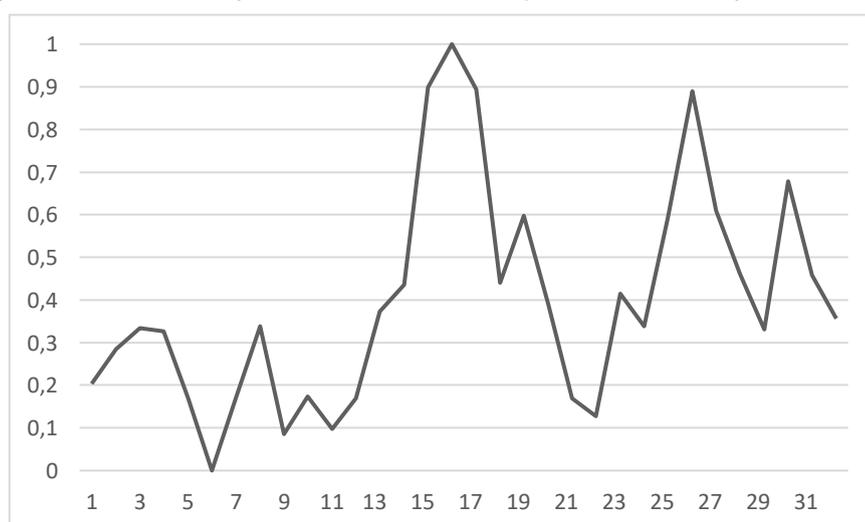
Conforme já comentado, os indicadores-chave escolhidos pela Empresa A são “Produtividade por funcionário da fábrica 2” (Figura 4.21) e “Scrap consolidado do produto A total” (Figura 4.22). A “Produtividade por funcionário da fábrica 2” está fortemente correlacionada apenas com o “Número de funcionários da Fábrica 2” ($p = -0,542$). O “Scrap consolidado do produto A total”, por sua vez, está fortemente correlacionado com o “Scrap direto do produto A.3 sem re-exame” ($p = 0,67$) e com o “Scrap direto do produto A com re-exame” ($p = 0,66$). As séries temporais desses cinco indicadores apresentam 32 dados cada (março/2013 até outubro/2015), já “limpos” e padronizados conforme a equação 2.10.

Figura 4.21 Dados Empresa A: Indicador “Produtividade por funcionário da fábrica 2”



Fonte: a autora.

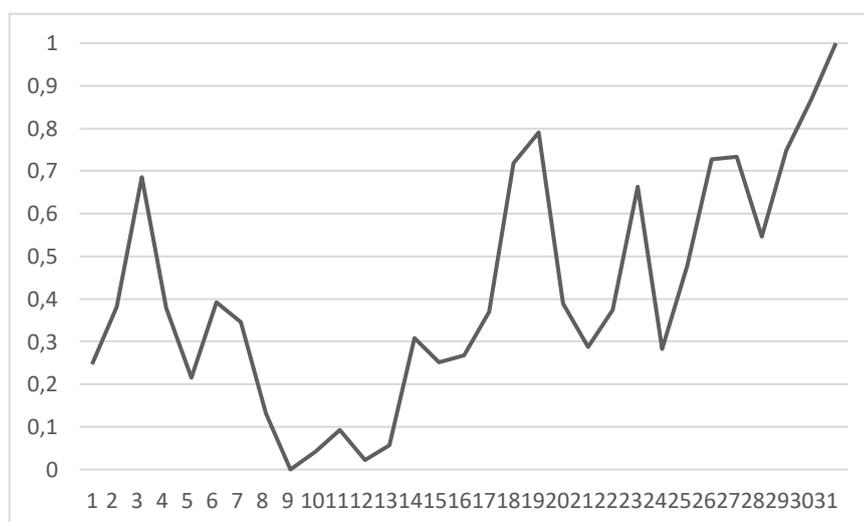
Figura 4.22 Dados Empresa A: Indicador “Scrap consolidado do produto A total”



Fonte: a autora.

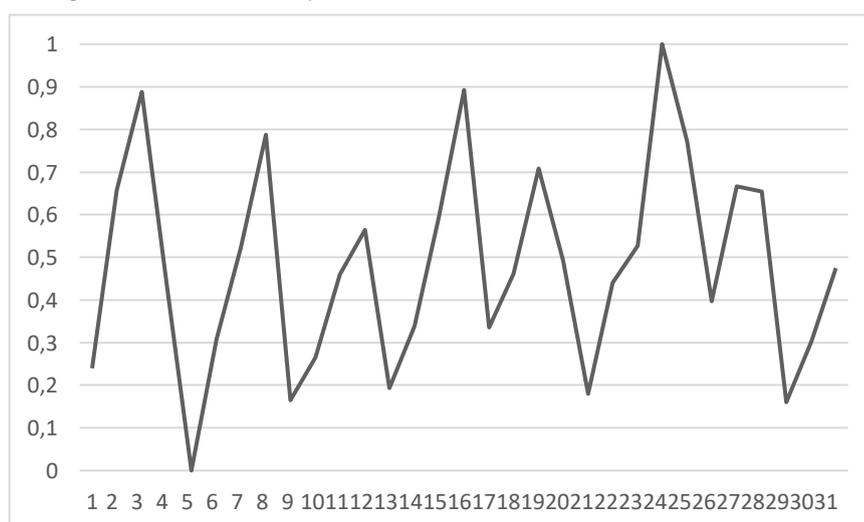
Os indicadores-chave escolhidos pela Empresa B são o “Endividamento total” (Figura 4.23) e a “Rentabilidade dos ativos” (Figura 4.24). Os indicadores mais fortemente correlacionados ao “Endividamento total” são a “Garantia ao Capital de Terceiros” ($p=-0,987$) e a “Independência financeira” ($p=-0,961$), enquanto os mais fortemente correlacionados à “Rentabilidade dos ativos” são “Rentabilidade do Ativo (IAGC-I)” ($p=+0,897$) e “Rentabilidade do Capital Integralizado” ($p=+0,8494$). Assim como realizado para a Empresa A, foram utilizadas as séries temporais “limpas” e padronizadas desses seis indicadores, neste caso contendo 31 dados cada (janeiro/2008 até julho/2015).

Figura 4.23 Dados Empresa B: Indicador “Endividamento total”



Fonte: a autora.

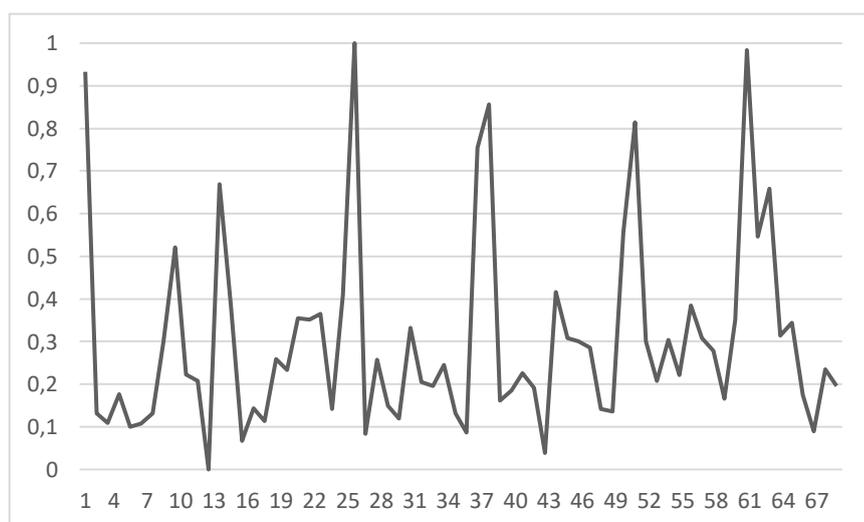
Figura 4.24 Dados empresa B: Indicador “Rentabilidade dos Ativos”



Fonte: a autora.

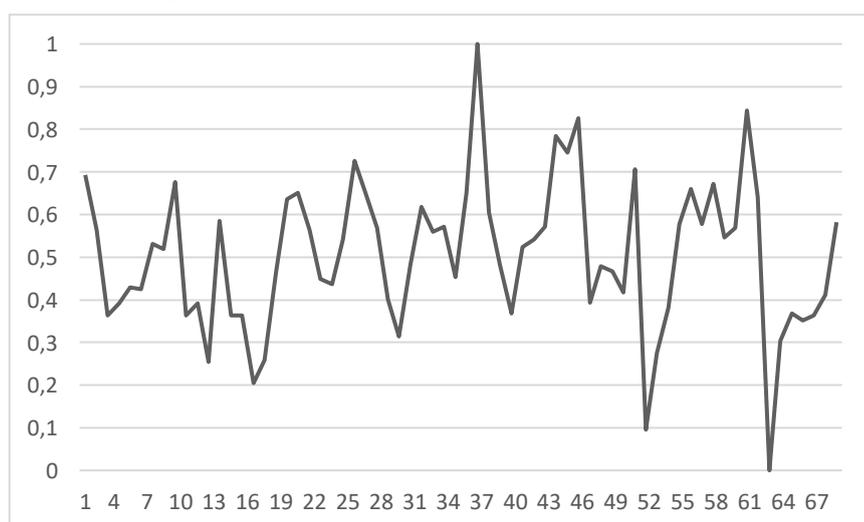
Os indicadores-chave escolhidos pela Empresa C são “EBITDA” (Figura 4.26) e “Custo médio dos produtos vendidos” (Figura 4.25). Os dois indicadores mais fortemente correlacionados ao primeiro são “Faturamento Total” ($p=0,56$) e “Venda total para clientes diretos” ($p=0,57$), e ao segundo também são “Faturamento Total” ($p=0,67$) e “Venda total para clientes diretos” ($p=0,62$). Esses quatro indicadores foram utilizados como dados de entrada das RNAs e, por este motivo, tiveram suas séries de dados padronizadas para o intervalo $[0, 1]$. As séries temporais dos indicadores em questão contêm 68 dados cada (março/2010 até outubro/2015), “limpos” e padronizados.

Figura 4.25 Dados empresa C: Indicador “Custo médio dos produtos vendidos”



Fonte: a autora.

Figura 4.26 Dados empresa C: Indicador “EBITDA”



Fonte: a autora.

A análise das séries temporais dos indicadores-chave das três empresas mostra a presença, em alguns casos bastante marcante, de sazonalidade. Os dados da Empresa A e da Empresa C são mensais, a partir disso foi criada uma série de dados para representar a época do ano referente à previsão, de forma que os dados coletados nos meses de janeiro, fevereiro, março, abril, maio, junho, julho, agosto, setembro, outubro, novembro e dezembro foram codificados, respectivamente, como “0”, “0,09”, “0,18”, “0,27”, “0,36”, “0,45”, “0,55”, “0,64”, “0,73”, “0,82”, “0,91” e “1”. Os dados da Empresa B são trimestrais, a partir disso foi criada uma série de dados para representar a época do ano referente à previsão, de forma que os dados coletados

nos meses de janeiro, de qualquer ano, receberam a codificação 0, os dados coletados nos meses de abril receberam a codificação 0,33, os coletados nos meses de julho foram codificados como 0,66 e os coletados em outubro foram classificados como 1.

Além dos dados internos da empresa e os referentes à época do ano, foram incluídas as informações de prospecção (baseadas na opinião de especialistas). Para todas as empresas foram utilizados os seguintes indicadores de prospecção:

- Valor esperado do câmbio do dólar para o próximo mês, obtido do relatório FOCUS do Banco Central do Brasil.
- IPCA esperado para os próximos 12 meses, obtido do relatório FOCUS do Banco Central do Brasil.
- INEC - Índice nacional de expectativa do consumidor Brasil.

Além disso, para as Empresas A foi incluído o ICEI (Índice de Confiança do Empresário Industrial - Indústria de transformação), para a Empresa B o prognóstico de safra do IBGE em volume produzido para o ano seguinte, e para a Empresa C o ICEI (Índice de Confiança do Empresário Industrial - Indústria Alimentícia).

Para realizar a previsão dos indicadores-chave, foram testados como dados de entrada combinações dos indicadores internos e externos um a um, dois a dois e três a três, sempre acompanhados dos dados históricos do indicador que se pretende prever. Foram realizados também testes utilizando apenas os dados históricos do próprio indicador, sem adição de outras informações, como entrada das RNA.

Para as empresas A e C, que apresentam dados mensais, foram testados três horizontes de previsão: o mês seguinte, 3 meses à frente e 6 meses à frente. Já para a empresa B, com dados trimestrais, foram realizados testes para prever o trimestre seguinte, 6 meses à frente (dois trimestres) e 1 ano à frente (4 trimestres).

As escolhas dos dados de entrada impactam muito na qualidade da previsão realizada. De uma forma geral, quanto maior a quantidade de dados para treinamento, melhor a qualidade do resultado (Guo *et al.*, 2012). Como não foi possível encontrar, para a realização deste trabalho, empresas que tenham mantido os mesmos indicadores sem grandes mudanças por muitos anos, a quantidade de dados disponíveis pelas três empresas é pequena. Adicionar os dados dos indicadores correlacionados e das prospecções de mercado juntamente com o indicador principal aumenta a quantidade de dados de entrada, porém aumenta também o ruído da

informação. Realizar estes testes ajudará a definir se estas “adições” melhoram ou pioram a qualidade das previsões realizadas.

4.3.2. Testes com as RNA

Para realizar a previsão dos indicadores-chave escolhidos pelas empresas, foram testadas diversas combinações de configurações de RNA, as redes MLP foram testadas com todas as configurações seguintes:

- 6 indicadores chave: 2 por empresa;
- 3 janelas de tempo (1, 3 e 6 meses);
- 29 configurações de neurônios na camada escondida: de 2 a 30;
- 4 configurações de funções de ativação: Sigmoide e Tangente Hiperbólica, podendo ser a mesma nas camadas escondida e de saída ou cada uma em uma das camadas;
- 2 opções de taxas de aprendizagem: 0,5 ou 0,9;
- 3 opções de formas de validar o aprendizado, por meio das seguintes divisões dos dados: *Leave one Out* (utiliza apenas um padrão no conjunto de validação), *holdout* de 10% (utiliza 10% dos dados para validação) e *holdout* de 30%.
- Constante de *momentum*: 0;

Considerando que todas as combinações destas diferentes configurações foram testadas, no total foram testadas $6 \times 3 \times 29 \times 4 \times 2 \times 3$ configurações, ou seja, 12.528 configurações diferentes de redes MLP foram testadas, cada uma das quais por 30 vezes. Desta forma, ficou-se com um total de $12528 \times 30 = 375.840$ testes com as MLP.

Já as redes RBF foram testadas para os mesmos 6 indicadores, variando o *spread* de 1 a 10, com as mesmas 3 janelas de tempo dos testes com as MLP, variando o número de centros de 1 ao número de dados de entrada (os quais variaram de 28 a 67 dependendo do indicador e da janela de previsão), totalizando 7440 testes realizados. Os centros foram escolhidos entre os próprios dados de entrada.

O tempo computacional máximo de uma RNA testada, considerando todos os testes realizados, foi de 13,7 segundos. Como as empresas, na prática, irão realizar previsões com baixa frequência, normalmente apenas uma vez por mês, este tempo não é importante, ou seja, o tempo computacional não é um critério de avaliação para determinar a melhor rede, mas sim a qualidade das previsões realizadas.

A Tabela 4.3 apresenta as três melhores configurações de rede neural encontradas para a previsão de cada indicador-chave, para cada janela de tempo estudada, utilizando como critério o menor erro % absoluto médio. As empresas que fazem parte deste estudo estabeleceram que, para que a previsão possa ser utilizada nas decisões gerenciais, esta deverá ter um erro de até 5%. Assim, a escolha da rede a ser implementada irá considerar que o erro máximo absoluto percentual deve ser inferior a 5%. Para todos os indicadores analisados foram encontradas redes com o pior erro, entre os 30 testes realizados, abaixo de 5%, com a única exceção sendo o indicador “Endividamento total”, da empresa B, para a janela de tempo de 4 trimestres, ou seja, a previsão do endividamento um ano no futuro.

Uma questão importante a ser analisada é o impacto que a escolha dos dados de entrada tem na qualidade das previsões. Analisando as três melhores redes para prever cada indicador em cada período, pode-se perceber que 22,2% das melhores redes encontradas utilizaram a informação da época do ano como dado de entrada, 48,1% utilizaram como entrada os dados de pelo menos um dos indicadores fortemente correlacionados e 63% utilizaram algum dado de prospecção de mercado para atingir seus resultados. A Tabela 4.4 estratifica estes números por indicador. Os dados de prospecção de mercado foram especialmente importantes para prever indicadores financeiros como “Endividamento” e “Rentabilidade dos ativos”.

Tabela 4.3 Melhores RNAs encontradas para a previsão dos indicadores-chave

Empresa	Indicador	Janela tempo	Erro % abs mín	Erro % abs méd	Erro % abs máx	Desvio Padrão	Dados de Entrada	Rede
A	Produtividade	1	0,04%	1,61%	4,72%	1,48%	Produtividade por funcionário da fábrica 2, Projeção do IPCA	MLP, F. ativação SIG SIG, 18 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
A	Produtividade	1	0,05%	1,66%	3,94%	1,17%	Produtividade por funcionário da fábrica 2, Número de funcionários da Fábrica 2 (sem temporários), ICEI	MLP, F. ativação SIG SIG, 6 neurônios escondidos, apresentação dos dados por <i>Houldout 10%</i>
A	Produtividade	1	0,09%	1,73%	4,84%	1,41%	Produtividade por funcionário da fábrica 2, Número de funcionários da Fábrica 2 (sem temporários), INEC	MLP, F. ativação SIG TANH, 6 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
A	Produtividade	3	0,01%	1,83%	4,60%	1,42%	Produtividade por funcionário da fábrica 2, Número de funcionários da Fábrica 2 (sem temporários)	MLP, F. ativação SIG SIG, 18 neurônios escondidos, apresentação dos dados por <i>Leave one Out colocar os demais em itálico tb...</i>
A	Produtividade	3	0,16%	1,86%	4,40%	1,18%	Produtividade por funcionário da fábrica 2	MLP, F. ativação TANH SIG, 7 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
A	Produtividade	3	0,05%	2,12%	4,19%	1,19%	Produtividade por funcionário da fábrica 2, Projeção do IPCA	MLP, F. ativação SIG SIG, 12 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
A	Produtividade	6	0,02%	1,36%	3,29%	0,87%	Produtividade por funcionário da fábrica 2, Mês correspondente, Projeção do câmbio	MLP, F. ativação SIG SIG, 20 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
A	Produtividade	6	0,02%	1,54%	4,36%	1,31%	Produtividade por funcionário da fábrica 2, Número de funcionários da Fábrica 2 (sem temporários), Projeção do câmbio	MLP, F. ativação SIG SIG, 18 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
A	Produtividade	6	0,05%	1,56%	3,18%	1,03%	Produtividade por funcionário da fábrica 2, Mês correspondente, Projeção do câmbio	MLP, F. ativação SIG TANH, 2 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>

Empresa	Indicador	Janela tempo	Erro % abs mín	Erro % abs méd	Erro % abs máx	Desvio Padrão	Dados de Entrada	Rede
A	Scrap	1	0,02%	0,64%	1,48%	0,40%	Scrap consolidado do produto A total, Scrap direto do produto A com re-exame, Mês correspondente	MLP, F. ativação SIG TANH, 9 neurônios escondidos, apresentação dos dados por <i>Houldout</i> 30%
A	Scrap	1	0,03%	0,64%	1,76%	0,54%	Scrap consolidado do produto A total, Scrap direto do produto A com re-exame, Mês correspondente	MLP, F. ativação SIG SIG, 22 neurônios escondidos, apresentação dos dados por <i>Houldout</i> 30%
A	Scrap	1	0,07%	0,66%	1,59%	0,40%	Scrap consolidado do produto A total, Scrap direto do produto A com re-exame, Mês correspondente	MLP, F. ativação SIG TANH, 13 neurônios escondidos, apresentação dos dados por <i>Houldout</i> 30%
A	Scrap	3	0,01%	0,52%	1,53%	0,41%	Scrap consolidado do produto A total, Scrap direto do produto A.3 sem re-exame, Scrap direto do produto A com re-exame	MLP, F. ativação SIG SIG, 8 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
A	Scrap	3	0,01%	0,67%	1,77%	0,57%	Scrap consolidado do produto A total, Mês correspondente	MLP, F. ativação SIG SIG, 2 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
A	Scrap	3	0,02%	0,70%	1,74%	0,49%	Scrap consolidado do produto A total, Mês correspondente, Projeção do IPCA	MLP, F. ativação SIG SIG, 2 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
A	Scrap	6	0,06%	0,74%	1,35%	0,41%	Scrap consolidado do produto A total, Scrap direto do produto A.3 sem re-exame	MLP, F. ativação SIG SIG, 2 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
A	Scrap	6	0,01%	0,79%	1,92%	0,60%	Scrap consolidado do produto A total	MLP, F. ativação SIG SIG, 2 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
A	Scrap	6	0,00%	0,86%	1,90%	0,57%	Scrap consolidado do produto A total, Scrap direto do produto A com re-exame, INEC	MLP, F. ativação TANH SIG, 2 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
B	Endividamento	1	0,00%	0,93%	2,46%	0,69%	Endividamento total, Garantia ao Capital de Terceiros, INEC	MLP, F. ativação TANH SIG, 4 neurônios escondidos, apresentação dos dados por <i>Houldout</i> 10%

Empresa	Indicador	Janela tempo	Erro % abs mín	Erro % abs méd	Erro % abs máx	Desvio Padrão	Dados de Entrada	Rede
B	Endividamento	1	0,02%	1,06%	2,92%	0,88%	Endividamento total, Garantia ao Capital de Terceiros, INEC	MLP, F. ativação SIG SIG, 13 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
B	Endividamento	1	0,02%	1,09%	2,48%	0,83%	Endividamento total, Independência Financeira, Projeção do câmbio	MLP, F. ativação SIG SIG, 24 neurônios escondidos, apresentação dos dados por <i>Houldout</i> 30%
B	Endividamento	2	1,24%	3,03%	4,01%	3,99%	Endividamento total, Projeção do IPCA, INEC	RBF com spread de 10
B	Endividamento	2	0,79%	4,28%	8,21%	2,15%	Endividamento total, Trimestre, Projeção do câmbio	MLP, F. ativação SIG TANH, 25 neurônios escondidos, apresentação dos dados por <i>Houldout</i> 10%
B	Endividamento	2	0,32%	4,43%	8,15%	2,76%	Endividamento total, Trimestre, Projeção do câmbio	MLP, F. ativação TANH SIG, 29 neurônios escondidos, apresentação dos dados por <i>Houldout</i> 10%
B	Endividamento	4	0,03%	5,24%	11,46 %	3,53%	Endividamento total, Trimestre, Projeção do IPCA	MLP, F. ativação SIG SIG, 27 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
B	Endividamento	4	0,03%	5,33%	12,38 %	4,01%	Endividamento total, Projeção do câmbio, Prognóstico de safra IBGE	MLP, F. ativação TANH TANH, 21 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
B	Endividamento	4	0,04%	5,36%	11,26 %	3,70%	Endividamento total, Projeção do câmbio, Projeção do IPCA	MLP, F. ativação TANH TANH, 20 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
B	Rentabilidade	1	0,01%	0,56%	1,19%	0,31%	Rentabilidade dos ativos, INEC	MLP, F. ativação SIG SIG, 2 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
B	Rentabilidade	1	0,01%	0,73%	1,69%	0,48%	Rentabilidade dos ativos, Projeção do IPCA, Prognóstico de safra IBGE	MLP, F. ativação SIG SIG, 2 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
B	Rentabilidade	1	0,00%	0,74%	1,68%	0,45%	Rentabilidade dos ativos, Prognóstico de safra IBGE	MLP, F. ativação SIG SIG, 2 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
B	Rentabilidade	2	0,01%	0,49%	1,27%	0,36%	Rentabilidade dos ativos	MLP, F. ativação SIG SIG, 23 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>

Empresa	Indicador	Janela tempo	Erro % abs mín	Erro % abs méd	Erro % abs máx	Desvio Padrão	Dados de Entrada	Rede
B	Rentabilidade	2	0,02%	0,60%	1,76%	0,45%	Rentabilidade dos ativos, Projeção do IPCA, INEC	MLP, F. ativação SIG SIG, 23 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
B	Rentabilidade	2	0,05%	0,61%	1,22%	0,32%	Rentabilidade dos ativos, INEC	MLP, F. ativação TANH SIG, 19 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
B	Rentabilidade	4	0,03%	0,53%	1,25%	0,36%	Rentabilidade dos ativos, Prognóstico de safra IBGE	MLP, F. ativação SIG SIG, 2 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
B	Rentabilidade	4	0,04%	0,56%	1,15%	0,34%	Rentabilidade dos ativos, INEC, Prognóstico de safra IBGE	MLP, F. ativação TANH SIG, 2 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
B	Rentabilidade	4	0,02%	0,59%	1,23%	0,34%	Rentabilidade dos ativos, Rentabilidade do Ativo (IAGC-I), Projeção do IPCA	MLP, F. ativação SIG SIG, 2 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
C	Custo produtos	1	0,01%	0,69%	1,49%	0,44%	Custo dos produtos vendidos, Venda total clientes diretos	MLP, F. ativação TANH TANH, 26 neurônios escondidos, apresentação dos dados por <i>Houldout 30%</i>
C	Custo produtos	1	0,01%	0,71%	1,82%	0,61%	Custo dos produtos vendidos, Faturamento total, Venda total clientes diretos	MLP, F. ativação SIG TANH, 26 neurônios escondidos, apresentação dos dados por <i>Houldout 30%</i>
C	Custo produtos	1	0,05%	0,73%	1,45%	0,47%	Custo dos produtos vendidos, Venda total clientes diretos	MLP, F. ativação TANH TANH, 11 neurônios escondidos, apresentação dos dados por <i>Houldout 30%</i>
C	Custo produtos	3	0,01%	0,73%	2,55%	0,71%	Custo dos produtos vendidos, Projeção do IPCA	MLP, F. ativação TANH SIG, 17 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
C	Custo produtos	3	0,06%	0,86%	2,45%	0,76%	Custo dos produtos vendidos, Projeção do IPCA	MLP, F. ativação SIG SIG, 15 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
C	Custo produtos	3	0,00%	0,89%	1,97%	0,65%	Custo dos produtos vendidos, Faturamento total	MLP, F. ativação SIG SIG, 28 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
C	Custo produtos	6	0,01%	0,85%	2,07%	0,64%	Custo dos produtos vendidos, Faturamento total, Venda total clientes diretos	MLP, F. ativação TANH SIG, 30 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>

Empresa	Indicador	Janela tempo	Erro % abs mín	Erro % abs méd	Erro % abs máx	Desvio Padrão	Dados de Entrada	Rede
C	Custo produtos	6	0,04%	0,88%	2,17%	0,58%	Custo dos produtos vendidos, Venda total clientes diretos	MLP, F. ativação SIG TANH, 16 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
C	Custo produtos	6	0,03%	0,98%	2,07%	0,63%	Custo dos produtos vendidos	MLP, F. ativação TANH SIG, 30 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
C	EBITDA	1	0,04%	1,42%	3,73%	1,01%	EBITDA, Faturamento total, Mês correspondente	MLP, F. ativação SIG SIG, 11 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
C	EBITDA	1	0,11%	1,43%	4,12%	1,10%	EBITDA, Projeção do IPCA	MLP, F. ativação TANH SIG, 12 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
C	EBITDA	1	0,01%	1,52%	3,28%	0,81%	EBITDA, Mês correspondente, Projeção do IPCA	MLP, F. ativação TANH SIG, 9 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
C	EBITDA	3	0,30%	0,85%	1,66%	0,72%	EBITDA, Faturamento total, Projeção do IPCA	RBF com spread de 5
C	EBITDA	3	0,06%	1,02%	2,58%	0,75%	EBITDA, Faturamento total, Projeção do IPCA	MLP, F. ativação SIG SIG, 23 neurônios escondidos, apresentação dos dados por <i>Houldout 30%</i>
C	EBITDA	3	0,05%	1,08%	2,34%	0,64%	EBITDA, Faturamento total, Projeção do IPCA	MLP, F. ativação SIG TANH, 17 neurônios escondidos, apresentação dos dados por <i>Houldout 30%</i>
C	EBITDA	6	0,03%	1,10%	3,30%	0,99%	EBITDA, Faturamento total, INEC	MLP, F. ativação SIG SIG, 4 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
C	EBITDA	6	0,02%	1,10%	2,79%	0,78%	EBITDA, Projeção do IPCA	MLP, F. ativação SIG SIG, 3 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
C	EBITDA	6	0,05%	1,12%	2,34%	0,69%	EBITDA, Faturamento total, Venda total clientes diretos	MLP, F. ativação SIG SIG, 3 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>

Fonte: a autora.

Tabela 4.4 Análise dos dados de entrada das RNA considerando as três redes com melhor desempenho

Empresa	Indicador	Indicador de Período	Indicador Interno Correlação	Indicador de Prospecção
A	Produtividade por funcionário da fábrica 2	22%	44%	78%
A	Scrap consolidado do produto A total	56%	67%	11%
B	Endividamento total	33%	33%	100%
B	Rentabilidade dos ativos	0%	11%	89%
C	Custo médio dos produtos vendidos	0%	67%	22%
C	EBITDA	22%	67%	78%

Fonte: a autora.

Em relação ao conjunto de pesos iniciais, já existem na literatura formas não-aleatórias de determiná-los, com ótimos resultados principalmente em relação ao tempo computacional, utilizando por exemplo *simulated annealing* e busca tabu (Gomes e Ludermir, 2013), intervalo de tolerância linear mutável (Adam *et al.*, 2014) e inicialização baseada na informação mútua (MIWI; *mutual information based weight initialization*) (Qiao *et al.*, 2016). Como o tempo computacional não é um limitante neste trabalho e os resultados atingidos foram considerados satisfatórios, não se justifica aumentar a complexidade da metodologia proposta com a inclusão de um algoritmo de seleção de pesos iniciais das RNAs, lembrando que quanto maior a complexidade da metodologia, menor é a probabilidade de mais empresas, especialmente as menores, conseguirem implementá-las.

Foram apresentadas aqui apenas as 3 melhores redes para prever cada indicador-chave, dentre as 375840 de redes MLP testadas. A próxima seção apresenta uma análise das configurações de rede que obtiveram melhores resultados.

4.3.3. Análise das melhores configurações de RNAs

A Tabela 4.5 apresenta a comparação das redes RBF e MLP, para os seis indicadores em análise, em termos de percentual das configurações testadas que atingiram o critério de desempenho de erro máximo dos 30 testes menor que 5%, ou seja, de todos os testes feitos, com todas as variações de parâmetros, quantas redes de cada tipo atingiram o objetivo de erro máximo.

Nenhuma RBF conseguiu prever os indicadores da empresa A com erro máximo menor que 5%, e para as empresas B e C, um percentual muito baixo das configurações testadas atingiu o objetivo. As redes MLP superaram as RBF para todos

os indicadores. A análise desta tabela também aponta para a importância da quantidade e qualidade dos dados disponíveis, uma vez que as mesmas configurações de rede foram testadas para todos os indicadores, porém mais configurações atingiram o objetivo na empresa C, a qual conta com o histórico de dados mais longo.

Tabela 4.5 Porcentagem das redes (MLP e RBF) com erro máximo menor do que 5%

Empresa	Indicador	Percentual de redes com erro baixo RBF	Percentual de redes com erro baixo MLP
A	Produtividade por funcionário da fábrica 2	0,0%	0,3%
A	Scrap consolidado do produto A total	0,0%	8,8%
B	Endividamento total	0,2%	2,8%
B	Rentabilidade dos ativos	0,3%	14,6%
C	Custo médio dos produtos vendidos	1,7%	15,8%
C	EBITDA	0,5%	11,2%

Fonte: a autora.

Observando as redes RBF mais profundamente, quanto às suas configurações que atingiram o objetivo de erro absoluto máximo de 5%, percebe-se que todas as redes atingiram o menor erro utilizando um grande número de centros (no mínimo 80% do valor de dados de entrada. Pode-se observar, ainda, a distribuição das redes por *spread*. Conforme a Figura 4.27, mais redes RBF atingiram o objetivo com *spread* entre 3 e 6.

Já observando as redes MLP mais profundamente, quanto às suas configurações que atingiram o objetivo de erro absoluto máximo de 5%, pode-se analisar a taxa de aprendizagem, conforme a Tabela 4.6. As duas taxas testadas, de 0,5 e 0,9, tiveram redes que alcançaram o objetivo, porém, uma maior quantidade de redes com a taxa de 0,5 atingiu o objetivo. Para o indicador “Produtividade por funcionário da fábrica 2”, da Empresa A, por exemplo, 66,7% das redes que tiveram erro máximo menor que 5% utilizaram a taxa de aprendizagem de 0,5.

Figura 4.27 Percentual de redes RBF com bom desempenho por Spread

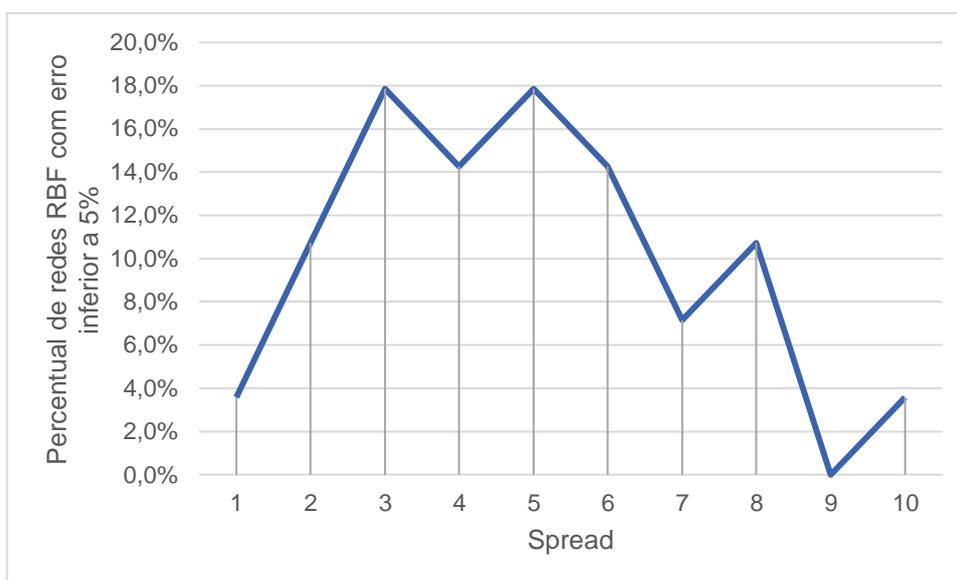


Tabela 4.6 Porcentagem das redes (MLP) que tiveram erro máximo menor do que 5% por meio da análise da taxa de aprendizagem

Empresa	Indicador	Taxa de 0,5	Taxa de 0,9
A	Produtividade por funcionário da fábrica 2	66,7%	33,3%
A	Scrap consolidado do produto A total	81,9%	18,1%
B	Endividamento total	69,8%	30,2%
B	Rentabilidade dos ativos	66,0%	34,0%
C	Custo médio dos produtos vendidos	53,3%	46,7%
C	EBITDA	79,6%	20,4%

Fonte: a autora.

Duas funções de ativação foram testadas nas redes MLP: sigmoide e tangente hiperbólica, combinadas de diferentes formas na camada escondida e camada de saída. A Tabela 4.7 demonstra o percentual de redes que atingiu o objetivo que utilizou cada função. Na maior parte dos casos, a combinação de função de ativação sigmoide, tanto na camada escondida quanto na camada de saída, foi a que apresentou o maior número de redes com bom desempenho. A exceção foi o indicador “Custo médio dos produtos vendidos”, da empresa C, que teve mais redes favoráveis com a função sigmoide na cada escondida e a tangente hiperbólica na camada de saída.

Outra questão importante a ser analisada diz respeito à quantidade de neurônios na camada escondida. Todas as quantidades testadas tiveram redes com boas previsões, porém, como pode ser visto na Figura 4.28, existe uma concentração

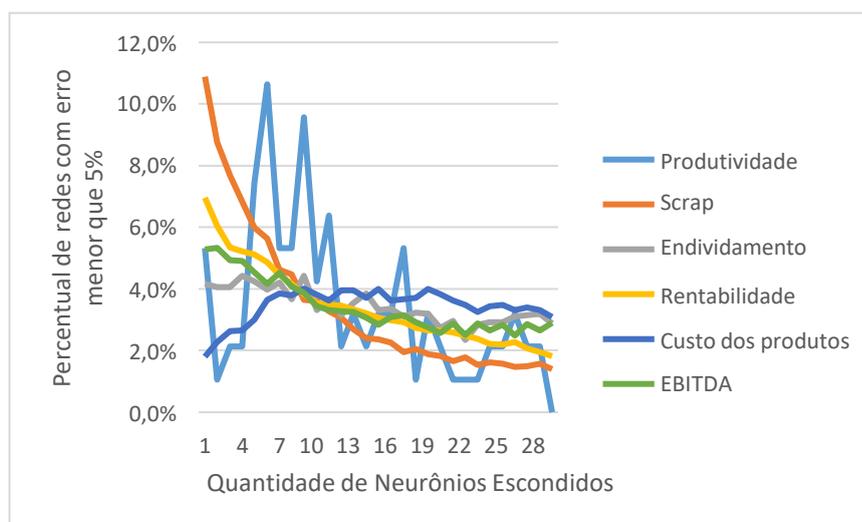
maior de bons resultados em redes com um menor número de neurônios na camada escondida.

Tabela 4.7 Porcentagem das redes (MLP) que tiveram erro máximo menor do que 5% por meio da análise da função de ativação

Emp resa	Indicador	Escondi da: sig; Saída: sig	Escondi da: tanh; Saída: tanh	Escondi da: sig; Saída: tanh	Escondi da: tanh; Saída: sig
A	Produtividade por funcionário da fábrica 2	50,0%	4,3%	22,3%	23,4%
A	Scrap consolidado do produto A total	39,0%	13,4%	18,3%	29,2%
B	Endividamento total	30,7%	19,2%	21,2%	28,8%
B	Rentabilidade dos ativos	33,3%	16,7%	21,5%	28,5%
C	Custo médio dos produtos vendidos	27,1%	21,2%	29,2%	22,4%
C	EBITDA	30,9%	20,0%	23,3%	25,8%

Fonte: a autora.

Figura 4.28 Porcentagem das redes (MLP) que tiveram erro máximo menor do que 5% por meio da análise da quantidade de neurônios escondidos



Fonte: a autora.

Diferentes formas de divisão dos dados nos conjuntos de treinamento, validação e testes foram testadas. Espera-se que redes com percentuais maiores de dados nos conjuntos de validação e testes tenham uma capacidade maior de avaliar novos dados, porém, a baixa quantidade de padrões disponíveis, realidade neste trabalho, justifica a necessidade de aumentar o percentual do conjunto de treinamento para que a rede possa apresentar resultados satisfatórios. A técnica *holdout* de 30% foi a que apresentou mais redes com desempenho adequado, conforme pode ser visto

na Tabela 4.8. Apenas o indicador “Produtividade por funcionário da fábrica 2”, da Empresa A, teve um maior % de redes bem sucedidas com o *Leave one Out*.

Tabela 4.8 Porcentagem das redes (MLP) que tiveram erro máximo menor do que 5% por meio da análise de avaliação do treinamento

Empresa	Indicador	Leave 1 out	Holdout 10%	Holdout 30%
A	Produtividade por funcionário da fábrica 2	43,5%	26,0%	30,5%
A	Scrap consolidado do produto A total	19,8%	16,3%	63,9%
B	Endividamento total	14,3%	34,0%	51,6%
B	Rentabilidade dos ativos	25,3%	21,4%	53,3%
C	Custo médio dos produtos vendidos	28,8%	19,9%	51,3%
C	EBITDA	10,0%	33,4%	56,6%

Fonte: a autora.

A realização de testes com tantas combinações possíveis, como a realizada neste trabalho, pode ser exaustiva e demandar muito tempo. Caso outras empresas queiram implementar a metodologia aqui apresentada, mas não disponham do tempo ou recursos necessários para realizar tantos testes, os resultados apresentados nesta seção poderão servir de guia para que uma rede com boa capacidade de previsão seja encontrada com menos esforços. Sugere-se então que os testes sejam iniciados com as seguintes variações e expandidos de acordo com a necessidade de acurácia de cada empresa: Rede neural MLP, com taxa de aprendizagem de 0,5, função de ativação sigmoide, com retenção de 30% dos dados para o conjunto de validação e variando os neurônios escondidos em até 10 unidades.

4.3.4. Escolha da rede a ser implementada

Para escolher as RNA a serem implementadas em cada empresa, foram selecionadas as três melhores para cada indicador e para cada horizonte de previsão, utilizando como critério o menor erro % absoluto médio. A escolha de qual das três opções deve ser implementada foi realizada com base no menor desvio padrão do erro, entre estas 3 opções. A Tabela 4.9 exemplifica esta escolha para o indicador “Produtividade por funcionário da fábrica 2” da Empresa A, para previsão do período seguinte. O mesmo procedimento foi realizado para todos os indicadores presentes na tabela 4.3, de todas as empresas, para todas as janelas de tempo em estudo.

Tabela 4.9 Exemplo de escolha de RNA para implementação (Empresa A; Indicador: “Produtividade por funcionário da fábrica 2”)

Rede	Erro % abs mín	Erro % abs médio	Erro % abs máx	Desvio Padrão do erro	Dados de Entrada	Rede
R1	0,04%	1,61%	4,72%	1,48%	Produtividade por funcionário da fábrica 2, Projeção do IPCA	MLP, F. ativação SIG SIG, 18 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>
R2	0,05%	1,66%	3,94%	1,17%	Produtividade por funcionário da fábrica 2, Número de funcionários da Fábrica 2 (sem temporários), ICEI	MLP, F. ativação SIG SIG, 6 neurônios escondidos, apresentação dos dados por <i>Houldout</i> 10%
R3	0,09%	1,73%	4,84%	1,41%	Produtividade por funcionário da fábrica 2, Número de funcionários da Fábrica 2 (sem temporários), INEC	MLP, F. ativação SIG TANH, 6 neurônios escondidos, apresentação dos dados por <i>Leave one Out</i>

Fonte: a autora.

Apesar de o menor erro médio ter sido atingido com a rede R1 (MLP com função de ativação SIG-SIG, 18 neurônios escondidos e avaliação do treinamento por *Leave one Out*, tendo como dados de entrada “Produtividade por funcionário da fábrica 2” e Projeção do IPCA), a rede R2 (MLP com função de ativação SIG-SIG, 6 neurônios escondidos e apresentação dos dados por *Houldout* 10%, com os dados de entrada “Produtividade por funcionário da fábrica 2”, Número de funcionários da Fábrica 2 (sem temporários) e ICEI), apresentou um desvio padrão menor para o erro, e por isto deve ser a escolhida.

5. DISCUSSÃO

Folan et al. (2007) pesquisaram a definição de desempenho dentro do contexto empresarial, e afirmam que o termo “desempenho” é difícil de definir, uma vez que seu significado pode variar com o contexto. Os autores explicam, porém, que desempenho se relaciona com a execução de uma ação, sendo que esta ação deve ser padronizada, não aleatória, quantificável e deve ter relevância. Desta forma, Folan et al. (2007) afirmam que o desempenho empresarial está relacionado com o progresso, com a capacidade de atingir objetivos. O processo de revisão de desempenho, de acordo com Farris et al. (2010), é definido como as atividades organizacionais para monitorar, avaliar e comunicar as informações de desempenho, que levam à tomada de decisão, auxiliando os gestores na conquista dos objetivos da unidade organizacional. Ghalayini e Noble (1996) também afirmam que medição de desempenho é utilizada para avaliar, controlar e melhorar os processos produtivos, de maneira que as empresas possam atingir suas metas e objetivos. Desta forma, a metodologia proposta neste trabalho objetiva melhorar o processo de gestão do desempenho das empresas, fazendo com que as mesmas possam melhorar suas tomadas de decisão e atingir seus objetivos mais facilmente.

A gestão do desempenho, de acordo com Choong (2014), refere-se a melhoria no cumprimento das metas estabelecidas. Franco-Santos et al. (2007) afirmam que não existe um entendimento comum entre os pesquisadores sobre o que é a medição do desempenho empresarial, porém explicam que ela inclui as medidas de desempenho, sendo que não existe consenso sobre a natureza e escolha dessas medidas; infraestrutura de suporte, a qual pode variar de simples métodos manuais até sistemas de informação sofisticados; e metas ou objetivos estratégicos. Segundo os mesmos autores, existem três processos necessários que continuem a medição de desempenho: definição das medidas, captura de informações para calcular as medidas e fornecimento de informação sobre as medidas. A revisão sistemática da literatura realizada neste trabalho objetivou, além de levantar questões de pesquisa, identificar e classificar os mais diversos indicadores de desempenho utilizados pelas indústrias, de forma a auxiliar nesta escolha das medidas de desempenho pelas empresas. A hierarquia de correlações feita a partir dos indicadores-chave, por sua vez, contribui para fornecer mais informações sobre os indicadores e os processos.

Quanto às funções da medição de desempenho, Franco-Santos et al. (2007) colocam que gerenciamento da estratégia, alinhamento organizacional, comunicação interna, influência no comportamento, monitoramento do processo e aprendizado são influenciados. Gimbert et al. (2010) coloca que, apesar de os sistemas de medição de desempenho terem sido inicialmente concebidos com o objetivo de implementar a estratégia, eles influenciam o processo de formulação da estratégia, ajudando os gestores a desenvolverem estratégias mais compreensíveis. Tanto as hierarquias de indicadores quanto a previsão de indicadores geram informações que contribuem para que os gestores possam formular e adaptar suas estratégias, reduzindo os riscos do processo qualitativo de tomada de decisão.

Apesar de a metodologia proposta estar de acordo com a literatura da área, foram identificadas dificuldades, vantagens e desvantagens durante a sua implementação, as quais serão discutidas a seguir, para cada uma das suas três etapas principais.

5.1. Fase 1: Coleta e análise dos dados

A coleta dos dados é uma das etapas mais importantes da metodologia, uma vez que a qualidade dos mesmos influencia os resultados de todas as outras etapas. As maiores dificuldades encontradas nesta etapa foram:

- Falta de indicadores: as empresas não medem tudo, e em alguns casos medem porém não registram, de forma que alguns indicadores clássicos, identificados na revisão de literatura, e que poderiam impactar os resultados da metodologia, não existem.
- Falta de histórico coerente de dados: alguns indicadores estavam sendo medidos nas empresas a pouco tempo, ou tiveram sua forma de medição ou cálculo alterados a pouco tempo, o que inviabiliza a utilização destas informações na metodologia.
- Falta de cooperação das empresas: Algumas empresas não concordaram em apresentar para esta pesquisa todos os indicadores disponíveis, retendo aqueles que classificam como informação sensível. A falta destes indicadores também impactou nos resultados obtidos, já que a Empresa C, que atingiu os melhores resultados, foi a única que não limitou o acesso à informação.

As vantagens desta etapa foram:

- Os seis passos funcionaram de acordo com o previsto. Tanto a inspeção visual quanto as análises gráficas foram importantes para identificação de inconsistências nos dados coletados, permitindo que os mesmos fossem revistos quando possível ou descartados.
- A coleta de indicadores externos aconteceu online de maneira simplificada, de forma que a utilização dos mesmos tem duas grandes vantagens: são mais fáceis e mais baratos de conseguir e melhoraram sensivelmente os resultados das etapas posteriores.

5.2. Fase 2: Correlação entre indicadores de desempenho

A maior dificuldade encontrada na fase de estabelecer as hierarquias dos indicadores de desempenho foi definir os indicadores-chave de cada empresa. Esta definição deve ser feita pelos gestores da própria indústria, uma vez que conhecem os processos, o negócio e também os objetivos da mesma. A escolha destes indicadores influencia os resultados de toda a metodologia, e conseqüentemente os resultados da aplicação da mesma, de forma que esta decisão deve ser tomada racionalmente, embasada nas estratégias da empresa. A participação da empresa também é fundamental durante a análise das hierarquias geradas, para que a mesma seja relevante dentro do contexto da indústria em questão.

A análise das hierarquias foi provavelmente o maior ganho obtido com a aplicação de toda a metodologia devido à duas questões:

- Identificação de correlações não intuitivas: devido à questão da terceira variável explicada anteriormente, foi possível identificar correlações que pareciam desconectadas, uma vez que os dois indicadores fortemente correlacionados são influenciados por uma terceira variável. A identificação dessas correlações levou tanto à decisão de modificar o conjunto de indicadores medidos, passando a medir a variável geradora, quanto a decisões gerenciais baseadas nesta informação.
- Redução das correlações a serem analisadas: analisar todas as correlações entre todos os indicadores seria inviável por demandar muito tempo. A criação das hierarquias a partir dos indicadores-chave separa as principais correlações para a empresa, àquelas que necessitam

análise, desde que os indicadores principais sejam escolhidos adequadamente.

- Redução do número de indicadores: Medir, registrar e analisar as informações de diversos indicadores gera muita burocracia e faz com que as empresas gastem recursos humanos e financeiros. As hierarquias mostram quais são os indicadores que estão realmente correlacionados com a estratégia da empresa, abrindo espaço para que as empresas reduzam ou eliminem a medição dos demais indicadores, utilizando assim seus recursos em outras atividades.

Duas discussões são levantadas a partir da análise das hierarquias. A primeira diz respeito ao equilíbrio a ser alcançado entre indicadores que interferem uns nos outros de maneira negativa. Sugere-se avaliar a melhor maneira de definir as metas para cada um destes indicadores, considerando a estratégia global da empresa. A segunda discussão é quanto à natureza dos indicadores, uma vez que neste trabalho foram utilizados indicadores estratégicos, táticos e operacionais conjuntamente, e sugere-se testar também hierarquias considerando apenas os indicadores de cada uma destas categorias, para que a tomada de decisão possa ser melhorada em todos os níveis hierárquicos.

5.3. Fase 3: Previsão futura dos indicadores-chave

A previsão de indicadores de desempenho pode auxiliar a tomada de decisão da empresa em questões importantes como compra de novos equipamentos e planejamento da capacidade fabril de médio e longo prazos, deixando o planejamento estratégico mais robusto.

Apesar de terem sido encontradas redes neurais com bons resultados para a previsão dos indicadores-chave das três empresas, a busca pelas melhores redes pode ser bastante árdua. Como mostrou a tabela 4.5, um percentual muito baixo de todas as redes testadas atingiu valores satisfatórios de previsão. A literatura sobre redes neurais costuma apresentar apenas as melhores redes encontradas, sem mostrar quantos testes foram realizados no total, de forma que não há parâmetros para saber se o resultado deste trabalho está coerente.

A literatura também costuma colocar as redes RBF como superiores às MLP, o que não ocorreu neste trabalho. Isto ocorre provavelmente por terem sido realizados

mais testes com a MLP. As redes RBF podem atingir resultados melhores com outras configurações, alterando, por exemplo, a forma de escolher os centros. Já as redes MLP podem ser testadas também em busca de melhores resultados utilizando a taxa de aprendizagem regressiva, o *momentum* diferente de zero ou um método não aleatório para definição dos pesos iniciais.

É preciso discutir também a questão dos dados de entrada, os quais impactam fortemente o resultado das previsões. Quanto maior a quantidade de períodos de dados de cada indicador, melhor a previsão. A utilização de dados externos de prospecção foi um dos grandes ganhos desta etapa da metodologia, já que a maior parte das melhores redes utilizaram esta informação.

6. CONCLUSÕES

A revisão sistemática da literatura, realizada acerca dos indicadores de desempenho da manufatura, buscou responder à primeira questão de pesquisa, identificando os indicadores de desempenho utilizados pelas organizações e também as melhores maneiras de selecioná-los. A primeira inovação deste trabalho consiste na classificação dos indicadores baseada no conceito de entrada-transformação-saída, o qual pode ser aplicado a indústrias de diferentes portes e setores.

A revisão de literatura também levantou a necessidade da realização de trabalhos quantitativos para auxiliar a análise das relações existentes entre os diferentes indicadores e o impacto que um pode ter sobre o outro, e também para realizar previsões futuras de indicadores de desempenho, e não trabalhar apenas com os dados históricos. Este trabalho buscou desenvolver uma metodologia que atenda a essas duas necessidades, e possa, assim, ser uma ferramenta de melhoria da gestão das empresas.

A metodologia proposta, a qual também é um ponto de inovação deste trabalho, ficou composta por três fases principais. A Fase 1 diz respeito à coleta e análise dos dados. Esta fase é importante para que as técnicas aplicadas na sequência sejam mais eficazes, uma vez que dados ruins podem “contaminar” toda a análise.

A Fase 2 da metodologia tem a intenção de responder à segunda questão de pesquisa, identificando relações entre indicadores e melhorando a compreensão dos processos das empresas. Esta fase diz respeito à análise das correlações estatísticas existentes entre os indicadores coletados. A Empresa A apresentou, no total, 4.513 correlações fortes entre indicadores; a Empresa B, 9.293, e a Empresa C, 13.945. Analisar todas estas correlações existentes seria inviável. Desta forma, construir hierarquias de correlações a partir dos indicadores principais das empresas ajuda a focar nas análises que são mais relevantes para as mesmas. Apesar de correlações entre indicadores já terem sido utilizadas em outros trabalhos, a análise delas em forma hierárquica é um dos pontos de inovação deste trabalho.

As hierarquias de correlações mostraram-se úteis como forma de gerenciar o conjunto de indicadores de desempenho. No caso da Empresa B, a análise das hierarquias mostrou indicadores redundantes, e permitiu a redução da quantidade de indicadores a serem acompanhados. Já para as empresas A e C, a análise das

hierarquias apontou a necessidade de incluir a medição de indicadores de chão de fábrica, já que ambas estão mais focadas em indicadores gerenciais, os quais, muitas vezes, têm comportamentos influenciados pela produção.

Além de melhorar o gerenciamento do conjunto de indicadores, as análises das correlações dos indicadores se mostraram úteis como uma ferramenta de melhoria da gestão das empresas. A Empresa A, por exemplo, pôde compreender melhor a relação existente entre o aumento da quantidade produzida e o aumento consequente das perdas de processo, e, a partir disto, pode planejar a sua produção de forma a equilibrar estes dois indicadores, sempre que possível. A Empresa A compreendeu, ainda, que suas atividades recebem uma influência muito grande do meio externo, e, agora, poderá pensar em planos de ação para minimizar o impacto de possíveis crises alheias à empresa.

A análise das hierarquias da Empresa C também serviu como “pontapé inicial” para mudanças gerenciais. A empresa estava focada nos produtos de “segunda linha”, acreditando que, em função da crise econômica, os clientes deixariam de comprar os produtos mais caros. A análise das correlações entre os indicadores, porém, mostrou que os produtos de “primeira linha” têm a produção mais eficiente e são os mais procurados pelos clientes que compram mais, tendo um impacto muito maior no faturamento e no lucro da empresa. A partir disto, a empresa passa a direcionar recursos de *marketing* buscando aumentar as vendas dos produtos de “primeira linha”.

As correlações entre os indicadores encontradas nesta segunda fase da metodologia, além de servirem como ferramenta de auxílio à gestão, foram utilizadas para definir os dados de entrada para a Fase 3, a qual consiste na previsão futura dos indicadores-chave e, assim, busca responder à terceira questão de pesquisa.

A previsão de indicadores-chave pode beneficiar a tomada de decisões das empresas. A previsão de indicadores financeiros como “EBITDA” (da Empresa C), por exemplo, pode respaldar decisões que influenciem muito a situação econômica das empresas, tais como investimentos em equipamentos e novas plantas industriais. Já a previsão de indicadores de fábrica, como o “Scrap de produção”, pode antecipar tendências de piora e permitir que ações sejam tomadas preventivamente, evitando perdas.

A previsão dos indicadores-chave foi realizada utilizando as redes neurais MLP e RBF, e testando diferentes configurações. O erro percentual máximo, dos conjuntos de teste, foi satisfatório, sendo que apenas uma previsão, relativa à “Rentabilidade

dos ativos” para um ano à frente, da Empresa B, ainda apresenta um nível de erro superior à 5%, o que inutiliza esta previsão para a empresa.

As redes MLP apresentaram desempenho superior às redes RBF, e suas melhores configurações utilizaram taxa de aprendizagem de 0,5, função de ativação sigmoide tanto na camada escondida quanto na camada de saída, com retenção de 30% dos dados para o conjunto de validação e variando os neurônios escondidos em até 10 unidades.

As redes neurais foram utilizadas amplamente na literatura para fins de previsão, porém a forma de escolha dos dados de entrada das mesmas, incluindo os indicadores fortemente correlacionados e, principalmente, dados de prospecção de mercado, é mais um ponto de inovação deste trabalho.

6.1.Limitações

A primeira limitação diz respeito à utilização das técnicas estatísticas e das redes neurais, no que concerne à disponibilidade de dados. Os métodos necessitam de dados históricos confiáveis dos indicadores de desempenho e, dessa forma, não seria possível implementar a metodologia aqui proposta em empresas novas ou naquelas que não possuam registros históricos de indicadores.

Outra dificuldade consistiu em criar uma metodologia simples o suficiente para ser aplicável em empresas que não dispõem de recursos abundantes, inclusive pequenas e médias empresas, mas que ainda seja robusta o suficiente para auxiliar a gestão. Algumas empresas ainda podem encontrar dificuldades com a implementação em função da necessidade de utilização de *softwares* específicos, como o SPSS para a análise estatística e o MATLAB para a previsão de indicadores de desempenho.

6.2.Sugestões de trabalhos futuros

Sugere-se que pesquisas futuras considerem as questões de pesquisa levantadas na revisão de literatura e expostas no item 2.1.3. Outros temas relevantes para pesquisas futuras incluem a utilização de simulação para investigar as relações entre diferentes indicadores de desempenho. Pode-se, ainda, pesquisar outros métodos de previsão de séries temporais para a previsão de indicadores de

desempenho, em especial métodos com boa acurácia para previsão de séries temporais curtas.

Além disto, sugere-se para pesquisas futuras os pontos levantados nas discussões, entre os quais estão os testes das redes RBF utilizando outra forma de escolher os centros e os testes com as redes MLP utilizando outra taxa de *momentum* e outra forma de escolher os pesos iniciais das redes.

REFERÊNCIAS

ABDEL-MAKSOU, A.; CERBIONI, F.; RICCERI, F.; VELAYUTHAM, S. Employee morale, non-financial performance measures, deployment of innovative managerial practices and shop-floor involvement in Italian manufacturing firms. **British Accounting Review**, v. 42, n. 1, p. 36–55, 2010. Elsevier Ltd.

ADAM, S. P.; KARRAS, D. A.; MAGOULAS, G. D.; VRAHATIS, M. N. Solving the linear interval tolerance problem for weight initialization of neural networks. **Neural Networks**, v. 54, p. 17–37, 2014. Elsevier Ltd. Disponível em: <<http://dx.doi.org/10.1016/j.neunet.2014.02.006>>. .

ADHIKARI, R. A neural network based linear ensemble framework for time series forecasting. **Neurocomputing**, v. 157, p. 231–242, 2015. Elsevier. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0925231215000338>>. .

ADHIKARI, R.; AGRAWAL, R. K. A combination of artificial neural network and random walk models for financial time series forecasting. **Neural Computing and Applications**, v. 24, n. 6, p. 1441–1449, 2014.

AGBEDEYI, O. D.; IGWEZE, A. H. Robust Method for Testing the Significance of Bivariate Correlation of Ordinal Data. **Mathematical Theory and Modeling**, v. 4, n. 11, p. 169–175, 2014.

AGHAEI CHADEGANI, A.; SALEHI, H.; MD YUNUS, M. M.; et al. A comparison between two main academic literature collections: Web of science and scopus databases. **Asian Social Science**, v. 9, n. 5, p. 18–26, 2013.

AMRINA, E.; VILSI, A. L. Key Performance Indicators for Sustainable Manufacturing Evaluation in Cement Industry. 12th Global Conference on Sustainable Manufacturing. **Anais** v. 26, p.19–23, 2015. Elsevier B.V.

AMRINA, E.; YUSOF, S. M. Interpretive structural model of key performance indicators for sustainable manufacturing evaluation in automotive companies. IEEE International Conference on Industrial Engineering and Engineering Management. **Anais...** . p.656–660, 2012.

AMRINA, E.; YUSOF, S. M. M. Key performance indicators for sustainable manufacturing evaluation in automotive companies. IEEE International Conference on Industrial Engineering and Engineering Management. **Anais...** . p.1093–1097, 2011.

BAI, Z. B. Z.; ZHANG, P. Z. P.; LIU, F. L. F.; TAN, R. T. R. Product development performance measures in manufacturing firm. 2007 IEEE International Conference on Industrial Engineering and Engineering Management. **Anais...** . p.926–929, 2007.

BANSIA, M.; VARKEY, J. K.; AGRAWAL, S. Development of a Reverse Logistics Performance Measurement System for a Battery Manufacturer. 3rd International Conference on Materials Processing and Characterisation. **Anais** v. 6, p.1419–1427, 2014. Elsevier B.V.

BATAINEH, M. H. **New neural network for real-time human dynamic motion prediction**, 2015. University of Iowa.

BISSESSUR, Y.; MARTIN, E. B.; MORRIS, A. J. Monitoring the performance of the paper making process. **Control Engineering Practice**, v. 7, p. 1357–1368, 1999.

BITITCI, U.; GARENGO, P.; DÖRFLER, V.; NUDURUPATI, S. Performance Measurement: Challenges for Tomorrow*. **International Journal of Management Reviews**, v. 14, n. 3, p. 305–327, 2012. Disponível em: <<http://doi.wiley.com/10.1111/j.1468-2370.2011.00318.x>>. Acesso em: 15/7/2014.

BNDES, B. N. DE D. E. E S. Normas Reguladoras do Produto BNDES Automático. **BNDES**, 2011.

BURGER, N.; DEMARTINI, M.; TONELLI, F.; BODENDORF, F.; TESTA, C. Investigating Flexibility as a Performance Dimension of a Manufacturing Value Modeling Methodology (MVMM): A Framework for Identifying Flexibility Types in Manufacturing Systems. *Procedia CIRP. Anais...* . v. 63, p.33–38, 2017. The Author(s). Disponível em: <<http://dx.doi.org/10.1016/j.procir.2017.03.343>>. .

CHAN, D. C. K.; YUNG, K. L.; IP, A. W. H. An application of fuzzy sets to process performance evaluation. **Integrated Manufacturing Systems**, v. 13, n. 4, p. 237–246, 2002.

CHEN, C. C. An objective-oriented and product-line-based manufacturing performance measurement. **International Journal of Production Economics**, v. 112, n. 1, p. 380–390, 2008.

CHEN, C. C.; CHENG, W. Y. Customer-focused and product-line-based manufacturing performance measurement. **International Journal of Advanced Manufacturing Technology**, v. 34, n. 11–12, p. 1236–1245, 2007.

CHOFREH, A.; GONI, F.; SHAHAROUN, A. M.; ISMAIL, S.; KLEMES, J. Sustainable enterprise resource planning: imperatives and research. **Journal of Cleaner Production**, v. 71, p. 139–147, 2014.

CHOMPU-INWAI, R.; DIAOTRAKUN, R.; THAIUPATHUMP, T. Key indicators for maintenance performance measurement: The aircraft galley and associated equipment manufacturer case study. 10th International Conference on Service Systems and Service Management - Proceedings of ICSSSM 2013. **Anais** p.844–849, 2013.

CHOONG, K. K. The fundamentals of performance measurement systems. **International Journal of Productivity and Performance Management**, v. 63, n. 7, p. 879–922, 2014.

COSKUN, A.; BAYYURT, N. Measurement frequency of performance indicators and satisfaction on corporate performance: A survey on manufacturing companies. **European Journal of Economics, Finance and Administrative Sciences**, v. 13, p. 79–87, 2008.

DAMODARAN, P.; HULETT, M. Analytical approximations to predict performance measures of manufacturing systems with general distributions, job failures and parallel processing. **European Journal of Operational Research**, v. 221, n. 1, p. 74–86, 2012. Elsevier B.V.

DIGALWAR, A. K.; TAGALPALLEWAR, A. R.; SUNNAPWAR, V. K. Green manufacturing performance measures: an empirical investigation from Indian manufacturing industries. **Measuring Business Excellence**, v. 17, n. 4, p. 59–75, 2013.

DOČEKALOVÁ, M. Construction of corporate social performance indicators for Czech manufacturing industry. **Acta Universitatis Agriculturae et Silviculturae**

Mendelianae Brunensis, v. 61, n. 2, p. 309–315, 2013.

DOCEKALOVÁ, M. P.; KOČMANOVÁ, A.; KOLENÁK, J. Development of Corporate Governance Performance Indicators for Czech Manufacturing Companies. **DANUBE: Law and Economics Review**, v. 6, n. 1, p. 57–72, 2015.

DONATE, J. P.; CORTEZ, P.; SÁNCHEZ, G. G.; MIGUEL, A. S. DE. Time series forecasting using a weighted cross-validation evolutionary artificial neural network ensemble. **Neurocomputing**, v. 109, p. 27–32, 2013. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0925231213000209>>. .

DÜZAKIN, E.; DÜZAKIN, H. Measuring the performance of manufacturing firms with super slacks based model of data envelopment analysis: An application of 500 major industrial enterprises in Turkey. **European Journal of Operational Research**, v. 182, n. 3, p. 1412–1432, 2007.

EFTHYMIIOU, K.; PAGOROPOULOS, A.; PAPAΚOSTAS, N.; MOURTZIS, D.; CHRYSOLOURIS, G. Manufacturing systems complexity: An assessment of manufacturing performance indicators unpredictability. **CIRP Journal of Manufacturing Science and Technology**, v. 7, n. 4, p. 324–334, 2014. CIRP.

EKONOMOU, L. Greek long-term energy consumption prediction using artificial neural networks. **Energy**, v. 35, n. 2, p. 512–517, 2010.

ESWARAMURTHI, K. G.; MOHANRAM, P. V. Improvement of manufacturing performance measurement system and evaluation of overall resource effectiveness. **American Journal of Applied Sciences**, v. 10, n. 2, p. 131–138, 2013.

FAHLMAN, S. E. **An empirical study of learning speed in backpropagation networks**. Pittsburgh, 1988.

FARRIS, J. A.; AKEN, E. M. VAN; TECH, V.; COLEMAN, G. Improving the performance review process A structured approach and case application. , p. 376–404, 2010.

FIELD, A. **Discovering Statistics with SPSS**. 2^o ed. Sage Publications of London, 2005.

FOLAN, P.; BROWNE, J. A review of performance measurement: Towards performance management. **Computers in Industry**, v. 56, n. 7, p. 663–680, 2005.

FOLAN, P.; BROWNE, J.; JAGDEV, H. Performance: Its meaning and content for today ' s business research. , v. 58, p. 605–620, 2007.

FRANCO-SANTOS, M.; KENNERLEY, M.; MICHELI, P.; et al. Towards a Definition of a Business Performance Measurement System. **International Journal of Operations & Production Management**, v. 27, n. 8, p. 784–801, 2007.

FULLERTON, R. R.; WEMPE, W. F. Lean manufacturing, non-financial performance measures, and financial performance. **International Journal of Operations & Production Management**, v. 29, n. 3, p. 214–240, 2009.

GARBIE, I. H. Performance analysis and measurement of reconfigurable manufacturing systems. **Journal of Manufacturing Technology Management**, v. 25, n. 7, p. 934–957, 2014.

GHALAYINI, A. M.; NOBLE, J. S. The changing basis of performance measurement. **International Journal of Operations & Production Management**, v. 16, n. 8, p. 63–80, 1996.

GHEYAS, I. A.; SMITH, L. S. A novel neural network ensemble architecture for time series forecasting. **Neurocomputing**, v. 74, n. 18, p. 3855–3864, 2011. Elsevier. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0925231211004504>>. .

GIL, A. C. **Como elaborar projetos de pesquisa**. 5ª ed. ed. São Paulo: Atlas, 2010.

GIMBERT, X.; BISBE, J.; MENDOZA, X. The role of performance measurement systems in strategy formulation processes. **Long Range Planning**, v. 43, n. 4, p. 477–497, 2010. Elsevier Ltd. Disponível em: <<http://dx.doi.org/10.1016/j.lrp.2010.01.001>>.

GOMES, C. F.; YASIN, M. M.; LISBOA, J. V. A literature review of manufacturing performance measures and measurement in an organizational context: a framework and direction for future research. **Journal of Manufacturing Technology Management**, v. 15, n. 6, p. 511–530, 2004.

GOMES, C. F.; YASIN, M. M.; LISBOA, J. V. An empirical investigation of manufacturing performance measures utilization: The perspectives of executives and financial analysts. **International Journal of Productivity and Performance Management**, v. 56, n. 3, p. 187–204, 2007.

GOMES, C. F.; YASIN, M. M.; LISBOA, J. V. Performance measurement practices in manufacturing firms revisited. **International Journal of Operations & Production Management**, v. 31, n. 1, p. 5–30, 2011.

GOMES, G. DA S.; LUDERMIR, T.; LIMA, L. Comparison of new activation functions in neural network for forecasting financial time series. **Neural Computing & Applications**, v. 20, n. 3, p. 417–439, 2011. Disponível em: <<http://ezp.waldenulibrary.org/login?url=http://search.ebscohost.com/login.aspx?direct=true&db=a9h&AN=59398369&site=eds-live&scope=site%5Cnhttp://content.ebscohost.com.ezp.waldenulibrary.org/ContentServer.asp?T=P&P=AN&K=59398369&S=R&D=a9h&EbscoContent=dGJyMM>>. .

GOMES, G. S. DA S.; LUDERMIR, T. B. Optimization of the weights and asymmetric activation function family of neural network for time series forecasting. **Expert Systems with Applications**, v. 40, n. 16, p. 6438–6446, 2013. Elsevier Ltd. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417413003515>>. .

GOSSELIN, M. An empirical study of performance measurement in manufacturing firms. **International Journal of Productivity and Performance Management**, v. 54, n. 5/6, p. 419–437, 2005.

GRANDO, A.; BELVEDERE, V. District's manufacturing performances: A comparison among large, small-to-medium-sized and district enterprises. **International Journal of Production Economics**, v. 104, n. 1, p. 85–99, 2006.

GRANT, J. L. **Short-Term Peak Demand Forecasting Using an Artificial Neural Network with Controlled Peak Demand Through Intelligent Electrical Loading**, 2014. University of Miami.

GUO, Z. X.; WONG, W. K.; LI, M. Sparsely connected neural network-based time series forecasting. **Information Sciences**, v. 193, p. 54–71, 2012. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0020025512000308>>. .

GURNEY, K. **An introduction to neural networks**. UCL Press Limited: UCL

Press Limited, 2004.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H.; JESÚS, O. DE. **Neural Network Design**. 2^a ed. ed. e-book, 2014.

HEIDARI, E.; SOBATI, M. A.; MOVAHEDIRAD, S. Accurate prediction of nanofluid viscosity using a multilayer perceptron artificial neural network (MLP-ANN). **Chemometrics and Intelligent Laboratory Systems**, v. 155, p. 73–85, 2016.

HENRI, J.-F.; JOURNEAULT, M. Environmental performance indicators: an empirical study of Canadian manufacturing firms. **Journal of environmental management**, v. 87, n. 1, p. 165–176, 2008.

HERZOG, N. V.; TONCHIA, S.; POLAJNAR, A. Linkages between manufacturing strategy, benchmarking, performance measurement and business process reengineering. **Computers and Industrial Engineering**, v. 57, n. 3, p. 963–975, 2009. Elsevier Ltd.

HON, K. K. B. Performance and Evaluation of Manufacturing Systems. **CIRP Annals - Manufacturing Technology**, v. 54, n. 2, p. 139–154, 2005.

HULETT, M.; DAMODARAN, P. Analytical approximations to predict performance measures of markovian type manufacturing systems with job failures and parallel processing. **European Journal of Operational Research**, v. 212, n. 1, p. 89–99, 2011. Elsevier B.V.

JAIN, S.; TRIANTIS, K. P.; LIU, S. Manufacturing performance measurement and target setting: A data envelopment analysis approach. **European Journal of Operational Research**, v. 214, n. 3, p. 616–626, 2011. Elsevier B.V.

JOINER, T. A.; SPENCER, X. S. Y.; SALMON, S. The effectiveness of flexible manufacturing strategies: The mediating role of performance measurement systems. **International Journal of Productivity and Performance Management**, v. 58, n. 2, p. 119–135, 2009.

JONES, S. D.; BUERKLE, M.; HALL, A.; RUPP, L.; MAUT, G. Work Group Performance Measurement and Feedback An Integrated Comprehensive System for a Manufacturing Department. **Group & Organization Management**, v. 18, n. 3, p. 269–291, 1993.

JUSOH, R.; IBRAHIM, D. N.; ZAINUDDIN, Y. The performance consequence of multiple performance measures usage: Evidence from the Malaysian manufacturers. **International Journal of Productivity and Performance Management**, v. 57, n. 2, p. 119–136, 2008a.

JUSOH, R.; IBRAHIM, D. N.; ZAINUDDIN, Y. Selection approach to assessing the alignment between business strategy and use of multiple performance measures in Malaysian manufacturing firms. **Asian Journal of Business and Accounting**, v. 1, n. 1, p. 67–92, 2008b.

KAMAL, M. M.; IRANI, Z. Analysing supply chain integration through a systematic literature review: a normative perspective. **Supply Chain Management: An International Journal**, v. 19, n. 5/6, p. 523–557, 2014.

KITCHENHAM, B. **Procedures for performing systematic reviews**. 2004.

KOURENTZES, N.; BARROW, D. K.; CRONE, S. F. Neural network ensemble operators for time series forecasting. **Expert Systems with Applications**, v. 41, n. 9,

p. 4235–4244, 2014. Elsevier Ltd. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417413009834>>. .

KRIESEL, D. **A Brief Introduction to Neural Networks**. 2007.

KUSIAK, A.; LI, W. Estimation of wind speed: A data-driven approach. **Journal of Wind Engineering and Industrial Aerodynamics**, v. 98, n. 10–11, p. 559–567, 2010. Elsevier. Disponível em: <<http://dx.doi.org/10.1016/j.jweia.2010.04.010>>. .

LAURENT, A.; OLSEN, S. I.; HAUSCHILD, M. Z. Carbon footprint as environmental performance indicator for the manufacturing industry. **CIRP Annals - Manufacturing Technology**, v. 59, n. 1, p. 37–40, 2010. CIRP.

LEVINE, D. M.; STEPHAN, D. F.; KREHBIEL, T. C.; BERENSON, M. L. **Statistics for managers using Microsoft Excel**. 6^o ed. Pearson Education, 2011.

LIN, Y. K.; CHANG, P. C. Performance indicator for a stochastic-ow manufacturing network with reworking actions based on reliability. **Scientia Iranica E**, v. 20, n. 6, p. 2201{2214, 2013a.

LIN, Y. K.; CHANG, P. C. Reliability-based performance indicator for a manufacturing network with multiple production lines in parallel. **Journal of Manufacturing Systems**, v. 32, n. 1, p. 147–153, 2013b. The Society of Manufacturing Engineers.

MACCHI, M. Comparing Performance Measures for the Trade Off of Flow Time and Throughput in. **IFIP International Federation for Information Processing**, v. 257, p. 143–150, 2008.

MAHMOOD, K.; QURESHI, I. M. A.; NISAR, A. An empirical study on measurement of performance through TQM in Pakistani aviation manufacturing industry. **International Journal of Quality & Reliability Management**, v. 31, n. 6, p. 665–680, 2014.

MAIA, A. L. S.; CARVALHO, F. A. Holt's exponential smoothing and neural network models for forecasting interval-valued time series. **International Journal of Forecasting**, v. 27, p. 740–759, 2011.

MANUPATI, V. K.; THAKKAR, J. J.; WONG, K. Y.; TIWARI, M. K. Near optimal process plan selection for multiple jobs in networked based manufacturing using multi-objective evolutionary algorithms. **Computers and Industrial Engineering**, v. 66, n. 1, p. 63–76, 2013. Elsevier Ltd.

MARTINS, R. A.; MELLO, C. H. P.; TURRIONI, J. B. **Guia para elaboração de monografia e TCC em engenharia de produção**. 1^a ed. ed. São Paulo: Atlas, 2014.

MATIJAŠ, M. **Electric Load Forecasting Using Multivariate Meta-Learning**, 2013. University of Zagreb.

METTERNICH, J.; BECHTLOFF, S.; SEIFERMANN, S. Efficiency and economic evaluation of cellular manufacturing to enable lean machining. Forty Sixth CIRP Conference on Manufacturing Systems 2013. **Anais v. 7, p.592–597, 2013. Elsevier B.V.**

MOHAMMADZADEH, A.; REZAZADEH, A.; NAZARI-SHIRKOUHI, S.; GHADAMYARI, M.; DALVAND, M. R. A performance measurement system under activity based costing for advanced manufacturing systems by an integrated fuzzy AHP-fuzzy TOPSIS approach. **Scientific Research and Essays**, v. 6, n. 22, p. 4856–

4866, 2011.

EL MOLA, K. G.; PARSAEI, H. Dimensions and measures of manufacturing performance measurement. 40th International Conference on Computers and Industrial Engineering: Soft Computing Techniques for Advanced Manufacturing and Service Systems. **Anais** p.607–612, 2010.

NENADÁL, J. Process performance measurement in manufacturing organizations. **International Journal of Productivity and Performance Management**, v. 57, n. 6, p. 460–467, 2008.

NGUYEN, D.; WIDROW, B. Improving the Learning Speed of two-layer Neural Networks by Choosing Initial Values of the Adaptive Weights. Proc. Int. Joint Conf. Neural Networks. **Anais** p.21–26, 1990. Ann Arbor.

NUDURUPATI, S. S.; BITITCI, U. S.; KUMAR, V.; CHAN, F. T. S. State of the art literature review on performance measurement. **Computers and Industrial Engineering**, v. 60, n. 2, p. 279–290, 2011.

O'DRISCOLL, E.; ÓG CUSACK, D.; O'DONNELL, G. E. The development of energy performance indicators within a complex manufacturing facility. **International Journal of Advanced Manufacturing Technology**, v. 68, n. 9–12, p. 2205–2214, 2013.

O'KANE, J. Simulating production performance: cross case analysis and policy implications. **Industrial Management & Data Systems**, v. 104, n. 4, p. 309–321, 2004.

OLIVELLA, J.; GREGORIO, R. A case study of an integrated manufacturing performance measurement and meeting system. **Journal of Manufacturing Technology Management**, v. 26, n. 4, p. 515–535, 2015.

PAOLI, C.; VOYANT, C.; MUSELLI, M.; NIVET, M. L. Forecasting of preprocessed daily solar radiation time series using neural networks. **Solar Energy**, v. 84, n. 12, p. 2146–2160, 2010. Elsevier Ltd. Disponível em: <<http://dx.doi.org/10.1016/j.solener.2010.08.011>>. .

PARTHIBAN, P.; GOH, M. An integrated model for performance management of manufacturing units. **Benchmarking: An International Journal**, v. 18, n. 2, p. 261–281, 2011.

PINTZOS, G.; MATSAS, M.; CHRYSOLOURIS, G. Defining manufacturing performance indicators using semantic ontology representation. 45th CIRP Conference on Manufacturing Systems 2012. **Anais** v. 3, p.8–13, 2012.

PLEHN, J.; ZÜST, R.; KIMURA, F.; SPROEDT, A.; SCHÖNSLEBEN, P. A method for determining a functional unit to measure environmental performance in manufacturing systems. **CIRP Annals - Manufacturing Technology**, v. 61, n. 1, p. 415–418, 2012.

POLYA, G. **How to Solve It: A New Aspect of Mathematical Method**. 1° ed ed. Princeton University Press., 2004.

PSOMAS, E.; KAFETZOPOULOS, D. Performance measures of ISO 9001 certified and non-certified manufacturing companies. **Benchmarking: An International Journal**, v. 21, n. 5, p. 756–774, 2014.

QIAO, J.; LI, S.; LI, W. Mutual information based weight initialization method for

sigmoidal feedforward neural networks. **Neurocomputing**, v. 207, p. 676–683, 2016. Elsevier. Disponível em: <<http://dx.doi.org/10.1016/j.neucom.2016.05.054>>. .

REZAI, K.; DEGHANBAGHI, M.; EBRAHIMPOUR, V. Performance evaluation of manufacturing systems based on dependability management indicators-case study: Chemical industry. **International Journal of Advanced Manufacturing Technology**, v. 43, n. 5–6, p. 608–619, 2009.

REZAZADEH, A.; MOHAMMADZADEH, A.; GHADAMYARI, M.; NAZARI-SHIRKOUHI, S.; DALVAND, M. R. Fuzzy multi criteria decision making approach for performance measurement of advanced manufacturing systems. **Indian Journal of Science and Technology**, v. 4, n. 10, p. 1295–1302, 2011.

RIBEIRO, D.; BRAGA, F.; SOUSA, R.; CARMO-SILVA, S. An application of the smed methodology in an electric power controls company. **Romanian Review Precision Mechanics, Optics and Mechatronics**, , n. 40, p. 115–122, 2011.

ROUSE, P.; PUTTERILL, M. An integral framework for performance measurement. **Management Decision**, v. 41, n. 8, p. 791–805, 2003. Disponível em: <<http://www.emeraldinsight.com/doi/10.1108/00251740310496305>>. .

ROVAI, A. P.; BAKER, J. D.; PONTON, M. K. **Social science research design and statistics: A practitioner's guide to research methods and IBM SPSS**. Watertree Press LLC, 2013.

RUIGAR, H.; GOLIAN, S. Prediction of precipitation in Golestan dam watershed using climate signals. **Theoretical and Applied Climatology**, v. 123, n. 3–4, p. 671–682, 2016. Disponível em: <<http://link.springer.com/10.1007/s00704-015-1377-2>>. .

SARMIENTO, R.; BYRNE, M.; BEALE, J.; KNOWLES, G. An exploratory study on contextual variables and manufacturing efficiency. **International Journal of Services and Operations Management**, v. 5, n. 3, p. 275–298, 2009.

SENKUVIENĖ, I.; JANKAUSKAS, K.; KVIETKAUSKAS, H. Using manufacturing measurement visualization to improve performance. **Mechanika**, v. 20, n. 1, p. 99–107, 2014.

SETIJONO, D. DisPMO and DePMO as six sigma-based forward-looking quality performance measures. **The TQM Journal**, v. 20, n. 6, p. 588–598, 2008.

SHARMA, V. **Electricity price time series forecasting in deregulated markets using recurrent neural network based approaches**, 2011. National University of Singapore.

SHEN, W.; GUO, X.; WU, C.; WU, D. Forecasting stock indices using radial basis function neural networks optimized by artificial fish swarm algorithm. **Knowledge-Based Systems**, v. 24, n. 3, p. 378–385, 2011. Elsevier B.V. Disponível em: <<http://dx.doi.org/10.1016/j.knosys.2010.11.001>>. .

SHI, Y.; ZHANG, J. The Application of Artificial Neural Network Model in Estimation of Single Tree Volume Growth. **IEEE International Conference on Industrial Engineering and Engineering Management**, , n. 200804022, p. 1–6, 2012.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Operations management**. Pearson Education, 2010.

SPINA, G.; CANIATO, F.; LUZZINI, D.; RONCHI, S. Past, present and future

trends of purchasing and supply management: An extensive literature review. **Industrial Marketing Management**, v. 42, p. 1202–1212, 2013.

STASINAKIS, C. **Applications of Hybrid Neural Networks and Genetic Programming in Financial Forecasting**, 2013. University of Glasgow. Disponível em: <<http://theses.gla.ac.uk/4921/>>. .

SUEYOSHI, T.; GOTO, M. Measurement of a linkage among environmental, operational, and financial performance in Japanese manufacturing firms: A use of Data Envelopment Analysis with strong complementary slackness condition. **European Journal of Operational Research**, v. 207, n. 3, p. 1742–1753, 2010. Elsevier B.V.

SWEENEY, D. J.; WILLIAMS, T. A.; ANDERSON, D. R. **Fundamentals of business statistics**. 6^o ed. Cengage Learning, 2013.

SZOPLIK, J. Forecasting of natural gas consumption with artificial neural networks. **Energy**, v. 85, p. 208–220, 2015. Elsevier Ltd. Disponível em: <<http://dx.doi.org/10.1016/j.energy.2015.03.084>>. .

TANGEN, S. Performance measurement: from philosophy to practice. , 1997.

TEMUR, G. T.; EMEKSIZOGLU, B.; GOZLU, S. A study on performance measurement of a plastic packaging organization's manufacturing system by AHP modeling. Portland International Conference on Management of Engineering and Technology. **Anais** p.1256–1263, 2007.

TONI, A. DE; TONCHIA, S. Performance measurement systems Models , characteristics and measures. , 1992.

TRANFIELD, D.; DENYER, D.; SMART, P. Towards a methodology for developing evidence-informed management knowledge by means of systematic review *. **British Journal of Management**, v. 14, p. 207–222, 2003.

TRAORE, S.; LUO, Y.; FIPPS, G. Deployment of artificial neural network for short-term forecasting of evapotranspiration using public weather forecast restricted messages. **Agricultural Water Management**, v. 163, p. 363–379, 2016. Elsevier B.V. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2015.10.009>>. .

TRIANTIS, K.; OTIS, P. Dominance-based measurement of productive and environmental performance for manufacturing. **European Journal of Operational Research**, v. 154, n. 2, p. 447–464, 2004.

TSENG, F. M.; CHIU, Y. J.; CHEN, J. S. Measuring business performance in the high-tech manufacturing industry: A case study of Taiwan's large-sized TFT-LCD panel companies. **Omega**, v. 37, n. 3, p. 686–697, 2009.

TSIKRIKTSIS, N. A review of techniques for treating missing data in OM survey research. **Journal of Operations Management**, v. 24, n. 1, p. 53–62, 2005.

UNIDO. **The Industrial Competitiveness of Nations. Looking back, forging ahead**. 2013.

UYAR, A. Quality performance measurement practices in manufacturing companies. **The TQM Journal**, v. 21, n. 1, p. 72–86, 2009.

VERRIER, B.; ROSE, B.; CAILLAUD, E.; REMITA, H. Combining organizational performance with sustainable development issues: the Lean and Green project benchmarking repository. **Journal of Cleaner Production**, v. 85, p. 83–93, 2014. Elsevier Ltd.

WANG, L.; ZENG, Y.; CHEN, T. Back propagation neural network with adaptive differential evolution algorithm for time series forecasting. **Expert Systems with Applications**, v. 42, n. 2, p. 855–863, 2015. Elsevier Ltd. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0957417414004941>>. .

WANG, Q. L.; LI, C. B. Environmental Performance Measurement for Green Manufacturing Program Based on BP Neural Network. **Key Engineering Materials**, v. 439–440, p. 999–1005, 2010.

WANG, Q.; LI, B. Innovative metrics for machine performance measurement and their applications in semiconductor manufacturing. 16th International Conference on Industrial Engineering and Engineering Management. **Anais** p.793–797, 2009.

WONG, C.; VERSACE, M. CARTMAP: a neural network method for automated feature selection in financial time series forecasting. **Neural Computing and Applications**, v. 21, n. 5, p. 969–977, 2012. Disponível em: <<http://link.springer.com/10.1007/s00521-012-0830-8>>. .

WONG, W. K.; XIA, M.; CHU, W. C. Adaptive neural network model for time-series forecasting. **European Journal of Operational Research**, v. 207, n. 2, p. 807–816, 2010. Elsevier B.V. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0377221710003784>>. .

WRIGHT, J.; SILVA, A.; SPERS, R. Prospecção de cenários: uma abordagem plural para o futuro do Brasil em 2020. **Revista Ibero Americana de Estratégia**, v. 9, n. 1, p. 56–76, 2010.

WU, J.-D.; LIU, J.-C. A forecasting system for car fuel consumption using a radial basis function neural network. **Expert Systems with Applications**, v. 39, n. 2, p. 1883–1888, 2012. Elsevier Ltd. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0957417411011729>>. .

YANG, C.-C.; LEU, Y.; LEE, C.-P. A dynamic weighted distancebased fuzzy time series neural network with bootstrap model for option price forecasting. **Romanian Journal of Economic Forecasting**, , n. 2, p. 115–129, 2014.

YANG, C.-L. L.; CHUANG, S.-P. P.; HUANG, R.-H. H. Manufacturing evaluation system based on AHP/ANP approach for wafer fabricating industry. **Expert Systems with Applications**, v. 36, n. 8, p. 11369–11377, 2009. Elsevier Ltd.

YIANGKAMOLSING, C.; BOHEZ, E. L.; BUEREN, I. Universal design (UD) principles for flexible packaging and corresponding minimal customer requirement set. **Packaging Technology and Science**, v. 23, n. 5, p. 283–300, 2010.

YOLCU, U.; EGRIOGLU, E.; ALADAG, C. H. A new linear & nonlinear artificial neural network model for time series forecasting. **Decision Support Systems**, v. 54, n. 3, p. 1340–1347, 2013. Elsevier B.V. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0167923612003557>>. .

YU, T. H.-K.; HUARNG, K.-H. A neural network-based fuzzy time series model to improve forecasting. **Expert Systems with Applications**, v. 37, n. 4, p. 3366–3372, 2010. Elsevier Ltd. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417409008793>>. .

ZAIM, O. Measuring environmental performance of state manufacturing through changes in pollution intensities: A DEA framework. **Ecological Economics**, v. 48, n. 1, p. 37–47, 2004.

ZHU, L.; SU, H.; LU, S.; WANG, Y.; ZHANG, Q. Coordinating and Evaluating of Multiple Key Performance Indicators for Manufacturing Equipment: Case Study of Distillation Column. **Chinese Journal of Chemical Engineering**, v. 22, n. 7, p. 805–811, 2014. Elsevier B.V.

APÊNDICE A. INDICADORES DE DESEMPENHO IDENTIFICADOS NA REVISÃO SISTEMÁTICA DA LITERATURA

Classification	Customer Indicator	Paper evidences
Cost	Warranty cost	4
	Expenditure on identifying and ensuring customers satisfaction	1
Customer relationship	Customer loyalty	7
	Number of new customers	4
	Customer diversification	3
	Litigations with customers	3
	Interaction with customer (meetings, surveys, feedback, cooperation)	2
	Customer orientation	1
Customer satisfaction	Customer complaints	24
	Customer satisfaction (general)	14
	Customer satisfaction from product characteristics	2
	Customer satisfaction from after sales services	1
Customer services	Service responsiveness	4
	Customer service representatives attitude, knowledge and skill of handling problems	2
	Quality of customer service	2
	Use of information and communication system for customer service	2
	Quickness in transferring the problem to the person who could solve it in the best way	1
	Technical supports provided to the customer	1
Dependability	On time delivery to customer	26
	Customer lead time	10
	Response time to customer requests	5
	Shipment accuracy	4
	Average delay	3
	Number of customer orders completed	1
Environment	Customer requirement to meet environmental performance	1
Quality	Return rate	15
	Warranty Claims Rate	11
	Customer perceived value	1
	No. of customer-detected design faults	1
Reverse Logistics	Buyer Supplier Relationship	1
	Effectiveness of collection planning schedule	1
	Recovery	1
	Reverse Logistics Cycle Time	1
	Reverse Logistics Fuel Consumption	1
	Reverse Logistics Machine Availability	1
	Reverse Logistics Profit	1
	Reverse Logistics Quality of documentation	1
	Reverse Logistics Return on Investment	1

Classification	Customer Indicator	Paper evidences
Sales	Accuracy of interpretation of customer requirements	1
	Accuracy of prediction of customer requirements	1
	Number of customer orders received	1
	Sales by customer recommendation	1

Classification	Product Indicator	Paper evidences
Dependability	Product Availability	2
Development	Number of new product launches	12
	Number of new patents	8
	Percent of products protected by patents	4
	Percent of sales due to new products	4
	Percent of sales from proprietary products	3
	Actual innovation rate	2
	Future innovation rate	1
	Number of product development initiatives	1
Development and Sustainability	Development of environmental friendly product design and packaging	2
	Design for disassembly	1
	Product passes safety tests	1
Development Financial	R&D expenditure	10
	Development project cost compared to budget	1
	Development projected profitability analysis	1
	Product development project payback time	1
Development Quality	Amount of technical changes in production	2
	Extent to which process design 'fool-proof' and minimize chances of employee errors	2
	Rate of successful product development projects	2
	Reworks and delay time caused by design failures	1
Development Time	Time-to-market new products	20
	On-time delivery of development project	2
	Time for completion of different types of product development projects	2
	Time spent on each stage of product development	2
	Ramp-up time	1
	Speed of changes in designs	1
	Speed of changes in product mix	1
Environment	Corporate effort to yield environmental protection products	2
	Environment friendliness relative to competitors	1
	Percentage of products and services, which are during their life cycle assessed for health and safety impacts	1
Financial	Unit product cost	11
	Reduction in product cost	4
	Cost of inferior products	1

Classification	Product Indicator	Paper evidences
	Life-cycle cost	1
	Product Inventory Cost	1
	Product profitability	1
	Product resale price	1
	Revenue per unit	1
Flexibility	Product variety	13
	Ability to customize production	6
	Percentage of standard, common, and unique parts	1
Quality	Final Product Quality level	7
	Product reliability	7
	Product durability	5
	Product functionality relative to competitors	2
	Product performance	2
	Conformity with requirements or expectations	1
	Product failure rates	1
	Products consistency	1
	Reasons for failures on the market	1

Classification	Equipment Indicator	Paper evidences
Cost	Maintenance costs	5
	Setup cost	5
	Energy costs	4
	Machine costs	3
	Tooling cost	2
	Failure cost	1
Dependability	Availability (equipment or facility)	11
	Equipment downtime	10
	Mean time between failures (MTBF)	4
	Machine capacity	2
	Failure rate	1
Efficiency	Equipment utilization	16
	Setup Time	11
	Overall Equipment Effectiveness (OEE)	8
	Equipment production rate	2
	Number of machines idle	1
Environment	Energy consumption	12
Flexibility	Number of parts produced by a machine	5
	Possibility of producing parts on different machines	5
	Set-up time flexibility	2
	Multipurpose tools usage	1
Maintenance	Age of plant and equipment	4

Classification	Equipment Indicator	Paper evidences
	Frequency of maintenance	4
	Extent to which preventive/productive maintenance work is carried	1
	Maintenance value added	1
	Mean Time To Repair	1
	Preventive maintenance completion as planned	1

Classification	Employee Indicator	Paper evidences
Dependability	Employee turnover	14
	Absenteeism	13
	Employee Lateness	3
	Number of employees	3
	Employee reliability	1
	Key staff turnover	1
	Number of new employees	1
Efficiency and Productivity	Labour productivity	4
	Labour efficiency variance	4
	Manpower utilization	4
	Proportion of overtime worked	2
	Labour rate variance	1
	Lost people potential	1
Environment	Employees involved in environmental performance improvements and green teams	1
Financial	Labour cost	10
	Overtime Pay	2
	Employee wage rate	1
Flexibility	Cross-training of production personal	3
	Workers authorized to inspect their own work	1
Knowledge	Employee improvement suggestions and participation	2
	Employee qualification and working experiences	1
	Percentage of skilled workers	1
	Promotion and personal development	1
	Willingness of employees to share knowledge	1
	Workers encouraged to solve problems	1
Morale	Employee involvement	5
	Employee satisfaction	5
	Employee attitude	3
	Employee complaints	3
	Profit share or other incentive plans	3
	Motivation of personnel	2
	Empowerment	1
	Number of Suggestions	1
	Injury rate	12

Classification	Employee Indicator	Paper evidences
Occupational health and safety	Occupational diseases and illnesses	4
	Insurance plans	3
	Employees knowledge of health and safety policy	2
	Lost time incidents	2
	Percentage of staff attending safety committee meetings	2
	Fatalities	1
	Number of Safe Days	1
	Safety check rate	1
Social	Gender equity	6
	Labour-Management relations	4
	Discrimination rate	1
	Number of employee hours per shift	1
	Percentage of employees covered by collective bargaining agreement	1
Training	Frequency of training and retraining	11
	Training expenses	6
	Training by outside trainers	2
	Environmental training	1
	No of apprentices	1
	On-job training for new starters	1
	Participation of employees as trainers	1
	Safety training budget	1
	Satisfaction of employees with overall training	1

Classification	Material Indicator	Paper evidences
Cost	Material cost	8
	Scrap cost	3
	Material Handling Cost	2
Dependability	Material availability	4
	On Time Delivery Raw Material	4
	Percentage of spare materials	1
	Production delay caused by late deliveries	1
	Purchase order errors	1
Efficiency	Materials efficiency variance	3
Environment	Material consumption/usage	8
	Material recycling	3
	Environment friendly raw materials usage	2
	Materials disposed	1
Flexibility	Material Handling Flexibility	4
	Raw material substitution possibility	4
Quality	Scrap Rate	18
	Quality of incoming materials	2

Classification	Material Indicator	Paper evidences
	Spoilage material rate	1
Supplier and Environment	Environmental audits or certification programs are to be carried out by the firm on its suppliers	1
	Environmental performance used as one of the criteria when choosing a supplier	1
	Environmental policies of the company are clearly communicated to the supplier	1
Supplier and Quality	Extent to which you select suppliers based on quality rather than price or schedule	1
	Supplier quality management	1
Supplier and Social Performance	Supplier Social certification	1
	Supplier Social commitment	1
	Supplier Social initiative	1
Supplier Relations	Supplier's coordination and relation	2
	Clarity of specifications provided to your suppliers	1
	Extension of long-term contracts to your suppliers	1
	Supplier rating	1
Supplier Time	Supplier lead time	1

Classification	Production Process Indicator	Paper evidences
Cost	Overhead cost of manufacturing	8
	Inventory cost	6
	Cost of quality	4
	Changeover cost	2
	Non-conformance costs	2
	Operational costs	1
	Process related cost	1
	Rework cost	1
	Shortage costs	1
	Utilization costs	1
	Waste disposal costs	1
Delivery	average truck operating time in system	1
	average waiting time for loading trucks	1
	percentage of tardy performance trucks	1
	Premium freights	1
	Responsiveness to urgent deliveries	1
	throughput of trucks	1
	transportation error: material change	1
Dependability	Process Capability	4
	Process reliability	4
	Capacity utilization	3
	Process Maintainability	1
	Systems failure	1
Effectiveness	Process effectiveness	2

Classification	Production Process Indicator	Paper evidences
	Cost Time Effectiveness	1
	Effectiveness of work time consumption	1
	Overall Resource Effectiveness	1
Efficiency	Process yield	8
	Production efficiency	6
	Manufacturing cycle efficiency	4
	Ratio of non-value-added to value-added activities	2
	Assembly Line efficiency	1
	Changeover efficiency	1
	Cost efficiency	1
	Inappropriate processing	1
	Line Balancing Efficiency	1
	Overall Fab Efficiency (OFE)	1
	Production line speed	1
	Waiting	1
Environment	Air emission (CO, Nox, Sox, CO ₂ , CH ₄ , N ₂ O, SF ₆ , HFCs and PFCs, volatile organic compound)	9
	Solid waste	8
	Water consumption	7
	Fuel consumption	2
	Hazardous waste	2
	Pollution intensity	2
	Water waste	2
	Eutrophication	1
	Land emission	1
	Land utilization	1
	Noise pollution	1
	Reduction in ozone depleting substance use	1
	Scrap metal	1
Flexibility	Volume Flexibility	8
	Lot size flexibility	5
	Process modification flexibility	5
	Expansion flexibility	4
	Production flexibility	4
	Routing flexibility	4
	Inventory flexibility	2
	Operation flexibility	2
	Program flexibility	2
	Technology flexibility	2
	Components production flexibility	1
	Cycle time Flexibility	1
	Delivery Flexibility	1
Minimum size order	1	

Classification	Production Process Indicator	Paper evidences
	No. of engineering changes	1
	Number of different parts and processes	1
Improvement	Development in manufacturing processes	2
	Degree of automation of the process	1
	Number of standard and advance features	1
Inventory	Work-in-process inventory (WIP)	10
	Inventory turnover ratio	5
	Inventory level	4
	Amount of components in the inventory	1
	Defective Inventory %	1
	Inventory accuracy	1
	Missing material amount	1
	Undefined material amount	1
	Unnecessary inventory	1
Layout	Unnecessary motion	4
	Product flow	1
	Work space area	1
Productivity	Production volume	10
	Schedule attainment	10
	Overall productivity	8
	Line Assembly Productivity	1
	Overproduction	1
	Unit of output per hours of labour used	1
	Unit of output per square foot used	1
Quality	Defect rate	20
	Rework Rate	17
	Quality rate (Conformance to specification)	14
	Reject rate	6
	Quality improvements	2
	System effectiveness in identifying non-conformance of product	2
	Amount of final inspection, review or checking	1
	Consistency in quality	1
	Extent to which inspection, review, or checking of work is automated	1
	Quality information usage	1
Time	Cycle time	20
	Manufacturing lead time	9
	Due date adherence	8
	Throughput time	8
	Flow Time	6
	Delivery speed	5
	Changeover time	4
	Completion time of an activity	2
	Cycle time utilization	2

Classification	Production Process Indicator	Paper evidences
	Makespan	2
	Processing Time	2
	Production Time	2
	Reconfiguration time	2
	Assembly lead time	1
	Manual handling time	1
	Process response time	1
	Takt time	1
	Time spent on rework/reprocessing	1

Classification	Corporate Indicator	Paper evidences
Environment	Environment capital usage	3
	governance structure for environmental safety and protection	2
	Resources usage	2
	Corporate effort for pollution protection	1
	Corporate effort to enhance recycling activities	1
	Corporate effort to prevent global warming and climate change	1
	Development and implementation of environment policy and green plan	1
	Financial impact of environmental performance	1
	Indicators providing information on the local, regional, or national condition of the environment	1
	Land used	1
	Market share due to green image of company	1
	Top management involvement and monitoring of the environmental activity progress	1
Financial	Cash flow	8
	Operating Costs	8
	Return on equity (ROE)	7
	Profit margin	6
	Return on Assets (ROA)	6
	Return on sales (ROS)	6
	Account receivable turnover	5
	Net assets	5
	Operating income	5
	Return on investment (ROI)	5
	Capital structure and value	4
	Earnings per share	4
	Economic Value Added (EVA)	4
	Future investment needs	3
	Quality accounting policies	3
	Sales Revenue	3
	Total costs by department	2
Consistency of investment over time	1	

Classification	Corporate Indicator	Paper evidences
	Debts	1
	Export revenues	1
	Liquidity	1
	Market value	1
	Number of doubtful account receivable	1
	Payback time	1
	Stock price	1
	Tobin's q ratio	1
	Total accumulated expenses vs. financial Budget	1
	Total of cash disbursements	1
	working capital ratio	1
Flexibility	Ability to fill in the gaps in customer needs and production	1
	Percentage of adjusting facilities	1
Governance	Fluctuation of Corporate Governance	4
	Ethical behaviour of management	3
	Experience/Reputation of management	3
	Corporate Governance composition	1
	Managerial flexibility	1
	Percentage of women within Corporate Governance	1
	Qualification and skills of Corporate Governance members	1
	Top management monitoring the progress	1
	Top management playing key role for resource allocation	1
	Top management responsibility for planning for change	1
	Top management support	1
	Total annual salaries and bonuses of Corporate Governance members	1
Health and safety	Development and implementation of health and safety policies	5
	Health and safety auditing	2
	health and safety capital costs	2
	Facilities safety	1
	Organizing for safety (control, communication, co-operation, competence)	1
	Top management and workforce involvement in health and safety	1
Knowledge management & IT	Investment in Knowledge Management	4
	Bottom line impact through knowledge management program	1
	Extent to which IT tools usage	1
	Information resources	1
	Number of times the knowledge has helped to solve problems	1
	Organizational learning program	1
	Percentage of reduction in total number of data	1
	Presentations, meetings, discussion etc. help to create new knowledge	1
	Suitability of organization culture for knowledge management	1
	Use of e-procurement	1

Classification	Corporate Indicator	Paper evidences
Marketing and Sales	Market share	12
	Sales growth	6
	Sales volume	6
	Sales rate	5
	Brand Awareness	3
	Geographic diversification	3
	Litigations due to break of market competition rules	3
	Potential for new competitors	3
	Company image in the market	2
	Market flexibility	2
	Average sales order	1
	Entrance to new markets	1
	Sales by company brand name	1
	Sales from production	1
Quality	Development of quality policies and system	2
	Encouragement of a company commitment to quality improvement	1
	Top management assumes that manufacturing quality improvement is a way to increase profit	1
	Top management involved in strategic quality management	1
Results	Organizational achievements	2
	Company efficiency	1
	Company growth	1
	Company productivity	1
	Factual approach to decision making	1
	Results orientation & value creation	1
Shareholders	Dispersion of Ownership	4
	Participation of shareholders on the firm's management	3
	Shareholder disputes	3
	Shareholders' equity	1
Social	Community relations	3
	Litigation with the community	2
	Community satisfaction	1
	Contributions to political parties, politicians and related institutions	1
	Corporate social responsibility & citizenship	1
	Donations	1
	Firm's culture and values	1
	Neighbouring community complaints	1
	Number of convictions for violations of laws or regulations relating to corruption	1
	Stakeholders complaints	1
	Total number of sanctions for anticompetitive behaviour	1
Total number of sanctions for breaching the law	1	
	Strategic alliances	4

Classification	Corporate Indicator	Paper evidences
Supply-chain relationships	Distribution network	1
	Supply Chain management	1

APÊNDICE B. INDICADORES DE DESEMPENHO DA EMPRESA A.

Categoria	Indicador
Clientes	Nível serviços das transportadoras A
	Nível serviços das transportadoras B
	Prazo de recebimento A
	Prazo de recebimento B
	Reclamação do cliente geral
	Reclamação do cliente Produto A
	Reclamação do cliente Produto B
	Reclamação do cliente Produto C
	Tempo total de resposta de reclamações
Corporação	Disponibilidade da internet/intranet/e-mail
	Disponibilidade da rede LAN e WAN
	Disponibilidade dos servidores
	Disponibilidade dos sistemas corporativos
	Implantação de novos projetos de grandes melhorias (mensal)
	Implantação de novos projetos de grandes melhorias (últimos 12 meses)
Equipamentos	Consumo de energia Fábrica 01
	Consumo de energia Fábrica 02
	Consumo de óleo combustível Fábrica 01
	Consumo de óleo combustível Fábrica 02
	Disponibilidade da automação industrial
	Horas de mão-de-obra em preditiva e preventiva
	Scrap consolidado do produto A total
	Scrap direto do produto A com re-exame
	Scrap direto do produto A sem re-exame
	Scrap direto do produto A.1 sem re-exame
	Scrap direto do produto A.2 sem re-exame
	Scrap direto do produto A.3 sem re-exame
	Scrap total de extrusão
	Scrap total de mistura de compostos
Externos	CDI mês
	CUB-PR SEM DESONERAÇÃO acumulado 12 meses
	CUB-PR SEM DESONERAÇÃO mês
	Dólar Oficial último dia mês
	Euro último dia mês
	IGP-DI/FGV mês
	IGP-DI/FGV últimos 12 meses
	IGP-M/FGV mês
	IGP-M/FGV últimos 12 meses
	INCC-DI últimos 12 meses
	INCC-DI/FGV mês
	INPC/IBGE mês
	INPC/IBGE últimos 12 meses
	IPA-DI/FGV mês
	IPA-DI/FGV últimos 12 meses
	IPC/FIPE mês
	IPC/FIPE últimos 12 meses
	IPCA/IBGE mês
IPCA/IBGE últimos 12 meses	

	IPCA-E/IBGE mês
	IPC-DI/FGV mês
	IPC-DI/FGV últimos 12 meses
	Petróleo Brent último dia mês
	Risco Brasil
	Salário mínimo nacional
	Salário mínimo Paraná-Agropecuária
	Salário mínimo Paraná-Industrial
	SELIC acumulada em 12 Meses
	SELIC mensal
	Taxa de desemprego
	Valor médio ponderado do dólar efetivo dos câmbios realizados
Funcionários	Horas de treinamento de funcionário geral ano
	Horas de treinamento de funcionário geral mês
	Horas de treinamento de funcionário indireto ano
	Horas de treinamento de funcionário indireto mês
	Horas de treinamento de funcionário industrial ano
	Horas de treinamento de funcionário industrial mês
	Índice de absenteísmo da mão de obra
	Índice de rotatividade da mão de obra
	Número de funcionários da área industrial (com temporários)
	Número de funcionários da área industrial (sem temporários)
	Número de funcionários da Fábrica 01 (com temporários)
	Número de funcionários da Fábrica 01 (sem temporários)
	Número de funcionários da Fábrica 02 (com temporários)
	Número de funcionários da Fábrica 02 (sem temporários)
	Número total de funcionários (diretos e indiretos)
	Número total de funcionários indiretos
Processo	Custo dos produtos defeituosos
	Erro de produção Produto A
	Erro de produção Produto B
	Erro de produção Produto C
	Erros de produção geral
	Implantação de pequenas melhorias no processo (12 meses)
	Implantação de pequenas melhorias no processo (mensal)
	Produtividade por funcionário da fábrica 1
	Produtividade por funcionário da fábrica 2
	Quantidade de dias de produção Fábrica 1
	Quantidade de dias de produção Fábrica 2
	Reprocesso de montagem e vulcanização
	Reprocesso de set-up extrusora
	Retrabalho direto Produto A
	Retrabalho direto Produto A.1
	Retrabalho direto Produto A.2
	Retrabalho direto Produto A.3
	Variação do peso acabado real do produto A

APÊNDICE C. INDICADORES DE DESEMPENHO DA EMPRESA B.

Categoria	Indicador
Clientes	PARTICIPAÇÃO COOPERATIVA NO CENTRO-SUL (AGROPECUÁRIO)
	PARTICIPAÇÃO COOPERATIVA NO NOROESTE (AGROPECUÁRIO)
	PARTICIPAÇÃO COOPERATIVA NO NORTE (AGROPECUÁRIO)
	PARTICIPAÇÃO COOPERATIVA NO OESTE (AGROPECUÁRIO)
	PARTICIPAÇÃO COOPERATIVA NO SUDOESTE (AGROPECUÁRIO)
	PARTICIPAÇÃO DA COOPERATIVA NO ESTADO (CONSOLIDADO TODOS RAMOS)
	PARTICIPAÇÃO DA REGIÃO CENTRO-SUL NO ESTADO (AGROPECUÁRIO)
	PARTICIPAÇÃO DA REGIÃO NOROESTE NO ESTADO (AGROPECUÁRIO)
	PARTICIPAÇÃO DA REGIÃO NORTE NO ESTADO (AGROPECUÁRIO)
	PARTICIPAÇÃO DA REGIÃO OESTE NO ESTADO (AGROPECUÁRIO)
	PARTICIPAÇÃO DA REGIÃO SUDOESTE NO ESTADO (AGROPECUÁRIO)
Corporação	COMPRAS ACUMULADAS
	CRESCIMENTO DOS INGRESSOS EXPURGADO
	CRESCIMENTO NOMINAL INGRESSOS/RECEITAS
	ESTOQUES
	TOTAL SOMA CONTAS PARA PONDERAÇÃO RANKING
Externos	CDI (ACUMULADO)
	CDI mês
	CUB (ACUMULADO)
	EURO
	IGP-DI
	IGP-DI (ACUMULADO)
	IGP-M
	IGP-M (ACUMULADO)
	INPC (ACUMULADO)
	IPCA (ACUMULADO)
	IPC-FIPE
	IPC-FIPE (ACUMULADO)
	POUPANÇA
	POUPANÇA (ACUMULADO)
	SELIC
	SELIC (ACUMULADO)
	USD FINAL DE MÊS
	USD MÉDIA MENSAL
	VARIAÇÃO ANUAL DÓLAR (%)
	VARIAÇÃO ANUAL EURO (%)
VARIAÇÃO ANUAL IGP-DI	
VARIAÇÃO ANUAL POUPANÇA	
Corporação	ATIVO FINANCEIRO
	ATIVO NÃO CIRCULANTE
	ATIVO OPERACIONAL
	ATIVOS: AGROPECUÁRIO
	ATIVOS: CONSUMO
	ATIVOS: CRÉDITO
	ATIVOS: EDUCACIONAL
	ATIVOS: INFRAESTRUTURA
	ATIVOS: SAÚDE
	ATIVOS: TODOS OS RAMOS

Categoria	Indicador
	ATIVOS: TRABALHO
	ATIVOS: TRANSPORTE
	ATIVOS: TURISMO E LAZER
	CAPITAL DE GIRO
	CAPITAL DE GIRO PRÓPRIO
	CAPITAL DE GIRO: FATURAMENTO
	CAPITAL SOCIAL POR ASSOCIADO
	CICLO FINANCEIRO
	DESPESAS ADMINISTRATIVAS
	DESPESAS COMERCIAIS
	DESPESAS PESSOAL
	DESPESAS TRIBUTÁRIAS OPERACIONAIS (%)
	DESPESAS TRIBUTÁRIAS OPERACIONAIS (R\$)
	EBITDA: EARNINGS BEFORE INTEREST RATES
	ENDIVIDAMENTO DE LONGO PRAZO
	ENDIVIDAMENTO FINANCEIRO DE LONGO PRAZO
	ENDIVIDAMENTO FINANCEIRO TOTAL
	ENDIVIDAMENTO TOTAL
	FATURAMENTO POR ASSOCIADO
	FATURAMENTO POR FUNCIONÁRIO
	FATURAMENTO: AGROPECUÁRIO
	FATURAMENTO: CONSUMO
	FATURAMENTO: CRÉDITO
	FATURAMENTO: EDUCACIONAL
	FATURAMENTO: INFRAESTRUTURA
	FATURAMENTO: SAÚDE
	FATURAMENTO: TODOS RAMOS
	FATURAMENTO: TRABALHO
	FATURAMENTO: TRANSPORTE
	FATURAMENTO: TURISMO E LAZER
	GARANTIA AO CAPITAL DE TERCEIROS
	GIRO DO ATIVO PERMANENTE
	GIRO DOS ATIVOS
	GRAU DE ENDIVIDAMENTO (IAGC-I)
	GRAU DE IMOBILIZAÇÃO (IAGC-I)
	IMOBILIZAÇÃO DE RECURSOS PRÓPRIOS
	IMOBILIZADO: AGROPECUÁRIO
	IMOBILIZADO: CONSUMO
	IMOBILIZADO: CRÉDITO
	IMOBILIZADO: EDUCACIONAL
	IMOBILIZADO: INFRAESTRUTURA
	IMOBILIZADO: SAÚDE
	IMOBILIZADO: TODOS RAMOS
	IMOBILIZADO: TRABALHO
	IMOBILIZADO: TRANSPORTE
	IMOBILIZADO: TURISMO E LAZER
	IMPOSTOS INCIDENTES S/ VENDAS E SERVIÇOS (%)
	IMPOSTOS INCIDENTES S/ VENDAS E SERVIÇOS (R\$)
	INDEPENDÊNCIA FINANCEIRA
	ÍNDICE DE AUTO-FINANCIAMENTO
	INGRESSOS E RECEITAS LIQUIDAS

Categoria	Indicador
	INGRESSOS LÍQUIDOS ANO ANTERIOR
	INGRESSOS TOTAIS ANO ANTERIOR ATUALIZADO. P/ IGP-DI
	INGRESSOS TOTAIS COOPERATIVA
	INGRESSOS TOTAIS: RAMO AGROPECUÁRIO
	LIQUIDEZ CORRENTE
	LIQUIDEZ CORRENTE (IAGC-I)
	LIQUIDEZ INTERNA
	LIQUIDEZ SECA
	LIQUIDEZ TOTAL
	MARGEM BRUTA
	MARGEM OPERACIONAL
	NECESSIDADE DE CAPITAL DE GIRO
	NECESSIDADE DE CAPITAL DE GIRO: FATURAMENTO
	PASSIVO NÃO CIRCULANTE
	PASSIVO OPERACIONAL
	PATRIMÔNIO LÍQUIDO
	PATRIMÔNIO LÍQUIDO
	PATRIMÔNIO LÍQUIDO POR ASSOCIADO
	PATRIMÔNIO LÍQUIDO: AGROPECUÁRIO
	PATRIMÔNIO LÍQUIDO: CONSUMO
	PATRIMÔNIO LÍQUIDO: CRÉDITO
	PATRIMÔNIO LÍQUIDO: INFRAESTRUTURA
	PATRIMÔNIO LÍQUIDO: SAÚDE
	PATRIMÔNIO LÍQUIDO: TODOS RAMOS
	PATRIMÔNIO LÍQUIDO: TRABALHO
	PATRIMÔNIO LÍQUIDO: TRANSPORTE
	PATRIMÔNIO LÍQUIDO: TURISMO E LAZER
	PERFIL DA DÍVIDA (IAGC-I)
	PERMANENTE
	PRAZO MÉDIO DE ESTOQUES
	PRAZO MÉDIO DE PAGAMENTO
	PRAZO MÉDIO DE RECEBIMENTO
	RENTABILIDADE DO ATIVO (IAGC-I)
	RENTABILIDADE DO CAPITAL INTEGRALIZADO
	RENTABILIDADE DOS ATIVOS
	REPRESENTATIVIDADE DAS DEVOLUÇÕES
	RESULTADO ANTES DESTINAÇÕES E DEPOIS AJUSTES
	RESULTADO FINANCEIRO (%)
	RESULTADO FINANCEIRO (R\$)
	RETORNO DOS INVESTIMENTOS
	SALDO DE TESOURARIA
	SOBRAS/PERDAS À DISPOSIÇÃO DA AGO
	SOBRAS: AGROPECUÁRIO
	SOBRAS: CONSUMO
	SOBRAS: CRÉDITO
	SOBRAS: INFRAESTRUTURA
	SOBRAS: SAÚDE
	SOBRAS: TODOS RAMOS
	SOBRAS: TRABALHO
	SOBRAS: TRANSPORTE
	TERMÔMETRO DE SOLVÊNCIA (LIQUIDEZ INTERNA)

Categoria	Indicador
	TERMÔMETRO DE SOLVÊNCIA KANITZ
	TESOURARIA (%)
	TESOURARIA: FATURAMENTO
	TOTAL ATIVOS
	TOTAL DESPESAS TRIBUTÁRIAS (%)
	TOTAL DESPESAS TRIBUTÁRIAS (R\$)
	TOTAL DISPÊNDIOS/DESPESAS OPERACIONAIS
	VARIAÇÃO DA NECESSIDADE DE CAPITAL DE GIRO
	VARIAÇÃO PATRIMONIAL (IAGC-I)
Funcionários	QUANTIDADE DE ASSOCIADOS
	QUANTIDADE DE ASSOCIADOS: AGROPECUÁRIO
	QUANTIDADE DE ASSOCIADOS: CONSUMO
	QUANTIDADE DE ASSOCIADOS: EDUCACIONAL
	QUANTIDADE DE ASSOCIADOS: INFRAESTRUTURA
	QUANTIDADE DE ASSOCIADOS: TODOS RAMOS
	QUANTIDADE DE ASSOCIADOS: TRABALHO
	QUANTIDADE DE FUNCIONÁRIOS
	QUANTIDADE DE FUNCIONÁRIOS: AGROPECUÁRIO
	QUANTIDADE DE FUNCIONÁRIOS: EDUCACIONAL
	QUANTIDADE DE FUNCIONÁRIOS: INFRAESTRUTURA
	QUANTIDADE DE FUNCIONÁRIOS: TRANSPORTE
	REMUNERAÇÃO MÉDIA DOS EMPREGADOS
	REMUNERAÇÃO MÉDIA DOS EMPREGADOS HOMENS
	VALORES A PAGAR ASSOCIADOS/ATIVO TOTAL
	VALORES A RECEBER ASSOCIADOS / PL
	VALORES A RECEBER ASSOCIADOS / VALORES A PAGAR ASSOCIADOS
	VALORES A RECEBER ASSOCIADOS/ATIVO TOTAL

APÊNDICE D. INDICADORES DE DESEMPENHO DA EMPRESA C.

Categoria	Indicador
Cientes	Compra média por cliente
	Devoluções
	Preço médio por kg Cliente 1
	Preço médio por kg Cliente 3
	Preço médio por kg Cliente 4
	Preço médio por kg Cliente 5
	Preço médio por kg Cliente 6
	Preço médio por kg Cliente 7
	Preço médio por kg Cliente 8
	Preço médio por kg Cliente 9
	Preço médio por kg Segmento 1
	Preço médio por kg Segmento 2
	Preço médio por kg Segmento 3
	Preço médio por kg Segmento 4
	Preço médio por kg Segmento 5
	Preço médio por kg Segmento 6
	Quantidade de clientes
	Quantidade de clientes que compraram acima de 5 mil reais
	Quantidade de ocorrências do SAC
	Venda total clientes diretos
	Vendas Cliente 1 (kg)
	Vendas Cliente 1 (R\$)
	Vendas Cliente 3 (kg)
	Vendas Cliente 3 (R\$)
	Vendas Cliente 4 (kg)
	Vendas Cliente 4 (R\$)
	Vendas Cliente 5 (kg)
	Vendas Cliente 5 (R\$)
	Vendas Cliente 6 (kg)
	Vendas Cliente 6 (R\$)
	Vendas Cliente 7 (kg)
	Vendas Cliente 7 (R\$)
	Vendas Cliente 8 (kg)
	Vendas Cliente 8 (R\$)
	Vendas Cliente 9 (kg)
	Vendas Cliente 9 (R\$)
	Vendas em kg Segmento 1
	Vendas em kg Segmento 2
	Vendas em kg Segmento 3
	Vendas em kg Segmento 4
	Vendas em kg Segmento 5
	Vendas em kg Segmento 6
Vendas em kg Segmento 7	
Vendas em R\$ Segmento 1	
Vendas em R\$ Segmento 2	
Vendas em R\$ Segmento 3	
Vendas em R\$ Segmento 4	
Vendas em R\$ Segmento 5	
Vendas em R\$ Segmento 6	

Categoria	Indicador
	Vendas em R\$ Segmento 7
Corporação	Comissões pagas MI
	Descontos concedidos
	Despesas Administrativas
	Despesas Comerciais
	Despesas Exportação
	Despesas Industriais
	Despesas Manutenção
	Despesas Marketing
	Despesas Páscoa
	Despesas Planejamento e Logística
	Despesas Totais
	EBITDA
	Faturamento ME Linha Normal
	Faturamento ME Linha Normal e Páscoa
	Faturamento MI Linha Normal
	Faturamento MI Linha Normal e Páscoa
	Faturamento MI Páscoa
	Faturamento total
	Faturamento Total Linha Normal
	Faturamento Total Páscoa
Fretes Próprios	
Fretes terceiros	
Equipamentos	Consumo de energia elétrica
	Consumo de gás
Externos	CDI mês
	Dólar Oficial último dia mês
	Euro último dia mês
	IGP-DI/FGV mês
	IGP-DI/FGV últimos 12 meses
	IGP-M/FGV mês
	IGP-M/FGV últimos 12 meses
	INCC-DI últimos 12 meses
	INCC-DI/FGV mês
	INPC/IBGE mês
	INPC/IBGE últimos 12 meses
	IPA-DI/FGV mês
	IPA-DI/FGV últimos 12 meses
	IPC/FIPE mês
	IPC/FIPE últimos 12 meses
	IPCA/IBGE mês
	IPCA/IBGE últimos 12 meses
	IPCA-E/IBGE mês
	IPC-DI/FGV mês
	IPC-DI/FGV últimos 12 meses
	Preço do Açúcar (USA)
	Preço do Cacau (NY)
	Preço do trigo (USA)
	Risco Brasil
	Salário mínimo nacional
	Salário mínimo Paraná-Industrial

Categoria	Indicador
	SELIC acumulada em 12 Meses
	SELIC mensal
	Taxa de desemprego
Funcionários	Absenteísmo 1º TURNO
	Absenteísmo 2º TURNO
	Absenteísmo 3º TURNO
	Absenteísmo médio da Fábrica
	Alimentação MDO
	Custo da MDO
	Média de Funcionários por dia 1º TURNO
	Média de Funcionários por dia 2º TURNO
	Média de Funcionários por dia 3º TURNO
	Média de Funcionários por dia TOTAL Fábrica
	Número de dias trabalhados 1º TURNO Fábrica
	Número de dias trabalhados 2º TURNO Fábrica
	Número de dias trabalhados 3º TURNO Fábrica
	Número de dias trabalhados TOTAL Fábrica
	Número TOTAL de funcionários último dia do mês
	Proporção funcionários Fábrica/totais
	Total de dias trabalhados pelos funcionários da fábrica no mês 1º TURNO
	Total de dias trabalhados pelos funcionários da fábrica no mês 2º TURNO
	Total de dias trabalhados pelos funcionários da fábrica no mês 3º TURNO
	Total de dias trabalhados pelos funcionários da fábrica no mês TOTAL
	Turnover
Material	Consumo de embalagens
	Consumo de matéria prima
	Estoque de embalagens
	Estoque de gás
	Estoque de matéria prima
	Quantidade comprada de açúcar extrafino
	Quantidade comprada de chocolate ao leite
	Quantidade comprada de cobertura fracionada ao leite
	Quantidade comprada de farinha de trigo comum
	Quantidade comprada de gordura de palma
Processo	Estoque de produto em elaboração
	Produção em toneladas Família 1
	Produção em toneladas Família 2
	Produção em toneladas Família 3
	Produção em toneladas Família 4
	Produção em toneladas Família 5
	Produção em toneladas Família 6
	Produção em toneladas Família 7
	Quantidade média por funcionários Fábrica
	Quantidade média por funcionários Gerais
	Quantidade Produzida Fábrica TOTAL
Produto	Custo dos produtos fabricados
	Custo dos produtos vendidos
	Estoque de produto acabado
	Preço médio por kg Família 1

Categoria	Indicador
	Preço médio por kg Família 2
	Preço médio por kg Família 3
	Preço médio por kg Família 4
	Preço médio por kg Família 5
	Preço médio por kg Família 7
	Vendas em kg Família 1
	Vendas em kg Família 2
	Vendas em kg Família 3
	Vendas em kg Família 4
	Vendas em kg Família 5
	Vendas em kg Família 6
	Vendas em kg Família 7
	Vendas em R\$ Família 1
	Vendas em R\$ Família 2
	Vendas em R\$ Família 3
	Vendas em R\$ Família 4
	Vendas em R\$ Família 5
	Vendas em R\$ Família 6
	Vendas em R\$ Família 7

APÊNDICE E. PROPOSTA DE LISTA REDUZIDA DE INDICADORES DA EMPRESA B.

Categoria	Indicador
Corporação	COMPRAS ACUMULADAS
	ESTOQUES
	CAPITAL DE GIRO
	CAPITAL SOCIAL POR ASSOCIADO
	CICLO FINANCEIRO
	DESPESAS ADMINISTRATIVAS
	DESPESAS COMERCIAIS
	DESPESAS PESSOAL
	DESPESAS TRIBUTÁRIAS OPERACIONAIS (%)
	EBITDA: EARNINGS BEFORE INTEREST RATES
	ENDIVIDAMENTO DE LONGO PRAZO
	ENDIVIDAMENTO FINANCEIRO DE LONGO PRAZO
	ENDIVIDAMENTO FINANCEIRO TOTAL
	ENDIVIDAMENTO TOTAL
	FATURAMENTO POR ASSOCIADO
	GARANTIA AO CAPITAL DE TERCEIROS
	GIRO DO ATIVO PERMANENTE
	GIRO DOS ATIVOS
	IMOBILIZAÇÃO DE RECURSOS PRÓPRIOS
	IMPOSTOS INCIDENTES S/ VENDAS E SERVIÇOS (%)
	INDEPENDÊNCIA FINANCEIRA
	ÍNDICE DE AUTO-FINANCIAMENTO
	INGRESSOS E RECEITAS LIQUIDAS
	INGRESSOS LÍQUIDOS ANO ANTERIOR
	INGRESSOS TOTAIS ANO ANTERIOR ATUALIZADO. P/ IGP-DI
	INGRESSOS TOTAIS COOPERATIVA
	INGRESSOS TOTAIS: RAMO AGROPECUÁRIO
	LIQUIDEZ CORRENTE
	LIQUIDEZ TOTAL
	MARGEM BRUTA
	MARGEM OPERACIONAL
	NECESSIDADE DE CAPITAL DE GIRO
	PASSIVO NÃO CIRCULANTE
	PASSIVO OPERACIONAL
	PATRIMÔNIO LÍQUIDO
	PATRIMÔNIO LÍQUIDO POR ASSOCIADO
	PERMANENTE
	PRAZO MÉDIO DE ESTOQUES
	PRAZO MÉDIO DE PAGAMENTO
	PRAZO MÉDIO DE RECEBIMENTO
	RENTABILIDADE DO CAPITAL INTEGRALIZADO
RENTABILIDADE DOS ATIVOS	
REPRESENTATIVIDADE DAS DEVOLUÇÕES	
RESULTADO ANTES DESTINAÇÕES E DEPOIS AJUSTES	
RESULTADO FINANCEIRO (%)	
SALDO DE TESOURARIA	
SOBRAS/PERDAS À DISPOSIÇÃO DA AGO	

Categoria	Indicador
	TERMÔMETRO DE SOLVÊNCIA (LIQUIDEZ INTERNA)
	TERMÔMETRO DE SOLVÊNCIA KANITZ
	TESOURARIA (%)
	TESOURARIA: FATURAMENTO
	TOTAL DESPESAS TRIBUTÁRIAS (%)
	TOTAL DISPÊNDIOS/DESPESAS OPERACIONAIS
Funcionários	QUANTIDADE DE ASSOCIADOS
	QUANTIDADE DE FUNCIONÁRIOS
	VALORES A PAGAR ASSOCIADOS/ATIVO TOTAL
	VALORES A RECEBER ASSOCIADOS / PL
	VALORES A RECEBER ASSOCIADOS / VALORES A PAGAR ASSOCIADOS
	VALORES A RECEBER ASSOCIADOS/ATIVO TOTAL