

Fábio Rafael Santos de Freitas

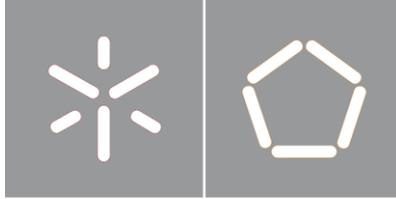
Desenvolvimento de um modelo preditivo de indicadores de desempenho em Sistemas de Gestão Integrada suportado em redes neurais artificiais



Universidade do Minho
Escola de Engenharia

Fábio Rafael Santos de Freitas

Desenvolvimento de um modelo preditivo de indicadores de desempenho em Sistemas de Gestão Integrada suportado em redes neurais artificiais



Universidade do Minho

Escola de Engenharia

Fábio Rafael Santos de Freitas

Desenvolvimento de um modelo preditivo de indicadores de desempenho em Sistemas de Gestão Integrada suportado em redes neurais artificiais

Dissertação de Mestrado

Mestrado em Engenharia e Gestão da Qualidade

Trabalho efetuado sob a orientação do

Professor Doutor José Pedro Teixeira Domingues

e do

Professor Doutor Lino António Antunes Fernandes Costa

DIREITOS DE AUTOR E CONDIÇÕES DE UTILIZAÇÃO DO TRABALHO POR TERCEIROS

Este é um trabalho académico que pode ser utilizado por terceiros desde que respeitadas as regras e boas práticas internacionalmente aceites, no que concerne aos direitos de autor e direitos conexos.

Assim, o presente trabalho pode ser utilizado nos termos previstos na licença abaixo indicada.

Caso o utilizador necessite de permissão para poder fazer um uso do trabalho em condições não previstas no licenciamento indicado, deverá contactar o autor, através do RepositóriUM da Universidade do Minho.

Licença concedida aos utilizadores deste trabalho



Atribuição-NãoComercial-SemDerivações

CC BY-NC-ND

<https://creativecommons.org/licenses/by-nc-nd/4.0/>

AGRADECIMENTOS

Agradeço primeiro a Deus, por me dar força e paciência em todos os momentos. “Esperei com paciência no SENHOR, e ele se inclinou para mim, e ouviu o meu clamor...”. - Salmos 40:1

Agradeço a todos os meus professores da Universidade do Minho pela importância que tiveram na minha formação académica.

Ao meu orientador professor doutor José Pedro Teixeira Domingues e ao meu coorientador professor doutor Lino António Antunes Fernandes Costa por ter aceitado o desafio de me acompanhar nesse projeto e ter paciência na orientação dessa investigação.

A minha esposa Arícia, por ser minha amiga e companheira. Estar ao seu lado me motivou a não desistir jamais, muito obrigado pelo amor e carinho que você sempre teve comigo.

A minha mãe, Sonia, por sempre se preocupar comigo, por interceder em cada momento meu da universidade, por estar do meu lado sempre que eu precisei, sem você nada disso teria sido possível.

Agradeço ao meu falecido pai, Jalsimar, por ter me dado apoio e motivação desde os meus primeiros dias da escola até os seus últimos dias comigo, você foi e ainda é um exemplo de determinação e perseverança para mim.

Agradeço também a minha irmã, Ingrid, que desde criança me ensinou muitas coisas e me ouviu e aconselhou em muitas situações.

A todos, muito obrigado.

DECLARAÇÃO DE INTEGRIDADE

Declaro ter atuado com integridade na elaboração do presente trabalho académico e confirmo que não recorri à prática de plágio nem a qualquer forma de utilização indevida ou falsificação de informações ou resultados em nenhuma das etapas conducente à sua elaboração.

Mais declaro que conheço e que respeitei o Código de Conduta Ética da Universidade do Minho

Desenvolvimento de um modelo preditivo de indicadores de desempenho em Sistemas de Gestão Integrada suportado em redes neurais artificiais

RESUMO

A rede neural artificial (ANN) é uma ferramenta eficiente para tratar problemas complexos, dessa forma, a sua utilização para o desenvolvimento de um método de previsão de indicadores chave de desempenho (KPI) poderá auxiliar empresas que utilizam o sistema de gestão integrada (SGI) a prever o seu desempenho, considerando que muitas organizações buscam implementar o SGI para obter melhorias e, para mensurar seu desempenho é necessário que existam KPI que fornecem suporte e auxílio à gestão da qualidade. A partir disso, objetiva-se avaliar a ANN para realizar a previsão KPI em empresas que adotam o SGI e, através dessa previsão, analisar se os seus indicadores mostrarão crescimento ou recuo no seu desempenho. Para tanto, foram coletados dados de empresas que utilizam o SGI e através do *software* da Palisade NeuralTools foram realizadas ANN. A interpretação das ANN se deu através de gráficos e análises de erro relativo. Os resultados foram baseados nos dados disponibilizados pelo *software* e analisados através de gráficos e tabelas subdivididos em 3 modelos preditivos. O modelo “A” prevê o desempenho de uma empresa através dos dados de anos anteriores da própria empresa, o modelo “B” visa prever o desempenho de uma empresa utilizando os dados dela e de outras empresas ao longo do ano e de anos anteriores e o modelo “C” prevê o desempenho de uma empresa no ano seguinte utilizando os dados dela e de outras empresas nos anos anteriores. Realizou-se um comparativo entre as previsões e os valores reais, o que permite concluir que os resultados utilizando as ANN são satisfatórios, embora alguns indicadores tenham apresentado desempenho melhor num modelo em detrimento de outro. Também foi possível concluir que a utilização dos modelos preditivos estudados pode trazer vantagens competitivas através da melhoria dos processos, visto que, a ANN também calcula quais variáveis mais impactaram na previsão de cada indicador, conferindo assim, melhor precisão nas tomadas de decisão.

Palavras chaves: Indicadores chave de desempenho; Redes Neurais Artificiais; Sistema de Gestão Integrada.

Development of a predictive model in Integrated Management Systems performance indicators supported on artificial neural networks

ABSTRACT

The artificial neural network (ANN) is an efficient tool to deal with complex problems, therefore, its use for the development of a prediction method of key performance indicators (KPI) can help companies that use the integrated management system (IMS) to predict their performance, considering that many organizations seek to implement the IMS to obtain improvements and, to measure their performance, it is necessary that there are KPIs that provide support and assistance to quality management. From this, the objective is to evaluate the ANN to perform the KPI forecast in companies that adopt the IMS and, through this forecast, analyze whether their indicators will show growth or retreat in their performance. For this purpose, data were collected from companies that use the IMS, and through the Palisade NeuralTools software, an ANN was developed. The interpretation of ANN was done through graphics and relative error analysis. The results were based on data provided by the software and analyzed through graphs and tables subdivided into 3 predictive models. Model "A" predicts the performance of a company using data from previous years of the company itself, model "B" aims to predict the performance of a company using data from it and other companies throughout the year and from previous years and the "C" model predicts the performance of a company in the following year using data from it and other companies in previous years. A comparison was made between forecasts and actual values, which allows us to conclude that the results using the ANN are satisfactory, although some indicators have performed better in one model than in another. It was also possible to conclude that the use of the studied predictive models can bring competitive advantages through the improvement of processes, since the ANN also calculates which variables had the most impact on the prediction of each indicator, thus providing better precision in decision-making.

Keywords: Artificial neural networks; Integrated Management System; Key performance indicators.

Índice

AGRADECIMENTOS.....	III
RESUMO.....	V
ABSTRACT	VI
ÍNDICE DE FIGURAS	IX
ÍNDICE DE TABELAS.....	XI
LISTA DE ABREVIATURAS E SIGLAS	XII
1. Introdução	1
1.1 Enquadramento	1
1.2 Objetivos	1
1.3 Estrutura da Dissertação.....	2
2. Revisão Bibliográfica	4
2.1 Sistema de Gestão Integrada	4
2.1.1 As Normas ISO 9001, ISO 14001, ISO 45001 e OHSAS 18001	5
2.1.2 Motivações para a implementação de um sistema de gestão integrada.....	9
2.1.3 Benefícios e obstáculos reportados após a integração	10
2.1.4 Estratégia e metodologia do SGI.....	11
2.1.5 A Evolução do SGI e o papel da qualidade nesse contexto	13
2.2 Indicadores de Desempenho.....	14
2.2.1 Indicadores Chave de Desempenho	14
2.2.2 Características do KPI.....	16
2.2.4 Indicadores utilizados no Projeto	16
2.3 Redes Neurais Artificiais	19
2.3.1 Função de ativação.....	20
2.3.2 Processos de Aprendizado	24
2.3.3 Percepção de Múltiplas Camadas	24
3 Metodologia	27

3.1 Coleta de dados	27
3.2 Software NeuralTools.....	28
3.3 Preparação dos dados	29
3.4 Treino e Teste	31
3.5 Previsão	38
4 Resultados e Discussões	39
4.1 Modelo preditivo do tipo A.....	39
4.2 Modelo preditivo do tipo B	47
4.3 Modelo preditivo do tipo C	50
5 Conclusões e Trabalhos Futuros.....	57
5.1 Conclusão	57
5.2 Trabalhos Futuros.....	57
Referências Bibliográficas.....	59

Índice de Figuras

Figura 1: Convergência entre ciclo PDCA e o SGA	8
Figura 2: Modelo evolucionário (adaptado de Domingues et al., 2015).....	12
Figura 3: Modelo sinérgico (adaptado por Zeng et al.,2007)	13
Figura 4: Modelo de um neurónio	20
Figura 5: Gráfico da função sigmoidal, com λ igual a 2	21
Figura 6: Gráfico da função degrau ou heaviside	22
Figura 7: Gráfico da função linear, onde $a=1$ e $b=0$	23
Figura 8: Percepção multicamadas com duas camadas ocultas	25
Figura 9: Comando Administrador do Conjuntos de Dados do NeuralTools	29
Figura 10: Caixa de diálogo do comando “Administrador de Conjunto de Dados”	30
Figura 11: Comando Treinar do NeuralTools.	31
Figura 12: Caixa de diálogo referente ao comando “Treinar”	32
Figura 13: Separador Configuração de rede da caixa de diálogo do comando Treino.....	33
Figura 14: Separador Tempo de Execução referente ao comando Treino	35
Figura 15: Janela de visualização de treinamento.....	36
Figura 16: Treinamento em andamento	37
Figura 17: Comparativo entre o valor real e a previsão nos anos de 2018 e 2019 de cada empresa em relação ao (a) índice de liquidez e (b) ROE usando lucro líquido.....	41
Figura 18:Comparativo entre o valor real e a previsão nos anos de 2018 e 2019 de cada empresa em relação aos indicadores (a) Engrenagem e (b) ROA usando lucro líquido.....	42

Figura 19: Comparativo entre o valor real e a previsão nos anos de 2018 e 2019 de cada empresa em relação aos indicadores (a) Margem EBIT e (b) Margem de lucro.....	43
Figura 20: Comparativo entre o valor real e a previsão nos anos de 2018 e 2019 de cada empresa em relação aos indicadores (a) EBITDA e (b) EBIT	44
Figura 21: Comparativo entre o valor real e a previsão nos anos de 2018 e 2019 de cada empresa em relação aos indicadores (a) Vendas e (b) Lucro líquido.	45
Figura 22: Comparativo entre o valor real e a previsão na rede neural do tipo B dos indicadores (a) Índice de liquidez (b) ROE usando lucro líquido (c) ROA usando lucro líquido (d) Margem de Lucro (e) Margem EBIT.....	49
Figura 23: Comparativo entre o valor real e a previsão na rede neural do tipo B dos indicadores (a) EBITDA (b) Engrenagem (c) EBIT (d) Vendas (e) Lucro líquido.	50
Figura 24: Comparativo entre o valor real e a previsão na rede neural do tipo C dos indicadores (a) Índice de liquidez (b) ROE usando lucro líquido (c) ROA usando lucro líquido (d) Margem de Lucro (e) Margem EBIT.....	53
Figura 25: Comparativo entre o valor real e a previsão na rede neural do tipo C dos indicadores (a) EBITDA (b) Engrenagem (c) EBIT (d) Vendas (e) Lucro líquido.	54
Figura 26: Comparativo entre os erros do treino e da previsão para as redes neurais dos tipos A, B e C.	55

Índice de Tabelas

Tabela 1: Motivações para a implementação de um SGI.....	10
Tabela 2: Erro relativo dos indicadores relacionados ao modelo preditivo do Tipo A.	39
Tabela 3: Variáveis que mais impactaram os indicadores previstos relacionados ao Tipo A.	40
Tabela 4: Área entre as curvas do valor real e da previsão para cada indicador no modelo preditivo tipo A.....	46
Tabela 5: Erro relativo dos indicadores relacionados ao modelo preditivo do Tipo B.	47
Tabela 6: Variáveis que mais impactaram os indicadores previstos relacionados ao Tipo B.	48
Tabela 7: Erro relativo dos indicadores relacionados ao modelo preditivo do Tipo C.	51
Tabela 8: Variáveis que mais impactaram os indicadores previstos relacionados ao Tipo C.	52
Tabela 9: Comparativo entre a fiabilidade de cada modelo preditivo em relação aos indicadores.....	56

Lista de Abreviaturas e Siglas

ANN	Rede Neural Artificial
APCER	Associação Portuguesa de Certificação
EBIT	Earnings Before Interest and Taxes
EBITDA	Earnings Before Interest, Taxes, Depreciation and Amortization
I4.0	Indústria 4.0
IMS	Integrated Management System
ISO	International Organization for Standardization
KPI	Indicadores Chave de Desempenho
KRI	Indicadores Chave de Resultados
LAJIR	Lucro antes dos juros e imposto de renda
OEE	Overall Equipment Effectiveness
OHSAS	Occupational Health and Safety Assessment Series
PI	Indicadores de Desempenho
RI	Indicadores de Resultados
ROA	Return on Assets
ROE	Return on common equity
SGA	Sistema de Gestão Ambiental
SGI	Sistema de Gestão Integrada
SGQ	Sistemas de Gestão da Qualidade

SGS

Sociedade Geral de Superintendência

1. Introdução

1.1 Enquadramento

Atualmente, muitas organizações buscam implementar o Sistema de Gestão Integrada (SGI) visando obter melhorias no seu desempenho e atender às necessidades e expectativas de várias partes interessadas simultaneamente. O SGI tem sido fundamental no processo de transformação para a Indústria 4.0 (I4.0). O SGI destaca-se como ferramenta essencial para a continuidade das operações das empresas, com o objetivo de melhoria contínua através da redução de custos, simplificação de documentos, atendimento estruturado, entre outros (Ferradaz, Domingues, Sampaio, & Arezes, 2020). Além disso, o SGI intervém na sustentabilidade da empresa e provoca transformações nos seus aspectos culturais, económicos e sociais, pois promove melhoria nas práticas de gestão da qualidade, meio ambiente, saúde e segurança (Stefano & Laux, 2017).

Os efeitos potenciais no desempenho de uma empresa podem ser alavancados através do SGI. Para mensurar a melhoria no desempenho de uma empresa é necessário que existam indicadores de desempenho que são um meio de suporte e auxílio à gestão da qualidade, pois são úteis para o controle e a identificação das necessidades e melhoria do seu desempenho (Góis, Vilanova, Santos, Porto, & Santos, 2017; Hernandez-Vivanco, Domingues, Sampaio, Bernardo, & Cruz-Cázares, 2019).

As redes neurais artificiais são uma ferramenta eficiente e consolidada mundialmente para tratar de problemas complexos. Por isso, o desenvolvimento de um método de previsão de indicadores chave de desempenho (KPI) através de redes neurais poderá auxiliar as empresas a prever o seu desempenho e, através disso, tomar decisões para melhorias como, por exemplo, a conquista de novas certificações de qualidade (Kovács, 2006; Zimon, Madzik, & Sroufe, 2020).

1.2 Objetivos

Os objetivos desta investigação decorrem da seguinte pergunta de investigação: Como prever indicadores de desempenho em empresas que utilizam o Sistema de Gestão Integrada?

Através da pergunta de investigação, o objetivo deste projeto é adotar redes neurais artificiais para proceder a previsão de KPI em empresas que adotam o SGI e, através dessa previsão, verificar se os

seus indicadores mostrarão evolução ou retrocesso no seu desempenho, baseado em variáveis de agrupamento como, por exemplo, o setor da empresa, o porte da empresa baseado no número de funcionários, a região onde ela se encontra e outros indicadores utilizados pela empresa. Dessa forma, pretende-se:

- Desenvolver um método preditivo de KPI em empresas que utilizam o SGI suportado em Rede Neural Artificial (ANN).
- Encontrar as variáveis que mais influenciam em cada KPI utilizado.

A restrição de selecionar apenas empresas que utilizam SGI nessa investigação baseou-se no fato de que nos últimos anos a automatização das empresas tem crescido muito em Portugal e em outras partes do mundo, e com isso muitas organizações têm optado pela implementação do SGI, uma das propostas desta investigação é mostrar que é possível criar um modelo preditivo de indicadores de desempenho em empresas que utilizam essa integração de sistema, e dessa forma valorizar a sua utilização. (Almeida, Domingues, & Sampaio, 2014).

Além disso, para a realização de uma boa ANN é necessário ter dados fiáveis e diversas características das empresas que utilizam o SGI ajudam a obter esses dados, como, por exemplo: padronização dos processos (Matias & Coelho, 2002; Vitoreli & Carpinetti, 2013); dados centralizados (Salomone, 2008); maior qualidade e segurança de informações (Matias & Coelho, 2002; Salomone, 2008).

1.3 Estrutura da Dissertação

Este trabalho está contido em cinco capítulos. O primeiro capítulo aborda a introdução do projeto, subdividida em três partes: objetivos, enquadramento e estrutura da dissertação.

O segundo capítulo contém a exposição da revisão bibliográfica, abordando os seguintes temas: Sistema de Gestão Integrada, onde evidenciou-se a norma ISO (*International Organization for Standardization*) 9001, assim como as suas certificações; indicadores de desempenho e a sua importância para o sucesso de uma empresa e, por fim, as Redes Neurais Artificiais, tratando a importância desse método para o desenvolvimento de modelos preditivos.

O capítulo seguinte discorre sobre a metodologia deste trabalho. Há uma explicação sobre o “software” utilizado, como ele funciona e quais foram os parâmetros escolhidos para a realização dessa dissertação.

No quarto capítulo, exibiram-se os resultados e as discussões acerca das ANN, realizaram-se análises de gráficos e tabelas com o objetivo de avaliar os modelos preditivos utilizados neste projeto.

As conclusões podem ser encontradas no quinto e último capítulo deste trabalho, juntamente com as recomendações para trabalhos futuros.

2. Revisão Bibliográfica

Com o avanço da tecnologia e a preocupação das empresas em diminuir os custos, a necessidade de integrar todas as atividades dentro de uma organização tornou-se fundamental para garantir a excelência, reduzir o retrabalho, aperfeiçoar processos, dentre outras melhorias (Ferradaz et al., 2020).

Existe um novo significado para qualidade, no qual o cliente não é mais a única preocupação para uma empresa, também se deve satisfazer as necessidades do ambiente e da comunidade de múltiplos sistemas e uma das maneiras de realizar isso é através do sistema de gestão integrada (Karapetrovic & Jonker, 2003).

2.1 Sistema de Gestão Integrada

A integração dos sistemas de gestão é um tópico cada vez mais popular de pesquisa e prática, devido a diversos padrões de sistema de gestão para negócios e funções que vão desde a qualidade e meio ambiente até a responsabilidade socioambiental empresarial (Karapetrovic & Jonker, 2003; Santos, da Silva, & Gómez, 2012).

Além disso, o SGI intervém na sustentabilidade da empresa e provoca transformações nos seus aspectos culturais, econômicos e sociais, pois une diversos sistemas, como os sistemas de qualidade ambiental, saúde e segurança que são fundamentais para uma organização, em um único sistema com recursos comuns que origina benefícios significativos que podem resultar na economia de custos e na redução do uso de recursos organizacionais valiosos (Almeida, Sampaio, & Santos, 2012; Klute-Wenig & Refflinghaus, 2015).

O SGI tem como finalidade otimizar o desempenho dos processos de uma organização com o objetivo de unir informações dentro de uma empresa de forma que todos os processos dela sejam alocados dentro de um mesmo sistema e num mesmo ambiente da forma mais simples possível (Pipino, 2021).

As certificações através da ISO são aliadas daqueles que buscam a melhoria contínua nas suas organizações. Muitas empresas tem buscado a implementação do SGI nas últimas décadas através de certificações como, por exemplo: Sistemas de Gestão da Qualidade (SGQ) - ISO 9000 e o Sistema de Gestão Ambiental (SGA) - ISO 14001 com o objetivo de otimizar o seu sistema (Coelho & Matias, 2010; Dias, 2017).

O SGA tem como objetivos aumentar a performance ambiental através da aprendizagem contínua com experiências passadas e *benchmarking*, que é um estudo dos melhores procedimentos utilizados em outras empresas, assim como diminuir os riscos de capital natural da organização (Azadeh, Hasani Farmand, & Jiryaei Sharahi, 2012).

O SGQ visa o modo como a organização trabalha, sendo baseado no processo e não no produto. Os seus requisitos complementam aos já existentes para produtos e serviços e, embora os processos afetem o produto final, ter uma certificação de SGQ não é uma garantia de qualidade de produtos (da Cunha Tavares, Batista M. Ribeiro Neto, & Carvalho Hoffmann, 2019).

Os efeitos potenciais no desempenho de uma organização podem ser alavancados através do SGI, ao mensurar os efeitos no desempenho de uma empresa é essencial que existam indicadores chave de desempenho (Hernandez-Vivanco et al., 2019).

Diversas empresas buscam as certificações ISO 9001, ISO 14001, OHSAS (*Occupational Health and Safety Assessment Series*) 18001 e ISO 45001, com o objetivo de integrar os sistemas de forma padronizada e obter melhoria contínua nas suas organizações (Vitoreli & Carpinetti, 2013).

2.1.1 As Normas ISO 9001, ISO 14001, ISO 45001 e OHSAS 18001

As normas ISO 9001, ISO 14001 e ISO 45001, norma que substitui a OHSAS 18001, são comuns num SGI (Zevallos & Renán, 2021). Os Sistemas de Gestão da Qualidade (ISO 9001), Meio Ambiente (ISO 14001) e Saúde e Segurança do Trabalho (ISO 45001) são muito utilizados pelas empresas com o objetivo de integrar os sistemas e dessa forma ter um efeito positivo no desempenho dos funcionários. Para que se tenham metas desafiadoras de produtividade é necessário eficiência das organizações e isso

pode ser conquistado através da existência de vários sistemas de gestão, como os citados acima (Souza & Georges, 2020).

As normas ISO são os padrões de gestão e são úteis para empresas e organizações de qualquer categoria que necessitem de ferramentas práticas para gerir as suas responsabilidades. A ISO 9001 refere-se à gestão da qualidade e a ISO 14001 refere-se à gestão ambiental, ambas possuem como objetivo a melhoria dos seus processos através da padronização (“ISO - International Organization for Standardization”, [s.d.]; Zimon et al., 2020).

Segundo a Sociedade Geral de Superintendência (SGS) de Portugal, outra norma muito implementada pelas organizações que utilizam o SGI é a OHSAS 18001, a sigla OHSAS significa *Occupational Health and Safety Assessment Series*, ou seja, Sistemas de Gestão da Saúde e Segurança Ocupacional tem como objetivo lidar com mudanças na legislação e proteger seus colaboradores, além de permitir às organizações gerir os riscos operacionais e melhorar o seu desempenho. A partir de 2018 a OHSAS 18001 foi substituída pela ISO 45001 (Lo, Pagell, Fan, Wiengarten, & Yeung, 2014; “OHSAS 18001 - Sistemas de Gestão da Saúde e Segurança Ocupacional | SGS Portugal”, [s.d.]).

ISO 9001: A ISO 9001 possui critérios para um SGQ e pode ser usada por qualquer organização, grande ou pequena, independente do seu ramo de atuação. Existem mais de um milhão de empresas em mais de 170 países com essa certificação (Cerqueira, Paes, & Turrioni, 2020; “ISO - ISO 9000 Family – Quality Management”, [s.d.]).

Essa padronização é baseada em uma série de princípios de gestão da qualidade como, por exemplo, o foco no cliente, a motivação, a implicação da alta administração e a abordagem do processo e melhoria contínua. A utilização da ISO 9001 auxilia que os clientes obtenham produtos e serviços de boa qualidade e consequentemente traz benefícios comerciais (Herrmann & Junior, 2014; “ISO - ISO 9000 Family – Quality Management”, [s.d.]).

Este certificado ajuda na capacidade de satisfazer as necessidades e expectativas dos clientes além da melhoria da organização no seu sistema de gestão e no seu desempenho global. Os principais benefícios da sua implementação e posterior certificação são: melhorar o desempenho da organização; melhorar a

capacidade de fornecer, de forma consistente, produtos e serviços que satisfaçam tanto os requisitos dos clientes como as exigências estatutárias e regulamentares aplicáveis; orientar o foco da organização no aumento da satisfação do cliente; fidelizar e captar novos clientes; tratar os riscos e oportunidades; o acesso a novos mercados; uma confiança acrescida nos processos de concepção, planeamento, produção do produto e/ou fornecimento do serviço; maior notoriedade e melhoria de imagem perante o mercado e sociedade em geral (“APCER - ISO 9001”, [s.d.]; Zimon et al., 2021).

ISO 14001: A ISO 14001 possui critérios para um SGA e sua consequente certificação. Ela mapeia uma estrutura que uma organização pode seguir para obter um SGA eficaz, é idealizado para qualquer categoria de empresa e garante aos seus gestores, colaboradores e aos *stakeholders* externos que o impacto ambiental está a ser medido e melhorado de forma contínua. Mais de 300.000 organizações em 171 países ao redor do mundo possuem a certificação ISO 14001 (Bonato & Caten, 2015; “ISO - ISO 14000 Family – Environmental Management”, [s.d.]).

A ISO 14001 adota a abordagem por processos, que incorpora o ciclo PDCA de melhoria contínua, conforme mostra a figura 1 (“APCER - ISO 14001”, [s.d.]; Popescu & Popescu, 2015).

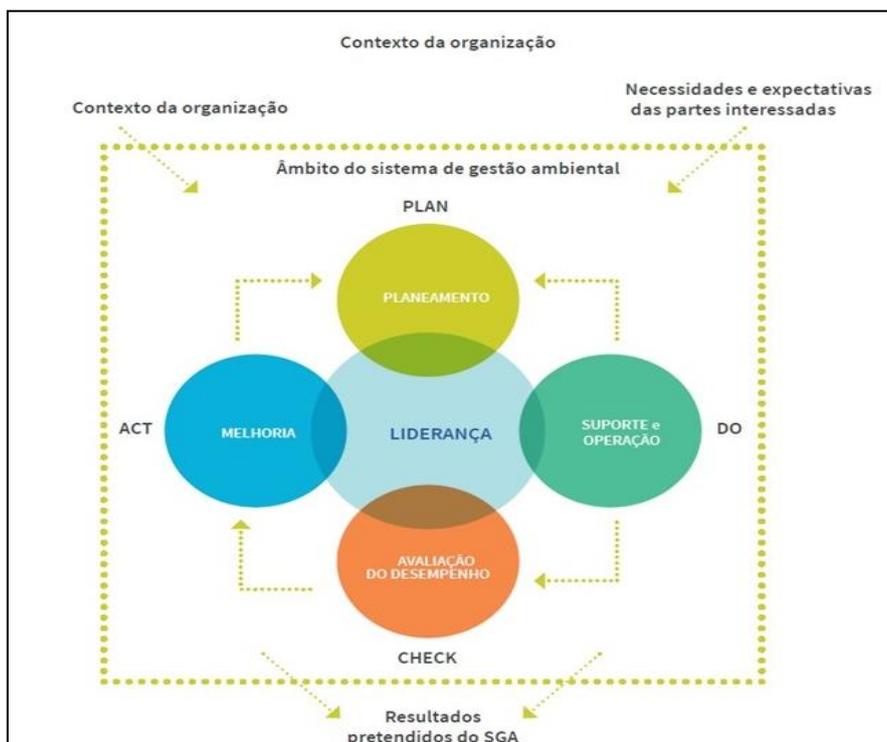


Figura 1: Convergência entre ciclo PDCA e o SGA

Fonte: ("APCER - ISO 14001", [s.d.])

Os principais benefícios da prática e posterior certificação da ISO 14001 são: alcance dos objetivos estratégicos através da incorporação de questões ambientais na gestão da organização e do aumento do envolvimento da gestão de topo e dos colaboradores na gestão ambiental; diminuição da expectativa de riscos ambientais, tais como emissões, derrames e outros acidentes; redução de custos através da melhoria da eficiência dos processos; diminuição dos prémios de seguros e minimização de multas e coimas, entre outros; benefícios competitivos decorrentes de uma melhoria da imagem da organização e a sua aceitação pela sociedade e pelo mercado ("APCER - ISO 14001", [s.d.]).

OHSAS 18001: A OHSAS 18001 visa o bem-estar dos seus colaboradores. Essa certificação mostra um compromisso da empresa com os seus colaboradores visando à saúde e segurança dos seus funcionários, considerando a prevenção contra acidentes e a redução de riscos (Bonato & Caten, 2015;

“OHSAS 18001 - Sistemas de Gestão da Saúde e Segurança Ocupacional | SGS Portugal”, [s.d.].(Bonato & Caten, 2015).

Alguns pesquisadores defendem uma integração de sistemas de gestão de qualidade, meio ambiente, saúde e segurança para aperfeiçoar o desempenho de uma empresa devido às semelhanças entre os padrões ISO 9001, ISO 14001, OHSAS 18001 ou ISO 45001. No entanto, é preciso considerar que cada sistema tem o seu próprio foco. A ISO 9001 tem o objetivo voltado à satisfação do cliente; a ISO 14001 visa apoiar a proteção ambiental e prevenir a poluição, promovendo uma harmonia social e econômica, enquanto a OHSAS 18001 foca no controle dos riscos ocupacionais e permite que a organização melhore o seu desempenho relacionado à segurança e saúde (Zeng, Shi, & Lou, 2007).

A OHSAS 18001 é aplicável a qualquer organização que deseja estabelecer um sistema de gestão de saúde e segurança ocupacional para eliminar ou minimizar o risco para os seus funcionários e outras partes interessadas; implementar, manter e melhorar um sistema de gestão de segurança e saúde ocupacional; buscar a certificação do seu sistema de gestão de segurança e saúde ocupacional por uma organização externa. A OHSAS oferece ajudas substanciais para minimizar o risco aos funcionários, demonstrar diligência, obter garantia, entre outros (Vinodkumar & Bhasi, 2011).

ISO 45001: A ISO 45001, que foi publicada em março de 2018, substituirá as atuais normas OHSAS 18001 e será alinhada com as normas ISO 9001 e ISO 14001. O objetivo desta norma é fazer com que as empresas compreendam a importância da responsabilidade com a saúde e a segurança ocupacional dos seus colaboradores (Bielza, 2021; “ISO 45001”, [s.d.]).

A norma ISO 45001 tem como principal objetivo analisar os perfis de risco em crescimento por meio de um processo ordenado para manter sua força de trabalho saudável, e dessa forma diminuindo o tempo de ociosidade para a obter produção diária ideal (Souza & Georges, 2020).

2.1.2 Motivações para a implementação de um sistema de gestão integrada

Existem motivações para a implementação do SGI e, por isso, há uma tendência de as empresas implementarem esse sistema com o objetivo de superar problemas oriundos de múltiplos sistemas de

gestão (Zeng, Xie, Tam, & Shen, 2011). Na tabela 1 é possível observar, através de uma revisão de literatura, que alguns autores consideram essa implementação como o melhor caminho a seguir.

Tabela 1: Motivações para a implementação de um SGI

Autores	Motivações
(Salomone, 2008; Stefano & Laux, 2017; Zeng et al., 2011)	Redução de documentação
(Matias & Coelho, 2002; Salomone, 2008; Zeng et al., 2011)	Redução de custos
(Poltronieri, Gerolamo, & Carpinetti, 2017; Vitoreli & Carpinetti, 2013; Zeng et al., 2011)	Diminuição da complexidade da gestão
(Matias & Coelho, 2002; Zeng et al., 2011)	Processo de certificação simplificado
(Gianni & Gotzamani, 2015; Karapetrovic & Jonker, 2003; Zeng et al., 2011)	Facilitação da melhoria contínua

Pode-se observar que a redução de custos e a melhoria contínua são duas das principais motivações das organizações, sendo as que possuem maior consenso entre os autores analisados nessa revisão de literatura.

2.1.3 Benefícios e obstáculos reportados após a integração

Diversos autores discorrem sobre os benefícios e os obstáculos que as empresas enfrentam, após a implementação do SGI. Os principais benefícios oriundos desta implementação para as organizações são a otimização através da unificação da auditoria, interna e externa, e a redução na documentação

economizando tempo e dinheiro. Também são destacados os benefícios relacionados às economias quanto as certificações de qualidade, responsabilidade ambiental e proteção da força de trabalho (Matias & Coelho, 2002; Salomone, 2008).

A falta de apoio financeiro e as pressões externas que as empresas atendem na implementação de cada um dos sistemas de gestão são relatados como obstáculos (Salomone, 2008). Além disso, alguns autores ponderam sobre o aumento da burocracia (Matias & Coelho, 2002), a falta de recursos humanos, treinamentos inadequados e a resistência de alguns colaboradores como obstáculos para implementação do SGI (Gianni & Gotzamani, 2015). Sendo assim, o comprometimento da liderança da empresa é de suma importância para que as organizações consigam implementar esses padrões relacionados a implementação do SGI (Zeng et al., 2007).

Os fatores que afetam a implementação do SGI em uma organização podem ser classificados como internos e externos. Internamente o maior obstáculo são os recursos humanos, seguido pela estrutura organizacional, cultura da empresa e compreensão e percepção dos colaboradores. Os fatores externos são orientação técnica, organismos de certificação, *stakeholders* e clientes, e ambiente institucional (Zeng et al., 2007).

Uma das etapas fundamentais nesse estudo é a identificação de indicadores de desempenho, pois eles possuem um grande impacto nas empresas quando se trata de mensurar a eficiência do SGI.

2.1.4 Estratégia e metodologia do SGI

O SGI possui diversas metodologias e estratégias, e a escolha por diferentes metodologias durante o processo da sua implementação proporciona um maior nível de integração quando comparado com o nível de integração obtido se for utilizada uma única metodologia. (Domingues, Sampaio, & Arezes, 2017)

Alguns dos modelos de integração são:

Modelo sistêmico: Modelo focado num SGI composto pelos subsistemas SGQ, SGA e Sistema de Gestão de Segurança e Saúde no Trabalho. Ele possui um pensamento voltado ao “equilíbrio” entre recursos,

processos e gestão de objetivos. (Domingues, Sampaio, & Arezes, 2015). Este modelo foi apresentado por (Karapetrovic & Willborn, 1998)

Modelo evolucionário: Este modelo possui uma ideia baseada na evolução do SGI e apresenta várias perspectivas conceituais onde são exibidos os subsistemas (Figura 2) (Domingues et al., 2015).

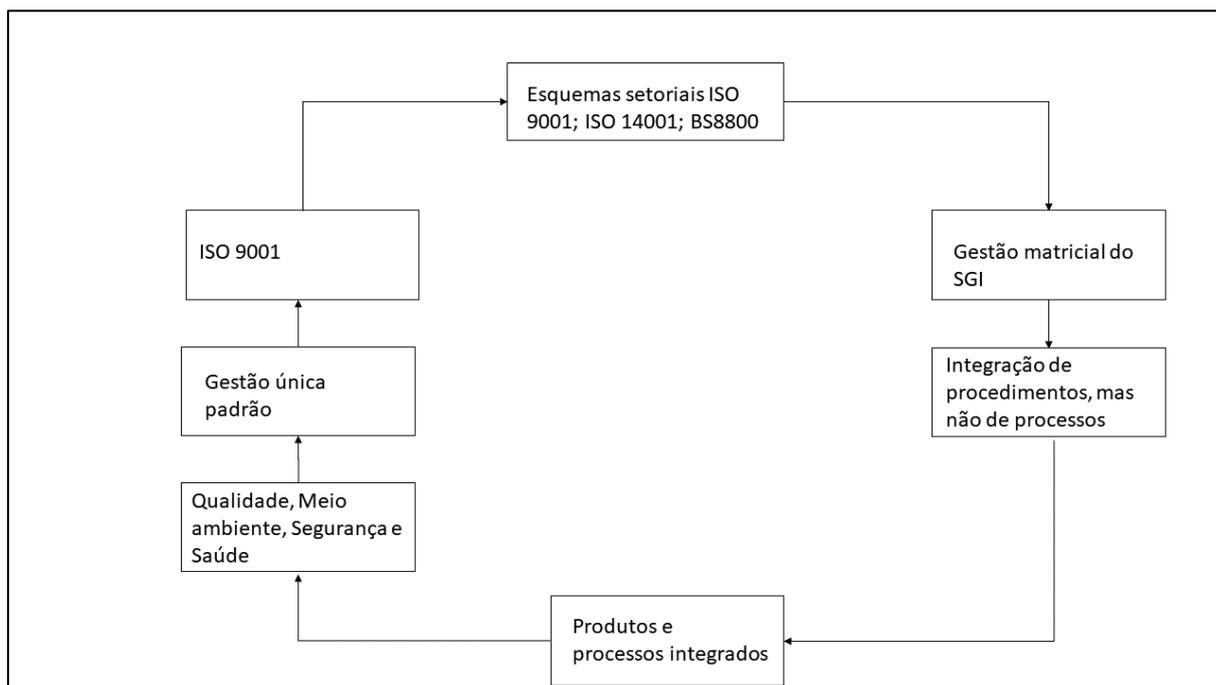


Figura 2: Modelo evolucionário (adaptado de Domingues et al., 2015)

Modelo sinérgico: O modelo sinérgico utiliza as normas ISO 9001, ISO 14001 e OHSAS 18001 como sinergia entre condições das normas, como desenvolvimento de objetivos e políticas, documentação, comprometimento da direção, melhoria contínua, comunicação, internet e auditorias (Domingues et al., 2015). Através dos itens citados anteriormente, o modelo sinérgico foi criado por (Zeng et al., 2007). Apresentado na Figura 3.

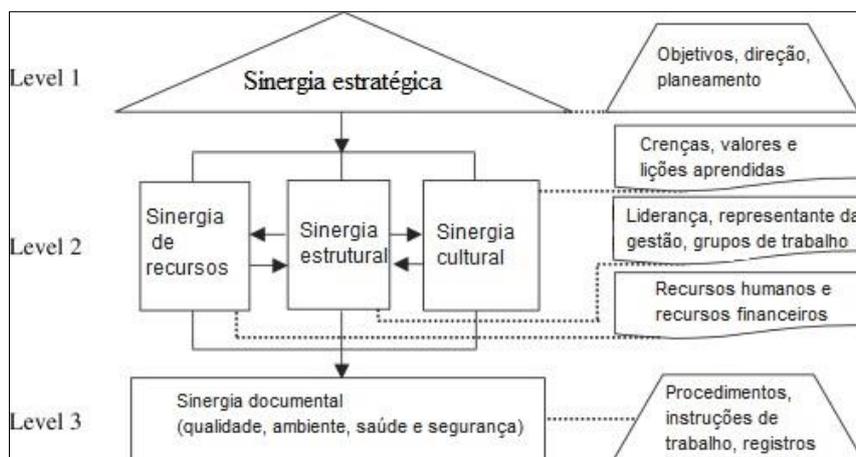


Figura 3: Modelo sinérgico (adaptado por Zeng et al.,2007)

2.1.5 A Evolução do SGI e o papel da qualidade nesse contexto

O SGI procura integrar as políticas de qualidade, meio ambiente, segurança e saúde, assim como os seus objetivos de gestão e procedimentos. Esses atributos são avaliados pela maioria das organizações como essenciais para haver uma boa implementação do SGI. Nesse sentido o papel da qualidade é muito importante, pois ajuda na melhoria contínua dos processos da empresa e essa melhoria é um dos principais benefícios que fazem com que as empresas queiram implementarem o SGI, tendo em vista que as economias estão cada vez mais competitivas e a busca por diferenciais frente a concorrência tornou-se essencial no mercado de trabalho (Almeida et al., 2014; Domingues et al., 2017).

A evolução das indústrias tem crescido muito, assim como a preocupação com a proteção ambiental e a prevenção da poluição, com isso, muitas empresas buscam o SGI como parte dessa evolução. Em Portugal o número de organizações que utilizam o SGI aumentou nos últimos anos e os benefícios relacionados a processos, documentação, responsabilidade dos colaboradores e melhoria contínua através da integração dos sistemas de gestão, faz com que novas empresas busquem por mais informações visando implementar o SGI (Almeida et al., 2014; Cabecinhas, Domingues, Sampaio, & Arezes, 2019).

2.2 Indicadores de Desempenho

A medição de desempenho não deve ser utilizada apenas para controlar, mas também como um fator de aprendizado e melhoria. Elas são utilizadas para mensurar e melhorar a eficiência e a qualidade dos processos de negócios, além de identificar oportunidade para melhorias no desempenho de processos (Wegelius-Lehtonen, 2001).

A medição de desempenho fornece *feedback* para aqueles que tomam as decisões dentro de uma empresa e os ajudam a melhorar o seu desempenho e a verificar se a empresa está a cumprir com os seus compromissos. Existem características que um bom sistema de medição de desempenho deve possuir, são elas: estratégico, holístico, relevante, oportuno, preciso e consistente (Barbuio, 2007).

É possível afirmar que existem quatro medidas de desempenho: indicadores chave de resultados (KRI): informam o resultado do esforço da organização em uma determinada área; indicadores de resultados (RI): informam a empresa como as equipas estão trabalhando para produzir resultados; indicadores de desempenho (PI): informam a organização o que as equipas estão entregando de forma a indicar aos colaboradores e aos gestores o que devem fazer; indicadores chave de desempenho (KPI): informam as lideranças onde é possível melhorar o desempenho da organização, nesse estudo será utilizado o KPI (Parmenter, 2015).

2.2.1 Indicadores Chave de Desempenho

Com o objetivo de ter organizações competitivas com outras no mercado são necessários produtos de qualidade e com um bom custo benefício para o cliente, para atingir esses objetivos e mensurá-los, é necessária a criação de KPI que são utilizados para medir, comparar e gerir o desempenho de uma empresa (Bhatti, Awan, & Razaq, 2014; Gosselin, 2005).

A maioria das empresas utiliza esses indicadores com o objetivo de mensurar como está o desempenho delas em relação aos seus objetivos e através deles saberem se estão no caminho certo e onde devem melhorar (Bhatti et al., 2014).

Os KPI podem ser definidos para medir a qualidade (Gosselin, 2005), os índices financeiros, a satisfação do funcionário, a satisfação de clientes, a segurança, o ambiente, o aprendizado e crescimento (Parmenter, 2015), dentre outros fatores que influenciam diretamente ou indiretamente uma empresa.

A avaliação de desempenho precisa ter dois fatores que são as métricas que promovem a quantificação das atividades ou objeto de controle de uma organização, indivíduo ou produto e os métodos que servem para calcular as métricas (Agostino & Sidorova, 2016).

Os KPI precisam levar alguns fatores em consideração de forma adequada para garantir um resultado equilibrado. O primeiro fator é o estratégico/operacional. Tanto a capacidade em longo prazo como em curto prazo são importantes, porém em diversas situações os KPI estratégicos são relatados em níveis hierárquicos mais altos e em intervalos menos regulares, enquanto os operacionais são focados em níveis mais baixos e com maior frequência (Barbuio, 2007; Domingues, Pedrosa, & Bernardino, 2020).

O segundo fator é o resultado. Em uma empresa os KPI podem ser definidos para mensurar tanto as atividades quanto o resultado dessas atividades, sendo ambos importantes. Os resultados costumam ser relatados em níveis hierárquicos mais altos e com menos frequência enquanto os voltados às atividades dizem respeito a níveis hierárquicos mais baixos e relatados com maior frequência (Barbuio, 2007; Domingues et al., 2020; Santos, Alves, & Monteiro, 2019).

O terceiro fator é o tipo *lead/lag*. A ideia de que o bom desempenho é a capacidade de lidar com a incerteza é facilitada por medidas de desempenho futuro ou problemas. O KPI *lead* é um indicador que pode prever o sucesso através de uma tendência de resultados futuros, enquanto o KPI tipo *lag* é um indicador orientado a resultados, que mede o desempenho com base num histórico (Barbuio, 2007; Basnarkov, Stojkoski, Utkovski, & Kocarev, 2020; Domingues et al., 2020).

O quarto fator é o qualitativo/quantitativo. Nem sempre é possível obter medidas confiáveis e consistentes, calculadas de forma objetiva. Em uma empresa existem vários aspectos de desempenho que podem ser medidos através de quantidade, outros, porém, só podem ser medidos por intermédio da sua qualidade (Barbuio, 2007; Neto, Dias, Medeiros, Dantas, & Neto, 2019).

O quinto fator é a eficiência/eficácia que é um fator fundamental no desempenho de uma organização. A eficácia é responsável por dizer o quão bem uma empresa atende a sua obrigação em termos de qualidade e quantidade de produção. A eficiência depende de como a organização usa os seus recursos disponíveis para maximizar a produção de modo que mais produção seja alcançada com o mesmo nível de recursos (Barbuio, 2007).

2.2.2 Características do KPI

Existem diversos tipos de KPI que podem ser utilizados em qualquer empresa. Porém, o foco deve ser selecionar medidas com qualidades adequadas e que entregam o melhor valor possível. As principais qualidades de um KPI são: controlável (que contribuam para um melhor desempenho se vinculados a um gerente ou equipe responsável); relevante (devem ser identificadas medidas que apoiem claramente os objetivos estratégicos da organização); verificável (os KPI devem ser auditáveis em termos de precisão e propósito); quantificável (os KPI devem ser mensuráveis); oportuno (os KPI precisam ser eficazes ao informar a tomada de decisões); acessível (os dados para mensurar o KPI devem ser acessíveis); custo eficaz para coletar (os KPI precisam ter um custo-benefício que seja vantajoso para a organização) (Barbuio, 2007).

O motivo para o baixo desempenho das empresas é baseado no desperdício em diferentes formas, sendo necessária a implementação de ações que reduzem o desperdício, sendo que, dessa forma haverá uma consequente melhoria de desempenho (Lindberg, Tan, Yan, & Starfelt, 2015). A gestão dos KPI consiste em monitorar o progresso dos principais indicadores, que apontarão se a empresa está a atuar com o desempenho desejado (Cruz & Ávila, 2021).

2.2.4 Indicadores utilizados no Projeto

Para avaliar o desempenho financeiro de uma empresa, os diretores e acionistas podem estudar os indicadores financeiros, que dizem respeito ao nível estratégico da empresa (Cruz & Ávila, 2021). Neste projeto, utilizaram-se modelos preditivos para dez diferentes indicadores, são eles:

Preço / Lucro operacional [= EBIT]: EBIT significa em inglês “Earnings Before Interest and Taxes”. Traduzindo para o português, significa “lucro antes dos juros e impostos”, também conhecido como LAJIR (Lucro Antes dos Juros e Imposto de Renda). Este indicador evidencia somente o lucro operacional da empresa, sem incluir despesas ou receitas financeiras (Nissim, 2019).

Preço / Lucro para o período [= Lucro líquido]: Lucro líquido é o rendimento real de uma empresa e seu cálculo é a diferença entre a receita total e o custo total (Gitman, 2010).

EBITDA: O EBITDA significa em inglês “Earnings Before Interest, Taxes, Depreciation and Amortization”. Traduzindo para o português, significa lucro antes dos juros, impostos, depreciação e amortização. Seu principal objetivo é demonstrar o lucro operacional da empresa (Gitman, 2010; Nissim, 2019).

ROE usando lucro líquido (%): ROE em inglês significa “Return on common equity”. Traduzindo para o português, significa retorno sobre o patrimônio. Ele mensura o retorno obtido sobre o investimento dos acionistas da empresa, ou seja, quanto maior for ROE, melhor para os proprietários. Sua fórmula é o lucro líquido dividido pelo fundo de acionista (Gitman, 2010; Pulungan & Insan, 2020).

ROA usando lucro líquido (%): ROA em inglês significa “Return on Assets”. Traduzindo para o português, significa Retorno Sobre o Ativo. ROA usando lucro líquido representa a rentabilidade total de uma empresa e sua principal finalidade é mensurar sua capacidade de gerar lucros com o montante de ativos que possui. Quando este indicador apresenta uma baixa rentabilidade, significa que sua eficácia operacional precisa ser melhorada. Sua fórmula é o lucro líquido dividido pelo total de ativos (Gitman, 2010; Leite, 2018).

Margem de lucro (%): A margem de lucro representa a percentagem acrescentada ao valor de custo de um determinado produto, é o lucro obtido depois da dedução de todos os custos despesas. É calculado também o P/L antes de impostos, que é dividido por receita operacional (volume de negócios) (Crepaldi, 2021; Gitman, 2010).

Margem EBIT (%): A margem EBIT é um dos indicadores mais utilizado nas empresas de capital aberto, sendo um indicador de lucratividade operacional (Neves, Pereira, Quevedo, Souza, & Aranha, 2019). Sua

fórmula é o Resultado antes dos impostos dividido por pela receita líquida, como a margem EBIT é dada em percentagem, após a divisão é multiplicado o valor por 100. Sua fórmula é EBIT dividido por receita operacional (Santos, Almeida, Costa, & Lyrio, 2019).

Índice de liquidez (x): O índice de liquidez representa a capacidade de pagamento da empresa relacionado as suas obrigações. Sua fórmula é o ativo circulante, que representa bens e direitos que deverão ser convertidos em dinheiro, como por exemplo: caixa da empresa, saldo no banco, contas a receber dos clientes, subtraído pelo estoque, em seguida o resultado é dividido pelo passivo circulante que está relacionado às contas dentro do exercício social da empresa, como por exemplo: impostos, aluguel, fornecedores. Essas contas são a curto prazo, que vencem antes de 12 meses da presente data (Gitman, 2010).

Engrenagem (%): A engrenagem, também conhecida como alavancagem financeira, é um indicador de risco financeiro associado a empresa, um elevado índice de engrenagem mostra uma alta proporção da dívida em relação ao património (Gitman, 2010).

Sua fórmula é passivo não circulante, que são obrigações financeiras de longo prazo listados no balanço da empresa, dívidas que vencem além de 12 meses da presente data (Pietro Netto et al, 2019), somado ao empréstimo (caso a empresa possua empréstimos), em seguida o resultado é dividido pelo fundo de acionista que é o montante do capital da empresa que pertence aos acionistas (Gitman, 2010).

Vendas: O indicador de vendas utilizado nesse projeto, é relacionado ao valor bruto que a empresa ganhou com suas vendas.

Desenvolver um modelo preditivo de indicadores de desempenho em SGI, suportado em redes neurais artificiais, torna possível auxiliar as empresas a antever o seu desempenho no futuro e, através disso, tomar decisões para melhorias como, por exemplo, a conquista de novas certificações de qualidade.

2.3 Redes Neurais Artificiais

As Redes Neurais Artificiais são sistemas digitais baseados na maneira como o cérebro humano trabalha e se constitui, onde a rede adquire conhecimento através de um processo de aprendizagem, utilizado para conter o conhecimento obtido e após a rede ter passado por este método. A ANN consegue projetar novos dados de saída com base na informação adquirida (Haykin, 2001).

As ANN possuem a capacidade de aprender com dados arbitrários e rastrear mudanças de um sinal ao longo do tempo, permitindo assim a resolução de problemas que não podem ser tratados com técnicas estatísticas convencionais (Abraham, 2005).

A ANN deve ser arquitetada de modo que a aplicação de um conjunto de entradas produza o conjunto desejado de saídas, para isso o número de neurónios ocultos na configuração afeta diretamente a qualidade da rede, uma grande quantidade de neurónios ocultos irá garantir o aprendizado correto e dessa forma a rede conseguirá prever com maior exatidão os dados em que foi treinada (Abraham, 2005).

Os dados de entrada passam por funções de transferência matemática que determinam a ativação do neurónio e posteriormente são comparados com os dados de saída. Caso sejam observadas divergências consideráveis, os dados de saída são ajustados até a obtenção da rede ideal (Haykin, 2001).

Os neurónios utilizados nas ANN são elementos matemáticos que processam informações cruciais para a rede neural. A figura 4 mostra este modelo de neurónio.

A soma das entradas (X) multiplicadas por seus pesos (w) é somada ao *bias* (b) através da junção aditiva, em seguida, passa pela função de ativação ($f(\cdot)$) gerando uma saída $y(t)$. A equação (1) é expressa como (Haykin, 2001):

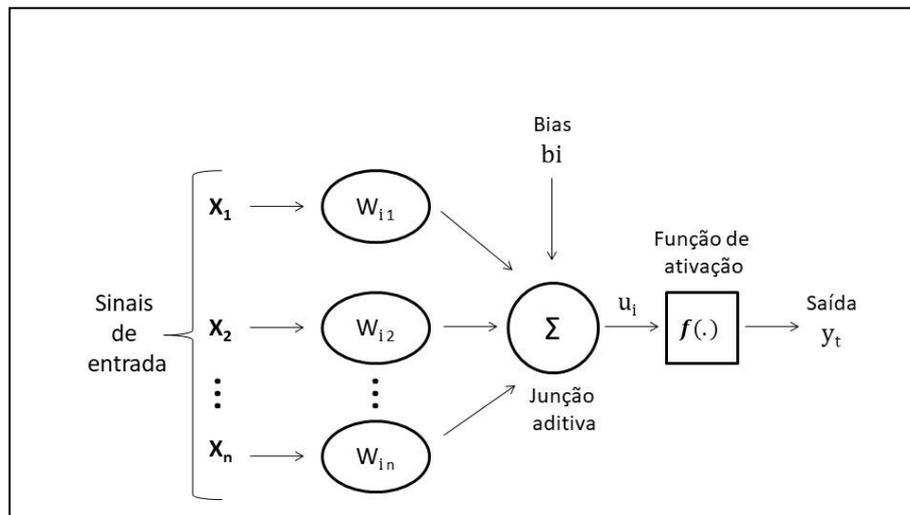


Figura 4: Modelo de um neurônio

Adaptado de Haykin (2001)

$$y_t = f \left(\left[\sum_{i=1}^n (x_i \times w_i) \right] + b_i \right) \quad \text{Equação (1)}$$

Em que:

$y(t)$ = saída

x_i = soma das entradas

w_i = pesos das entradas

b_i = bias

2.3.1 Função de ativação

A função de ativação ou de transferência define a saída de um neurônio e deve possuir algumas propriedades como: a função não pode ser negativa, pois ou o neurônio troca sinal com outro neurônio ou não troca, não há como trocar sinal negativo; a função precisa ser contínua, pois um neurônio não pode modificar o sinal com outro neurônio, indefinidamente. Diversos tipos de funções preenchem os exemplos acima, porém normalmente são usadas três funções que são (Cerqueira, Andrade, Poppi, & Mello, 2001):

a) Função sigmoidal ou logística

Esta é a função de transferência mais utilizada em redes neurais e a que mais se aproxima da saída de um neurónio biológico. Algebricamente, a função sigmoidal é descrita da seguinte forma (Equação 2), onde λ é o parâmetro de inclinação da função, quanto maior o valor de λ , maior a inclinação da curva. (Cerqueira et al., 2001):

$$y(x) = \frac{1}{1 + e^{-\lambda x}} \quad \text{Equação (2)}$$

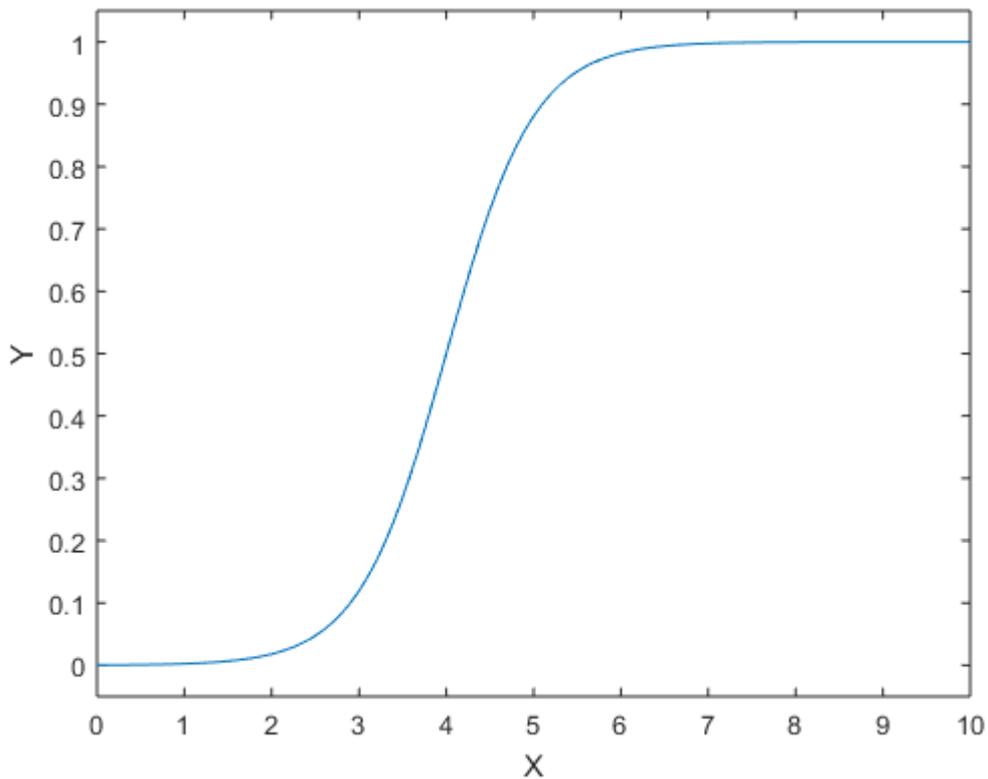


Figura 5: Gráfico da função sigmoidal, com lâmbda igual a 2
Fonte: o autor

b) Função Degrau ou Heaviside

A função degrau ou heaviside também é utilizada nas redes neurais como função de ativação, ela é descontínua com valor zero quando o seu argumento é menor ou igual a zero e valor um quando o seu argumento é maior ou igual a 0 (Equação 3) e é representada através da Figura 6 (Almada, 2019).

$$y(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad \text{Equação (3)}$$

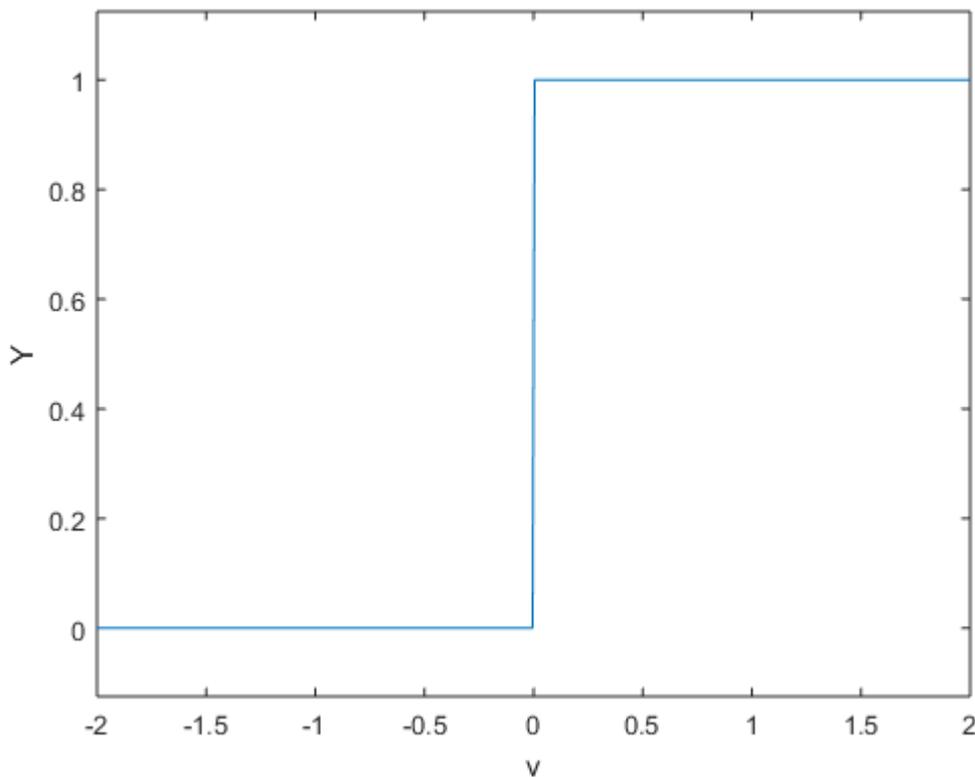


Figura 6: Gráfico da função degrau ou heaviside
Fonte: o autor

c) Função Linear

A função linear é demonstrada pela equação 4, onde “a” é o coeficiente angular, responsável pela inclinação da reta e “b” é o coeficiente linear, responsável pelo intercepto da reta no eixo x. Ela também é utilizada como função de ativação nas redes neurais e é representada na Figura 7(Haykin, 2001).

$$y(x) = ax + b$$

Equação (4)

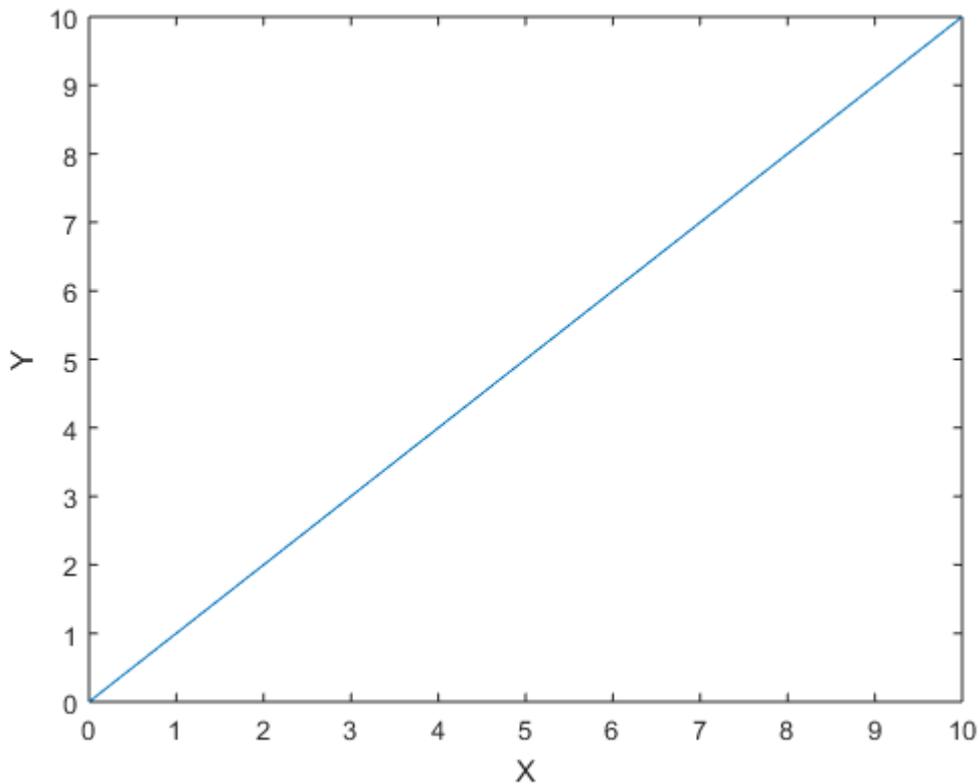


Figura 7: Gráfico da função linear, onde a=1 e b=0
Fonte: o autor

2.3.2 Processos de Aprendizado

Uma das propriedades mais importante para a ANN é a sua habilidade em aprender através do ambiente e melhorar o seu desempenho através da aprendizagem (Haykin, 2001).

Uma ANN pode aprender acerca do seu ambiente através de um processo interativo de ajustes aplicados a seus pesos sinápticos e níveis de bias, dessa forma a rede se torna mais instruída sobre o seu ambiente após cada iteração do processo de aprendizagem e é capaz de produzir uma saída desejada através de um conjunto de entrada (Haykin, 2001).

Para a solução de um problema de aprendizagem é denominado um algoritmo de aprendizagem, porém não há um único algoritmo de aprendizagem, mas sim uma variedade deles onde cada um oferece as suas vantagens específicas. Estes algoritmos divergem entre si pela forma como é formulado o ajuste de um peso sináptico de um neurónio (Haykin, 2001).

A ANN possui muitas características, como os pesos sinápticos que são as forças de conexões entre neurónios, que são utilizados com o objetivo de armazenar o conhecimento adquirido e após a rede ter passado pelo processo de aprendizagem, é capaz de projetar novos dados de saída com base no conhecimento previamente adquirido no treinamento (Haykin, 2001). Possuem também as *bias* que são dados independentes aos termos de entrada para aperfeiçoar o ajuste da ANN e possuem as camadas múltiplas, também conhecidas como rede de múltiplas camadas (Cerqueira et al., 2001).

2.3.3 Perceptão de Múltiplas Camadas

A rede de múltiplas camadas consiste em um conjunto de unidades que constituem a camada de entrada, uma ou mais camadas ocultas e uma camada de saída. O sinal de entrada se propaga para frente através da rede, camada por camada. Estas redes são chamadas de perceptão de múltiplas camadas. Nessas redes, cada camada tem a sua própria função, a saída recebe estímulos da parte intermediária e constrói um padrão que será a resposta. As camadas intermediárias extraem características, os seus pesos sinápticos são codificações de características apresentadas aos padrões

de entrada, isso permite que a ANN crie a sua própria representação. A rede de múltiplas camadas é dividida em três tipos: Camada de entrada - responsável por receber estímulos do ambiente e conectá-los a camada intermediária; camada intermediária - tem a função de extrair grande parte das informações comportamentais da aplicação; camada de saída - informa a que classe pertence à amostra recebida na entrada (Gardner & Dorling, 1998; Haykin, 2001).

O treinamento da rede de múltiplas camadas é realizado e demonstrado em sua entrada o seu aprendizado, ou seja, cada amostra produz uma resposta na saída que é comparada com a desejada, havendo divergências irá gerar um erro que será utilizado para reajustar os pesos sinápticos da conexão (Gardner & Dorling, 1998; Haykin, 2001).

Na figura 8 é possível observar um perceptão de multicamadas com duas camadas intermediárias onde i_n são as entradas e o_n são as saídas.

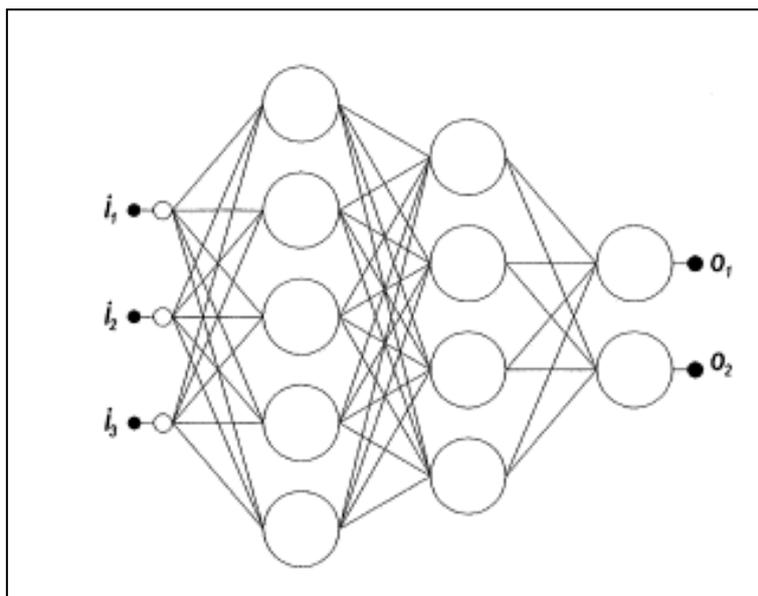


Figura 8: Perceptão multicamadas com duas camadas ocultas
Fonte: Gardner e Dorling (1998).

O perceptão de múltiplas camadas pode modelar funções não lineares e também ser treinado para generalizar com precisão quando apresentados dados novos e invisíveis, tais características o classificam

como uma excelente alternativa para o desenvolvimento de modelos numéricos (Gardner & Dorling, 1998).

Com base no estudo teórico sobre os sistemas de gestão integrada, os indicadores de desempenho e as redes neurais, podemos observar que as redes neurais podem ser uma mais valia para a previsão de indicadores de desempenho em sistemas de gestão integrada.

3 Metodologia

Para potencializar a previsão de indicadores de desempenho, em empresas que utilizam o SGI, utilizou-se ANN como instrumento de predição desses indicadores. Nesta investigação foram utilizados três tipos de ANN:

Tipo A: Desenvolveram-se ANN para 10 empresas individuais, nas quais, previram-se os seus indicadores através dos dados da própria empresa baseado nos indicadores relativos aos anos de 2010 a 2019.

Tipo B: Desenvolveram-se ANN com dados de 50 empresas diferentes em uma mesma rede. Neste caso, através de dados de diversas empresas, realizou-se uma média com os indicadores de 2010 a 2019 para prever os indicadores das outras empresas.

Tipo C: Assim como no Tipo B, desenvolveram-se ANN com dados de 50 empresas. Neste caso, através dos dados destas empresas, realizou-se uma média com os indicadores de 2010 a 2018 para prever indicadores relacionados ao ano de 2019 de outras empresas.

3.1 Coleta de dados

Inicialmente, realizou-se uma coleta através do banco de dados “Orbis Europe”, que é um recurso de dados comparáveis com informações sobre mais de 400 milhões de empresas e entidades de todo o mundo (Bureau van Dijk, 2021). Selecionaram-se empresas portuguesas que possuem o SGI e utilizaram-se os seguintes indicadores:

- | | |
|---------------------------------------|---|
| 1) Ativo permanente; | 9) P/L após impostos; |
| 2) Ativos fixos tangíveis; | 10) P/L para o período [= Lucro líquido]; |
| 3) Outros ativos fixos; | 11) Custos de funcionários; |
| 4) Ativos correntes; | 12) Depreciação e Amortização; |
| 5) Estoque; | 13) Outros itens operacionais; |
| 6) Devedores; | 14) Fluxo de caixa; |
| 7) Outros ativos circulantes; | 15) Valor agregado; |
| 8) Dinheiro e equivalente a dinheiro; | 16) EBITDA; |

- | | |
|---|--|
| 17) Fundos de acionistas; | 33) ROE usando P/L antes de impostos (%); |
| 18) Capital; | 34) ROA usando P/L antes de impostos (%); |
| 19) Outros fundos de acionistas; | 35) ROE usando lucro líquido (%); |
| 20) Passivo não circulante; | 36) ROA usando lucro líquido (%); |
| 21) Dívida de longo prazo; | 37) Margem de lucro (%); |
| 22) Passivo circulante; | 38) Margem EBIT (%); |
| 23) Credores; | 39) Fluxo de caixa / receita operacional (%); |
| 24) Outros passivos circulantes; | 40) Rotatividade de ativos líquidos (x); |
| 25) Capital de giro; | 41) Período de coleta (dias); |
| 26) Receita operacional (volume de negócios); | 42) Período de crédito (dias); |
| 27) Vendas; | 43) Razão atual (x); |
| 28) P/L operacional [= EBIT]; | 44) Índice de liquidez (x) |
| 29) P/L financeiro; | 45) Índice de liquidez dos acionistas (x); |
| 30) Despesas financeiras; | 46) Índice de solvência (baseado em ativos) (%); |
| 31) P/L antes de impostos; | 47) Engrenagem (%). |
| 32) Tributação; | |

Estes indicadores foram utilizados nas redes tipo A, B e C. Além disso, na rede tipo B e C, também reutilizaram dados referentes ao setor de cada empresa, à região onde se localiza e ao porte da empresa. Conforme o Instituto Nacional de Estatística de Portugal, empresas com até 10 funcionários são consideradas micro, empresas com até 50 funcionários são consideradas pequenas, empresas com até 250 funcionários são consideradas médias e empresas com mais de 250 funcionários são consideradas grandes (“Portal do INE”, [s.d.]).

3.2 Software NeuralTools

Em seguida, os dados coletados foram ajustados em planilhas no Excel para possibilitar a utilização da ferramenta base desta investigação, o NeuralTools, um software da Palisade que foi escolhido pelos seguintes motivos (Palisade, 2015):

- i. Utilização fácil: o NeuralTools é um software de redes neurais simples, com uma linguagem acessível e de fácil utilização, que ao contrário de outros softwares semelhantes, não exige grandes conhecimentos na área da programação.
- ii. Parceria com a Universidade do Minho: A Palisade possui uma parceria com a Universidade do Minho, permitindo que os alunos possam ter acesso aos seus softwares de forma gratuita.
- iii. Funciona através do Microsoft Excel: o NeuralTools funciona como uma extensão do Excel, dessa forma, para utilização do programa é necessário organizar os dados desejados dentro do Microsoft Excel.

Devido aos benefícios apresentados, selecionou-se o NeuralTools como ferramenta principal para esta investigação.

3.3 Preparação dos dados

A primeira fase da ANN constituiu-se na preparação dos dados coletados no “Orbis Europe”, no intervalo entre 2010 e 2019. Organizaram-se os dados no Microsoft Excel de forma vertical, de modo que a primeira célula de cada coluna correspondesse ao nome da variável, formando assim o “input” da ANN.

Em seguida, realizou-se o tratamento dos dados através do NeuralTools. Desta forma, o software disponibiliza o comando “Administrador do conjunto de dados”, conforme a figura 9, que permite definir a gestão dos conjuntos de dados que serão utilizados para a realização do treino, do teste e da previsão.

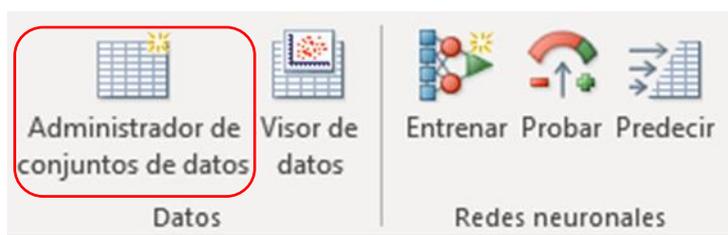


Figura 9: Comando Administrador do Conjuntos de Dados do NeuralTools

Através das variáveis utilizadas nas ANN, os conjuntos de dados foram estruturados. Organizaram-se as variáveis em colunas adjacentes, nas quais a primeira célula de cada coluna é o nome da variável. Dessa

forma, cada linha é equivalente a um caso e, cada caso compreende um indicador oriundo de cada uma das séries de variáveis de *input*.

Após selecionar o comando “Administrador de Conjunto de Dados”, contido no menu “Dados”, apresentou-se a seguinte janela de opções, ilustrada na Figura 10.

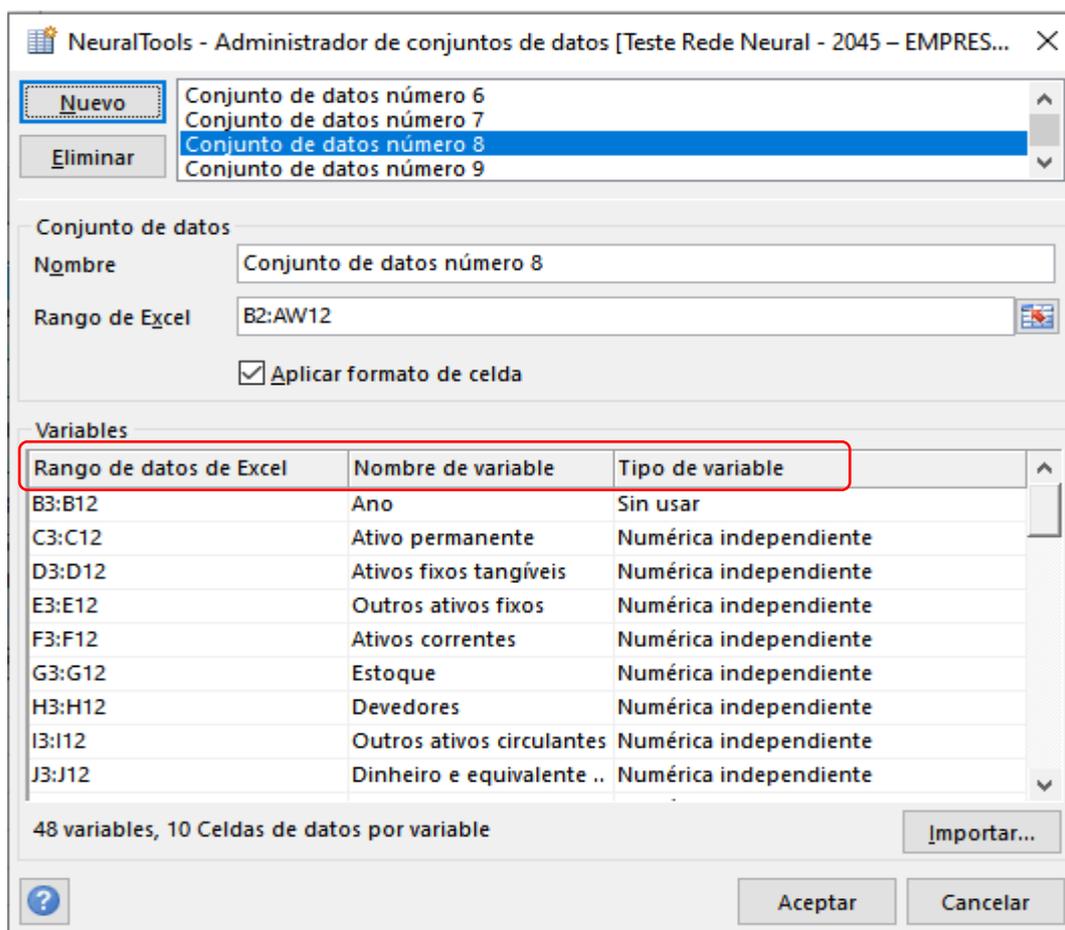


Figura 10: Caixa de diálogo do comando “Administrador de Conjunto de Dados”

Nesta janela, é possível efetuar diversas ações, mas para este projeto, utilizaram-se apenas as ações para produzir conjunto de dados, definir tipo de variável e mudar o nome do conjunto de dados.

Para produzir conjunto de dados, foi necessário selecioná-los no Microsoft Excel ou colocar o seu intervalo no local onde está escrito “Rango de Excel”, que em português significa “Gama de valores”. Para definir o tipo de variável, selecionou-se a opção “Tipo de Variável” e, em seguida, a opção desejada. Através

das opções, foi possível selecionar se a variável era dependente (*output*) ou independente (*input*) e, se era uma variável numérica ou categórica. Ainda na figura 10, é possível observar que foi utilizada a opção “sin usar” que em português é “não usar”, para a variável “Ano”. Esta opção é selecionada caso haja uma variável com o objetivo apenas de organizar os dados, mas não se pretende utilizar na ANN. Após a configuração, os dados foram habilitados para as etapas de treino, teste e previsão.

3.4 Treino e Teste

Após a definição e a configuração do comando de conjunto de dados, iniciou-se a etapa de treinar e testar a ANN; nesta investigação o treino e o teste foram executados em paralelo, premindo a opção “entrenar” do NeuralTools, que em português significa treinar.

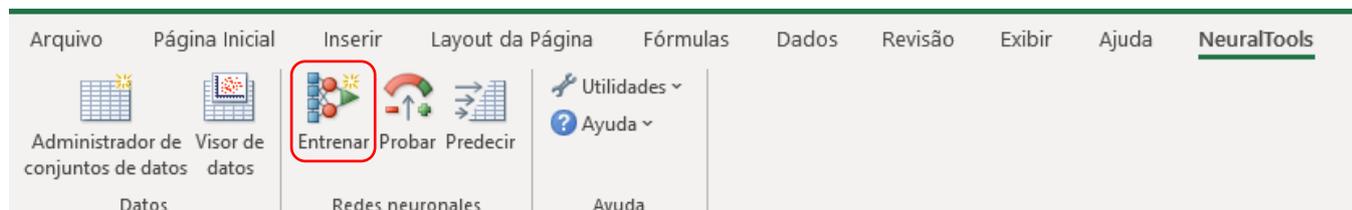


Figura 11: Comando Treinar do NeuralTools.

Ao selecionar a opção “treinar”, apresenta-se a sua respectiva caixa de diálogo, conforme a figura 12.

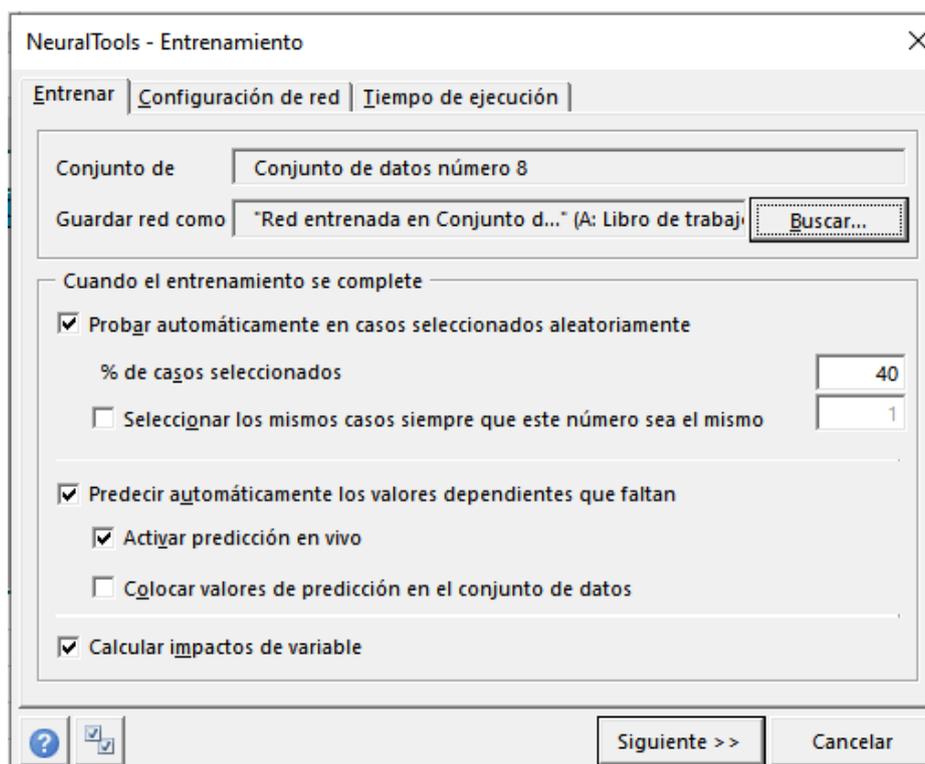


Figura 12: Caixa de diálogo referente ao comando “Treinar”

A caixa de diálogo acima permite fazer várias configurações referente ao treino e teste, nessa investigação foi marcada a opção “Probar automáticamente en casos seleccionados aleatoriamente % de casos seleccionados” que em português significa “testar automaticamente em casos seleccionados aleatoriamente % de casos seleccionados”. Essa opção permite seleccionar a percentagem de variáveis que serão testadas. Nesta investigação foram testadas diversas percentagens com o objetivo de otimizar os testes e foram seleccionados os percentagem de 20% para os testes e previsões tipo A e 40% para os tipos B e C, pois foram os que obtiveram melhores resultados.

Foi seleccionado também a opção “Predecir automaticamente los valores dependientes que faltan” que em português significa “Prever automaticamente os valores dependentes ausentes” e, em seguida, a opção “Activar predicción en vivo” que em português significa “Ativar previsão instantânea”. Estes comandos têm como objetivo seleccionar a previsão automática de valores de “output”, para os casos em que os valores das variáveis dependentes estão a faltar. Dessa forma, é possível obter rapidamente as respostas necessárias, através de uma única operação (Palisade, 2015).

Por fim, selecionou-se “Calcular impactos de variable” que em português significa “Calcular impactos das variáveis”. Esta aplicação tem como objetivo utilizar os dados usados no treino para mensurar cada variável independente, aferindo a elas um valor em percentagem, referente ao seu impacto na variável dependente da previsão. Dessa forma, é possível analisar quais variáveis tem um impacto maior ou menor na previsão

Ao clicar no botão “Configuración de red”, que em português significa “configuração de rede”, abre a seguinte janela, figura 13.

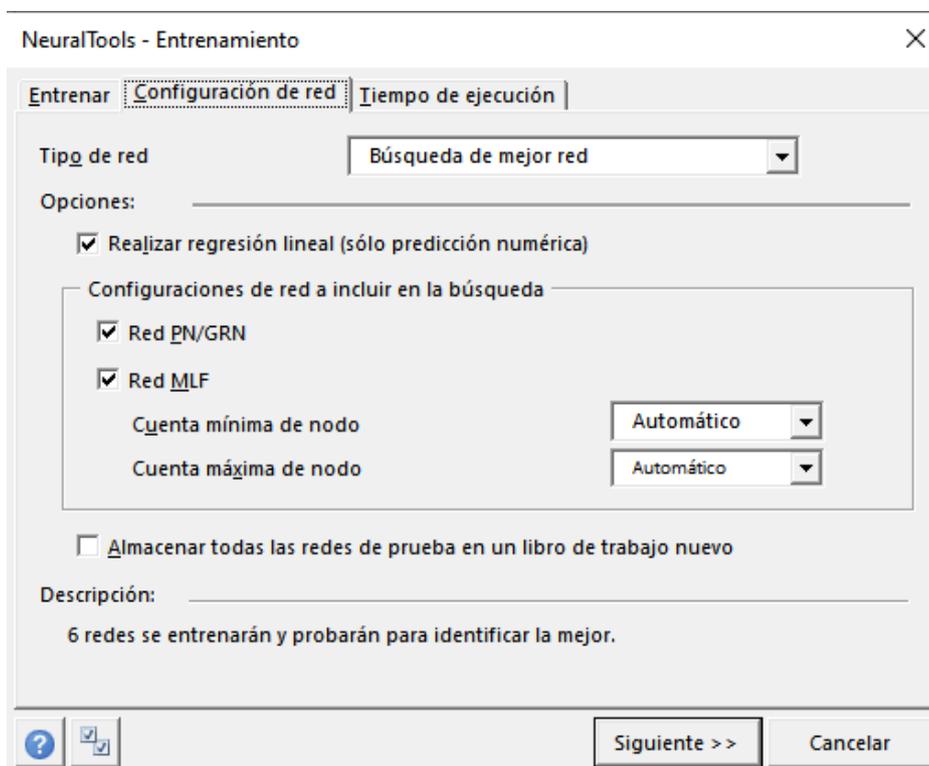


Figura 13: Separador Configuração de rede da caixa de diálogo do comando Treino

Neste separador foi permitido escolher o “tipo de red” que em português é “tipo de rede”. Ele possui três opções, “Red PN/GRN”, “Red MLF” e “Búsqueda de mejor red”. Dessa forma o NeuralTools permite utilizar diferentes configurações de rede com o objetivo de obter a melhor previsão possível.

A “Red PN/GRN” em português significa Redes Neurais Probabilísticas (PNN) e “Redes Multi-Layer Feedforward (MLF)” em português significa Redes Neurais de Regressão Generalizada (GRNN). A “Búsqueda de mejor red”, que em português significa “busca da melhor rede”.

A Rede Neural Probabilística é utilizada em problemas de classificação, onde o usuário não necessita adotar qualquer decisão no que diz respeito a estrutura da rede, elas possuem sempre duas camadas ocultas de neurônios, devido a isso esse tipo de rede possui um tempo de treino muito reduzido (Palisade, 2015).

Na Rede Neural de Regressão Generalizada, o usuário necessita apontar quantos neurônios as camadas ocultas devem conter, esse tipo de rede admite previsões rápidas e tem uma maior fiabilidade quando o valor de uma variável independente se afasta do intervalo padrão do conjunto de treino. Nesse caso, o software em questão permite utilizar uma ou duas camadas ocultas e atribuir entre 2 e 100 nós por camada. Esse tipo de rede permite ser utilizada quando a variável dependente é numérica ou categórica (Palisade, 2015).

Para as redes neurais utilizadas nesta investigação foi utilizado a opção “busca da melhor rede”. Quando essa opção é utilizada, o NeuralTools treina e testa uma variedade de configurações de redes até gerar a que produz as melhores previsões para os seus dados, a seleção da melhor rede é executada automaticamente pelo NeuralTools baseado na comparação do erro obtido por cada rede, ou seja, a rede que tiver a menor percentagem de erro, será a escolhida pelo software (Palisade, 2015).

Na figura 13 é possível observar a opção “Cuenta mínima de nodo”, que em português significa “Contagem mínima de nós”, através dessa opção é possível selecionar entre 2 a 100 nós por camada ou optar pela opção “automático” que foi a escolhida nesse projeto, em que o próprio software irá utilizar diversos tipos de nós automaticamente para encontrar a rede com a menor percentagem de erro.

Na figura 14 é exibido o separador “Tiempo de ejecución” que em português significa “Tempo de execução” na caixa de diálogo referente ao comando Treino.

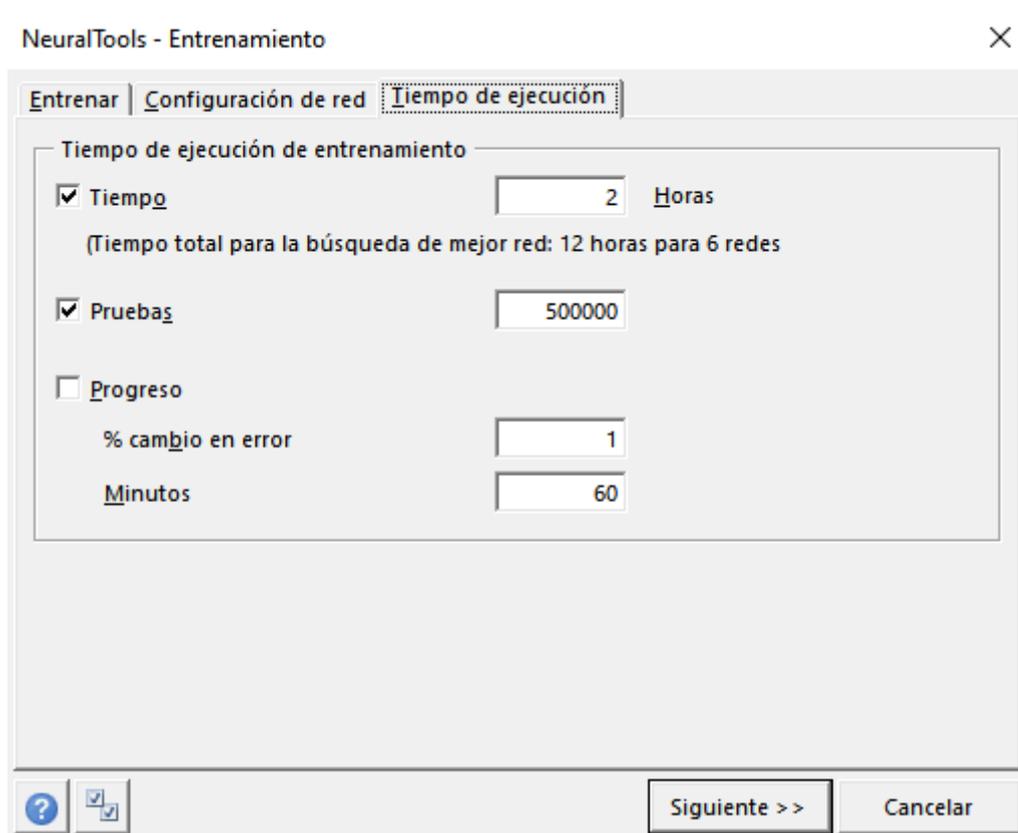


Figura 14: Separador Tempo de Execução referente ao comando Treino

Neste separador foi possível realizar algumas configurações para a rede, como selecionar o tempo de treino e o número de experimentos realizados por rede. Após uma extensa observação dos testes, definiu-se como mais adequada a configuração de 2 horas e 500.000 experimentos para as redes tipo A, e de 2 horas e 1.000.000 experimentos para as redes do tipo B e C.

Após concluir a configuração dos 3 separadores do comando treino, clicou-se no botão "siguiete" que traduzido para português significa "seguinte", e redireciona para janela abaixo (Figura 15).

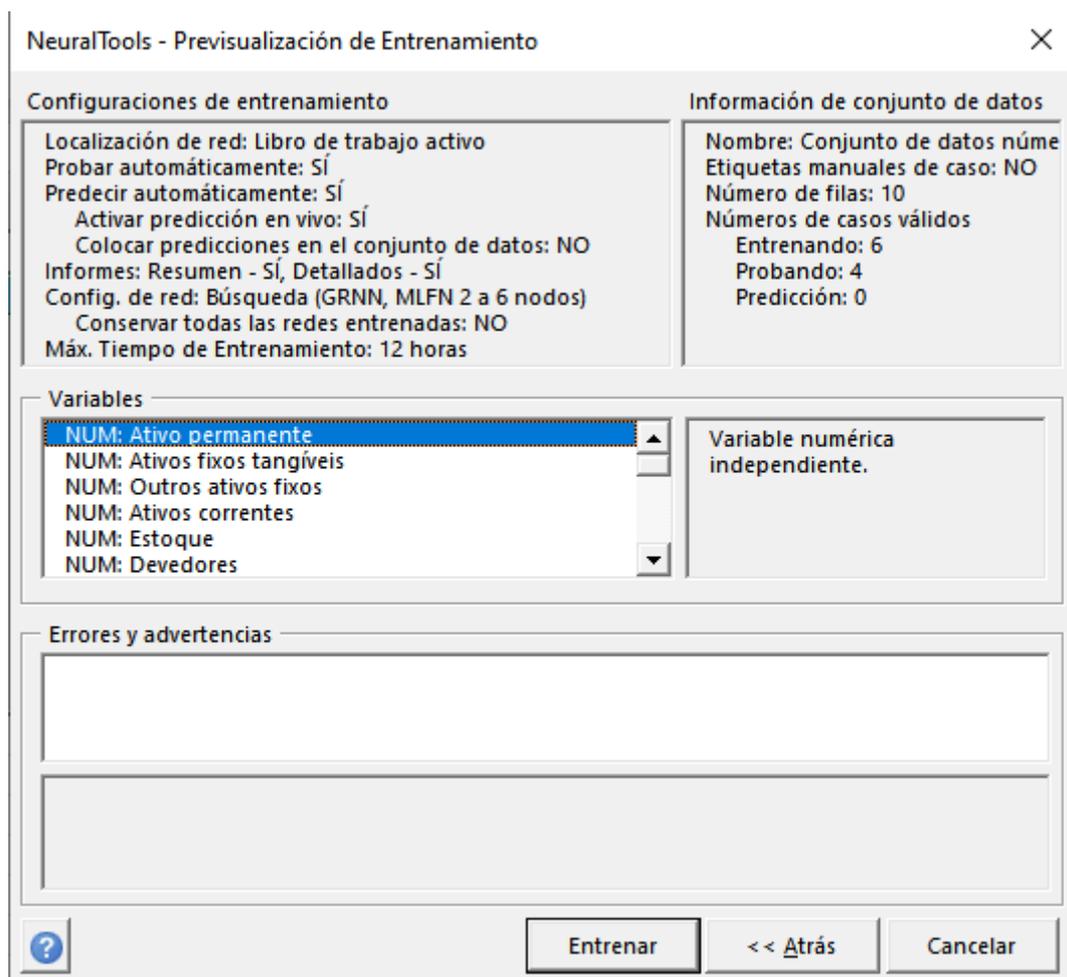


Figura 15: Janela de visualização de treinamento.

A janela “Previsualización de Entrenamiento” que em português significa “visualização de treinamento” mostra o que será realizado durante o treinamento. Através dela, o software verifica se existe algum erro com os dados antes de iniciar o treinamento. Após verificar a inexistência de erros na configuração, clicou-se no botão “entrenar” que em português significa “treinar”. Dessa forma, surge a seguinte janela (Figura 16):

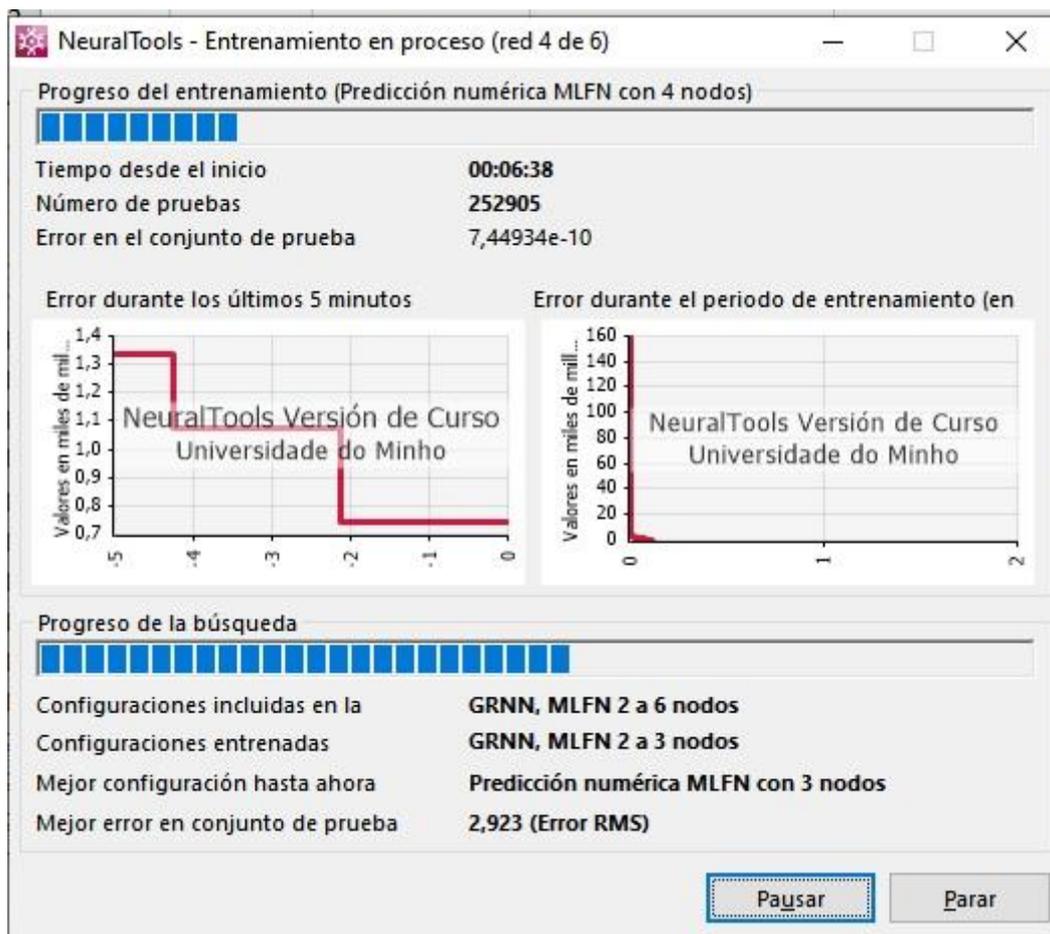


Figura 16: Treinamento em andamento

Na figura acima, relacionada à janela “Entrenamiento en proceso” que em português significa “treinamento em andamento”, executou-se o treinamento da rede neural com os seus respectivos dados, informando o seu progresso. O NeuralTools tende a melhorar a rede com o tempo e mostra a sua evolução através dos gráficos que podem ser observados na figura 16, além de informar em tempo real a duração do treino até o momento, o erro do treino durante os últimos 5 minutos, o número de treinamentos realizados até o momento, e a melhor configuração de rede até o momento.

Os treinos, quando não foram interrompidos ao premir a opção “pausar”, ocorreram até que um dos critérios definidos para a parada fosse alcançado.

Nesta investigação, o treino, o teste e a previsão foram realizados em simultâneo e as variáveis dependentes, em todos os casos, foram numéricas. O NeuralTools define como padrão uma tolerância de erro de até 30%, ou seja, caso o valor treinado esteja dentro dessa margem de erro, ele é considerado correto, caso ultrapasse essa margem é considerado como incorreto.

3.5 Previsão

O principal objetivo da ANN é a previsão das variáveis, que é a última fase da rede neural. Para realizar a previsão foi necessário deixar duas células em branco para que a rede pudesse prever os valores destas lacunas e, em seguida, compará-los com o valor real. Como citado anteriormente, realizou-se o treino e a previsão juntamente, uma vez que, as lacunas admitidas durante o treino foram utilizadas para a previsão dos valores das variáveis do conjunto de dados.

Ao término de cada rede neural, obtiveram-se os valores de treino e previsão, além de um relatório de desempenho da rede treinada com as seguintes informações: Melhor configuração; variáveis dependentes e independentes; erro quadrático médio; erro absoluto médio; desvio de erro absoluto; percentagem de más previsões; impacto das variáveis; histograma das diferenças residuais e gráficos de dispersão. Tais informações foram de grande valia para selecionar a melhor configuração de rede.

Por fim, calculou-se o erro de percentagem de cada teste e previsão com o auxílio do Excel. Os resultados obtidos foram analisados.

4 Resultados e Discussões

A seguir, é possível verificar os resultados, em formato de tabelas e gráficos, e análises realizadas para as 120 redes neurais, subdivididas em três tipos de modelos preditivos (A, B e C). Segue-se também uma abordagem sobre qual modelo preditivo é o mais indicado para cada um dos indicadores utilizados.

4.1 Modelo preditivo do tipo A

No tipo A, realizou-se a previsão individual de 10 indicadores para cada empresa, sendo 10 empresas que utilizam o SGI, totalizando 100 ANN. Tal como referido, o NeuralTools determina como corretos a previsão e o treino que apresenta um erro de percentagem relativo de até 30%. Com base nesta informação, foi possível compor a tabela 2, com os valores dos erros relativos de cada indicador e a média geral.

Tabela 2: Erro relativo dos indicadores relacionados ao modelo preditivo do Tipo A.

INDICADOR UTILIZADO	PREVISÕES CORRETAS (%)	TREINOS CORRETOS (%)
Índice de liquidez	95	93
EBITDA	85	83
ROE usando lucro líquido	60	70
Engrenagem	70	90
EBIT	60	60
Vendas	100	100
ROA usando lucro líquido	65	53
Margem EBIT	85	73
Margem de Lucro	70	53
Lucro Líquido	55	57
Média	74,5	73

Ao analisar a tabela 2, é possível observar que, para o indicador “Índice de liquidez” 95% das previsões e 93% treinos apresentaram erro menor do que 30%, sendo considerados corretos pelo NeuralTools. Analogamente, após observar os demais indicadores é possível distinguir que, entre eles há indicadores que obtiveram previsões e treinos ótimos e podem ser utilizados pelas empresas com maior fiabilidade para prever os seus indicadores, são eles: índice de liquidez; EBITDA; vendas; e margem EBIT que tiveram uma percentagem de previsão acima da média. Outros ficaram próximo à média e possuem uma fiabilidade menor que os citados anteriormente como, por exemplo, engrenagem, e margem de lucro. Dos indicadores analisados, quatro foram abaixo da média, são eles: ROE usando lucro líquido, ROA usando lucro líquido, EBIT, e lucro líquido.

Durante a ANN, calcularam-se as variáveis que mais impactaram na previsão de cada indicador, como é possível observar na tabela 3. Através dessa informação é possível compreender quais variáveis precisam melhorar para afetar o desempenho de um indicador específico.

Tabela 3: Variáveis que mais impactaram os indicadores previstos relacionados ao Tipo A.

INDICADOR	VARIÁVEIS
Índice de Liquidez	Razão atual (x); Outros ativos fixos e Vendas.
EBITDA	Fluxo de caixa; ROE usando lucro líquido (%) e Capital de giro.
ROE usando lucro líquido	ROE usando P / L antes de impostos (%); Fluxo de caixa / receita operacional (%) e ROA usando P / L antes de impostos (%).
Engrenagem	Dívida de longo prazo; Fluxo de Caixa e Índice de liquidez dos acionistas (x).
EBIT	EBITDA; margem EBIT (%) e Margem de lucro (%).
Vendas	Período de crédito (dias); Receita operacional (volume de negócios) e Índice de liquidez dos acionistas (x).
ROA usando lucro líquido	Margem EBIT (%); EBIT; Capital.
Margem EBIT	Margem de lucro (%); Fundos de acionistas e Índice de liquidez (x).
Margem de Lucro	ROE usando lucro líquido (%); Estoque e ROA usando P / L antes de impostos (%).
Lucro Líquido	ROE usando P / L antes de impostos (%); ROE usando lucro líquido (%) e Tributação.

Para completar as análises, foi necessário comparar os valores previstos com os reais de cada indicador. Na figura 17 é possível observar o comparativo entre o valor real e a previsão do índice de liquidez e do ROE usando lucro líquido. Tanto para o índice de liquidez (a) como para o ROE usando lucro líquido (b), a diferença entre o valor real e a previsão não sofreu variação abrupta na maioria dos pontos analisados, podendo considerar uma fiabilidade aceitável.

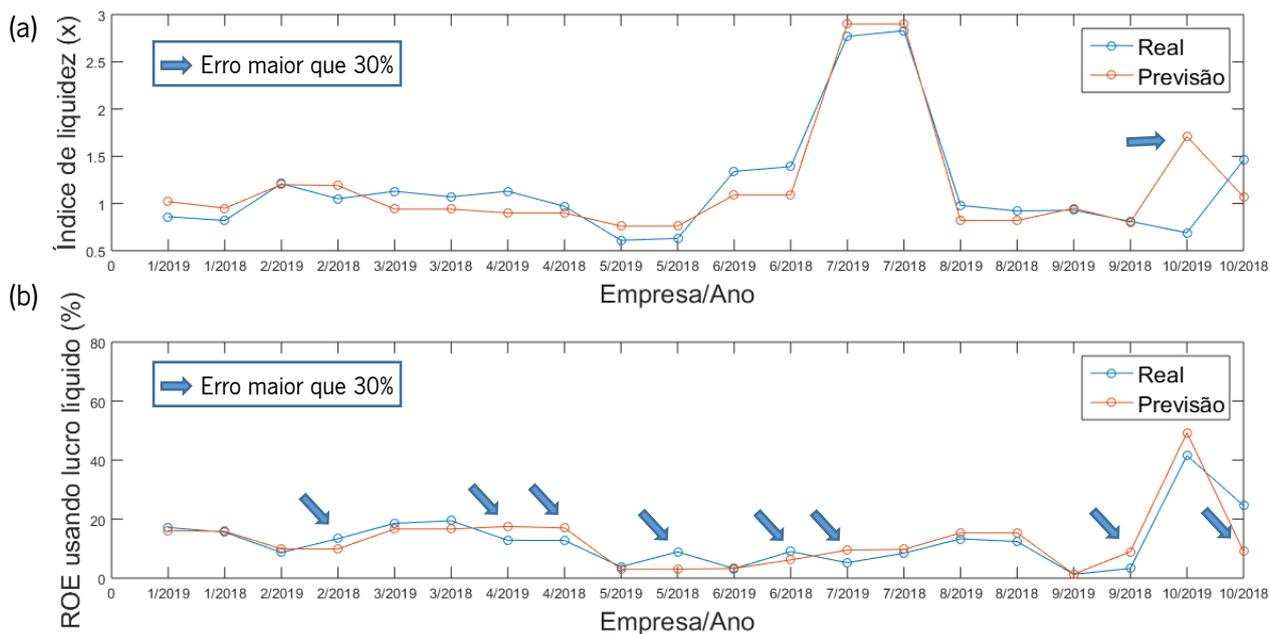


Figura 17: Comparativo entre o valor real e a previsão nos anos de 2018 e 2019 de cada empresa em relação ao (a) índice de liquidez e (b) ROE usando lucro líquido.

Desenvolveram-se também gráficos comparando os valores previstos com os reais da engrenagem e do ROA usando lucro líquido, que podem ser observados na Figura 18. Para o indicador engrenagem (a) a previsão exibiu alguns pontos de valor distante do valor real, e muitos pontos próximos, podendo considerar que a fiabilidade da previsão foi boa. Da mesma forma aconteceu para o ROA usando lucro líquido (b), podendo considerar também uma boa fiabilidade para este indicador.

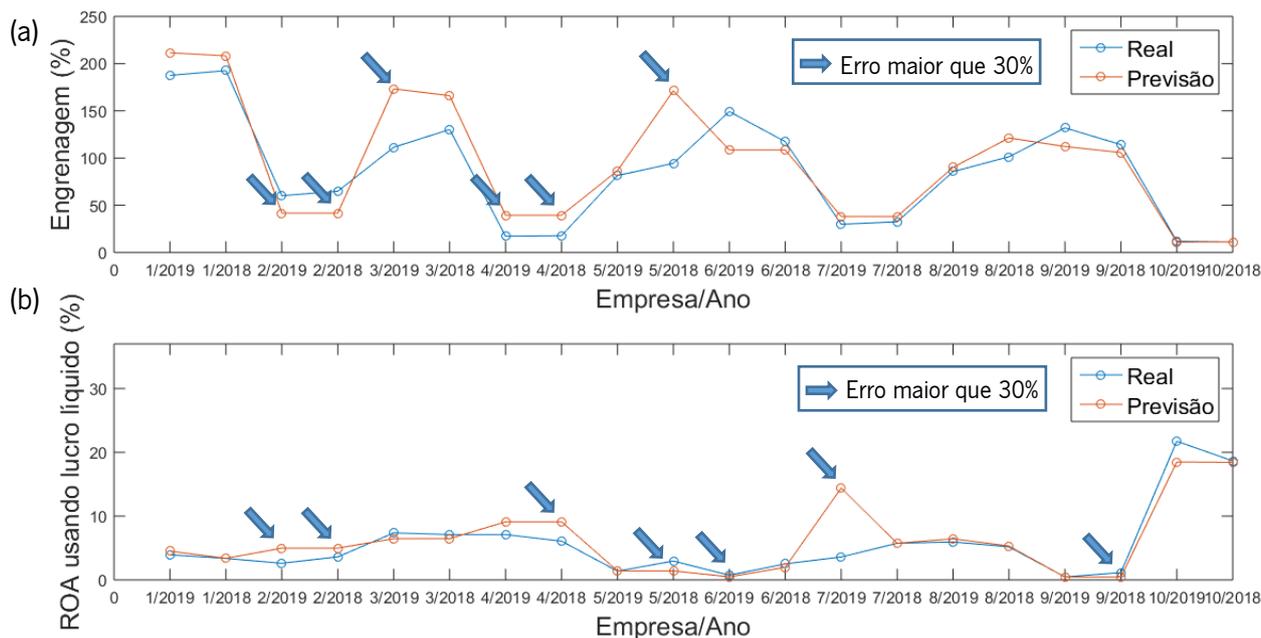


Figura 18:Comparativo entre o valor real e a previsão nos anos de 2018 e 2019 de cada empresa em relação aos indicadores (a) Engrenagem e (b) ROA usando lucro líquido.

Na figura 19 apresentam-se os comparativos entre o valor real e a previsão para (a) margem EBIT e (b) margem de lucro, sendo possível observar que, tanto para a margem EBIT quanto para a margem de lucro, a proximidade entre os valores reais e da previsão prevaleceu em todos os pontos analisados, podendo-se constatar uma alta fiabilidade em ambos os casos.

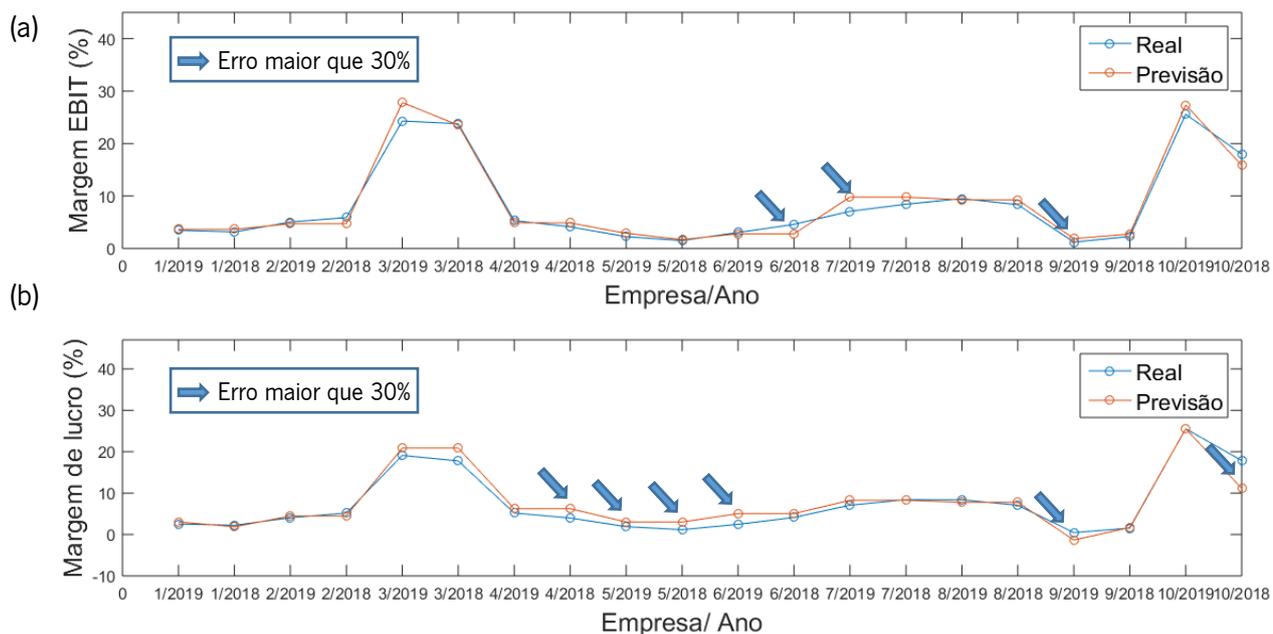


Figura 19: Comparativo entre o valor real e a previsão nos anos de 2018 e 2019 de cada empresa em relação aos indicadores (a) Margem EBIT e (b) Margem de lucro.

A mesma fiabilidade ótima pode ser observada na Figura 20, em relação aos indicadores (a) EBIT e (b) EBITDA. Analisando os gráficos, é possível observar que, tanto para EBITDA quanto para EBIT, a previsão apresentou praticamente todos os pontos com elevada proximidade do valor real, com exceção da empresa 6 no ponto relativo ao ano de 2018, em que a diferença foi relativamente alta, para os dois indicadores, em relação aos demais casos analisados.

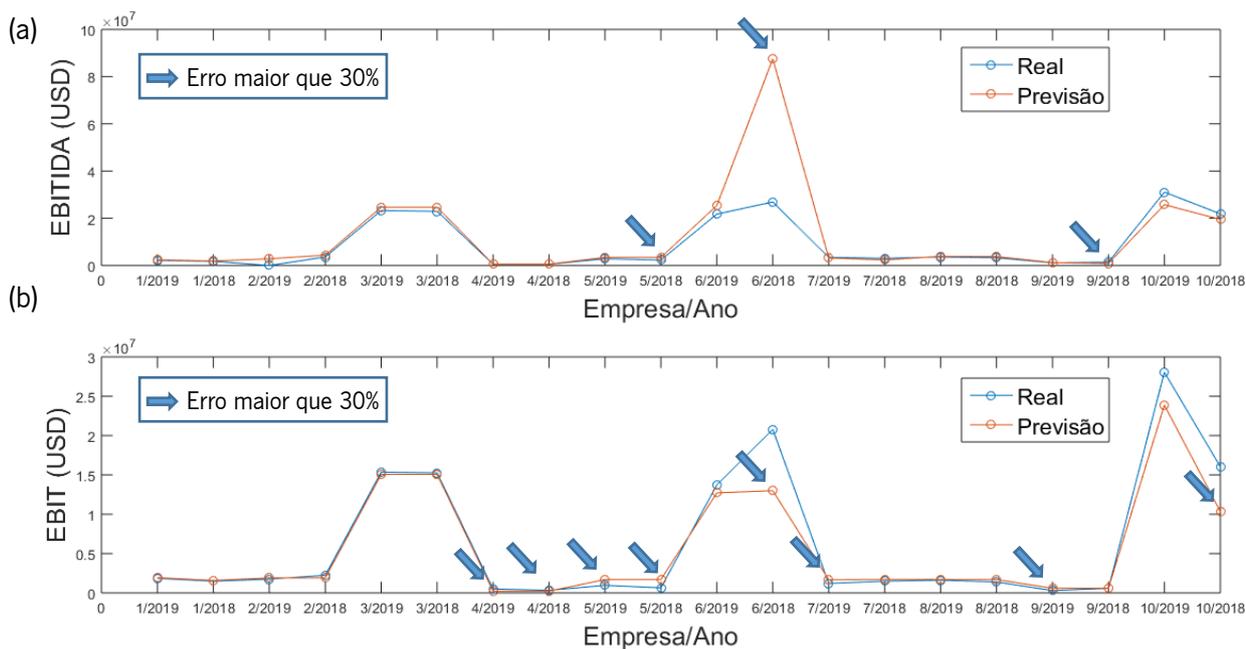


Figura 20: Comparativo entre o valor real e a previsão nos anos de 2018 e 2019 de cada empresa em relação aos indicadores (a) EBITDA e (b) EBIT

De maneira análoga, é possível observar na figura 21 que, para o indicador (a) vendas, o comportamento foi o mesmo, praticamente todos os pontos apresentaram proximidade entre o valor real e a previsão, exceto na empresa 6, para o ano de 2018. O lucro líquido (b), por sua vez, exibiu alguns pontos de previsão distantes do valor real, e muitos pontos próximos, podendo considerar uma fiabilidade de previsão mediana.

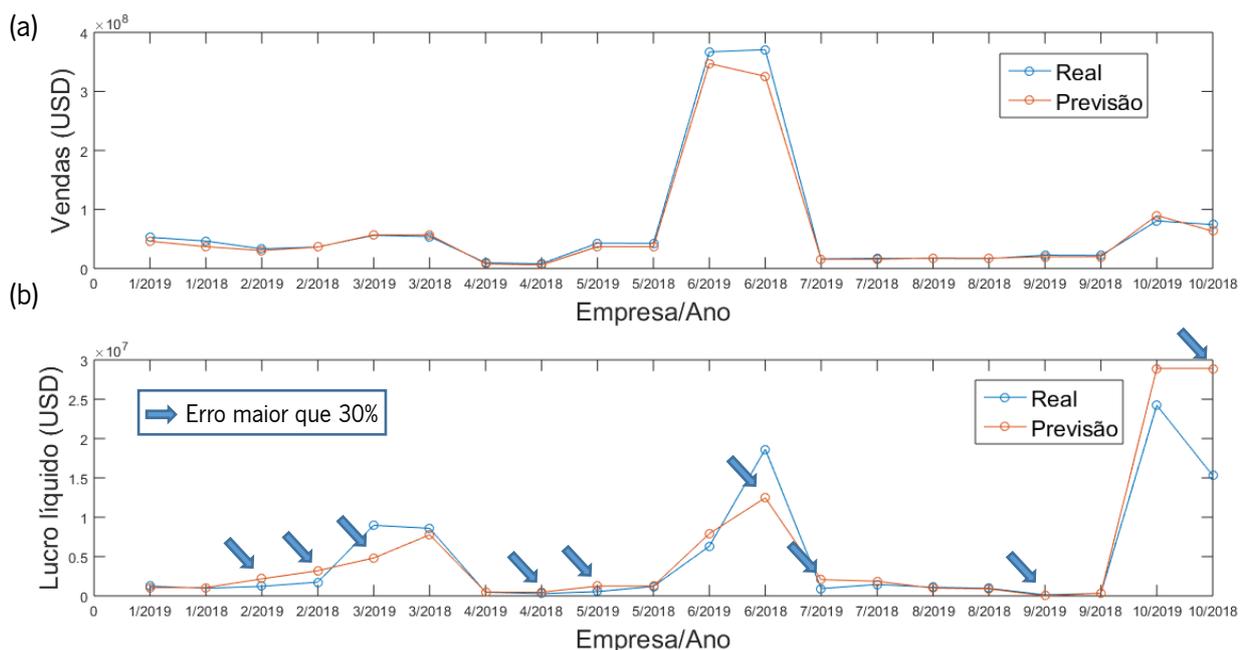


Figura 21: Comparativo entre o valor real e a previsão nos anos de 2018 e 2019 de cada empresa em relação aos indicadores (a) Vendas e (b) Lucro líquido.

Foi constatado que o ponto da empresa 6 relacionado ao ano de 2018 foi fora do padrão em todos os indicadores cuja unidade de medida foi o dólar, que foram nos casos do lucro líquido, vendas, EBIT, EBITDA, isso demonstra que essa empresa em especial teve resultados inesperados em comparação com as outras, os motivos para isso podem ser inúmeros, como, por exemplo: investimento elevado nesse ano, e o aumento da estrutura da organização, considerando que para os indicadores de vendas e lucro líquido a reta real foi superior a de previsão.

Com o auxílio do Matlab, calculou-se a diferença entre a área sob a curva da previsão e a área sob a curva do valor real para cada indicador. Considerou-se como 100% a área sob a curva do valor real para, através desta consideração, determinar o percentual de desvio que a previsão exibiu. Estes valores foram agrupados na tabela 4:

Tabela 4: Área entre as curvas do valor real e da previsão para cada indicador no modelo preditivo tipo A

INDICADOR UTILIZADO	Percentagem (%)
Índice de liquidez	-0,94
ROE usando lucro líquido	-3,64
Engrenagem	-10,27
ROA usando lucro líquido	-12,64
Margem EBIT	-5,17
Margem de Lucro	-7,65
EBITDA	-39,32
EBIT	11,62
Vendas	-7,66
Lucro Líquido	-7,58

Foi possível observar que, com exceção do indicador EBIT, os demais indicadores apresentaram percentuais negativos, ou seja, os valores previstos foram maiores do que os valores reais. Além disso, quanto menor o valor da percentagem, em módulo, melhor o ajuste e a previsão.

Contrastando a tabela 2, a tabela 4, e as figuras 17,18,19,20, 21, referentes ao tipo A, é possível verificar que os indicadores: índice de liquidez (x); vendas (USD); margem EBIT (%); e margem de lucro (%) possuem uma alta taxa de fiabilidade para o modelo preditivo relacionado ao tipo A.

Para outros indicadores como: ROE usando lucro líquido (%); lucro líquido (USD); ROA usando lucro líquido (%); EBIT (USD); EBITDA (USD); e Engrenagem (%), a fiabilidade não é tão elevada como os indicadores citados anteriormente, mas possuem uma boa fiabilidade e podem ser utilizados nesse modelo preditivo.

No caso do indicador EBITDA (USD), embora a percentagem relativa a tabela 4 ter sido muito superior aos outros indicadores, esse valor se deu graças ao ponto relacionado ao ano de 2018 da empresa 6,

caso esse ponto fosse desconsiderado o percentual seria -3,86%, dessa forma esse indicador pode ser considerado com uma boa fiabilidade.

4.2 Modelo preditivo do tipo B

Para o tipo B, foram utilizadas 50 empresas e, assim como no tipo A, certificou-se de que todas adotam um SGI. Para isto, realizaram-se 10 ANN, uma rede para cada indicador citado na tabela 5 com o objetivo de comparar qual o tipo que possui uma melhor eficiência e quais indicadores são mais adequados para este modelo preditivo. Neste caso, através de dados de diversas empresas, realizou-se uma média com os indicadores de 2010 a 2019 para prever os valores das outras empresas, desta forma determinaram-se os seguintes resultados, que podem ser observados na tabela 5.

Tabela 5: Erro relativo dos indicadores relacionados ao modelo preditivo do Tipo B.

INDICADOR UTILIZADO	PREVISÕES CORRETAS (%)	TREINOS CORRETOS (%)
Índice de liquidez	50	90
EBITDA	50	50
ROE usando lucro líquido	100	80
Engrenagem	50	50
EBIT	50	40
Vendas	50	70
ROA usando lucro líquido	100	70
Margem EBIT	100	80
Margem de Lucro	100	90
Lucro Líquido	50	80
Média	70	64

As percentagens de previsão do Tipo B foram 50% ou 100% pois, para cada indicador realizou-se a previsão de duas empresas, com o objetivo de que possuísem mais valores para o treino e a ANN apresentasse maior eficiência, dessa forma é possível observar que os indicadores: ROE usando lucro líquido (%); ROA usando lucro líquido (%); margem EBIT (%) e margem de Lucro (%) obtiveram os melhores resultados e são indicadores mais fiáveis de se prever através do Tipo B.

Durante a ANN relacionada ao tipo B, calcularam-se as variáveis que mais impactaram na previsão de cada indicador, como se pode observar na tabela 6. Através dessa informação é possível determinar quais variáveis precisam ser aprimoradas para que determinados indicadores alcancem melhoria no desempenho.

Tabela 6: Variáveis que mais impactaram os indicadores previstos relacionados ao Tipo B.

INDICADOR	VARIÁVEIS
Índice de Liquidez	Razão atual (x); ROE usando P/L antes de impostos (%) e EBIT.
EBITDA	Estoque; Índice de liquidez dos acionistas (x); e Vendas.
ROE usando lucro líquido	ROE usando P/L antes de impostos (%); ROA usando lucro líquido; e Margem EBIT (%)
Engrenagem	Margem de lucro (%); ativos fixos tangíveis; e passivo não circulante.
EBIT	Margem EBIT (%); margem de lucro (%); e ROA usando P/L antes de impostos (%).
Vendas	Receita operacional (volume de negócios); valor agregado e razão atual (x).
ROA usando lucro líquido	ROA usando P/L antes de impostos (%); Índice de solvência (baseado em ativos) (%); e Engrenagem (%).
Margem EBIT	Margem de lucro (%); ROE usando P/L antes de impostos (%) e Engrenagem (%).
Margem de Lucro	Margem EBIT (%); outros ativos fixos; e Fluxo de caixa/receita operacional (%)
Lucro Líquido	Passivo não circulante; fluxo de caixa; e Tributação.

A figura 22 expõe um comparativo entre o valor real e a previsão dos indicadores (a) Índice de liquidez (b) ROE usando lucro líquido (c) ROA usando lucro líquido (d) Margem de Lucro (e) Margem EBIT. Examinando o gráfico de cada indicador na figura 22, é possível ponderar que para o ROE usando lucro líquido e para a margem EBIT as barras relacionadas à previsão foram próximas da real, tanto para a empresa 1, quanto para a empresa 2, sendo uma boa previsão. Para os indicadores ROA usando lucro líquido, margem de lucro e índice de liquidez, a empresa 1 apresentou maior proximidade entre o valor real e a previsão, em relação à empresa 2.

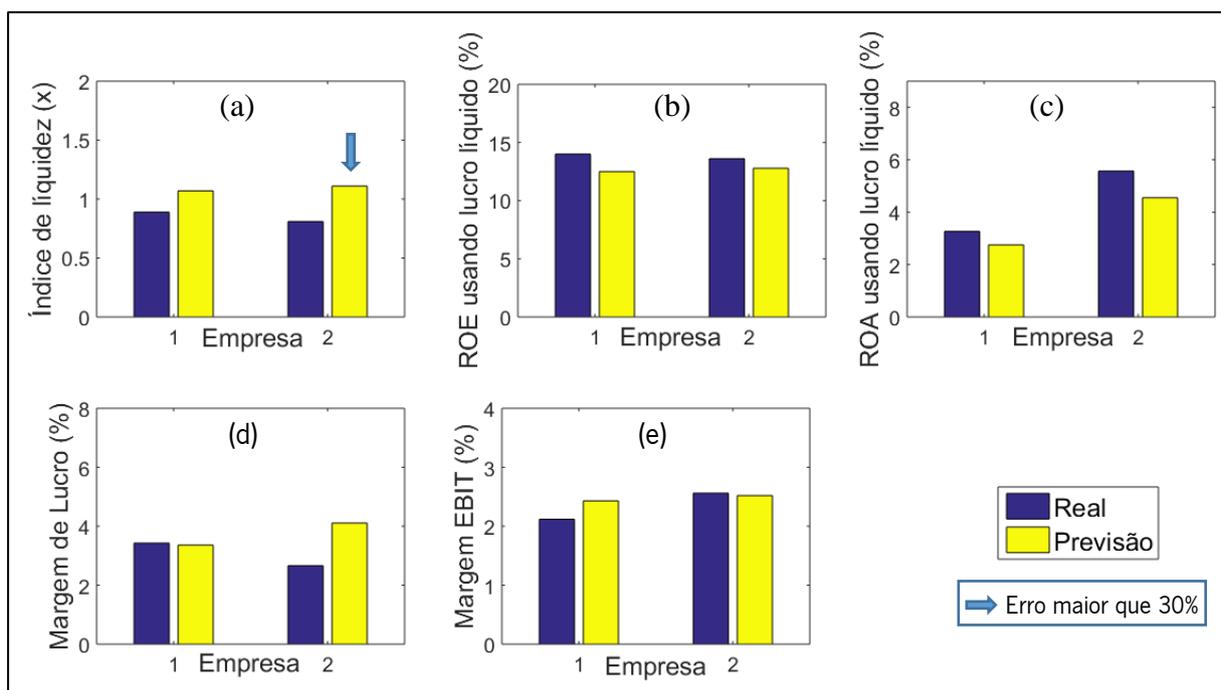


Figura 22: Comparativo entre o valor real e a previsão na rede neural do tipo B dos indicadores (a) Índice de liquidez (b) ROE usando lucro líquido (c) ROA usando lucro líquido (d) Margem de Lucro (e) Margem EBIT.

Analogamente, a figura 23 exhibe os resultados para os indicadores (a) EBITDA (b) Engrenagem (c) EBIT (d) Vendas e (e) Lucro líquido. Ao analisar os gráficos, foi possível considerar que, para o indicador EBITDA, as empresas 1 e 2 mostraram valores de previsão próximos ao valor real. Para EBIT e lucro líquido verificou-se que o valor da previsão na empresa 1 foi mais próximo do valor real do que na empresa 2. No caso dos indicadores engrenagem e vendas, as duas empresas analisadas apresentaram valores previstos distantes dos valores reais.

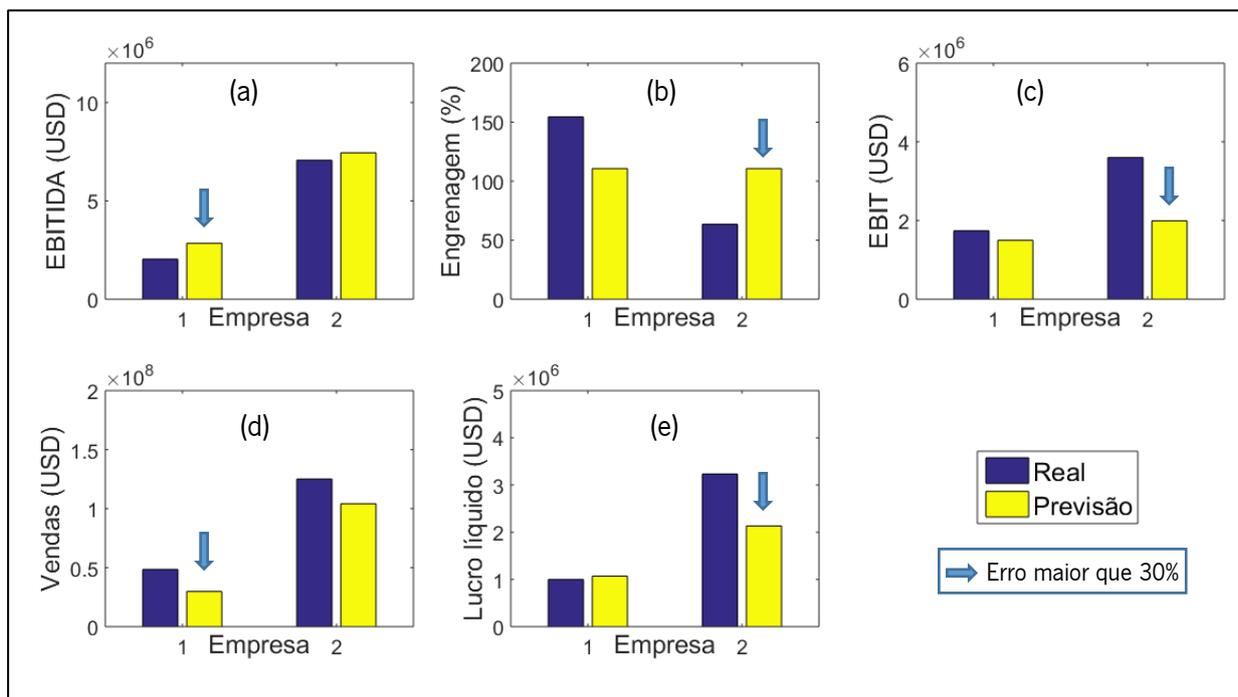


Figura 23: Comparativo entre o valor real e a previsão na rede neural do tipo B dos indicadores (a) EBITDA (b) Engrenagem (c) EBIT (d) Vendas (e) Lucro líquido.

Contrastando a tabela 5 com as figuras 22 e 23, relacionadas ao tipo B, é possível analisar que os indicadores: ROE usando lucro líquido (%); margem EBIT (%); EBITDA(USD); ROA usando lucro líquido (%); e margem de lucro (%) possuem uma boa fiabilidade para o modelo preditivo relacionado ao tipo B. Para outros indicadores como: índice de liquidez (x); EBIT (USD); e lucro líquido (USD), a proximidade entre o valor real e o previsto não é elevada como nos indicadores citados anteriormente, mas, ainda assim, a diferença não é tão dispar quanto a observada nos indicadores de engrenagem (%) e vendas (USD), que podem apresentar previsões com erros maiores que os indicadores citados anteriormente.

4.3 Modelo preditivo do tipo C

Para o tipo C, foram utilizadas as mesmas 50 empresas relacionadas ao tipo B, porém ao contrário do tipo B onde foram utilizados dados de 2010 a 2019 com o objetivo de prever os dados de 2019 de outras

empresas, utilizaram-se informações de 2010 a 2018, com a finalidade de prever os indicadores de 2019. Para isto, realizaram-se 10 ANN, uma rede para cada indicador citado na tabela 7, com o objetivo de prever qual tipo possui uma melhor eficiência e quais indicadores são mais adequados para este modelo preditivo. Neste caso, através de dados de diversas empresas, realizou-se uma média com os indicadores de 2010 a 2018 para prever os valores das outras empresas, desta forma encontraram-se os seguintes dados expostos na tabela 7.

Tabela 7: Erro relativo dos indicadores relacionados ao modelo preditivo do Tipo C.

INDICADOR UTILIZADO	PREVISÕES CORRETAS (%)	TREINOS CORRETOS (%)
Índice de liquidez	100	70
EBITDA	50	40
ROE usando lucro líquido	100	70
Engrenagem	100	60
EBIT	50	60
Vendas	50	40
ROA usando lucro líquido	100	70
Margem EBIT	100	50
Margem de Lucro	100	60
Lucro Líquido	100	40
Média	85	56

Assim como no tipo B, as percentagens de previsão do Tipo C foram 50% ou 100%, pois para cada indicador realizou-se a previsão de duas empresas, para assim obter mais valores para o treino e maior eficiência na ANN. Dessa forma, foi possível observar que os indicadores: índice de liquidez, ROE usando lucro líquido, engrenagem, ROA usando lucro líquido, margem EBIT, margem de lucro e lucro líquido obtiveram os melhores resultados e são indicadores mais fiáveis de se prever através do Tipo C.

Durante a ANN relacionada ao tipo C, calcularam-se as variáveis que mais impactaram na previsão de cada indicador, como é possível observar na tabela 8. Esta informação mostra quais são as variáveis da empresa que podem ser abordadas para obter melhorias mais contundentes em determinado indicador.

Tabela 8: Variáveis que mais impactaram os indicadores previstos relacionados ao Tipo C.

INDICADOR	VARIÁVEIS
Índice de Liquidez	Razão atual (x); ROA usando P/L antes de impostos (%) e Estoque.
EBITDA	Outros itens operacionais; Custos de funcionários; e Lucro líquido.
ROE usando lucro líquido	ROE usando P / L antes de impostos (%); ROA usando lucro líquido (%); e Margem EBIT (%)
Engrenagem	Índice de solvência (baseado em ativos) (%); Fluxo de caixa / receita operacional (%); Período de coleta (dias).
EBIT	Índice de liquidez (x); Rotatividade de ativos líquidos (x); e Razão atual (x).
Vendas	Dinheiro e equivalente a dinheiro; Estoque; Receita operacional (volume de negócios);
ROA usando lucro líquido	ROA usando P/L antes de impostos (%); ROE usando lucro líquido (%); e Fluxo de caixa / receita operacional (%).
Margem EBIT	Receita operacional (volume de negócios); P / L após impostos; e Estoque.
Margem de Lucro	Margem EBIT (%); ROE usando P / L antes de impostos (%); e outros passivos circulantes.
Lucro Líquido	Depreciação e Amortização; Dívida de longo prazo; e Fundos de acionistas.

Na figura 24, tem-se gráficos que demonstram o comparativo entre o valor real e a previsão na rede neural do tipo C dos indicadores (a) Índice de liquidez (b) ROE usando lucro líquido (c) ROA usando lucro líquido (d) Margem de Lucro (e) Margem EBIT. Para os indicadores Índice de liquidez e Margem de lucro

tanto a empresa 1 quanto a 2 apresentaram bons resultados. A empresa 1 apresentou bom resultado para o indicador Margem EBIT, a empresa 2, porém, apresentou maior distanciamento entre o valor real e o previsto. No indicador ROE usando lucro líquido, a empresa 2 apresentou bom resultado, enquanto a empresa 1 teve um distanciamento maior entre o valor previsto e o real. Para ROA usando lucro líquido, as duas empresas analisadas não apresentaram convergência entre os valores reais e previstos. Além disso, todos os indicadores analisados na figura 24, apresentaram erro menor que 30%. Dessa forma, todos os indicadores abaixo possuem uma boa fiabilidade para o modelo preditivo tipo C.

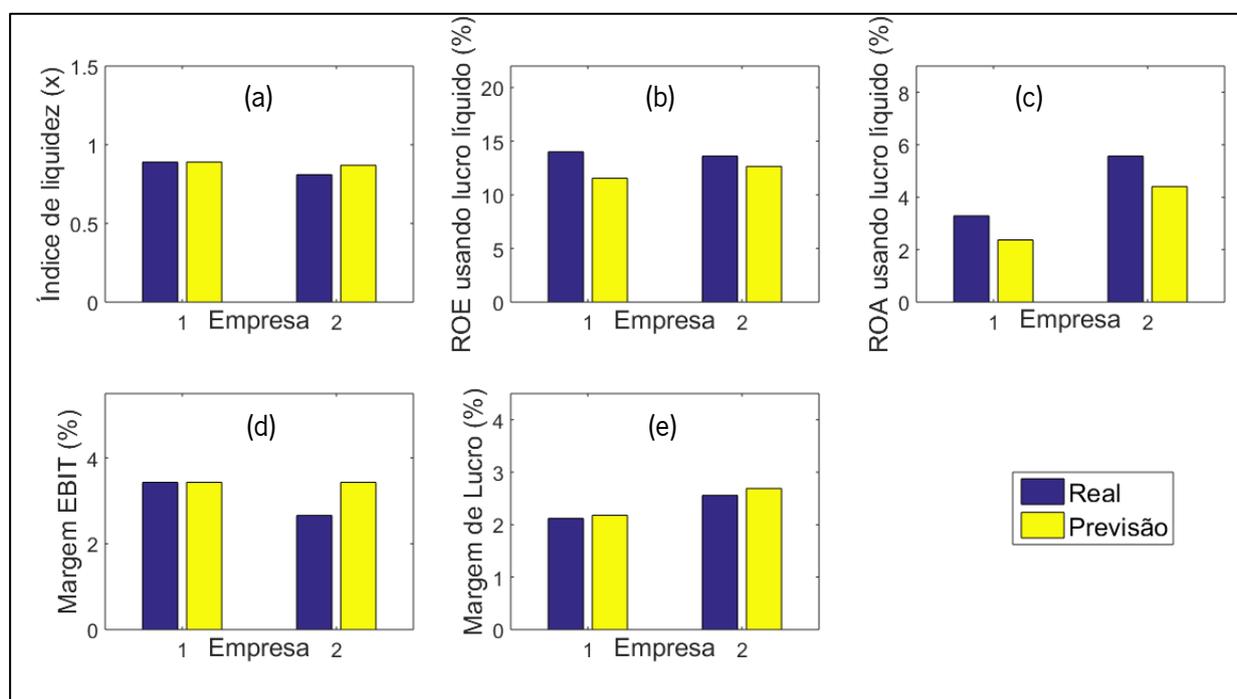


Figura 24: Comparativo entre o valor real e a previsão na rede neural do tipo C dos indicadores (a) Índice de liquidez (b) ROE usando lucro líquido (c) ROA usando lucro líquido (d) Margem de Lucro (e) Margem EBIT.

A mesma análise pode ser realizada na figura 25, para os indicadores (a) EBITDA (b) Engrenagem (c) EBIT (d) Vendas (e) Lucro líquido. Estudando-os, pode-se observar que para engrenagem, lucro líquido, e EBITDA o valor da previsão na empresa 1 foi mais próximo do valor real do que na empresa 2. No caso

dos indicadores EBIT, e vendas, as duas empresas avaliadas apresentaram valores previstos mais distantes dos valores reais que os indicadores mencionados anteriormente.

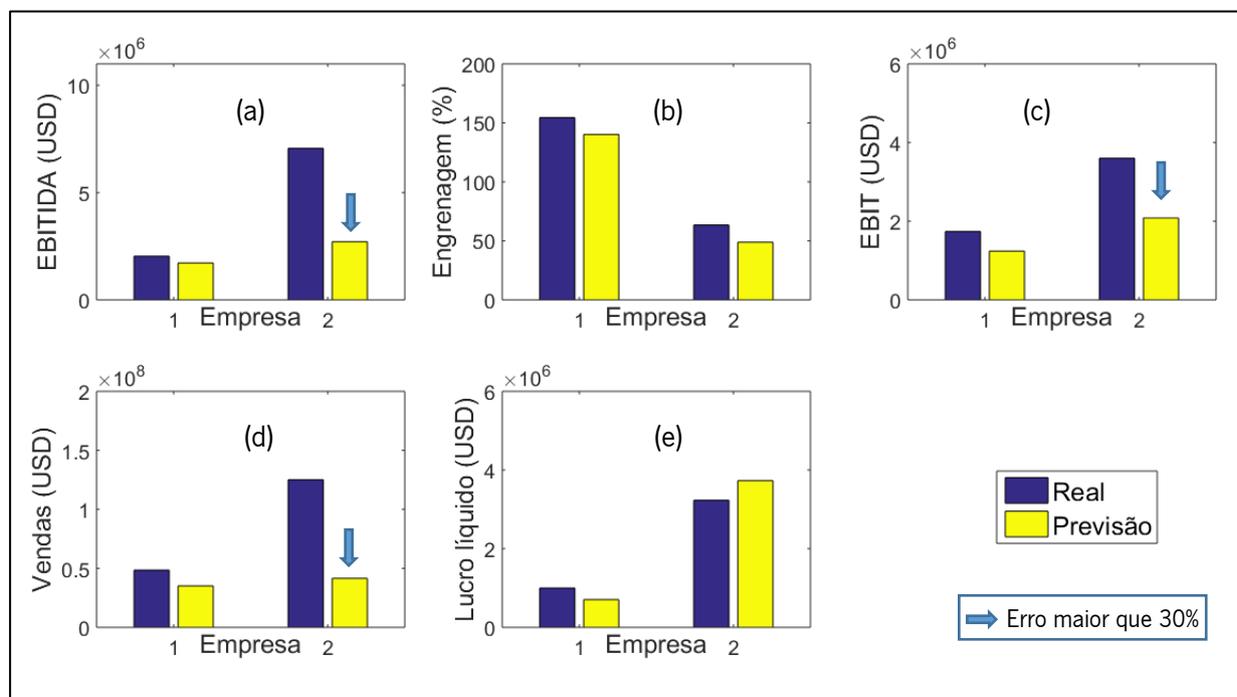


Figura 25: Comparativo entre o valor real e a previsão na rede neural do tipo C dos indicadores (a) EBITDA (b) Engrenagem (c) EBIT (d) Vendas (e) Lucro líquido.

Comparando a tabela 7 com as figuras 24 e 25, relacionadas ao modelo preditivo do tipo C, é possível analisar que os indicadores: índice de liquidez (x); ROE usando lucro líquido (%); engrenagem (%); margem EBIT (%); ROA usando lucro líquido (%); margem de lucro (%) e lucro líquido (USD) possuem uma elevada fiabilidade para o modelo preditivo relacionado ao tipo C. Para EBITDA (USD) a fiabilidade não é tão elevada como os indicadores citados anteriormente, mas, ainda assim, pode ser viável a sua aplicação neste modelo. Já para os indicadores: EBIT (USD) e vendas (USD), ao contrário dos indicadores citados anteriormente, o risco de obter previsões com erros elevados é maior.

Na figura 26 é possível fazer uma comparação entre a previsão e o treino dos tipos A, B e C, sendo pressuposto observar que a percentagem de erro relativo do treino e da previsão sejam semelhantes. Para os tipos A e B isso acontece e a percentagem média de previsão de A é discretamente superior ao de B. No modelo preditivo do tipo C, a percentagem média do Treino é consideravelmente inferior ao da previsão, isso acontece pois, embora alguns indicadores apresentaram uma percentagem elevada de acertos, outros não se mostraram muito eficazes, gerando essa diferença na média geral. Porém, em ambos os casos, observaram-se indicadores eficazes na previsão de valores e outros indicadores que não foram eficazes.

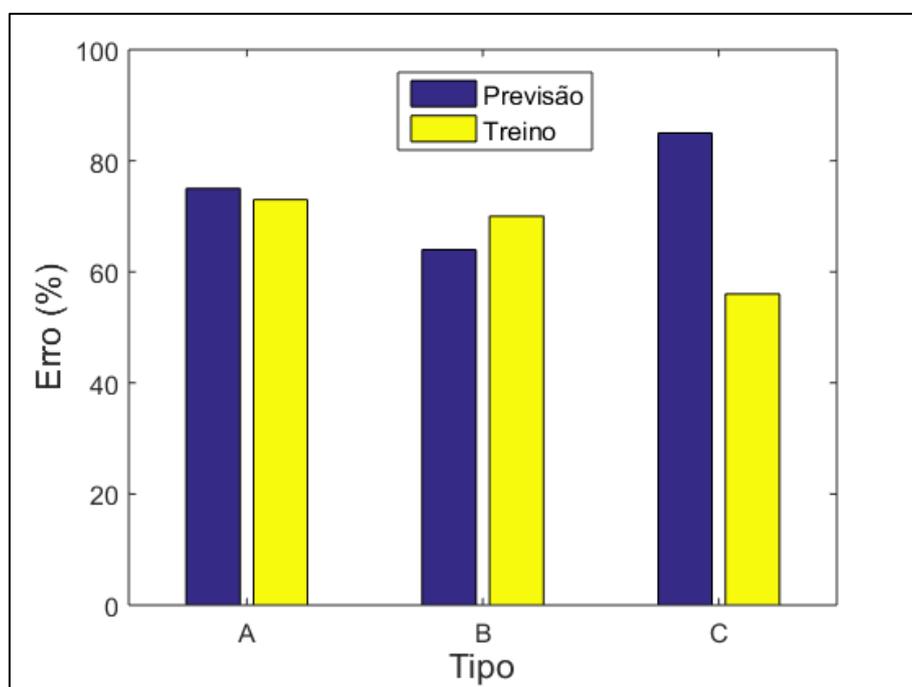


Figura 26: Comparativo entre os erros do treino e da previsão para as redes neurais dos tipos A, B e C.

Ao analisar os três tipos de modelos preditivos, observou-se que cada modelo tem seus prós e contras de acordo com a necessidade de cada organização, sendo assim, a tabela 9 possui a finalidade de mostrar qual modelo preditivo é mais apropriado para cada um dos indicadores estudados neste projeto. A tabela 9 foi criada com base nas tabelas 2 e 4 (modelo preditivo tipo A); tabela 5 e Figuras 22 e 23 (modelo preditivo tipo B); tabela 7 e Figuras 24 e 25 (modelo preditivo tipo C).

Tabela 9: Comparativo entre a fiabilidade de cada modelo preditivo em relação aos indicadores.

NÍVEL DE FIABILIDADE DE CADA MODELO PREDITIVO			
INDICADOR UTILIZADO	TIPO A	TIPO B	TIPO C
Índice de liquidez	Alta	Média	Alta
EBITDA	Média	Alta	Média
ROE usando lucro líquido	Média	Alta	Alta
Engrenagem	Média	Baixa	Alta
EBIT	Baixa	Média	Baixa
Vendas	Alta	Baixa	Baixa
ROA usando lucro líquido	Baixa	Alta	Alta
Margem EBIT	Alta	Alta	Alta
Margem de Lucro	Alta	Alta	Alta
Lucro Líquido	Média	Média	Alta

5 Conclusões e Trabalhos Futuros

Neste capítulo, será possível tomar conhecimento das conclusões obtidas a partir dos resultados das análises. Além disso, serão apresentadas propostas úteis para o caso de uma possível continuação desta investigação.

5.1 Conclusão

Em virtude dos factos mencionados, é possível afirmar a possibilidade de prever indicadores de desempenho em empresas que utilizam o sistema de gestão integrada através de um modelo preditivo utilizando redes neurais artificiais e, dessa forma, avaliar se os seus indicadores possuem uma tendência positiva ou negativa ao longo dos meses, ou no ano seguinte.

Para iniciar o processo do desenvolvimento do modelo preditivo, foi necessário utilizar a base de dados do Orbis Europe, de onde foram tirados todos os dados das empresas utilizadas nesse projeto, foram utilizadas apenas empresas com sistema de gestão integrada, em seguida, utilizou-se o “software” da Palisade Neuraltools para o desenvolvimento das ANN. Foram realizados 3 tipos de modelos preditivos de acordo com a necessidade de cada empresa e os três apresentaram bons resultados para a maioria dos indicadores.

Utilizaram-se as estatísticas geradas pelo próprio Neuraltools e pelo Matlab para gerar gráficos que ajudaram na análise das ANN. Através dessas análises, concluiu-se que os resultados gerados pelos modelos preditivos realizados nessa dissertação possuem um excelente potencial para prever indicadores com alto índice de fiabilidade e dessa forma ajudar as empresas que utilizam o SGI a saber se os seus indicadores possuem uma tendência de crescimento ou não, permitindo melhorar o funcionamento das empresas.

5.2 Trabalhos Futuros

Para esse projeto, foi utilizado como banco de dados o Orbis Europe, que apresenta apenas indicadores financeiros dos dez últimos anos. Para projetos futuros sugere-se a inserção de indicadores além dos financeiros e com um intervalo maior do que dez anos.

Nessa dissertação foram utilizadas apenas empresas que utilizam SGI, devido à falta de dados e de tempo hábil não foi possível realizar ANN para empresas que não utilizam esse sistema, tendo em consideração que algumas redes levaram mais de uma hora para gerar os seus dados e foram realizados 120 ANN para esta dissertação. Sugere-se fazer ANN também em empresas que não utilizam o SGI para avaliar se esse modelo preditivo pode ser utilizado em todas as categorias de empresa.

Sugere-se também a utilização de mais empresas nos modelos preditivos para avaliar se os resultados serão os mesmos.

Referências Bibliográficas

- Abraham, A. (2005). Artificial Neural Networks. In *Handbook of Measuring System Design* (Vol. 17). <https://doi.org/10.1002/0471497398.mm421>
- Agostino, D., & Sidorova, Y. (2016). A performance measurement system to quantify the contribution of social media: New requirements for metrics and methods. *Measuring Business Excellence*, 20(2), 38–51. <https://doi.org/10.1108/MBE-05-2015-0030>
- Almada, M. (2019). *Modelos de neurônios em redes neurais artificiais*. <https://doi.org/10.13140/RG.2.2.32042.16323>
- Almeida, J., Domingues, P., & Sampaio, P. (2014). Different perspectives on management systems integration. *Total Quality Management & Business Excellence*, 25. <https://doi.org/10.1080/14783363.2013.867098>
- Almeida, J., Sampaio, P., & Santos, G. (2012). *Sistemas de gestão integrados: Motivações, obstáculos, benefícios e factores críticos de sucesso*. Recuperado de <http://repositorium.sdum.uminho.pt/>
- APCER - ISO 9001. ([s.d.]). Recuperado 8 de junho de 2021, de <https://www.apcergroup.com/pt/certificacao/pesquisa-de-normas/81/iso-9001>
- APCER - ISO 14001. ([s.d.]). Recuperado 8 de junho de 2021, de <https://apcergroup.com/pt/certificacao/pesquisa-de-normas/169/iso-14001>
- Azadeh, A., Hasani Farmand, A., & Jiryaei Sharahi, Z. (2012). Performance assessment and optimization of HSE management systems with human error and ambiguity by an integrated fuzzy multivariate approach in a large conventional power plant manufacturer. *Journal of Loss Prevention in the Process Industries*, 25(3), 594–603. <https://doi.org/10.1016/j.jlp.2012.01.003>
- Barbuio, F. (2007). *Performance Measurement: A Practical Guide to KPIs and Benchmarking in Public Broadcasters*. Commonwealth Broadcasting Association.

Basnarkov, L., Stojkoski, V., Utkovski, Z., & Kocarev, L. (2020). Lead–lag relationships in foreign exchange markets. *Physica A: Statistical Mechanics and Its Applications*, *539*, 122986. <https://doi.org/10.1016/j.physa.2019.122986>

Bhatti, M. I., Awan, H., & Razaq, Z. (2014). The key performance indicators (KPIs) and their impact on overall organizational performance. *Quality & Quantity: International Journal of Methodology*, *48*(6), 3127–3143.

Bielza, I. (2021). Recta final de la migración a la ISO 45001. *AENOR: Revista de la normalización y la certificación*, (369), 6–9.

Bonato, S. V., & Caten, C. S. T. (2015). Diagnóstico da integração dos sistemas de gestão ISO 9001, ISO 14001 e OHSAS 18001. *Production*, *25*, 626–640. <https://doi.org/10.1590/0103-6513.004811>

Bureau van Dijk. (2021). Orbis—Compare Private Company Data—Bureau van Dijk. Recuperado 2 de outubro de 2021, de Orbis website: <https://www.bvdinfo.com/en-gb/our-products/data/international/orbis>

Cabecinhas, M., Domingues, P., Sampaio, P., & Arezes, P. M. (2019). Revisiting Diffusion Models: Portuguese Integrated Management Systems Evolution. In P. M. Arezes, J. S. Baptista, M. P. Barroso, P. Carneiro, P. Cordeiro, N. Costa, ... G. Perestrelo (Orgs.), *Occupational and Environmental Safety and Health* (p. 661–675). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-14730-3_70

Cerqueira, E. O. de, Andrade, J. C. de, Poppi, R. J., & Mello, C. (2001). Redes neurais e suas aplicações em calibração multivariada. *Química Nova*, *24*, 864–873. <https://doi.org/10.1590/S0100-40422001000600025>

Cerqueira, R. J., Paes, V., & Turrioni, J. B. (2020). ISO 9001 E A CERTIFICAÇÃO DIANTE IMPACTOS ECONÔMICOS: UMA REVISÃO SISTEMÁTICA. *Journal of Open Research*, *1*(1), e8–e8.

Coelho, D., & Matias, J. (2010, junho 11). *An Empirical Study on Integration of the Innovation Management System (MS) with other MSs within Organizations*.

Crepaldi, S. (2021). *Planejamento Tributário* (4ª ed). Saraiva Educação S.A.

Cruz, P. L., & Ávila, L. V. (2021). USO DE INDICADORES FINANCEIROS E NÃO FINANCEIROS PARA GERENCIAMENTO NAS ORGANIZAÇÕES: QUANDO DEVEM SER CONSIDERADOS KPI OU KRI. *Revista GESTO: Revista de Gestão Estratégica de Organizações*, 9(2), 88–100. <https://doi.org/10.31512/gesto.v9i2.324>

da Cunha Tavares, J., Batista M. Ribeiro Neto, J., & Carvalho Hoffmann, S. (2019). *Sistemas de gestão integrados: Qualidade, meio ambiente, responsabilidade social, segurança e saúde no trabalho* (5ª ed). São Paulo: SENAC SÃO PAULO.

Dias, I. I. C. (2017). *Contributo da certificação ISO 9001 para a melhoria contínua do sistema de gestão da qualidade implementado em meio hospitalar* (MasterThesis, Instituto Politécnico de Lisboa, Escola Superior de Tecnologia da Saúde de Lisboa). Instituto Politécnico de Lisboa, Escola Superior de Tecnologia da Saúde de Lisboa. Recuperado de <https://repositorio.ipl.pt/handle/10400.21/8528>

Domingues, J. P. T., Sampaio, P., & Arezes, P. M. (2015). Analysis of integrated management systems from various perspectives. *Total Quality Management & Business Excellence*, 26(11–12), 1311–1334. <https://doi.org/10.1080/14783363.2014.931064>

Domingues, P., Sampaio, P., & Arezes, P. M. (2017). Management systems integration: Survey results. *International Journal of Quality & Reliability Management*, 34(8), 1252–1294. <https://doi.org/10.1108/IJQRM-03-2015-0032>

Domingues, R., Pedrosa, I., & Bernardino, J. (2020). Indicadores Chave de Desempenho em Marketing. *Revista Ibérica de Sistemas e Tecnologias de Informação*, (E35), 128–140.

Ferradaz, C., Domingues, P., Sampaio, P., & Arezes, P. (2020, julho 16). *Management Systems Integration and Industry 4.0: A Prospective Insight*.

Gardner, M. W., & Dorling, S. R. (1998). Artificial neural networks (the multilayer perceptron)—A review of applications in the atmospheric sciences. *Atmospheric Environment*, *32*(14), 2627–2636. [https://doi.org/10.1016/S1352-2310\(97\)00447-0](https://doi.org/10.1016/S1352-2310(97)00447-0)

Gianni, M., & Gotzamani, K. (2015). Management systems integration: Lessons from an abandonment case. *Journal of Cleaner Production*, *86*, 265–276. <https://doi.org/10.1016/j.jclepro.2014.08.023>

Gitman, L. J. (2010). *Princípios de Administração Financeira* (12ª ed). São Paulo: Pearson Prentice Hall,.

Góis, S.ª R. M. O. de, Vilanova, S.ª I. A., Santos, srª N. T. dos, Porto, srª N. R. A. C., & Santos, srª S. R. S. dos. (2017). INDICADORES COMO FERRAMENTA DA GESTÃO DE QUALIDADE: UM ESTUDO BIBLIOGRAFICO. *Caderno de Graduação - Ciências Biológicas e da Saúde - UNIT - SERGIPE*, *4*(1), 11–11.

Gosselin, M. (2005). An empirical study of performance measurement in manufacturing firms. *International Journal of Productivity and Performance Management*, *54*(5/6), 419–437. <https://doi.org/10.1108/17410400510604566>

Haykin, S. (2001). *Redes neurais: Princípios e prática* (2ª ed). Bookman.

Hernandez-Vivanco, A., Domingues, P., Sampaio, P., Bernardo, M., & Cruz-Cázares, C. (2019). Do multiple certifications leverage firm performance? A dynamic approach. *International Journal of Production Economics*, *218*, 386–399. <https://doi.org/10.1016/j.ijpe.2019.07.016>

Herrmann, J. R., & Junior, J. C. C. (2014). Sistema de gestão da qualidade ISO 9001:2008: Uma estratégia de gestão para as organizações contábeis do RS. *Revista Eletrônica de Ciências Contábeis*, *3*(5), 220–247.

ISO - International Organization for Standardization. ([s.d.]). Recuperado 8 de junho de 2021, de ISO website: <https://www.iso.org/home.html>

ISO - ISO 9000 family—Quality management. ([s.d.]). Recuperado 8 de junho de 2021, de ISO website: <https://www.iso.org/iso-9001-quality-management.html>

ISO - ISO 14000 family—Environmental management. ([s.d.]). Recuperado 8 de junho de 2021, de ISO website: <https://www.iso.org/iso-14001-environmental-management.html>

ISO 45001: Sistemas de gestão de saúde e segurança ocupacionais. ([s.d.]). Recuperado 8 de junho de 2021, de <https://www.sgs.pt/pt-pt/sustainability/social-sustainability/audit-certification-and-verification/iso-45001-occupational-health-and-safety-management-systems-ohsms>

Karapetrovic, S., & Jonker, J. (2003). Integration of standardized management systems: Searching for a recipe and ingredients. *Total Quality Management & Business Excellence*, 14(4), 451–459. <https://doi.org/10.1080/1478336032000047264>

Karapetrovic, S., & Willborn, W. (1998). Integration of quality and environmental management systems. *The TQM Magazine*, 10(3), 204–213. <https://doi.org/10.1108/09544789810214800>

Klute-Wenig, S., & Refflinghaus, R. (2015). Integrating sustainability aspects into an integrated management system. *The TQM Journal*, 27(3), 303–315. <https://doi.org/10.1108/TQM-12-2013-0128>

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

Leite, K. C. A. (2018). FORMAS DE MEDIÇÃO DO RENDIMENTO E CONSEQUÊNCIAS NO CÁLCULO DO RETORNO SOBRE OS ATIVOS (ROA): UMA REVISÃO CONCEITUAL. *Humanidades e Inovação*, 5(2). Recuperado de <https://revista.unitins.br/index.php/humanidadeseinovacao/article/view/396>

Lindberg, C.-F., Tan, S., Yan, J., & Starfelt, F. (2015). Key Performance Indicators Improve Industrial Performance. *Energy Procedia*, 75, 1785–1790. <https://doi.org/10.1016/j.egypro.2015.07.474>

Lo, C. K. Y., Pagell, M., Fan, D., Wiengarten, F., & Yeung, A. C. L. (2014). OHSAS 18001 certification and operating performance: The role of complexity and coupling. *Journal of Operations Management*, 32(5), 268–280. <https://doi.org/10.1016/j.jom.2014.04.004>

Matias, J. C. D. O., & Coelho, D. A. (2002). The integration of the standards systems of quality management, environmental management and occupational health and safety management. *International Journal of Production Research*, 40(15), 3857–3866. <https://doi.org/10.1080/00207540210155828>

Neto, R. A. de S., Dias, G. F., Medeiros, M., Dantas, A. S., & Neto, M. V. de S. (2019). Definindo indicadores de desempenho em projetos: Uma análise qualitativa da literatura. *Exacta*, 17(3), 131–148. <https://doi.org/10.5585/exactaep.v17n3.8203>

Neves, L. de L., Pereira, A. dos S., Quevedo, R. C., Souza, T. C. M. de, & Aranha, J. A. M. (2019). INDICADORES FINANCEIROS: UMA ANÁLISE SETORIAL DAS EMPRESAS DE PAPEL E CELULOSE LISTADAS NA B3. *Encontro Internacional de Gestão, Desenvolvimento e Inovação (EIGEDIN)*, 3(1). Recuperado de <https://desafioonline.ufms.br/index.php/EIGEDIN/article/view/8792>

Nissim, D. (2019). *EBITDA, EBITA, or EBIT?* (SSRN Scholarly Paper N° ID 2999675). Rochester, NY: Social Science Research Network. <https://doi.org/10.2139/ssrn.2999675>

OHSAS 18001—Sistemas de Gestão da Saúde e Segurança Ocupacional | SGS Portugal. ([s.d.]). Recuperado 8 de junho de 2021, de <https://www.sgs.pt/pt-pt/health-safety/quality-health-safety-and-environment/health-and-safety/health-safety-and-environment-management/ohsas-18001-occupational-health-and-safety-management-systems>

Palisade. (2015). Manual do Usuário NeuralTools—Add-In de Rede Neural para o Microsoft® Excel (Versão 7). Palisade Corporation.

Parmenter, D. (2015). *Key performance indicators: Developing, implementing, and using winning KPI* (3ª ed). John Wiley & Sons.

Pipino, P. H. A. (2021). *Sistema integrado de gestão empresarial (ERP) na construção civil*. Recuperado de <http://rdu.unicesumar.edu.br/handle/123456789/7361>

Poltronieri, C. F., Gerolamo, M. C., & Carpinetti, L. C. R. (2017). Um instrumento para a avaliação de sistemas de gestão integrados. *Gestão & Produção*, 24, 638–652. <https://doi.org/10.1590/0104-530X1697-14>

Popescu, C. R., & Popescu, V. A. (2015). The Assessment Methodology Pdca/Pdsa—A Methodology for Coordinating the Efforts to Improve the Organizational Processes to Achieve Excellence. *Challenges of the Knowledge Society*, 693–696.

Portal do INE. ([s.d.]). Recuperado 16 de julho de 2021, de https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine_faqs&FAQSfaq_boui=64092016&FAQSmodo=1&xlang=pt

Pulungan, D. R., & Insan, M. Y. (2020). EFFECT OF NET PROFIT MARGIN AND RETURN ON EQUITY ON THE STOCK PRICE. *International Journal of Economic, Technology and Social Sciences (Injects)*, 1(1), 23–28. <https://doi.org/10.53695/injects.v1i1.58>

Salomone, R. (2008). Integrated management systems: Experiences in Italian organizations. *Journal of Cleaner Production*, 16(16), 1786–1806. <https://doi.org/10.1016/j.jclepro.2007.12.003>

Santos, A. H., Alves, G. R. da S., & Monteiro, J. I. (2019). *A APLICABILIDADE DOS KPIS COMO VANTAGEM COMPETITIVA NA CADEIA DE SUPRIMENTOS*. 10.

Santos, C. de F. S. O., da Silva, M. E., & Gómez, C. R. P. (2012). Gestão estratégica da Responsabilidade Socioambiental Empresarial: Operacionalização por meio do Sistema de Gestão Integrado. *REGE - Revista de Gestão*, 19(4), 535–552. <https://doi.org/10.5700/rege477>

Santos, L. R. L. B., Almeida, S. R. V., Costa, T. de A., & Lyrio, E. F. (2019). Impactos do Impairment Test Nos Indicadores de Desempenho das Companhias que atuam no Segmento de Exploração, Refino e Distribuição de Petróleo, Gás e Biocombustíveis Listadas na BM&FBOVESPA. *Pensar Contábil*, 21(74).

Recuperado de <http://www.atena.org.br/revista/ojs-2.2.3-08/index.php/pensarcontabil/article/view/3470>

Souza, P. H. M. de, & Georges, M. R. R. (2020). Sistemas de Gestão Integrado em Meio Ambiente e Segurança do Trabalho e Sustentabilidade: Um estudo sobre as certificações no contexto das operações empresariais. *Revista Nacional de Gerenciamento de Cidades*, 8(64). <https://doi.org/10.17271/2318847286420202566>

Stefano, N. M., & Laux, R. O. (2017). Sustentabilidade empresarial por meio do Sistema de Gestão Integrada (SGI). *Sustainable Business International Journal*, (70). <https://doi.org/10.22409/sbijournal2017.i70.a10254>

Vinodkumar, M. N., & Bhasi, M. (2011). A study on the impact of management system certification on safety management. *Safety Science*, 49(3), 498–507. <https://doi.org/10.1016/j.ssci.2010.11.009>

Vitoreli, G. A., & Carpinetti, L. C. R. (2013). Análise da integração dos sistemas de gestão normalizados ISO 9001 e OHSAS 18001: Estudo de casos múltiplos. *Gestão & Produção*, 20, 204–217. <https://doi.org/10.1590/S0104-530X2013000100015>

Wegelius-Lehtonen, T. (2001). Performance measurement in construction logistics. *International Journal of Production Economics*, 69(1), 107–116. [https://doi.org/10.1016/S0925-5273\(00\)00034-7](https://doi.org/10.1016/S0925-5273(00)00034-7)

Zeng, S. X., Shi, J. J., & Lou, G. X. (2007). A synergetic model for implementing an integrated management system: An empirical study in China. *Journal of Cleaner Production*, 15(18), 1760–1767. <https://doi.org/10.1016/j.jclepro.2006.03.007>

Zeng, S. X., Xie, X. M., Tam, C. M., & Shen, L. Y. (2011). An empirical examination of benefits from implementing integrated management systems (IMS). *Total Quality Management & Business Excellence*, 22(2), 173–186. <https://doi.org/10.1080/14783363.2010.530797>

Zevallos, C., & Renán, J. (2021). Adecuación del sistema de gestión de seguridad y salud en el trabajo de la empresa FERREYROS S.A. a la norma ISO 45001:2018. *Universidad Inca Garcilaso de la Vega*. Recuperado de <http://repositorio.uigv.edu.pe/handle/20.500.11818/5419>

Zimon, D., Madzik, P., Dellana, S., Sroufe, R., Ikram, M., & Lysenko-Ryba, K. (2021). Environmental effects of ISO 9001 and ISO 14001 management system implementation in SSCM. *The TQM Journal*. <https://doi.org/10.1108/TQM-01-2021-0025>

Zimon, D., Madzik, P., & Sroufe, R. (2020). The Influence of ISO 9001 & ISO 14001 on Sustainable Supply Chain Management in the Textile Industry. *Sustainability*, *12*(10), 4282. <https://doi.org/10.3390/su12104282>