

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

ANTONIO RICARDO LUNARDI

**COMPARAÇÃO DE TOPOLOGIAS PARA ANFIS E RNAS APLICADAS A
INDICADORES DE DESEMPENHO DE CADEIAS DE SUPRIMENTOS**

CURITIBA

2022

ANTONIO RICARDO LUNARDI

**COMPARAÇÃO DE TOPOLOGIAS PARA ANFIS E RNAS APLICADAS A
INDICADORES DE DESEMPENHO DE CADEIAS DE SUPRIMENTOS**

**ANFIS AND ANNS TOPOLOGIES COMPARISON APPLIED ON SUPPLY
CHAIN PERFORMANCE INDICATORS**

Trabalho de conclusão de curso de graduação apresentado como requisito para obtenção do título de Bacharel em Engenharia Controle e Automação do curso de Engenharia de Controle e Automação da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientador: Prof. Dr. Glauber Gomes de Oliveira Brante.

Coorientador: Prof. Dr. Francisco Rodrigues Lima Júnior.

CURITIBA

2022



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

ANTONIO RICARDO LUNARDI

**COMPARAÇÃO DE TOPOLOGIAS PARA ANFIS E RNAS APLICADAS A
INDICADORES DE DESEMPENHO DE CADEIAS DE SUPRIMENTOS**

Trabalho de conclusão de curso de graduação apresentado como requisito para obtenção do título de Bacharel em Engenharia Controle e Automação do curso de Engenharia de Controle e Automação da Universidade Tecnológica Federal do Paraná (UTFPR).

Data de aprovação: 10 de junho de 2022

Francisco Rodrigues Lima Júnior
Doutor
Universidade Tecnológica Federal do Paraná

Glauber Gomes de Oliveira Brante
Doutor
Universidade Tecnológica Federal do Paraná

Mariana Antonia Aguiar Furucho
Doutora
Universidade Tecnológica Federal do Paraná

Eduardo de Freitas Rocha Loures
Doutor
Universidade Tecnológica Federal do Paraná

CURITIBA

2022

RESUMO

A gestão da cadeia de suprimentos é uma atividade fundamental no mercado contemporâneo para o funcionamento das empresas. São abordados na literatura muitos métodos quantitativos para avaliação de desempenho de cadeias de suprimentos com a finalidade de melhorar o funcionamento de uma organização por meio de diversas abordagens. No entanto a literatura não encontra muitos estudos de métodos quantitativos com técnicas de IA (inteligência artificial). Nesse contexto, o estudo busca a comparar como se adequam as RNAs (redes neurais artificiais) artificiais e as redes neuro-*fuzzy*, para fazer aproximações de função do modelo SCOR[®] (*Supply Chain Operations Reference*). São propostos três modelos de rede baseados em RNAs PMC (perceptron multicamada) ou ANFIS (*adaptive-based-neuro-fuzzy inference system*), sendo cada modelo baseado em um indicador de desempenho do SCOR[®], por meio de várias topologias com configurações distintas para cada um deles. O estudo concluiu matematicamente que, de modo geral, as redes ANFIS possuem capacidade consideravelmente maior. Testes de hipótese t pareados foram usados para validar os resultados, tendo obtido sucesso em todos os casos.

Palavras-chave: RNA, ANFIS, cadeia de suprimentos, IA, *fuzzy*, SCOR[®].

ABSTRACT

Supply chain management is an essential practice for nowadays market to companies success. Literature contains many quantitative methods for supply chain performance evaluation, that are used in order to improve organizations operations. However, there are not many AI (artificial intelligence) quantitative methods in the literature. In this context, the present study aims to compare artificial neural networks with neuro-fuzzy networks, in the context of making function approximations using the SCOR[®] (Supply Chain Operations Reference) model. Three network models based on MLP (multi-layer perceptron) ANN (artificial neural networks) or ANFIS (adaptive-based-neuro-fuzzy inference system) are proposed, each one based on a different SCOR[®] performance indicator. Many topologies are made using distinct configurations. The study showed that in general ANFIS have noticeable higher capabilities. t-paired hypothesis tests were used in order to validate the results, being successful in all cases.

Key-words: ANN, ANFIS, supply chain, AI, fuzzy, SCOR[®].

LISTA DE ABREVIATURAS E SIGLAS

ANFIS - *Adaptive-network-based fuzzy inference system* (Sistema de inferência *fuzzy* baseado em rede adaptativa).

BFGS - Broyden-Fletcher-Goldfarb-Shanno.

ENEGEP – Encontro Nacional de Engenharia de Produção.

EQM - Erro quadrático médio.

GDM - *Gradient descent momentum* (momento de gradiente descendente).

LM - Levenberg-Marquardt.

MCDM - *Multicriteria decision making* (tomada de decisão multicritérios).

PMC - Perceptron multicamada.

R - Índice de correlação linear.

REQM – Raiz quadrada do erro quadrático médio.

RNA - Rede neural artificial.

RP - *Resilient propagation* (propagação resiliente).

SCC - *Supply Chain Council* (Conselho de Cadeia de Suprimentos).

SCG - *Scale conjugate gradient* (gradiente de conjugado em escala).

SCOR[®] - *Supply Chain Operations Reference* (Referência de operações em cadeia de suprimentos).

SUMÁRIO

| | |
|--|----|
| 1 INTRODUÇÃO | 9 |
| 1.1 Tema | 9 |
| 1.1.1 Delimitação do tema | 9 |
| 1.2 Problemas e premissas | 10 |
| 1.3 Objetivos | 12 |
| 1.3.1 Objetivo geral | 12 |
| 1.3.2 Objetivos específicos | 12 |
| 1.4 Justificativa | 12 |
| 1.5 Estrutura do trabalho | 13 |
| 2 FUNDAMENTAÇÃO TEÓRICA | 14 |
| 2.1 O modelo SCOR® | 14 |
| 2.2.1 Modelos para avaliação de desempenho que combinam SCOR® com métodos quantitativos. | 17 |
| 2.2 Redes neurais artificiais | 19 |
| 2.3 Algoritmos de treinamento | 21 |
| 2.3.1 GDM (Termo de <i>Momentum - Gradient Descendent Momentum</i>) | 22 |
| 2.3.2 LM (Levenberg-Marquardt) | 22 |
| 2.3.3 BFGS (Broyden-Fletcher-Goldfarb-Shano) | 23 |
| 2.3.4 SCG (<i>Scale Conjugate Gradient</i>) | 23 |
| 2.3.5 RP (<i>Resilient Propagation</i>) | 23 |
| 2.4 Sistemas <i>fuzzy</i> | 24 |
| 2.4.1 Definições básicas sobre a Teoria dos Conjuntos Fuzzy | 24 |
| 2.4.1.1 Função de pertinência único (<i>singleton</i>) | 25 |
| 2.4.1.2 Função de pertinência gaussiano | 25 |
| 2.4.1.3 Função de pertinência sigmoidal | 26 |
| 2.4.1.4 Função de pertinência triangular | 26 |
| 2.4.1.5 O produto cartesiano entre conjuntos <i>fuzzy</i> | 27 |
| 2.4.2 Inferência <i>fuzzy</i> de tipo lógico | 27 |
| 2.3 Sistemas neuro- <i>fuzzy</i> de tipo lógico | 29 |
| 3 METODOLOGIA E PROCEDIMENTOS | 31 |
| 3.1 Os Modelos computacionais avaliados | 33 |
| 3.2 Variáveis geradas para os modelos PMC e ANFIS | 34 |

| | |
|--|----|
| 3.2.1 Modelo 1 - <i>Total cost to serve</i> | 35 |
| 3.2.2 Modelo 2 - <i>Overall value at risk</i> | 37 |
| 3.2.3 Modelo 3 - <i>Perfect order fulfillment</i> | 38 |
| 4 RESULTADOS | 42 |
| 4.1 Definição das amostras para treinamento e testes dos modelos | 42 |
| 4.2 Resultados das redes PMC | 44 |
| 4.3 Resultados dos modelos ANFIS | 49 |
| 4.4 Análise estatística | 52 |
| 5 CONCLUSÕES | 55 |
| REFERÊNCIAS | 57 |

1 INTRODUÇÃO

1.1 Tema

A avaliação de desempenho de cadeias de suprimentos é uma atividade crítica para a melhoria contínua de todos os tipos de operações em uma empresa. A literatura apresenta diversos sistemas de avaliação de desempenho baseados em métodos multicritério e técnicas de IA (inteligência artificial). Os sistemas baseados em RNAs (redes neurais artificiais) e ANFIS (*Adaptive-network-based fuzzy inference system*) se destacam por sua capacidade de modelar relacionamentos não lineares entre as métricas e por permitirem a adaptação ao ambiente de uso por meio de dados históricos de desempenho (SILVA et al., 2010). Nesse contexto, o presente estudo avalia e compara métodos de aprendizagem e topologias de RNAs PMC (Perceptron multicamada) e ANFIS, com o objetivo de determinar o quão bem se eles se adequam para apoiar a aproximação de função de indicadores de desempenho de cadeias de suprimentos.

Mentzer et al. (2001) definem a gestão de uma cadeia de suprimentos como a “coordenação estratégica e sistêmica das funções de negócio tradicionais e de ações táticas numa empresa e através de seus negócios ao longo da cadeia”, com o intuito de melhorar o desempenho de longo prazo das empresas e da cadeia de modo global. A gestão de cadeias de suprimentos envolve o manejo estratégico dos fluxos de finanças, serviços, bens, informações e relacionamentos interempresariais. Nesse ambiente, o gerenciamento colaborativo tende a gerar uma condição de sinergia, na qual a cadeia toda se torna mais eficaz do que a junção de suas partes individuais (MENTZER et al. 2001; SHAFIEE et al. 2014).

1.1.1 Delimitação do tema

Uma das principais fontes de inspiração de sistemas de IA é o embasamento em sistemas biológicos. O sistema nervoso é o que dá ao ser humano a capacidade de aprender e resolver problemas complexos (FERNEDA, 2006). RNAs são técnicas de processamento distribuído que imitam sistemas neurais biológicos (KURTGOZ et al., 2017). De acordo com um estudo de revisão da literatura desenvolvido por Tkác e Verner (2016), o tipo de RNA mais utilizado é o PMC. Redes PMC podem ser aplicadas em diversos problemas envolvendo aproximação, reconhecimento de padrões e predição de séries temporais.

As RNAs podem ser configuradas por meio de vários fatores da própria rede, tais como o número de camadas ocultas, a quantidade de cada neurônio em cada camada, o peso de cada

entrada, o limiar de ativação para cada neurônio e a função de ativação. Ainda há as configurações dos fatores do algoritmo de treinamento. Cada algoritmo possui seus fatores, dos quais depende sua relação iterativa. Há ampla variedade de métodos de aprendizagem que podem ser aplicados para conduzir o treinamento supervisionado de redes PMC. Com o objetivo de aperfeiçoar a versão original do *backpropagation*, novos algoritmos têm sido propostos a fim de tornar o treinamento mais rápido e alcançar maior acurácia de predição (SILVA et al., 2010).

A lógica *fuzzy* é uma abordagem de IA de natureza diferente das RNAs, sem inspiração biológica. Ela torna possível avaliar como objetivas características tratadas de maneira a princípio subjetivas. De modo combinado, quando se utilizam RNAs baseadas em lógica *fuzzy*, tem-se o que se chama de sistemas neuro-*fuzzy*. As ANFIS, propostas por Jang em 1993, são o tipo de modelo mais popular de sistemas neuro-*fuzzy* da atualidade (SABRI et al., 2013).

A literatura sobre gestão de cadeia de suprimentos apresenta estudos que propõem modelos de apoio à avaliação de desempenho. Há estudos que apresentam revisões sistemáticas das abordagens existentes (MAESTRINI et al., 2017), discussões sobre os indicadores usados no processo de avaliação (CUTHBERTSON; PIOTROWICZ, 2011) e análises de alguns modelos existentes (ESTAMPE et al., 2013). Os modelos quantitativos têm recebido crescente atenção na última década. Dezenas de técnicas vêm sendo testadas, incluindo em métodos de tomada de decisão multicritério (MCDM), programação matemática, técnicas estatísticas e de IA (LIMA JR. & CARPINETTI, 2017).

1.2 Problemas e premissas

Diversos estudos têm ressaltado a relevância de se medir (ou avaliar) o desempenho de cadeias de suprimentos como modo de desenvolvimento do planejamento e de estratégias de gestão (MARCHAND & RAYMOND, 2008; ESTAMPE et al., 2013). A avaliação de desempenho de cadeias de suprimentos envolve vários fatores que cooperam para alcançar determinados objetivos. Por isso, requer a adoção de indicadores relacionados a processos intra e interorganizacionais, bem como dados atualizados, integrados e de fácil acesso para que decisões sejam tomadas racionalmente (NUDURUPATI & BITITCI, 2005). Alguns benefícios da avaliação de desempenho de cadeias de suprimentos são o monitoramento efetivo dos resultados, melhoria do entendimento de processos chave, identificação de problemas potenciais e criação de uma percepção sobre possíveis ações futuras (AHI & SEARCY, 2015). Entretanto, vários fatores fazem com que a avaliação de cadeias de suprimentos seja uma tarefa

difícil. Fazê-la na prática requer a análise de diversos fatores em um processo transversal. Há também entraves como dados históricos descentralizados e o fato de diversas métricas serem desconexas (NAINI et al., 2011).

O modelo SCOR[®] (*supply chain operations reference*) é um guia referência em gestão. Estudiosos apontam sua ampla utilização tanto no meio empresarial como acadêmico (AKKAWUTTIWANICH; YENRADEE, 2018). Por possuir relacionamentos causais bem definidos, um conjunto de indicadores de desempenho propostos pelo SCOR[®] é adotado neste estudo para compor as variáveis de entrada e saída dos modelos computacionais.

A literatura apresenta estudos comparativos entre algoritmos de aprendizagem considerando diferentes domínios de problema. Tripathy e Kumar (2009) realizaram uma comparação com o objetivo de escolher o algoritmo mais adequado para predição da variação de temperatura de produtos alimentares durante a secagem solar. Nesse estudo, o SCG (*Scale conjugate gradient*) apresentou melhor acurácia que o BFGS (Broyden-Fletcher-Goldfarb-Shanno) e o LM (Levenberg-Marquardt). Em um estudo sobre controle de processos de moagem, Mukherjee e Routroy (2012) compararam os algoritmos LM e BFGS e concluíram que o primeiro converge mais rapidamente e é mais preciso. Maroufpoora et al. (2019) compararam GDM (*Gradient descendent momentum*), SCG e LM. Eles constataram que, para apoiar a modelagem de distribuição de uniformidade de água, o mais apropriado é o LM. Esses resultados demonstram que o desempenho de cada algoritmo depende dos dados utilizados na aplicação. Dessa forma, o desenvolvimento de uma comparação entre algoritmos de treinamento diferentes de redes neurais se mostra necessário para apontar quais fornecem resultados mais precisos na avaliação de cadeias de suprimento.

Frequentemente sistemas *fuzzy* têm sido utilizados para gestão de cadeias de suprimento, dentro de um amplo espectro de aplicações (KAR; DAS; GHOSH, 2014 e NHU; NITSUWAT; SODANIL, 2013). Dentre os sistemas *fuzzy*, ANFIS é a técnica mais utilizada devido ao seu baixo custo por se tratar de modelagem computacional, transparência e robustez por modelos estatísticos (AWADALLA; BAYOUMI; SOLIMAN, 2009; TAYLAN; KARAGÖZOĞLU, 2009). Eles evoluíram em termos de flexibilidade e adaptabilidade (LIU & LI, 2004).

O primeiro trabalho de iniciação científica feito pelo autor deste TCC foi realizado justamente sobre o tema de RNAs aplicadas a indicadores do modelo SCOR[®]. O trabalho foi apresentado no congresso ENEGEP (Encontro Nacional de Engenharia de Produção)

(LUNARDI & LIMA JR., 2019) e publicado no periódico científico de engenharia da Gestão & Produção® (LUNARDI & LIMA JR., 2021) após aprofundamento da pesquisa.

1.3 Objetivos

1.3.1 Objetivo geral

Comparar métodos de aprendizagem supervisionada de RNAs PMC e ANFIS, determinando assim o quão bem adequados são eles para aproximação de funções de indicadores de desempenho de cadeias de suprimentos e sua performance relativa. Este estudo tem como base as métricas dos atributos do modelo SCOR®. O estudo também visa a dar continuidade à pesquisa que foi realizada na iniciação científica comentada anteriormente.

1.3.2 Objetivos específicos

- Analisar inicialmente os principais métodos de avaliação quantitativa de cadeias de suprimentos da literatura para o entendimento das atuais concepções e metodologias abordadas para o problema;
- Apresentar as teorias específicas de cadeia de suprimentos, de RNAs e ANFIS para o embasamento do trabalho;
- Simular aleatoriamente os valores de entrada das redes a partir dos indicadores de nível 2 do SCOR® e calcular as saídas pelas fórmulas por meio de planilhas do MS Excel®;
- Definir as configurações das várias topologias das redes e realizar os testes;
- Analisar comparativamente a acurácia dos modelos de RNAs e ANFIS através do EQM (erro quadrático médio) da etapa de validação, a fim de determinar os mais adequados;
- Verificar se há diferença estatística significativa entre os valores estimados e os esperados para validação dos modelos;
- Comparar a performance geral de RNAs PMC e ANFIS.

1.4 Justificativa

A partir da pesquisa bibliográfica realizada neste trabalho, abordada com mais detalhes no Capítulo 2 e com resultados compilados na Tabela 1, é possível afirmar que seria uma importante contribuição para o campo da gestão da cadeia de suprimentos o advento de novas tecnologias e ferramentas. Os únicos modelos quantitativos para avaliação de

desempenho baseado em métricas do SCOR[®] usando RNAs ou ANFIS foram, respectivamente, os dois de Lima Jr. e Carpinetti (2019 e 2020). Muito embora não haja no momento uma aplicação imediata para o estudo, sua importância se pauta na inovação e na intenção de abrir caminho para a criação de uma nova área de aplicabilidade no que tange à modelagem das relações de causa e efeito entre indicadores de desempenho de cadeias de suprimentos.

Apesar das relações de causa e efeito entre os indicadores serem conhecidas por meio das equações propostas pelo SCOR[®], este estudo poderá servir como base para estudos futuros que utilizem RNAs e/ou ANFIS para analisar relações entre indicadores em casos que essas não forem explícitas, principalmente quanto ao processo de modelagem, escolha de parâmetros dos modelos e de algoritmos de aprendizagem.

Uma comparação de ANFIS e RNAs é importante pois ambos são métodos de IA de aprendizagem supervisionada com grande capacidade preditiva. O que contribui para entender as limitações e potencialidades de cada um no universo de aplicação presente neste estudo.

1.5 Estrutura do trabalho

- Capítulo 1 – Introdução – Aqui são apresentados o tema, tópicos de teoria sobre cadeias de suprimentos, os problemas e as premissas envolvidas para a realização do trabalho, as motivações e sua justificativa, o que se pretende e, por fim, a estrutura geral da obra.
- Capítulo 2 – Fundamentação teórica – São abordados a teoria do modelo SCOR[®], de RNAs e ANFIS. Há também na seção os estudos pesquisados sobre técnicas quantitativas para avaliação de desempenho baseados no modelo SCOR[®].
- Capítulo 3 – Metodologia e Procedimentos – Essa seção trata da classificação do trabalho em termos de método e os procedimentos que serão realizados para o estudo, treinamento das redes, realização das simulações, como foram coletados e analisados os dados. São apresentadas as definições das métricas utilizadas, o esquema dos modelos de aproximação de função proposto pelo trabalho.
- Capítulo 4 – Resultados – Aqui são estruturadas as definições de como foram feitos os testes.
- Capítulo 5 – Conclusão – São feitas inferências e considerações sobre os resultados.

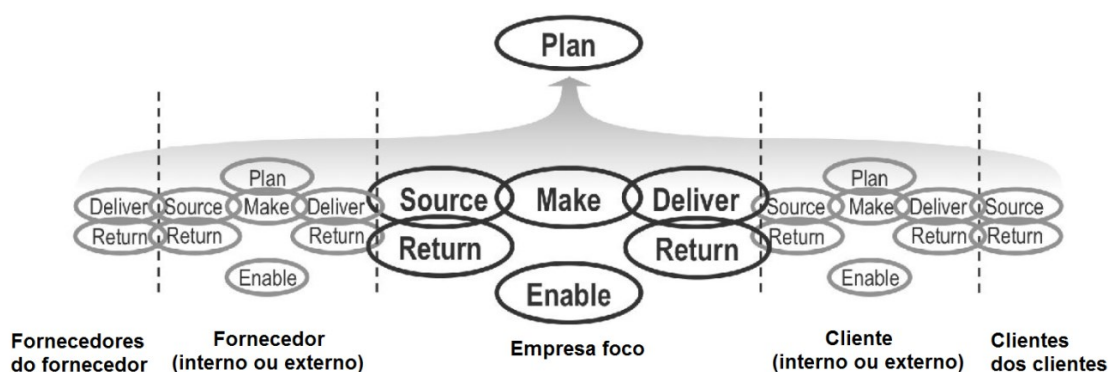
2 FUNDAMENTAÇÃO TEÓRICA

2.1 O modelo SCOR®

O modelo SCOR® foi desenvolvido pelo *Supply Chain Council*, uma organização de profissionais da área sem fins lucrativos. É pioneiro como um *framework* interempresarial para avaliar e fazer melhorias em processos de gestão de cadeias de suprimentos (SSC, 2012).

O modelo SCOR® está dividido em quatro seções principais. A seção “Desempenho” apresenta métricas padronizadas para descrever o desempenho dos processos e definir metas estratégicas. A seção “Processos” define uma estrutura de processos de gestão e descreve as relações entre eles. A seção “Práticas” sugere práticas de gestão de processos que resultam em níveis de desempenho significativamente melhores. Já a seção “Pessoas” define habilidades requeridas para executar os processos da cadeia de suprimentos (SCC, 2012). Conforme ilustra a Figura 1, os processos de gestão sugeridos pelo SCOR®, denominados *plan*, *source*, *make*, *deliver*, *return* e *enable*, integram os diferentes elos ao longo de uma cadeia produtiva. Cada processo possui métricas de desempenho associadas, que permitem monitorá-los e otimizá-los a partir da comparação entre os resultados obtidos e as metas definidas para cada métrica (AKKAWUTTIWANICH & YENRADEE, 2018).

Figura 1 - Processos de gerenciamento do SCOR®



Fonte: SCC (2012)

A seção do SCOR® sobre avaliação de desempenho apresenta duas modalidades de elementos para avaliação, chamados de atributo e métrica. Um atributo é definido como um grupo de métricas para se expressar uma estratégia, enquanto a métrica (ou indicador) é um padrão para se aferir o desempenho de uma cadeia de suprimentos ou processo. O SCOR® propõe cinco atributos de desempenho: *reliability*, *responsiveness*, *costs*, *agility* e *assets*. O atributo *reliability* se refere à habilidade de executar tarefas segundo o esperado. *Responsiveness* descreve a velocidade com que tarefas são realizadas. *Agility* consiste na

capacidade de responder a estímulos externos e de mudar por eles. O atributo *Costs* se refere aos custos de operação de processos da cadeia de suprimentos, enquanto *asset* é a habilidade de utilizar ativos com eficácia (SCC, 2012, DISSANAYAKE & CROSS, 2018).

O Quadro 1 dispõe de forma resumida os atributos do SCOR[®], suas definições pelo manual e as métricas que são no trabalho utilizadas.

Quadro 1 - Atributos de desempenho do SCOR[®]

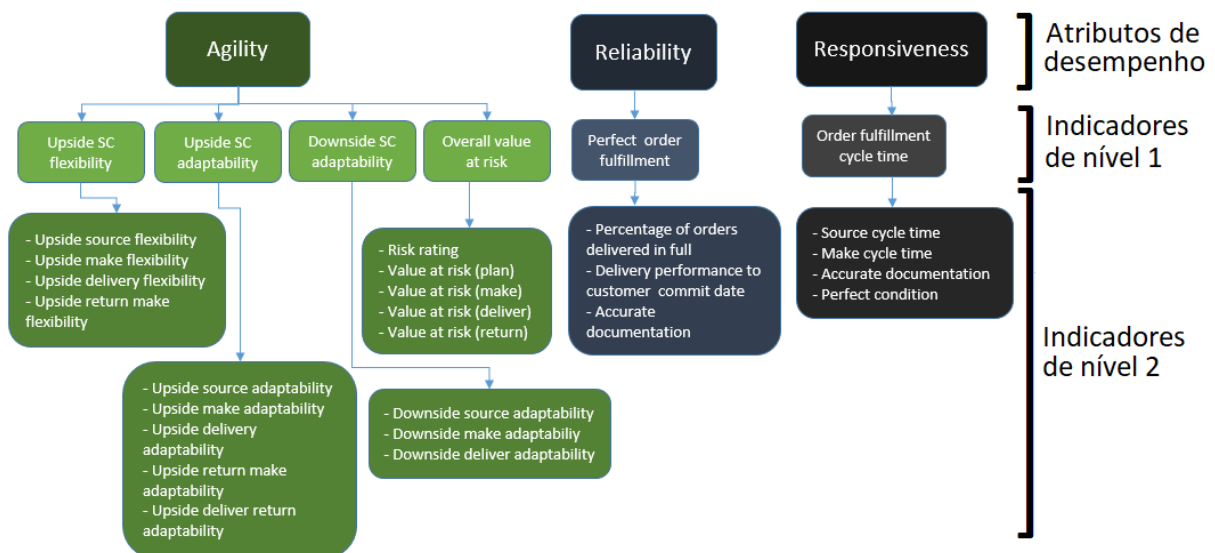
| Atributo | Definição | Métricas (nível 1) |
|-----------------------|--|---|
| <i>Reliability</i> | A habilidade de executar tarefas segundo o esperado | Cumprimento Perfeito de Ordens (<i>Perfect Order Fulfillment</i>) |
| <i>Responsiveness</i> | Descreve a velocidade com que tarefas são realizadas | Flexibilidade Superior de Cadeia de Suprimento (<i>Upside Supply Chain Flexibility</i>) Adaptabilidade Superior de Cadeia de suprimentos (<i>Upside Supply Chain Adaptability</i>) Adaptabilidade Inferior de Cadeia de Suprimento (<i>Downside Supply Chain Adaptability</i>) |
| <i>Agility</i> | Capacidade de responder a estímulos externos e de mudar por eles | Valor Geral de Risco (<i>Overall Value at Risk</i>) |
| <i>Costs</i> | Custo de operação de processos da cadeia de suprimento | Custo Total para Fornecer (<i>Total Cost to Serve</i>) Retorno de Bens Fixos da Cadeia de Suprimentos (<i>Return on Supply Chain Fixed Assets</i>) Retorno de Capital Utilizado (<i>Return on Working Capital</i>) |
| <i>Asset</i> | Habilidade de utilizar propriedades com eficácia | Tempo de Ciclo de Conversão de Caixa (<i>Cash-to-Cash Cycle Time</i>) |

Fonte: Baseado em Dissanayake e Cross (2018)

Os atributos de desempenho são divididos pelo modelo SCOR[®] em duas categorias: externos e internos. Os atributos externos são aqueles que dizem respeito a conceitos que são de relacionamento para com o ambiente de fora da organização, isso é, com foco no cliente. Os internos dizem respeito a categorias de dentro da própria organização. A Figura 2 (a) ilustra os atributos sugeridos pelo SCOR[®] e as métricas de nível 1 e 2 associadas a cada atributo de

orientação interna, *agility*, *reliability* e *responsiveness*. A Figura 2 (b) faz o papel equivalente para os atributos de orientação externa, *cost* e *asset*. As métricas de níveis hierárquicos diferentes possuem relações de causa e efeito quantificáveis, o que torna possível prever os valores das métricas de um nível superior com base nas métricas do nível imediatamente inferior. Dessa forma, assim como as métricas de nível 3 podem ser usadas para prever os valores das métricas de nível 2, as métricas de nível 2 também podem ser aplicadas para estimar os níveis de desempenho das métricas de nível 1. Essa característica contribui para que as métricas do SCOR® sejam frequentemente adotadas em modelos quantitativos de apoio à avaliação de desempenho. Como na prática a empresa-foco precisa desenvolver e implementar mecanismos para coletar dados e medir cada um dos indicadores adotados, o SCOR® não recomenda que a empresa-foco utilize todos os indicadores sugeridos, mas priorize a seleção dos indicadores de desempenho que são críticos para seus processos de gestão (SCC, 2012).

Figura 2 (a) – Atributos e métricas de desempenho de orientação interna sugeridos pelo SCOR®



Fonte: Autoria própria (2021)

Figura 2 (b) – Atributos e métricas de desempenho de orientação externa sugeridos pelo SCOR®



Fonte: Autoria própria (2021)

2.2.1 Modelos para avaliação de desempenho que combinam SCOR® com métodos quantitativos.

No caso das abordagens baseadas em julgamentos comparativos pareados de especialistas, propostas por Clivillé e Berrah (2012), Yang e Jiang (2012), Kocaoglu et al. (2013), Bukhori et al. (2015), Sellitto et al. (2015) e Dissanayake e Cross (2018), quanto maior o número de métricas e cadeias consideradas na avaliação, maior é a dificuldade de garantir a consistência dos dados. Outro problema é que, como os modelos baseados em métodos multicritério (SEIFBARGHY, 2009; GOLPARVAR & KOCAOGLU et al., 2013; MOHARAMKHANI et al., 2017; AKKAWUTTIWANICH; YENRADEE, 2018) produzem uma saída baseada em uma combinação linear ponderada dos valores de entrada, eles não são adequados para lidar com relações causais não-lineares entre as métricas de nível 1 e nível 2 do SCOR®. Entretanto, modelos baseados em técnicas de IA (GANGA & CARPINETTI, 2011; AGAMI et al., 2014; LIMA JR. & CARPINETTI, 2019) apresentam essa habilidade. No entanto, uma dificuldade em utilizar os modelos baseados em inferência *fuzzy* (GANGA & CARPINETTI, 2011; AGAMI et al., 2014) refere-se à necessidade de parametrizar e atualizar manualmente centenas de regras de decisões com base na opinião de especialistas, a fim de ajustar os relacionamentos causais entre as métricas de entrada e saída. Dentre todos os modelos encontrados na pesquisa, somente os sistemas baseados em redes neurais (LIMA JR. & CARPINETTI, 2019) possuem a capacidade de realizar ajuste automático dos parâmetros adaptativos do modelo usando dados históricos de desempenho. Embora esses modelos citados neste parágrafo tenham trazido diversas contribuições para o avanço da literatura e prática na

avaliação de desempenho de cadeias de suprimentos, eles apresentam algumas limitações e dificuldades de uso relacionadas às técnicas adotadas.

Sabe-se, porém, que as RNAs também possuem suas limitações. As redes funcionam como uma caixa preta, em que um conjunto de escalares compacta toda a informação que alimenta o sistema. Não é possível saber se o sistema atingiu um ponto de mínimo global, mesmo após muitas etapas iterativas. As redes não consideram os pesos das variáveis de entrada e não são capazes de lidar com aproximações e medidas de incertezas. Sistemas que combinam lógica *fuzzy* com RNAs são capazes de lidar melhor com algumas das limitações dos sistemas RNAs convencionais (AKKOÇ, 2012; APICHOTTANAKUL; PATHMNAKUL; PIEWTHONGNGAM; 2012).

A Tabela 1 contém um resumo de todos os modelos quantitativos mapeados pela pesquisa na literatura.

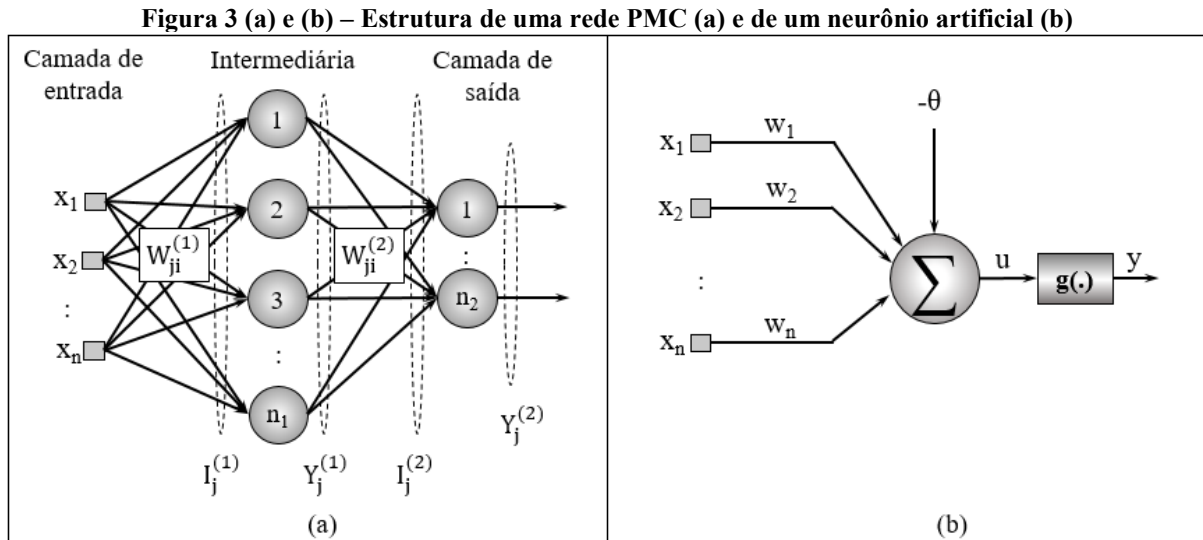
Tabela 1 – Técnicas utilizadas em modelos quantitativos para avaliação de desempenho baseados no SCOR®

| Autores | Método(s) |
|-----------------------------------|---|
| Golparvar & Seifbarghy (2009) | TOPSIS (<i>Technique for Order of Preference by Similarity to Ideal Solution</i>) |
| Ganga & Carpinetti (2011) | Sistemas de inferência <i>fuzzy</i> do tipo Mamdani |
| Jalalvand et al. (2011) | DEA (<i>Data envelopment analysis</i>) and PROMETHEE II |
| Clivillé & Berrah (2012) | MACBETH (<i>Measuring Attractiveness by a Categorical Based Evaluation Technique</i>) |
| Yang & Jiang (2012) | Novo método baseado em números <i>fuzzy</i> e M(1,2,3) |
| Kocaoglu et al. (2013) | AHP (<i>Analytic Hierarchy Process</i>) and TOPSIS |
| Agami et al. (2014) | Sistemas de inferência <i>fuzzy</i> do tipo Mamdani |
| Bukhori et al. (2015) | AHP |
| Sellitto et al. (2015) | AHP |
| Moharamkhani et al. (2017) | <i>Interval-valued Fuzzy TOPSIS</i> |
| Liu & Liu (2017) | DEA |
| Akkawuttiwanich & Yenradee (2018) | Fuzzy QFD (<i>Quality Function Deployment</i>) |
| Dissanayake & Cross (2018) | AHP e modelagem de equações estruturais |
| Lima Jr. & Carpinetti (2019) | RNAs PMC |
| Lima Jr. & Carpinetti (2020) | ANFIS |

Fonte: Autoria própria (2018)

2.2 Redes neurais artificiais

RNAs são técnicas de processamento distribuído que imitam sistemas neurais biológicos (KURTGOZ et al., 2017). De acordo com um estudo de revisão da literatura desenvolvido por Tkác e Verner (2016), o tipo de RNA mais utilizado é o PMC. As RNAs têm várias utilidades matemáticas que podem ser aplicadas nos mais diversos campos do conhecimento. Algumas das principais aplicações são para solucionar numericamente problemas envolvendo funções, predizer séries temporais e reconhecer padrões. Conforme ilustra a Figura 3 (a), uma RNA do tipo PMC é composta por uma camada de entrada, uma camada de saída e uma ou mais camadas intermediárias (ABDI-KHANGHAH et al., 2018). Cada camada possui unidades de processamento básicas chamadas neurônios artificiais, cuja estrutura é detalhada na Figura 3 (b). As conexões entre esses neurônios possuem diferentes pesos. Os valores iniciais desses parâmetros são definidos aleatoriamente, sendo modificados posteriormente durante o processo de treinamento da rede. Cada neurônio possui um limiar de ativação (*bias*) que ajuda a aumentar o desempenho da rede (KURTGOZ et al., 2017).



Fonte: Lima Jr. e Carpinetti (2019)

Na Figura 3 (a), são representados os sinais de entrada (x_1, x_2, \dots, x_n), as matrizes de pesos sinápticos (W_{ji}^L) que ligam os neurônios (j) de cada camada (L) aos neurônios de sua camada antecessora (i), as entradas ponderadas (I_j^L) dos neurônios e as saídas produzidas por cada um (Y_j^L). O treinamento das redes tradicionalmente é feito utilizando um algoritmo de aprendizagem supervisionada denominado *backpropagation*, o qual é composto de duas etapas. Esse treinamento requer um conjunto de amostras dos valores das variáveis de entrada e saída da rede, as quais são subdivididas em subconjunto de treinamento e subconjunto de validação. A quantidade de amostras recomendada para o treinamento é de 60% a 90%. O número de vezes em que tais amostras são processadas pela rede, chamado número de épocas, serve como um critério de parada do treinamento (SILVA et al., 2010; REZAEE et al., 2018).

Na etapa *forward*, os sinais de entrada (x_i) são ponderados pelos pesos sinápticos da primeira camada intermediária $W_{ji}^{(1)}$, para cada elemento de peso

$$I = \sum_{i=1}^n w_i \cdot x_i - \theta. \quad (1)$$

A variável θ é a representação do *bias*. Posteriormente, esse vetor de entradas ponderado conforme a equação é modificado por uma função de ativação, tal como a função tangente hiperbólica, gerando assim os valores do vetor $I_j^{(1)}$. Os procedimentos realizados nas camadas posteriores são similares. Contudo, nestes casos, os sinais de entrada dessas das camadas se referem às saídas das camadas anteriores (SILVA et al., 2010; REZAEE et al., 2018).

A função de ativação $g(I)$ deve ser diferenciável em todo seu domínio.

$$g(I) = \frac{e^I - e^{-I}}{e^I + e^{-I}} = \tanh(I). \quad (2)$$

Na etapa *backward*, as respostas produzidas pela rede para cada amostra são comparadas com as respectivas amostras das variáveis de saída do subconjunto de treinamento (respostas desejadas). O objetivo principal do algoritmo *backpropagation* consiste em encontrar valores ótimos para os pesos sinápticos e os limiares de ativação da rede, de modo a minimizar o erro quadrático médio resultante da diferença entre as saídas desejadas e as os valores preditos. As correções nos valores desses parâmetros são feitas com base nessa diferença, de modo a minimizar o erro. O ajuste desses parâmetros se inicia pela camada de saída e segue posteriormente para a(s) camada(s) intermediária(s). O processo é repetido até que o número de épocas de treinamento ou o valor de erro quadrático médio definido seja atingido. Ao final do treinamento, os parâmetros da rede estarão ajustados de modo a determinar uma relação numérica entre as variáveis de entrada e saída (BILGEHAN, 2011).

Para conduzir o processo de treinamento de redes PMC e selecionar as topologias de rede mais adequadas para cada modelo, diversos estudos aplicam um procedimento conhecido como validação cruzada, o qual é composto por uma série de testes (TKÁC & VERNER, 2016; REZAEI et al., 2018; LIMA JR. & CARPINETTI, 2019). Em cada teste, são avaliadas várias combinações de valores para os parâmetros da rede com o objetivo de selecionar aquela que resulta no menor EQM na etapa de validação. O EQM é calculado pelo quadrado da diferença entre o valor esperado e o valor obtido. Esse procedimento também costuma ser aplicado para avaliar a acurácia de algoritmos de aprendizagem com o propósito de escolher o mais apropriado (SILVA et al., 2010).

2.3 Algoritmos de treinamento

Há ampla variedade de métodos de aprendizagem que podem ser aplicados para conduzir o treinamento supervisionado de redes PMC. Com o objetivo de aperfeiçoar a versão original do *backpropagation*, novos algoritmos têm sido propostos a fim de tornar o treinamento mais rápido e alcançar maior acurácia de predição. Nesta seção serão descritos alguns dos mais utilizados algoritmos de treinamento, os quais também foram adotados por este estudo. A principal diferença entre tais algoritmos é a forma como é feito o cálculo da direção de ajuste dos parâmetros e da magnitude desse ajuste a cada iteração (TKÁC & VERNER, 2016).

2.3.1 GDM (Termo de *Momentum* - *Gradient Descendent Momentum*)

Também conhecido por termo de *momentum*, o algoritmo GDM se constitui por uma simples modificação no algoritmo tradicional de *backpropagation*. A mudança se trata de um termo adicional que configura a quantidade de alteração das matrizes sinápticas entre duas iterações sucessivas. Quando o termo de *momentum* é igual a zero a equação do algoritmo GDM se torna igual ao do algoritmo tradicional de *backpropagation* (SILVA et al., 2010; REZAEI et al., 2018). A equação

$$W_{ji}^{(L)}(t+1) = W_{ji}^{(L)}(t) + \alpha \cdot (W_{ji}^{(L)}(t) - W_{ji}^{(L)}(t-1)) + \eta \cdot \delta_j^{(L)} \cdot Y_i^{(L-1)}, \quad (3)$$

representa o ajuste dos pesos do algoritmo GDM, em que η é a taxa de aprendizagem, o valor α é o coeficiente de *momentum*, um parâmetro ajustável que define a magnitude dos ajustes iterativos rumo à minimização do erro. O valor de $\delta_j^{(L)}$ é o gradiente local em relação ao j -ésimo neurônio da camada de saída na equação dada por

$$\delta_j^{(L)} = (d_j - Y_j^{(L)}) \cdot g'(I_j^{(L)}). \quad (4)$$

Uma grande diferença entre as soluções ideal e final implica em grande passo do termo de *momentum*, já uma pequena diferença resulta em um pequeno passo. O algoritmo torna a convergência muito mais eficaz que o algoritmo tradicional (SILVA et al., 2010; REZAEI et al., 2018).

2.3.2 LM (Levenberg-Marquardt)

No algoritmo LM o ajuste é feito usando um método gradiente de segunda ordem baseado em mínimos quadrados para modelos não-lineares. O algoritmo LM se diferencia do algoritmo tradicional de *backpropagation* e do GDM pois não funciona como um método de descida para minimizar a função do erro quadrático médio, é uma aproximação do método de Newton. O parâmetro μ é a taxa de ajuste de convergência, $J(W)$ representa uma matriz jacobiana (matriz de derivadas de segunda ordem), $J^T(W)$ sua versão transposta e I é a matriz identidade. Os parâmetros se relacionam pela equação

$$\Delta W = (J^T(W) \cdot J(W) + \mu \cdot I)^{-1} \cdot J^T(W) \cdot (d_j - Y_i^{(L)}). \quad (5)$$

Estudos indicam que o algoritmo LM conduz as funções à convergência de 10 a 100 vezes mais rápido que o algoritmo tradicional de *backpropagation* (SILVA et al., 2010; REZAEI et al., 2018).

2.3.3 BFGS (Broyden-Fletcher-Goldfarb-Shano)

O algoritmo BFGS, foi desenvolvido combinando características do termo de *momentum*, por utilizar dados da primeira derivada parcial, e do algoritmo Gauss-Newton, que utiliza a segunda derivada parcial e também possui a capacidade de resolver problemas de tipo não-linear, de maneira conjugada (MUKHERJEE & ROUTROY, 2012). A abreviatura do algoritmo é dada pelos desenvolvedores Broyden, Fletcher, Goldfarb e Shanno, que apesar de não terem realizado primeiramente a combinação entre os dois algoritmos descritos, eles foram os responsáveis pela mais importante melhoria em sua taxa de convergência. O algoritmo utiliza a expressão de ajuste de pesos

$$W(t + 1) = W(t) - \alpha_t \cdot [\nabla^2 J(W(t))]^{-1} \cdot \nabla J(W(t)), \quad (6)$$

em que, $\nabla^2 J(\cdot)$ é a matriz hessiana ao quadrado, $\nabla J(\cdot)$ é a matriz hessiana e α_t é um escalar que define o passo de ajuste (MUKHERJEE & ROUTROY, 2012).

2.3.4 SCG (Scale Conjugate Gradient)

Já o algoritmo SCG também utiliza derivadas de segunda ordem. Como algoritmo conjugado de escala, possui sistema de otimização numérica. O método possui direção do ajuste variável. Pelo fato de aplicar direção de ajuste conjugada possui convergência mais rápida do que o algoritmo de *backpropagation*

$$W(t + 1) = W(t) + \alpha_t \cdot d_t, \quad (7)$$

no qual d_t determina a direção do ajuste (CHAUHAN ET AL., 2020).

2.3.5 RP (Resilient Propagation)

Algoritmo proposto por Riedmiller e Braun (1993) com o intuito de se aprimorar o algoritmo do termo de *momentum*. Este método realiza uma adaptação local das atualizações dos pesos de acordo com o comportamento da função de erro. Ao contrário de outras técnicas adaptativas, o efeito do algoritmo RP não é prejudicado pela influência imprevisível da magnitude da derivada, mas apenas pelo comportamento do sinal dela ao longo do tempo.

O ajuste dos pesos das conexões entre os neurônios usando o algoritmo RP é feito por meio do uso das equações (SANTRA, CHAKRABORTY e SEN, 2008)

$$\Delta W_{ji}^{(t)} = W_{ji}^{(t)}, \text{ se } \frac{\partial E}{\partial w_{ij}} > 0, \quad (8)$$

$$\Delta W_{ji}^{(t)} = -W_{ji}^{(t)}, \text{ se } \frac{\partial E}{\partial w_{ij}} < 0, \quad (9)$$

$$\Delta W_{ji}^{(t)} = 0, \text{ caso contrário.} \quad (10)$$

Considera-se que $\Delta W_{ji}^{(t)}$ é a matriz de variação dos pesos que será acrescentada à sua homóloga $W_{ji}^{(t)}$ para cálculo da matriz posterior, de posição $t + 1$. São feitas as mudanças incrementais nos valores dos pesos a partir do sinal da derivada para que sejam calculadas as atualizações dos mesmos dadas por Santra, Chakraborty e Sem (2008):

$$W_{ji}^{(t+1)} = W_{ji}^{(t)} + \Delta W_{ji}^{(t)}. \quad (11)$$

2.4 Sistemas *fuzzy*

Zadeh em 1965 foi quem formulou primeiramente a teoria dos conjuntos *fuzzy* (FST – *Fuzzy Set Theory*). A palavra do inglês *fuzzy*, segundo o dicionário Cambridge®, pode ser traduzida como desfocado, difuso ou vago (FUZZY, 2021).

A classificação de um certo conjunto de unidades em classes pode ser aplicada a muitos conceitos, tais como objetos, atitudes humanas, desempenho, linhas de pensamento, dentre tantos outros quanto se possa citar. Pode-se, por exemplo, categorizar um grupo de animais como domesticável ou não domesticável. No entanto, classificações de pertencimento como essas são normalmente imprecisas quando se trata de estabelecer limiares entre classes vizinhas. Isso se deve à natureza vaga de nossa linguagem. Se houvesse apenas estas duas classes, qual linha separaria os pensamentos profundos dos rasos? Para demonstrar com números, qual seria o limiar de divisão dos números maiores que 1 dos muito maiores que 1? (ZADEH, 1965).

Apesar de sua natureza imprecisa, a separação em classes é muito importante para a comunicação humana, o reconhecimento de padrões e a capacidade de abstração. Com o intuito de representar as supracitadas classes, o autor propôs os conjuntos *fuzzy*, que se diferenciam por considerarem a existência de graus contínuos de pertencimento dentro de um intervalo (ZADEH, 1965).

2.4.1 Definições básicas sobre a Teoria dos Conjuntos Fuzzy

A FST permite a modelagem de sistemas com graus de incerteza. Entre os extremos de verdadeiro $[1; 0]$ e falso $[0; 0]$, para um determinado atributo, podem-se assumir valores intermediários dentro de um intervalo de pertinência contínuo $[0; 1]$. A lógica *fuzzy* permite que critérios subjetivos de avaliação sejam convertidos em objetivos (numéricos) (ZADEH, 1965).

Todo o equacionamento que segue nesta seção e nas seguintes sobre sistemas e lógica *fuzzy* foi baseado em Ruthkowski (2004). Um conjunto *fuzzy* A é descrito por

$$A = \{(\mathbf{x}, \mu_a(\mathbf{x})), \mathbf{x} \in \mathbf{X}\}, \quad (12)$$

em que μ_a é a função de pertinência, em que cada elemento $\mathbf{x} \in \mathbf{X}$ possui um grau de pertinência $\mu_a(\mathbf{x}) \in [0; 1]$ para o conjunto A . O espaço \mathbf{X} é chamado universo de discurso, e pode-se denotar $A \subseteq \mathbf{X}$.

Quando o universo de discurso é dado em termos discretos e possui um número de elementos finito n , pode ser representado por

$$A = \sum_{i=1}^n \mu_a(x_1)/x_1 + \dots + \mu_a(x_n)/x_n. \quad (13)$$

Para o caso contínuo, há o equivalente

$$A = \int_x \mu_a(x_1)/x_1. \quad (14)$$

Tanto a somatória como a integral das equações (13) e (14) não representam somas de parcelas, mas sim a união de conjuntos numéricos. São notações usadas para conectar os elementos aos seus graus de pertinência.

Uma t-conorma é uma função S de duas variáveis *fuzzy*

$$S: [0; 1] \times [0; 1] \rightarrow [0; 1]. \quad (15)$$

Uma t-conorma entre dois argumentos é denotada com a forma

$$S\{a, b\} = a * b, \quad (16)$$

e pode ser generalizada para n argumentos por

$$S\{a_i\} = a_1 * a_2 * \dots * a_n. \quad (17)$$

2.4.1.1 Função de pertinência único (*singleton*)

A função de pertinência único tem valor 1 em apenas um ponto do universo de discurso e tem valor zero para todos os demais, como em

$$\mu_{Singl}(\mathbf{x}) = \begin{cases} 1 & \text{para } \mathbf{x} = \bar{\mathbf{x}} \\ 0 & \text{para } \mathbf{x} \neq \bar{\mathbf{x}} \end{cases} \quad (18)$$

2.4.1.2 Função de pertinência gaussiano

Uma função de pertinência gaussiana tem dois parâmetros: \bar{x} está ligado ao centro da função e σ diz respeito à largura

$$\mu_{Gauss}(x) = \exp\left(-\frac{(x-\bar{x})^T(x-\bar{x})}{\sigma^2}\right). \quad (19)$$

2.4.1.3 Função de pertinência sigmoidal

São dois os parâmetros que definem uma função de pertinência sigmoidal: a é responsável pela obliquidade e c pelo ponto de cruzamento. A equação é descrita em

$$\mu_{\text{sigmoidal}}(x) = \frac{1}{1 + \exp[-a(x-c)]}. \quad (20)$$

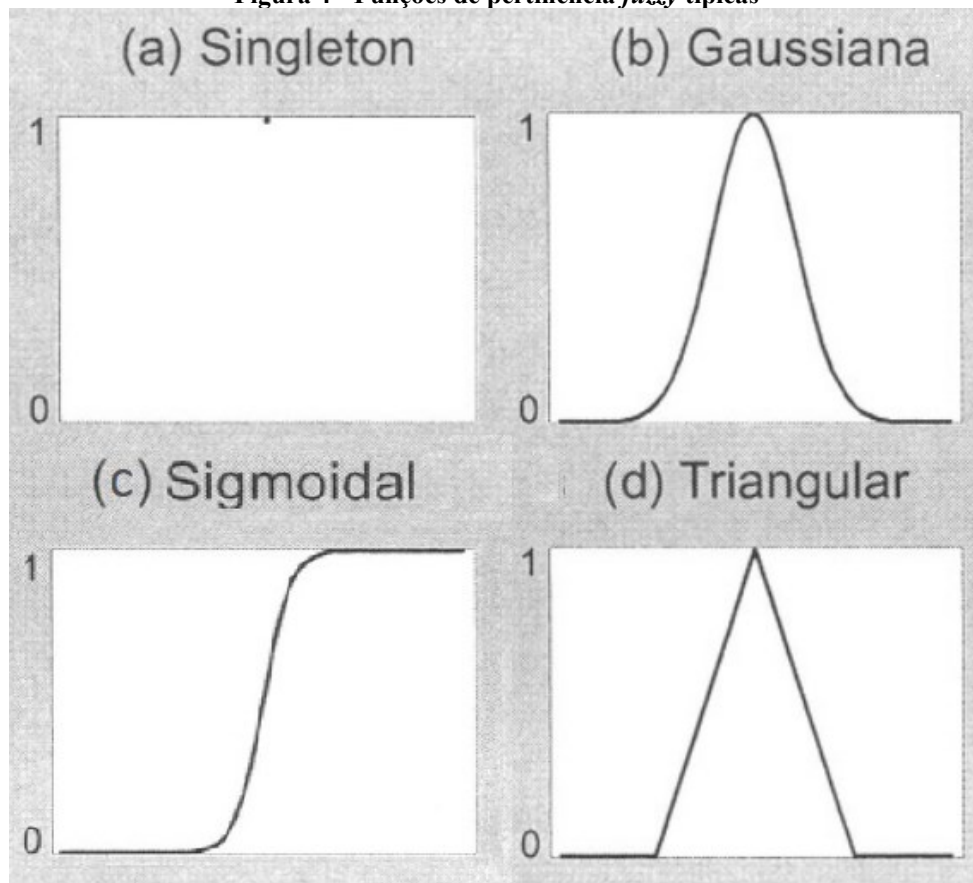
2.4.1.4 Função de pertinência triangular

A curva de pertinência triangular possui três parâmetros, $\{a, b, c\}$, sendo que $a < b < c$. A curva pode ser representada por

$$\mu_{\text{Triângulo}}(x) = \max\left(\min\left(\frac{x-a}{b-c}, \frac{c-a}{c-b}, 0\right), 0\right). \quad (21)$$

As quatro funções de pertinência que foram explicadas nesta seção são ilustradas na Figura 4.

Figura 4 - Funções de pertinência *fuzzy* típicas



Fonte: baseado em Rutkowski (2004)

2.4.1.5 O produto cartesiano entre conjuntos *fuzzy*

Pode-se usar qualquer operador t-conorma como produto cartesiano. O produto cartesiano entre os conjuntos $A_1 \subseteq X_1$ e $A_2 \subseteq X_2, \dots, A_n \subseteq X_n$ é denotado por $A_1 \times A_2 \dots \times A_n$. Utilizando a função de pertinência para o caso do operador mínimo, torna-se


$$\mu_{A_1 \times A_2 \dots \times A_n}(x_1, x_2, \dots, x_n) = \min_{i=1,2,\dots,n} \{\mu_{A_i}(x_i)\}, \quad (22)$$

e para o caso do operador produto

$$\mu_{A_1 \times A_2 \dots \times A_n}(x_1, x_2, \dots, x_n) = \prod_{i=1}^n \mu_{A_i}(x_i), \quad (23)$$


As Figuras 5 e 6 representam respectivamente produtos cartesianos definidos pelos operadores mínimo e produto.

Figura 5 - Produto cartesiano definido pelo operador mínimo



Fonte: Rutkowski (2004)

Figura 6 - Produto cartesiano definido pelo operador produto



Fonte: Rutkowski (2004)

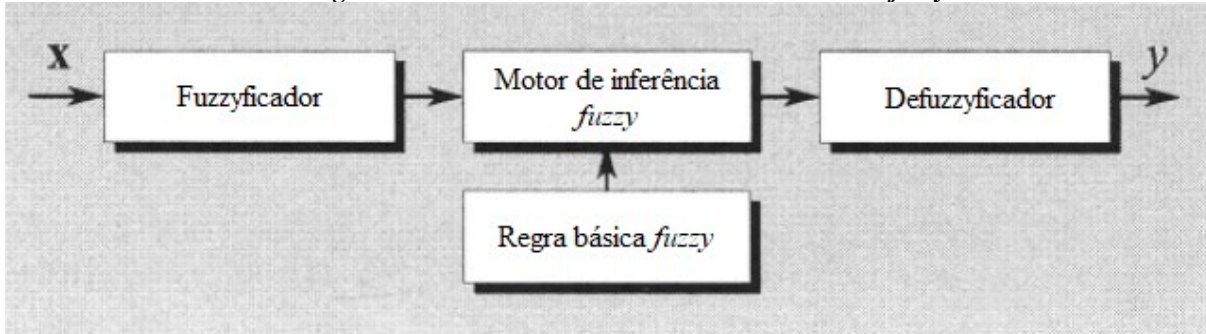
2.4.2 Inferência *fuzzy* de tipo lógico

A inferência *fuzzy* que é usada para aproximação de funções foi proposta por Takagi e Sugeno (1985). O tipo de função de inferência neuro-*fuzzy* utilizado no trabalho foi proposto Jang (1993), baseado no trabalho de Takagi e Sugeno (1985) e é tratada por Rutkowski (2004) por sistemas de “tipo lógico”. Ela utiliza implicações *fuzzy* para inferência e conjuntos *fuzzy* para agregação. Para sistemas de tipo lógico, a implicação é realizada por um operador t-norma da forma

$$T\{\mathbf{a}\} = T\{a_1, a_2, a_3, \dots, a_n\} = T\{a_1 \cdot a_2 \cdot a_3 \dots a_n\}. \quad (24)$$

A Figura 7 ilustra o sistema de inferência *fuzzy* de múltiplas entradas e única saída, tal que $X \rightarrow Y, X \subset R^n$, e $Y \subset R$. Um sistema MISO, composto por um fuzzificador, uma regra básica *fuzzy*, um motor de inferência *fuzzy* e um defuzzificador.

Figura 7 - Funcionamento do sistema de inferência *fuzzy*



Fonte: Adaptado de Rutkowski (2004)

O fuzzificador mapeia o espaço de entrada $X \rightarrow Y$ para um conjunto *fuzzy* definido em X . O fuzzificador mais comumente utilizado mapeia $\bar{x} = [\bar{x}_1, \dots, \bar{x}_n] \in X$ nos conjuntos $A' \in X$, caracterizado pela função de pertinência

$$\mu = \mu_{A'}(\bar{x}) = \begin{cases} 1 & \text{se } \bar{x} = \bar{x} \\ 0 & \text{se } \bar{x} \neq \bar{x} \end{cases} \quad (25)$$

A regra *fuzzy* básica consiste em uma coleção de regras *fuzzy* SE-ENTÃO, agregadas pela disjunção da conjunção, na forma

$$R^{(k)}: \text{SE } x \text{ é } A^k \text{ ENTÃO } y \text{ é } B^k. \quad (26)$$

em que $\bar{x} = [x_1, \dots, x_n] \in X, y \in Y, A^k = A_1^k \times A_2^k \times \dots \times A_n^k$. Considera-se que $A_1^k, A_2^k, \dots, A_n^k$ são conjuntos *fuzzy* caracterizados pela pertinência de funções $\mu_{A_i^k}(x_i), i = 1, 2, \dots, N$. $B_1^k, B_2^k, \dots, B_n^k$ são conjuntos *fuzzy* caracterizados pela pertinência de funções $\mu_{B_i^k}(x_i), i = 1, 2, \dots, N$.

Considera-se que o motor *fuzzy* determina o mapeamento dos conjuntos *fuzzy* em X para os conjuntos *fuzzy* de saída Y . Cada regra das N determina o conjunto $\bar{B}^k = A' \cdot (A^k \rightarrow B^k)$, dada pela regra de inferência

$$\tau_k(\bar{x}) = T_{i=1}^n \{ \mu_{A_i^k}(\bar{x}_i) \} = \mu_{A^k}(\bar{x}). \quad (27)$$

em que $A^k = A_1^k \times A_1^k \times \dots \times A_1^k$.

A pertinência de funções do tipo $A^k \rightarrow B^k$ usado na inferência de tipo lógico é uma implicação direta da proposição lógica (não-*fuzzy*). Uma das implicações *fuzzy* mais simples e utilizadas pode ser expresso pela relação

$$\mu_{A^k \rightarrow B^k}(x, y) = \min\{1, 1 - \mu_{A^k}(x) + \mu_{B^k}(y)\}. \quad (28)$$

Os sistemas *fuzzy* possuem um problema devido à complexidade advinda do processo ou sistema de modelagem. Em especial, o processo de inferência de Takagi e Sugeno (1985), limita-se por demandar um conjunto de dados representativos de todas medições ou amostras das variáveis do sistema a ser modelado. A inferência pode ser muito demorada, pelo longo tempo demandado para que se obtenham todas as amostras da modelagem (Lima Jr. 2020).

2.3 Sistemas neuro-*fuzzy* de tipo lógico

Nesta abordagem, a função $I(\cdot)$ é uma t-norma dada por

$$I(\mu_{A^k}(\mathbf{x}), \mu_{B^k}(y^r)) = T\{\mu_{A^k}(\mathbf{x}), \mu_{B^k}(y^r)\}. \quad (29)$$

O conjunto de saída agregado *fuzzy* $B' \subseteq Y$ é dado por

$$\mu_{B'}(y^r) = S_{k=1}^N\{\mu_{B^k}(y^r)\} = S_{k=1}^N\{T\{\mu_{A^k}(\mathbf{x}), \mu_{B^k}(y^r)\}\}. \quad (30)$$

Como, consequência, tem-se a fórmula


$$y = \frac{\sum_{r=1}^N y^r \cdot S_{k=1}^N\{T\{T_{i=1}^N\{\mu_{A^k}(\mathbf{x}), \mu_{B^k}(y^r)\}\}\}}{\sum_{r=1}^N S_{k=1}^N\{T\{T_{i=1}^N\{\mu_{A^k}(\mathbf{x}), \mu_{B^k}(y^r)\}\}\}}. \quad (31)$$

De maneira alternativa, pode-se denotar

$$agr_r = (\mathbf{x}, y^r) = T_{k=1}^N\{I_{k,r}(\mathbf{x}, y)\}. \quad (32)$$

A arquitetura geral de um sistema ANFIS pode ser observada na Figura 8.

Figura 8 – Arquitetura geral de um sistema ANFIS



Fonte: Adaptado de Rutkowski (2004)

Assim, a generalização do sistema de inferência neuro-fuzzy é definida por

$$y = f(\mathbf{x}) = \frac{\sum_{k=1}^N f^{(k)}(\bar{\mathbf{x}}) \cdot \mu_{a^k}(\bar{\mathbf{x}})}{\sum_{k=1}^N \mu_{a^k}(\bar{\mathbf{x}})}. \quad (33)$$

De modo a esclarecer o funcionamento geral ANFIS, segue um resumo baseado em Jang (2003) e Lima Jr e Carpinetti (2020), que foi adaptado à notação e modelo de Rutkowski (2004):

Na camada I da Figura 8 ocorre o processo de fuzzificação, em que um conjunto de entradas numéricas é convertido em um ou mais de conjuntos *fuzzy*, com valores de pertinência definidos. Cada nó da camada II corresponde à parte antecedente da respectiva regra de inferência, na qual diz respeito às possíveis combinações realizadas na primeira camada. O objetivo da segunda camada é compor relações lógicas entre as funções de pertinência para determinar suas saídas que equivalem ao peso de cada regra. A camada III contém o operador t-norma e a regra de inferência que são aplicadas a cada valor de entrada. A camada IV termina o processo agregando as saídas da camada III por meio da soma de todas elas, já de forma defuzzificada.

3 METODOLOGIA E PROCEDIMENTOS

A primeira etapa deste trabalho consistiu em um estudo bibliográfico sobre avaliação de cadeias de suprimentos, modelo SCOR[®], modelos de avaliação de desempenho, RNAs, ANFIS e algoritmos de treinamento supervisionado. As buscas de artigos foram feitas nas bases de periódicos *Science Direct*, *Emerald Insight*, *Scopus*, *Springer*, *Taylor & Francis* e *IEEE-Xplore*, utilizando combinações entre as strings “*supply chain performance evaluation*”, “*supply chain performance measurement*”, “*fuzzy inference*”, “*neural networks*”, “*training algorithm*”, “*fuzzy logic*”, “ANFIS” e “SCOR”.

Os resultados da revisão bibliográfica permitiram delimitar a seguinte lacuna de pesquisa que: não foram encontrados estudos que comparem a acurácia de RNAs e ANFIS no sentido de determinar qual o mais adequado para realizar aproximação de função dos indicadores do SCOR[®]. Os resultados da revisão bibliográfica também subsidiaram o desenvolvimento da etapa de modelagem e simulação computacional. Nessa etapa, as amostras para treinamento e validação dos modelos foram geradas usando o MS Excel[®].

Dois fatores foram determinantes para que se optasse por realizar esta pesquisa com dados simulados e não com valores reais previamente utilizados por companhias que fazem uso do SCOR[®]. O primeiro trata da dificuldade de se obter dados reais de avaliações de empresas com o modelo, já que normalmente se tratam de dados confidenciais intimamente ligados ao desempenho e à estrutura da empresa. Mesmo que eles fossem disponibilizados por alguma companhia, seriam necessárias centenas de amostras de históricos de desempenho para o treinamento dos modelos. O segundo fator é que a base de dados do modelo do SCOR[®], a SCORmark[®], não está disponível para fins acadêmicos, mas apenas para empresas, optou-se então por utilizar no presente trabalho dados simulados.

Os dados foram definidos com base nos limites estabelecidos para as variáveis em Lima Jr e Carpinetti (2019), e depois foram normalizados no intervalo [0,1]. Esse procedimento foi realizado pela ferramenta de amostragem do próprio MS Excel[®]. Já os valores das métricas de nível 1 são obtidos a partir das expressões sugeridas pelo SCOR[®] (SCC, 2012). Por apresentarem naturezas distintas com os mesmos intervalos das variáveis de entrada, os valores das equações possuirão também intervalos de mínimo e máximo distintos. Para efeitos comparativos, todas as saídas foram normalizadas (métricas de nível 1), ficando também dentro do intervalo [0, 1]. A planilha do MS Excel[®] gerada para os testes contém todas as entradas e suas respectivas saídas em formato matricial. Cada vetor de entrada de métricas de nível 2, tem por correspondente um valor de saída de nível 1.

A modelagem, o treinamento e a validação dos modelos foram realizados por meio do *software* MATLAB® e das *toolboxes* *Neural Network Tool* e *Neuro Fuzzy Designer*. As ferramentas permitem que sejam programadas RNAs e ANFIS, respectivamente, com praticidade. É possível definir por meio de interfaces gráficas das *toolboxes* todas as configurações das redes sem a necessidade de programar com código.

Em ambos os tipos de rede, os arquivos de *input*, *target*, *output*, *data*, *input delay state*, *layer delay state* e a própria rede podem ser salvos em formato de arquivo ou importados da memória. Todos os parâmetros da rede, bem como função de ativação, algoritmo de treinamento, número de camadas, quantidade de neurônios são editáveis. Para ANFIS foram utilizados os mesmos dados das RNAs PMC. É possível editar na *toolbox* a função de pertinência, os operadores lógicos, e a regra de inferência.

A comparação de desempenho das RNAs e ANFIS foi realizada em várias topologias diferentes para cada indicador, variando na quantidade de neurônios na camada intermediária, conforme detalhado na seção 4.2 e 4.3 respectivamente. Obtiveram-se os valores dos fatores de cada algoritmo empiricamente, por tentativa e erro. Tais fatores são os parâmetros das equações das redes nas configurações do MATLAB®, que podem fornecer precisões de resultado diversas a depender de seus valores em relação à função que se deseja aproximar.

Com base em Silva et al. (2010), o método de validação cruzada usando amostragem aleatória foi adotado para conduzir a implementação e a avaliação das topologias e dos algoritmos de aprendizagem. A validação cruzada é de grande utilidade em problemas de modelagem por predição, pois tem a capacidade de determinar qual a topologia mais adequada e qual algoritmo de aprendizagem possui a maior acurácia de predição. A partir de um conjunto de dados é possível generalizar um modelo matemático e compara-se o mesmo conjunto com um segundo para estimar o quão preciso é o modelo.

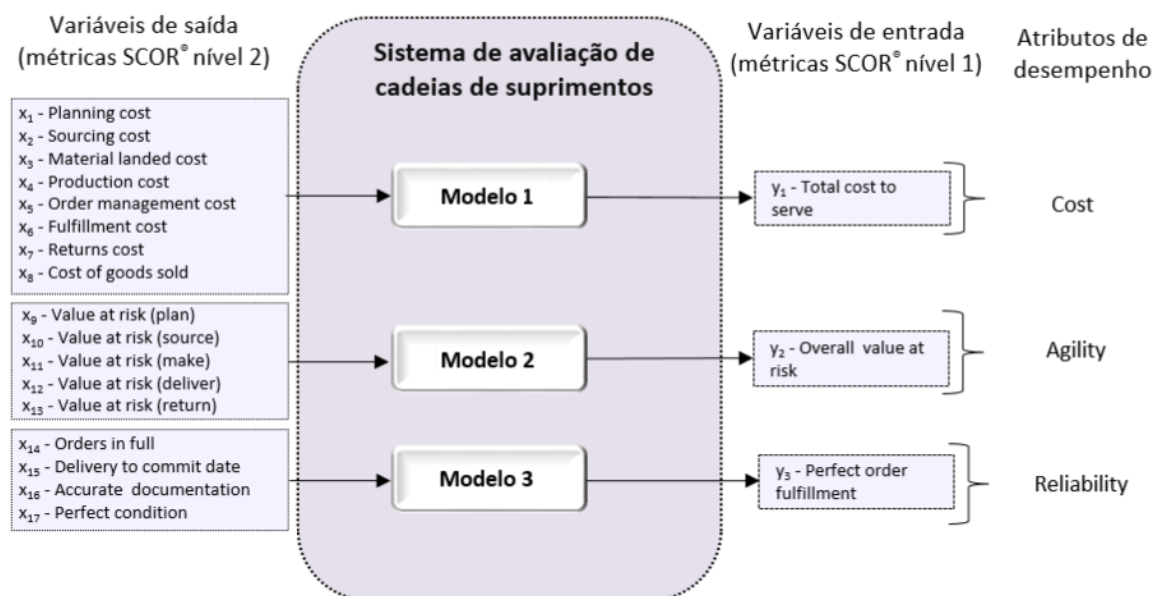
O índice de correlação de Pearson é uma medida matemática que estabelece a direção e a intensidade da correlação de duas variáveis aleatórias. É uma ferramenta com recorrente utilização para aplicações tais como estimação de tempo de atraso, análise de dados, entre muitos outros, incluindo a aproximação de funções, conteúdo de que trata este estudo (BENESTY, CHEN e HUANG, 2008).

No presente estudo, foi calculado o índice de correlação de Pearson e foram feitos alguns testes de regressão linear. Por último, testes de hipótese com amostras pareadas serão feitos para determinar se há diferença significativa entre os valores esperados e os dados estimados por cada topologia de rede selecionada.

3.1 Os Modelos computacionais avaliados

Os modelos de rede serão utilizados tanto nas redes PMC como ANFIS para que sejam feitas as aproximações de função das mesmas e verifique-se a acurácia. A Figura 9 apresenta a arquitetura do sistema de avaliação de desempenho de cadeias de suprimentos desenvolvido com base em Ganga e Carpinetti (2011), SCC (2012) e Lima Jr. e Carpinetti (2019), que é utilizado para a condução deste estudo. Esse sistema é composto por 3 modelos de rede. Enquanto as variáveis de entrada são definidas pelas métricas de nível 2 do SCOR[®], as variáveis de saída se referem às métricas de nível 1. Os indicadores de nível 1 foram escolhidos de modo a contemplar diferentes atributos de desempenho do SCOR[®] de acordo com os que foram considerados mais interessantes para predição e análise. O próprio SCOR[®] sugere que as métricas a serem utilizadas sejam apenas as que interessam à aplicação. Desse modo, foram escolhidos 3 modelos, sendo um para cada atributo de desempenho considerado relevante, como seria feito em uma aplicação real. O Modelo 1 foi construído com o auxílio do atributo *costs*, o Modelo 2 de rede com *agility* e o Modelo 3 com *reliability*. A estrutura mostrada na Figura 9 é a arquitetura dos sistemas realizados para aproximação de função tanto por RNAs PMC quanto para ANFIS. A partir desse padrão, foram testadas várias combinações de configurações topológicas, totalizando 81 modelos computacionais.

Figura 9 – Arquitetura do sistema de avaliação de desempenho em modelos



Fonte: Autoria própria (2018)

Em contraste com o artigo de referência (LIMA JR. & CARPINETTI, 2019), no qual foram utilizadas um número de 20 configurações, o objetivo deste trabalho é comparar o

funcionamento das redes em várias configurações diferentes, variando o número de neurônios e algoritmos de treinamento para as redes PMC. Para ANFIS, variam-se e as funções de pertinência, o operador t-norma e a regra de inferência. Optou-se assim por ter várias possibilidades para a análise de vários tipos de topologias.

Foram utilizadas as métricas de três atributos de desempenho e não sete como no artigo de referência (LIMA JR. & CARPINETTI, 2019), pois as três funções foram consideradas suficientes tendo em vista a diferença da natureza de suas fórmulas considerando as possibilidades do SCOR[®]. Além disso, o intuito do trabalho não é fazer mapeamento de todo o modelo, já que o próprio SCOR[®] sugere que se deve fazer a análise das métricas mais importantes para o negócio ou estudo em questão. A alimentação exagerada do sistema pode tornar a análise demorada e custosa.

3.2 Variáveis geradas para os modelos PMC e ANFIS

Os Quadros 2, 3 e 4 apresentam uma descrição das métricas do SCOR[®] que representam as entradas e saídas dos modelos PMC e ANFIS. Mais detalhes sobre elas podem ser consultados no modelo SCOR[®] (SCC, 2012). Após a definição teórica de cada variável dos Quadros 2, 3 e 4, há sua respectiva definição matemática. Os valores de x_1 a x_8 bem como y_1 são simplesmente custos, que apesar de possuírem respectivas métricas de nível 3, podem ser utilizados de modo puramente numérico para esta aplicação. As variáveis de x_9 até x_{13} e y_2 possuem valor de produto entre impacto monetário e probabilidade, pois tratam de chances e impactos de riscos. Os valores de entrada de x_{14} a x_{17} são proporções entre as entregas adequadamente realizadas e a quantidade total de entregas feitas.

As seguintes subseções 3.2.1, 3.2.2 e 3.2.3 apresentam as descrições das métricas dos respectivos Modelos 1, 2 e 3. Isso é, primeiramente é feita uma lista com a explicação teórica sobre ao que se refere cada variável, a seguir em cada tabela há o nome de cada variável de nível 2 que é utilizada para calcular cada variável de nível 1, seu respectivo *range* (intervalo de valores que a função pode resultar) e sua representação na forma de equação. As variáveis foram normalizadas para as comparação e padronização no processo de geração das amostras aleatórias. Porém, é importante ressaltar que as descrições das fórmulas presentes nas subseções já citadas neste parágrafo não estão normalizadas, mas do modo exato que apresentam-se no SCOR[®].

3.2.1 Modelo 1 - *Total cost to serve*

O Modelo 1 é aplicado para fazer a aproximação funcional de uma equação com todas as entradas e saídas de valor monetário, são elas (SCC, 2012):

1. ***Sourcing cost***: o custo total associado com o gerenciamento de pedidos, recebimento, inspeção e armazenagem de produtos, mercadorias e serviços. Custos incluem aquisição de material, gerenciamento da compra de pedidos, custos de trabalho, gerenciamento da performance de fornecedores.
2. ***Planning cost***: o custo total de pessoal, automação, patrimônio e despesas gerais associadas aos processos de planejamento da cadeia de suprimentos. São também componentes do critério organização, preparo, hospedagem, coleta e julgamento de dados, planos de publicação, gerenciamento.
3. ***Material landed cost***: o custo total associado com a aquisição de componentes e produtos, o seguro dos bens envolvidos, tarifas e taxas de transporte, alfândega, e sua disponibilização no local de uso ou estocagem.
4. ***Production cost***: o custo do gerenciamento e execução dos processos de produção. Processos como agendamento de atividades produtivas, realizar atividades transformadoras no produto, tais como dar forma, procedimentos químicos, reparos.
5. ***Order management cost***: o custo total de pessoal, automação e patrimônio para responder perguntas e requerimentos, cotações, dar entrada, rastrear e faturar pedidos. Pode incluir o custo de crédito a clientes ou coleções.
6. ***Fulfillment cost***: o custo de pessoal, automação, patrimônio e despesas associadas com o cumprimento de pedidos, incluindo custos com manuseio físico de produtos, transporte de bens entre localidades.
7. ***Returns cost***: o custo de disposição de materiais retornados devido a erros de planejamento, problemas na qualidade do fornecedor, na entrega ou produção. Custos de retrabalho por imperfeições da entrega.
8. ***Cost of goods sold***: o custo de materiais diretos, mão de obra e despesas gerais associadas com a aquisição ou produção de produtos acabados.
9. ***Total cost to serve***: soma dos custos diretos como custos dos materiais, salários da cadeia de suprimentos e indiretos como o custo para entregar produtos, fazer manutenção, serviços, requerimentos e retornos.

O cálculo da variável de nível 1, *total cost to serve*, é feito através da equação

$$\begin{aligned} [\textit{Total cost to serve}] = & [\textit{Sourcing cost}] + [\textit{Planning cost}] + [\textit{Material landed cost}] + \\ & [\textit{Production cost}] + [\textit{Order management cost}] + [\textit{Fulfillment cost}] + [\textit{Returns cost}] + \\ & [\textit{Cost of goods sold}]. \quad (34) \end{aligned}$$

Quadro 2 - Características do Modelo 1

| Nome da variável | Representação da variável | Range da variável |
|---|---------------------------|-------------------|
| <i>Sourcing cost</i> Valor monetário | x ₁ | [0,1] |
| <i>Planning cost</i> Valor monetário | x ₂ | [0,1] |
| <i>Material landed cost</i> Valor monetário | x ₃ | [0,1] |
| <i>Production cost</i> Valor monetário | x ₄ | [0,1] |
| <i>Order management cost</i> Valor monetário | x ₅ | [0,1] |
| <i>Fulfillment cost</i> Valor monetário | x ₆ | [0,1] |
| <i>Returns cost</i> Valor monetário | x ₇ | [0,1] |
| <i>Cost of goods sold</i> Valor monetário | x ₈ | [0,1] |
| <i>Total cost to serve</i> Valor monetário | y ₁ | [0,8] |

Fonte: Autoria própria (2021)

3.2.2 Modelo 2 - Overall value at risk

Os indicadores analisados pela rede PMC 2 são calculados por meio de um produto entre o tipo de risco e o seu impacto monetário (SCC, 2012).

1. Soma dos riscos monetizados relacionados ao processo “*plan*”,

$$[Value\ at\ risk\ (plan)] = [Probability\ of\ return\ risk\ event] \times [Monetized\ impact\ of\ risk\ return\ event]. \quad (35)$$

2. Soma dos riscos monetizados relacionados ao processo “*source*”,

$$[Value\ at\ risk\ (source)] = [Probability\ of\ source\ risk\ event] \times [Monetized\ impact\ of\ source\ risk\ event]. \quad (36)$$

3. Soma dos riscos monetizados relacionados ao processo “*make*”,

$$[Value\ at\ risk\ (make)] = [Probability\ of\ make\ risk\ event] \times [Monetized\ impact\ of\ make\ risk\ event]. \quad (37)$$

4. Soma dos riscos monetizados relacionados ao processo “*deliver*”,

$$[Value\ at\ risk\ (deliver)] = [Probability\ of\ deliver\ risk\ event] \times [Monetized\ impact\ of\ deliver\ risk\ event]. \quad (38)$$

5. Soma dos riscos monetizados relacionados ao processo “*return*”,

$$[Value\ at\ risk\ (return)] = [Probability\ of\ plan\ risk\ event] \times [Monetized\ impact\ of\ plan\ risk\ event]. \quad (39)$$

6. Consiste na soma das probabilidades de eventos de risco que podem impactar nos processos da cadeia multiplicada pelo impacto monetário desses eventos, seguindo a expressão

$$[Overall\ value\ at\ risk] = VaR\ (plan) + VaR\ (make) + VaR\ (deliver) + VaR\ (return) + VaR\ (source). \quad (40)$$

Quadro 3 - Características do Modelo 2

| Nome da variável | Representação da variável | Range da variável |
|--------------------------------|---------------------------|-------------------|
| <i>Value at risk (plan)</i> | x ₉ | [0,1] |
| <i>Value at risk (source)</i> | x ₁₀ | [0,1] |
| <i>Value at risk (make)</i> | x ₁₁ | [0,1] |
| <i>Value at risk (deliver)</i> | x ₁₂ | [0,1] |
| <i>Value at risk (return)</i> | x ₁₃ | [0,1] |
| <i>Overall value at risk</i> | y ₂ | [0,5] |

Fonte: Autoria própria (2021)

3.2.3 Modelo 3 - *Perfect order fulfillment*

O indicador do qual trata a rede PMC 3 diz respeito à proporção do número de ordens entregues em perfeitas condições em relação ao número total de pedidos.

1. **Total perfect orders:** avalia a quantidade de ordens que será entregue em perfeitas condições, sem nenhum tipo de falha considerada pelo manual e é calculado por

$$[\text{Total perfect orders}] = [\text{total number of orders delivered with accurate documentation}] / [\text{total number of orders delivered}] \times 100\%. \quad (41)$$

2. **Total number of orders:** Mede simplesmente a quantidade de ordens realizadas, dado pela expressão

$$[\text{Total number of orders}] = [\text{number of orders delivered in perfect conditions}] / [\text{total number of orders delivered}] \times 100\%. \quad (42)$$

3. **Perfect order fulfillment:** refere-se ao percentual de pedidos que tenham sido entregues na data combinada pelo cliente, sem danos e com documentação completa e precisa, como segue

$$[\text{Perfect order fulfillment}] = [\text{Total perfect orders}] / [\text{Total number of orders}]. \quad (43)$$

Quadro 4 - Características do Modelo 3

| Nome da variável | Variáveis e seus intervalos | Range da variável |
|----------------------------------|-----------------------------|-------------------|
| <i>Total perfect orders:</i> | X ₁₄ | [100] |
| <i>Total number of orders</i> | X ₁₅ | [1, 100] |
| <i>Perfect order fulfillment</i> | Y ₃ | [0,1] |

Fonte: Autoria própria (2021)

Os testes do indicador *Perfect order fulfillment* foram um caso à parte, tendo em vista que o indicador é não-linear. Inicialmente foi considerada, para o *total number of orders*, uma quantidade aleatória entre 1 e 100 e o valor de ordens perfeitamente realizadas, uma quantidade aleatória entre 1 e o *total number of orders*, como no Quadro 5.

Quadro 5 - Características do Modelo 3 (descartado)

| Nome da variável | Variáveis e seus intervalos | Range da variável |
|----------------------------------|------------------------------------|-----------------------------------|
| <i>Total perfect orders:</i> | x_{14} | [1, 100] |
| <i>Total number of orders</i> | x_{15} | [1, <i>total perfect orders</i>] |
| <i>Perfect order fulfillment</i> | y_3 | [0,1] |

Fonte: Autoria própria (2021)

Não foi possível fazer a aproximação de função para o Modelo 3 (*total perfect orders*), que é detalhado no Quadro 5 por nenhum algoritmo testado neste trabalho.

O que foi feito para conseguir uma aproximação de função adequada no caso do Modelo 3, foi fixar a variável *total number of orders* em 100 unidades. E, portanto, deixar apenas a variável *total perfect order*, variando aleatoriamente entre os valores de 1 a 100, na forma do Quadro 4.

Isso se deve à natureza mais complexa da função de modelagem. A amostragem aleatória para este modelo de rede é feita por uma fração, cujo numerador é uma função composta. A função interna do numerador é presente também no denominador, da forma

$$f(x) = \frac{h(g(x))}{g(x)}, \quad (28)$$

como detalhado pelo Quadro 5.

4 RESULTADOS

Com o propósito de avaliar as configurações topológicas e os algoritmos de aprendizagem, foi feito o processo de validação cruzada baseado em amostragem aleatória por meio das seguintes etapas (SILVA et al., 2010; LIMA JR. & CARPINETTI, 2019):

1. Divisão aleatória das amostras em subconjunto de treinamento e de validação; definição dos parâmetros das topologias candidatas (número de neurônios na camada intermediária e tipo de função de ativação);
2. Definição das topologias de rede de treinamento;
3. Execução do processo de treinamento supervisionado;
4. Validação do modelo com base no cálculo de uma medida de erro baseada na diferença entre os valores preditos pela rede e os valores de saída do subconjunto de validação;

4.1 Definição das amostras para treinamento e testes dos modelos

A quantidade de amostras de treinamento foi definida com base em testes computacionais e no estudo de Lima Junior e Carpinetti (2019). Como mostra o Quadro 6, 500 amostras foram geradas para cada Modelo. 70% das amostras foram utilizadas para o treinamento e 30% para validação das redes. Cada amostra é um vetor com as variáveis de entrada e a variável de saída, que é calculada através da fórmula dada pelo SCOR®. Para todos os indicadores foi utilizada a função de distribuição de probabilidade uniforme, na qual todos os valores de imagem que estão presentes na função possuem a mesma chance de serem obtidos. Assim a rede irá criar uma aproximação numérica da função, como ilustrado no esquema da Figura 9. A partir dos resultados do estudo anterior (LUNARDI & LIMA JR, 2021), considerou-se como satisfatório o número de épocas para cada treinamento de 4000 nas redes PMC, e essa quantidade foi utilizada em todos os treinamentos das RNAs. Em todos os testes realizados para as redes PMC. A literatura diverge na quantidade de épocas que se considera satisfatória para ANFIS. Akkoç (2012) argumenta que 500 épocas é uma quantidade satisfatória. Para Lima Jr. e Carpinetti 30 épocas geraram um resultado já estabilizado. Considerando que havia uma baixa quantidade de topologias que não atingiram um valor de erro estabilizado até 30 épocas, optou-se por utilizar para as topologias ANFIS deste trabalho o número de épocas igual a 50.

Quadro 6 – Quantidade de amostras dos subconjuntos de treinamento e validação

| Modelo | Número total de amostras | Tamanho do subconjunto de treinamento | Tamanho do subconjunto de validação |
|---------------|---------------------------------|--|--|
| 1 | 500 | 350 | 150 |
| 2 | 500 | 350 | 150 |
| 3 | 500 | 350 | 150 |
| 4 | 500 | 350 | 150 |

Fonte: Autoria própria (2020)

A acurácia dos modelos implementados foi medida por meio do EQM (calculado durante a etapa de validação), entre os valores preditos pela rede e os que foram calculados no Excel[®] pela respectiva equação para cada métrica de nível 1.

Para cada rede foram feitos 3 treinamentos e 3 testes, de modo que os valores de erro das redes apresentados neste estudo representam uma média entre os resultados de EQM. Isso foi feito para contemplar as variações de resultados inerentes ao processo, levando em conta a natureza em até certo ponto aleatória do processo. No caso das ANFIS, o MATLAB[®] fornece o REQM (raiz do erro quadrático médio). Para comparação e padronização foram convertidos todos os valores de erro para EQM.

Em relação aos modelos PMC, cada um dos três modelos apresentados foi testado com os cinco algoritmos já discutidos no estudo (GDM, BFGS, LM, SCG e RP). As topologias foram montadas com quantidades variadas de neurônios nas camadas intermediárias, de modo a poder avaliar e comparar os resultados. A função de ativação utilizada é a de tangente hiperbólica, que foi determinada como melhor opção pelo estudo de Lima Jr, e Carpinetti (2019).

O critério de escolha da função de ativação foi a de qual delas apresentava resultados mais acurados. Para as ANFIS, variaram-se a função de pertinência, o operador dos conectivos lógicos e a regra de inferência. Optou-se por testar topologias ANFIS sem variar o algoritmo de treinamento, para seguir o modelo proposto por Jang (1993). Além disso, o MATLAB[®] não apresenta uma riqueza de variedade de algoritmos pra ANFIS como no caso das RNAs. Além do mais, os parâmetros utilizados são eficazes em criar variedades bastante distintas na acurácia das topologias para os indicadores aqui estudados.

4.2 Resultados das redes PMC

O Quadro 7 lista todas as topologias das redes PMC usadas para os três modelos de rede. Foram feitos três testes que variam em cinco unidades a quantidade de neurônios para cada algoritmo de treinamento. As quantidades de neurônios para as topologias com menos deles foi de 1 a 5, a depender do caso, como mostrado no Quadro 7. O Quadro 7 trata de todos os cinco algoritmos GDM, LM, BFGS, RP e SCG.

Quadro 7 – Topologias das redes PMC e suas configurações

| Modelo PMC e quantidade de variáveis de entrada (<i>n</i>) | Numeração da topologia | Neurônios na camada intermediária | Algoritmo de treinamento |
|--|------------------------|-----------------------------------|--------------------------|
| 1 – <i>Total cost to serve</i> (<i>n</i> =8) | 1 | 2 | GDM |
| | 2 | 7 | GDM |
| | 3 | 12 | GDM |
| | 4 | 3 | LM |
| | 5 | 8 | LM |
| | 6 | 13 | LM |
| | 7 | 1 | BFGS |
| | 8 | 6 | BFGS |
| | 9 | 11 | BFGS |
| | 10 | 2 | RP |
| | 11 | 7 | RP |
| | 12 | 12 | RP |
| | 13 | 3 | SCG |
| | 14 | 8 | SCG |
| | 15 | 13 | SCG |
| 2 – <i>Value at risk</i> (<i>n</i> =5) | 16 | 4 | GDM |
| | 17 | 9 | GDM |
| | 18 | 14 | GDM |
| | 19 | 5 | LM |
| | 20 | 10 | LM |
| | 21 | 15 | LM |
| | 22 | 4 | BFGS |
| | 23 | 9 | BFGS |
| | 24 | 14 | BFGS |
| | 25 | 5 | RP |
| | 26 | 10 | RP |
| | 27 | 15 | RP |
| | 28 | 6 | SCG |
| | 29 | 11 | SCG |
| | 30 | 16 | SCG |
| 3 – <i>Perfect order fulfillment</i> (<i>n</i> =2) | 31 | 6 | GDM |
| | 32 | 11 | GDM |
| | 33 | 16 | GDM |
| | 34 | 2 | LM |
| | 35 | 7 | LM |
| | 36 | 12 | LM |
| | 37 | 1 | BFGS |
| | 38 | 6 | BFGS |
| | 39 | 11 | BFGS |
| | 40 | 2 | RP |
| | 41 | 7 | RP |
| | 42 | 12 | RP |
| | 43 | 3 | SCG |
| | 44 | 8 | SCG |
| | 45 | 13 | SCG |
| | 46 | 4 | SCG |

Fonte: Autoria própria (2022)

A Tabela 2 diz respeito, de maneira análoga ao Quadro 7, aos resultados de EQM dos treinamentos e de R na etapa de validação. R é obtido a partir de 1 menos o erro da etapa de validação. As topologias seguem a mesma numeração em ambas as tabelas. O número de

variáveis de entrada do modelo se encontra após o nome do indicador, representado pela letra n, na primeira coluna da tabela.

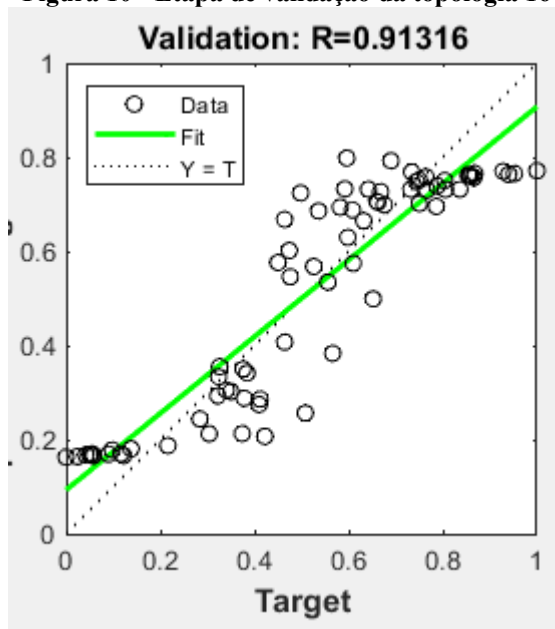
Tabela 2 – EQM e índice de correlação R para os modelos de rede PMC

| Modelo | Numeração da topologia PMC | EQM | R (validação) |
|--------------------------------------|-------------------------------|------------------------|---------------|
| 1 – <i>Total cost to serve</i> | 1 | $1,23 \times 10^{-2}$ | 0,90520 |
| | 2 | $2,50 \times 10^{-3}$ | 0,97850 |
| | 3 | $2,08 \times 10^{-3}$ | 0,98130 |
| | 4 | $8,27 \times 10^{-6}$ | 0,99994 |
| | 5 | $6,39 \times 10^{-6}$ | 0,99999 |
| | 6 | $2,80 \times 10^{-6}$ | 0,99998 |
| | 7 | $1,81 \times 10^{-3}$ | 0,99982 |
| | 8 | $2,49 \times 10^{-8}$ | 1 |
| | 9 | $1,78 \times 10^{-9}$ | 1 |
| | 10 | $8,37 \times 10^{-5}$ | 0,99927 |
| | 11 | $1,10 \times 10^{-6}$ | 0,99999 |
| | 12 | $2,12 \times 10^{-6}$ | 0,99998 |
| | 13 | $7,11 \times 10^{-5}$ | 0,99945 |
| | 14 | $1,57 \times 10^{-6}$ | 0,99999 |
| 2 – <i>Value at risk</i> | 15 | $7,91 \times 10^{-6}$ | 0,99993 |
| | 16 | $1,20 \times 10^{-2}$ | 0,91316 |
| | 17 | $8,35 \times 10^{-3}$ | 0,93354 |
| | 18 | $8,64 \times 10^{-3}$ | 0,96584 |
| | 19 | $9,81 \times 10^{-3}$ | 0,92542 |
| | 20 | $1,87 \times 10^{-6}$ | 0,99999 |
| | 21 | $6,18 \times 10^{-10}$ | 1 |
| | 22 | $6,32 \times 10^{-4}$ | 0,99536 |
| | 23 | $2,18 \times 10^{-5}$ | 0,99983 |
| | 24 | $3,20 \times 10^{-5}$ | 0,99984 |
| | 25 | $4,92 \times 10^{-5}$ | 0,99975 |
| | 26 | $1,98 \times 10^{-5}$ | 0,99984 |
| | 27 | $1,90 \times 10^{-5}$ | 0,99992 |
| | 28 | $1,93 \times 10^{-6}$ | 0,99998 |
| | 29 | $1,41 \times 10^{-6}$ | 0,99999 |
| | 30 | $3,16 \times 10^{-6}$ | 0,99998 |
| 3 – <i>Perfect order fulfillment</i> | 31 | $3,34 \times 10^{-6}$ | 0,98339 |
| | 32 | $5,07 \times 10^{-4}$ | 0,99788 |
| | 33 | $3,28 \times 10^{-3}$ | 0,98439 |
| | 34 | $9,75 \times 10^{-5}$ | 0,99943 |
| | 35 | $1,41 \times 10^{-8}$ | 1 |
| | 36 | $3,13 \times 10^{-8}$ | 1 |
| | 37 | $1,31 \times 10^{-3}$ | 0,99450 |
| | 38 | $6,51 \times 10^{-7}$ | 1 |
| | 39 | $3,28 \times 10^{-8}$ | 1 |
| | 40 | $1,99 \times 10^{-4}$ | 0,99873 |
| | 41 | $2,64 \times 10^{-6}$ | 0,99998 |
| | 42 | $5,91 \times 10^{-6}$ | 0,99996 |
| | 43 | $1,20 \times 10^{-5}$ | 0,99994 |
| | 44 | $1,60 \times 10^{-6}$ | 0,99999 |
| | 45 | $6,48 \times 10^{-6}$ | 0,99996 |

Fonte: Autoria própria (2022)

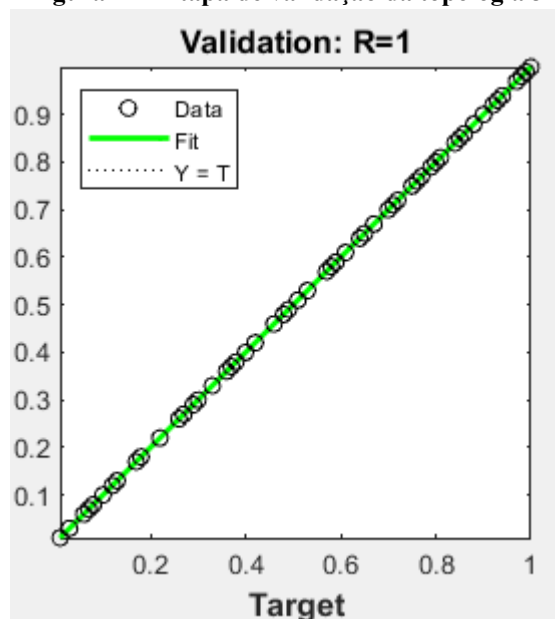
As Figuras 10 e 11 que são dispostos a seguir correlacionam os resultados obtidos pelas redes PMC com os valores esperados. Os valores esperados foram calculados através das fórmulas fornecidas pelo SCOR[®]. Como as saídas foram normalizadas, os resultados esperados do eixo Y variam de 0 a 1. Essa visualização permite que se tenha uma noção sobre o grau de dispersão dos resultados.

Figura 10 - Etapa de validação da topologia 16



Fonte: Autoria própria (2022)

Figura 11 - Etapa de validação da topologia 3



Fonte: Autoria própria (2022)

A etapa de validação usa, como explicitado no Quadro 6, 150 amostras para testagem (30% do total), que não foram utilizadas para o treinamento das redes.

São traçadas uma linha pontilhada preta e uma linha contínua verde. A pontilhada é a reta de valor médio dos resultados esperados, e a verde dos calculados pela rede.

Como a topologia de número 3 teve uma acurácia consideravelmente maior do que a 16, é visível que os resultados se alinham com os valores de 0 até 1, os quais foram obtidos pelos cálculos das fórmulas e posterior normalização.

4.3 Resultados dos modelos ANFIS

O Quadro 8 classifica as topologias ANFIS por numeração de cada topologia de acordo com suas configurações de tipo de função de pertinência, operador dos conectivos lógicos e regra de inferência. As topologias utilizadas para cada um dos três modelos são divididas por três tipos de função de pertinência: triangular, gaussiana e sigmoideal. Para cada uma das funções de pertinência há dois operadores t-norma (conectivos lógicos): mínimo e produto. Por sua vez, cada operador é utilizado para duas regras de inferência: Função linear e função constante. A enumeração da topologia ANFIS tem início dando continuidade à das redes PMC, começando com o número 46.

Quadro 8 – Topologias ANFIS e suas configurações

| Modelo ANFIS e número de variáveis de entrada (n) | Numeração da topologia | Função de pertinência | Operador t-norma (conectivos lógicos) | Regra de inferência |
|---|------------------------|-----------------------|---------------------------------------|---------------------|
| 1 – <i>Total cost to serve</i> (n=8) | 46 | Triangular | Mínimo | Função linear |
| | 47 | | | Constante |
| | 48 | | Produto | Função linear |
| | 49 | | | Constante |
| | 50 | Gaussiana | Mínimo | Função linear |
| | 51 | | | Constante |
| | 52 | | Produto | Função linear |
| | 53 | | | Constante |
| | 54 | Sigmoidal | Mínimo | Função linear |
| | 55 | | | Constante |
| | 56 | | Produto | Função linear |
| | 57 | | | Constante |
| 2 – <i>Value at risk</i> (n=5) | 58 | Triangular | Mínimo | Função linear |
| | 59 | | | Constante |
| | 60 | | Produto | Função linear |
| | 61 | | | Constante |
| | 62 | Gaussiana | Mínimo | Função linear |
| | 63 | | | Constante |
| | 64 | | Produto | Função linear |
| | 65 | | | Constante |
| | 66 | Sigmoidal | Mínimo | Função linear |
| | 67 | | | Constante |
| | 68 | | Produto | Função linear |
| | 69 | | | Constante |
| 3 – <i>Perfect order fulfillment</i> (n=2) | 70 | Triangular | Mínimo | Função linear |
| | 71 | | | Constante |
| | 72 | | Produto | Função linear |
| | 73 | | | Constante |
| | 74 | Gaussiana | Mínimo | Função linear |
| | 75 | | | Constante |
| | 76 | | Produto | Função linear |
| | 77 | | | Constante |
| | 78 | Sigmoidal | Mínimo | Função linear |
| | 79 | | | Constante |
| | 80 | | Produto | Função linear |
| | 81 | | | Constante |

Fonte: Autoria própria (2022)

A Tabela 3 mostra os resultados de EQM e R (etapa de validação) obtidos em cada topologia ANFIS, como apresentadas pelo Quadro 8.

Tabela 3 – EQM e índice de correlação R para os modelos de rede ANFIS

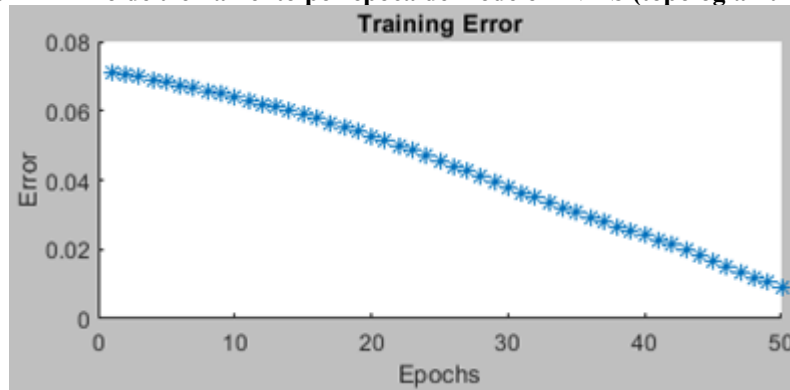
| Modelo | Numeração da topologia | EQM de treinamento | R (validação) |
|--------------------------------------|-------------------------------|---------------------------|----------------------|
| 1 – <i>Total cost to serve</i> | 46 | $1,64 \times 10^{-14}$ | 0,99999 |
| | 47 | $3,03 \times 10^{-9}$ | 1,00000 |
| | 48 | $2,39 \times 10^{-15}$ | 0,99992 |
| | 49 | $8,60 \times 10^{-4}$ | 0,99914 |
| | 50 | $1,38 \times 10^{-13}$ | 0,99990 |
| | 51 | $2,69 \times 10^{-6}$ | 0,99993 |
| | 52 | $1,38 \times 10^{-13}$ | 0,99990 |
| | 53 | $2,38 \times 10^{-13}$ | 0,99989 |
| | 54 | $2,96 \times 10^{-6}$ | 0,99993 |
| | 55 | $4,76 \times 10^{-6}$ | 0,98563 |
| 2 – <i>Value at risk</i> | 56 | $7,39 \times 10^{-14}$ | 0,99987 |
| | 57 | $1,29 \times 10^{-7}$ | 0,99850 |
| | 58 | $4,51 \times 10^{-11}$ | 0,99674 |
| | 59 | $3,87 \times 10^{-10}$ | 0,99907 |
| | 60 | $1,78 \times 10^{-17}$ | 1,00000 |
| | 61 | $3,87 \times 10^{-10}$ | 0,99707 |
| | 62 | $3,23 \times 10^{-9}$ | 0,99990 |
| | 63 | $2,12 \times 10^{-5}$ | 0,98607 |
| | 64 | $4,40 \times 10^{-11}$ | 0,99610 |
| | 65 | $8,54 \times 10^{-8}$ | 0,99971 |
| 3 – <i>Perfect order fulfillment</i> | 66 | $1,44 \times 10^{-9}$ | 0,99245 |
| | 67 | $3,58 \times 10^{-4}$ | 0,13087 |
| | 68 | $4,21 \times 10^{-10}$ | 0,97836 |
| | 69 | $1,98 \times 10^{-5}$ | 0,91921 |
| | 70 | $6,45 \times 10^{-17}$ | 0,99834 |
| | 71 | $1,21 \times 10^{-15}$ | 0,99814 |
| | 72 | $6,45 \times 10^{-17}$ | 0,99834 |
| | 73 | $1,21 \times 10^{-15}$ | 0,99968 |
| | 74 | $4,90 \times 10^{-16}$ | 0,99868 |
| | 75 | $1,34 \times 10^{-6}$ | 0,99864 |
| | 76 | $4,19 \times 10^{-17}$ | 0,99833 |
| | 77 | $1,97 \times 10^{-18}$ | 0,99916 |
| | 78 | $1,49 \times 10^{-15}$ | 0,99799 |
| | 79 | $2,25 \times 10^{-3}$ | 0,99849 |
| | 80 | $1,49 \times 10^{-15}$ | 0,99800 |
| | 81 | $8,16 \times 10^{-5}$ | 0,99826 |

Fonte: Autoria própria (2022)

As Figuras 12 e 13 mostram *screen shots* da *toolbox* do MATLAB® *Neuro Fuzzy Designer*, para a topologia de número 81 e 54, respectivamente. O eixo x trata do número de épocas do treinamento e o eixo y do valor do erro em escala.

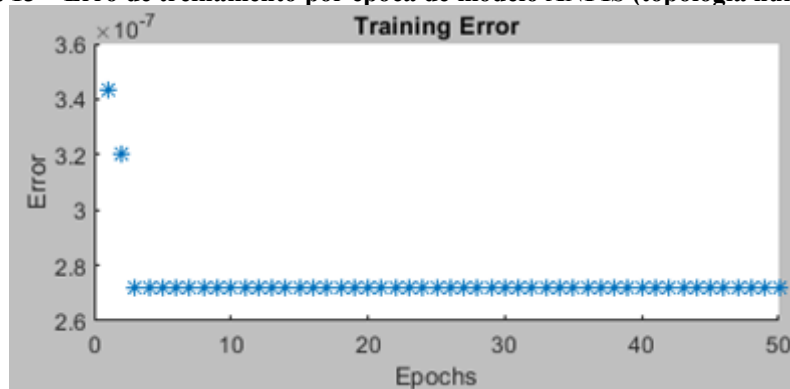
Para os casos de EQMs mais altos, ocorreu uma descendência perceptível em todas as épocas, como mostrado da Figura 12. Na maioria dos casos o EQM foi decrescente nas primeiras épocas e logo atingiu um ponto de descendência muito pequena, tornando-se aproximadamente constante, como no caso da Figura 13.

Figura 12 – Erro de treinamento por época de modelo ANFIS (topologia número 81)



Fonte: Autoria própria (2022)

Figura 13 – Erro de treinamento por época de modelo ANFIS (topologia número 54)



Fonte: Autoria própria (2022)

4.4 Análise estatística

Os testes foram conduzidos utilizando o teste t pareado, que é adequado quando as observações nas duas populações de interesse são coletadas em pares. Sendo a média da população 1 representada por μ_1 e a média da população 2 dada por μ_2 , tomando as diferenças entre cada par de observações como $D_j = X_j - Y_j$, tal que $j = 1, 2, \dots, n$, o procedimento do teste t pareado consiste em analisar se a média das diferenças (μ_D) entre duas populações equivale a um valor especificado Δ_0 . Se não houver diferença significativa entre as duas populações, então a média das diferenças deve ser zero ($\mu_D = \Delta_0 = 0$). Portanto, conforme mostra o Quadro 5, para

um teste com nível de significância α , a hipótese nula será dada por $H_0: \mu_D = 0$. A hipótese alternativa é representada por $H_1: \mu_D \neq 0$. Na estatística de teste T_0 , o parâmetro μ_D é estimado pela média amostral das diferenças (\bar{D}). Para testar o critério de rejeição, utiliza-se o valor tabelado $t_{\alpha/2, n-1}$ (Montgomery & Runger, 2009). Em todos os testes, foi adotado o nível de significância $\alpha = 0,05$.

Quadro 5 – Hipóteses analisadas, estatística de teste e critério de rejeição da hipótese nula

| |
|--|
| Hipótese nula $H_0: \mu_D = \Delta_0$ |
| Hipótese alternativa $H_1: \mu_D \neq \Delta_0$ |
| Região de rejeição: $t_0 > t_{\alpha/2, n-1}$ ou $t_0 < t_{\alpha/2, n-1}$ |
| Estatística teste: $T_0 = \frac{\bar{D} - \Delta_0}{S_D / \sqrt{n}}$, sendo $S_D = \sqrt{\frac{\sum_{i=1}^n (D_i - \bar{D})^2}{n-1}}$ |

Fonte: Montgomery & Runger (2009)

A Tabela 4 apresenta os resultados dos testes de hipótese para os modelos PMC e ANFIS. Nessa tabela, \bar{D} é a média da distribuição das diferenças e S_D é o desvio padrão. Além disso, todos os valores de T_0 estão fora da região de rejeição da hipótese nula, sendo maiores em módulo que 2,04523. Esses resultados mostram que a hipótese nula não pode ser rejeitada, o que indica que não há diferença significativa entre os valores esperados e os valores preditos para cada métrica de nível 1. Portanto, ratificam que as redes PMC e ANFIS são adequadas e bastante eficazes para apoiar a avaliação de desempenho de cadeia de suprimentos baseada nas métricas de nível 1 do SCOR[®].

Tabela 4 – Resultados dos testes de hipótese para os modelos PMC e ANFIS

| Modelo | Indicador do SCOR [®] | Topologia | \bar{D} | S_D | T_0 | $t_{\alpha/2, n-1}$ |
|---------|--------------------------------|-----------|---------------------------|--------------------------|--------|---------------------|
| PMC 1 | TCS | 11 | $-1.681000 \cdot 10^{-4}$ | $2.94517 \cdot 10^{-5}$ | -31.26 | 2,04523 |
| PMC 2 | VR | 25 | $1,11141 \cdot 10^{-4}$ | $2.70983 \cdot 10^{-5}$ | 225.19 | 2,04523 |
| PMC 3 | POF | 34 | $-2,206033 \cdot 10^{-3}$ | $1.21516 \cdot 10^{-6}$ | 99.43 | 2,04523 |
| ANFIS 1 | TCS | 47 | $1.27487 \cdot 10^{-5}$ | $6.01766 \cdot 10^{-7}$ | 116,04 | 2,04523 |
| ANFIS 2 | VR | 58 | $-3.65966 \cdot 10^{-7}$ | $-2.60483 \cdot 10^{-7}$ | 7.69 | 2,04523 |
| ANFIS 3 | POF | 71 | $-6.42999 \cdot 10^{-8}$ | $6.56206 \cdot 10^{-9}$ | -53,67 | 2,04523 |

Fonte: Autoria própria (2022)

A Tabela 5 apresenta o coeficiente de correlação de Pearson para as topologias escolhidas, de forma análoga à Tabela 4. Classificando as topologias por Modelo, indicador avaliado e numeração.

Tabela 5 – Coeficiente de correlação de Pearson

| Modelo | Indicador do SCOR [®] | Numeração da topologia | Coeficiente de correlação de Pearson |
|---------|--------------------------------|------------------------|--------------------------------------|
| PMC 1 | TCS | 11 | 0.999465964730258 |
| PMC 2 | VR | 25 | 0.999626036304079 |
| PMC 3 | POF | 34 | 0,999549378999856 |
| ANFIS 1 | TCS | 47 | 0,999999982475609 |
| ANFIS 2 | VR | 58 | 0,99999999857774 |
| ANFIS 3 | POF | 71 | 0,99999999998543 |

Fonte: Autoria própria (2022)

Como o esperado, os coeficientes de correlação de Pearson seguem a tendência dos testes t pareados. Os modelos têm a ordem crescente de correlação, conforme menor é o desvio padrão mostrado na Tabela 4. Em outras palavras, ranqueando-se os modelos pelo critério de o quão o coeficiente de correlação de Pearson está próximo de 1, há a mesma ordem de ranqueamento do quão pequeno é a variância dos testes t pareados.

5 CONCLUSÕES

Foi possível verificar nas redes PMC que para os algoritmos utilizados de um modo geral, as redes com mais neurônios dos trios obtiveram melhores resultados. Porém, quando se compara a diferença de precisão entre a topologia com menos neurônios para a intermediária com a diferença entre a intermediária e a de mais neurônios, percebe-se que no primeiro caso há um salto de precisão muito maior. Em vários casos, no passo da rede com quantidade intermediária de neurônios para a de maior quantidade, houve uma leve diminuição da precisão. Isso se deve ao fato das redes PMC estarem, para as topologias com maior quantidade de neurônios, próximos da otimização de tal parâmetro.

O desempenho alcançado pelos algoritmos de treinamento das redes PMC em ordem crescente de acurácia equivale a GDM, RP, SCG, BFGS e LM. Embora o erro da etapa de treinamento do algoritmo LM seja consideravelmente maior do que o BFGS, quando são analisados os erros da etapa de validação, que é a que interessa para a aproximação de função, a comparação leva a uma vantagem ligeiramente maior do LM, consagrando-se como o melhor algoritmo de treinamento para aproximações de funções do tipo analisado por este estudo.

Para as redes ANFIS, notou-se que as regras de inferência feitas com funções lineares têm sempre desempenho melhor do que as de funções constantes, tratando-se da acurácia de aproximação. Operador t-norma produto possui desempenho melhor do que o operador mínimo em todos os casos. As combinações entre o operador mínimo e a função constante trouxe os resultados mais baixos observados para a grande maioria dos casos, em oposição a combinações de operador produto com função linear, que teve os mais altos. A função de pertinência triangular foi a que obteve majoritariamente os desempenhos mais baixos e a sigmoideal atingiu de forma global os resultados intermediários. Por fim, os melhores resultados, de forma geral, foram atingidos pela função gaussiana.

Comparativamente, os comportamentos de treinamento das funções ANFIS e redes PMC foram bastante diferentes. As redes PMC, na grande maioria dos casos, possuem uma minimização do erro que se desacelera aos poucos. Já no caso das ANFIS há uma abrupta minimização do erro no início, e posteriormente, torna-se praticamente nula para as topologias de acurácia mediana ou alta que foram testadas. Nos casos de desempenho menor, as ANFIS possuem um caimento quase que constante, com gráfico do erro próximo a uma linha reta, nos gráficos de magnitude de erro por número de época. De um modo geral, os modelos ANFIS possuem desempenho muito mais acurado que as redes PMC. Fato que pode ser observado também pela pelos testes de hipótese t pareados, e pelo coeficiente de correlação de Pearson,

que foi mais próximo de 1 para as redes ANFIS, cujo desempenho de erro na etapa de validação foi muito menor. De acordo com os testes estatísticos, todas as topologias escolhidas estão fora da região de rejeição, para um valor $\alpha = 0,05$, sendo aprovadas.

Entretanto, caso fossem realizados testes que realizassem um número muito maior de épocas, as redes PMC seriam capazes de atingir EQMs mais acurados. Como pode-se observar no estudo anterior (LUNARDI & LIMA JR, 2021), em que se realizaram 20000 épocas de treinamento para cada rede PMC, constatou-se que a minimização do erro sempre é considerável com o passar das épocas. É preciso, porém, salientar que esse processo de minimização pode ser extremamente lento.

Para as amostras modeladas inicialmente para o Modelo 3, que não puderam ser aproximadas, é possível que RNAs com maiores quantidades de camadas intermediárias, ou ANFIS com outros algoritmos de treinamento, sejam mais adequadas para aproximar esse tipo de função. Fato que pode ser testado por algum futuro estudo de comportamento das RNAs ou ANFIS. Após a remodelagem do indicador, foi obtida uma função que pode ser modelada mais facilmente pelas redes.

As técnicas computacionais de RNAs e ANFIS são ferramentas poderosas para aproximação de função e possuem capacidade de ser aplicadas a áreas do conhecimento de gestão. Embora não seja usual, já no presente há aplicações que auxiliam os gestores a tomar decisões com ferramentas de IA. Porém, há ainda um vasto campo a ser explorado, considerando a versatilidade desses métodos. Espera-se que o trabalho colabore com a disseminação das técnicas aqui abordadas no universo da teoria de gestão, para a modernização e desenvolvimento das cadeias de suprimentos.

REFERÊNCIAS

- ABDI-KHANGHAH, Mahdi et al. Prediction of solubility of N-alkanes in supercritical CO₂ using RBF-ANN and MLP-ANN. **Journal of CO₂ Utilization**, v. 25, p. 108-119, 2018.
- AGAMI, Nedaa; SALEH, Mohamed; RASMY, Mohamed. An innovative fuzzy logic based approach for supply chain performance management. **IEEE Systems Journal**, v. 8, n. 2, p. 336-342, 2012.
- AHI, Payman; SEARCY, Cory. Assessing sustainability in the supply chain: A triple bottom line approach. **Applied Mathematical Modelling**, v. 39, n. 10-11, p. 2882-2896, 2015.
- AKKAWUTTIWANICH, Piyanee; YENRADEE, Pisal. Fuzzy QFD approach for managing SCOR performance indicators. **Computers & Industrial Engineering**, v. 122, p. 189-201, 2018.
- AKKOÇ, S. An empirical comparison of conventional techniques, neural networks and the three stage hybrid Adaptive Neuro Fuzzy Inference System (ANFIS) model for credit scoring analysis: The case of Turkish credit card data. **European Journal of Operational Research**, v. 222, n. 1, p. 168-178, 2012.
- AWADALLAH, Mohamed A.; BAYOUMI, Ehab HE; SOLIMAN, Hisham M. Adaptive deadbeat controllers for brushless DC drives using PSO and ANFIS techniques. **Journal of Electrical Engineering**, v. 60, n. 1, p. 3-11, 2009.
- BEG, Ismat; RASHID, Tabasam. TOPSIS for hesitant fuzzy linguistic term sets. **International Journal of Intelligent Systems**, v. 28, n. 12, p. 1162-1171, 2013.
- BENESTY, Jacob; CHEN, Jingdong; HUANG, Yiteng. On the importance of the Pearson correlation coefficient in noise reduction. **IEEE Transactions on Audio, Speech, and Language Processing**, v. 16, n. 4, p. 757-765, 2008.
- BERTRAND, J. Will M.; FRANSOO, Jan C. Operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, 2002.
- BILGEHAN, Mahmut. Comparison of ANFIS and NN models—With a study in critical buckling load estimation. **Applied Soft Computing**, v. 11, n. 4, p. 3779-3791, 2011.
- BUKHORI, Ikhsan Bani; WIDODO, Kuncoro Harto; ISMOYOWATI, Dyah. Evaluation of poultry supply chain performance in XYZ slaughtering house Yogyakarta using SCOR and AHP Method. **Agriculture and Agricultural Science Procedia**, v. 3, p. 221-225, 2015.
- CHAUHAN, Rishika et al. Experimental and theoretical evaluation of thermophysical properties for moist air within solar still by using different algorithms of artificial neural network. **Journal of Energy Storage**, v. 30, p. 101408, 2020.
- CHEN, Chen-Tung. Extensions of the TOPSIS for group decision-making under fuzzy environment. **Fuzzy sets and systems**, v. 114, n. 1, p. 1-9, 2000.
- CLIVILLÉ, Vincent; BERRAH, Lamia. Overall performance measurement in a supply chain: towards a supplier-prime manufacturer based model. **Journal of Intelligent Manufacturing**, v. 23, n. 6, p. 2459-2469, 2012.
- COUNCIL, Supply Chain. Inc., Supply Chain Operations Reference Model. Revision 11.0. Supply Chain Council. 2012.
- CUTHBERTSON, Richard; PIOTROWICZ, Wojciech. Performance measurement systems in supply chains. **International Journal of Productivity and Performance Management**, 2011.
- DA SILVA, Ivan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. Redes Neurais Artificiais para engenharia e ciências aplicadas curso prático. **São Paulo: Artliber**, 2010.

DISSANAYAKE, C. Kalpani; CROSS, Jennifer A. Systematic mechanism for identifying the relative impact of supply chain performance areas on the overall supply chain performance using SCOR model and SEM. **International Journal of Production Economics**, v. 201, p. 102-115, 2018.

ESTAMPE, Dominique et al. A framework for analysing supply chain performance evaluation models. **International Journal of Production Economics**, v. 142, n. 2, p. 247-258, 2013.

FAN, Xuemei et al. An evaluation model of supply chain performances using 5DBSC and LMBP neural network algorithm. **Journal of Bionic Engineering**, v. 10, n. 3, p. 383-395, 2013.

FUZZY. In: **DICTIONARY**, Cambridge. Cambridge advanced learner's dictionary. **Disponível em:** <https://dictionary.cambridge.org/pt/dicionario/ingles-portugues/fuzzy>. Acesso em: 02/01/2021.

GANGA, Gilberto Miller Devós; CARPINETTI, Luiz Cesar Ribeiro; POLITANO, Paulo Rogério. A fuzzy logic approach to supply chain performance management. **Gestão & produção**, v. 18, n. 4, p. 755-774, 2011.

GOLPARVAR, Maziyar; SEIFBARGHY, Mehdi. Application of SCOR Model in an Oil-producing Company. 2009.

GUNASEKARAN, Angappa; PATEL, Chaitali; TIRTIROGLU, Ercan. Performance measures and metrics in a supply chain environment. **International journal of operations & production Management**, 2001.

GUNASEKARAN, Angappa; PATEL, Christopher; MCGAUGHEY, Ronald E. A framework for supply chain performance measurement. **International journal of production economics**, v. 87, n. 3, p. 333-347, 2004.

JALALVAND, F. et al. A method to compare supply chains of an industry. **Supply Chain Management: An International Journal**, 2011.

JANG, J-S. R. ANFIS: adaptive-network-based fuzzy inference system. **IEEE Transactions on Systems**, v.23, n.3, p.665-685, 1993.

KAR, Samarjit; DAS, Sujit; GHOSH, Pijush Kanti. Applications of neuro fuzzy systems: A brief review and future outline. **Applied Soft Computing**, v. 15, p. 243-259, 2014.

KOCAOĞLU, Batuhan; GÜLSÜN, Bahadır; TANYAŞ, Mehmet. A SCOR based approach for measuring a benchmarkable supply chain performance. **Journal of Intelligent Manufacturing**, v. 24, n. 1, p. 113-132, 2013.

KURTGOZ, Yusuf; KARAGOZ, Mustafa; DENIZ, Emrah. Biogas engine performance estimation using ANN. **Engineering science and technology, an international journal**, v. 20, n. 6, p. 1563-1570, 2017.

LIMA-JUNIOR, Francisco Rodrigues; CARPINETTI, Luiz Cesar Ribeiro. Quantitative models for supply chain performance evaluation: a literature review. **Computers & Industrial Engineering**, v. 113, p. 333-346, 2017.

LIMA-JUNIOR, Francisco Rodrigues; CARPINETTI, Luiz Cesar Ribeiro. Predicting supply chain performance based on SCOR® metrics and multilayer perceptron neural networks. **International Journal of Production Economics**, v. 212, p. 19-38, 2019.

LIU, Fuh-hwa Franklin; LIU, Yu-cheng. A methodology to assess the supply chain performance based on gap-based measures. **Computers & Industrial Engineering**, v. 110, p. 550-559, 2017.

LIU, Puyin; LI, Hong-Xing. Fuzzy neural network theory and application. **World Scientific**, 2004.

LUNARDI, Antonio Ricardo; LIMA JUNIOR, Francisco Rodrigues. Comparação entre métodos de aprendizagem de redes neurais artificiais aplicados à avaliação de desempenho de cadeias de suprimentos. **Gestão & Produção**, v. 28, n. 3, 2021.

LUNARDI, Antonio Ricardo; LIMA JUNIOR, Francisco Rodrigues. Comparação entre métodos de aprendizagem de redes neurais artificiais aplicados à avaliação de desempenho de cadeias de suprimentos. *In: ENEGEP*, Santos: 16 de outubro, 2019.

MAESTRINI, Vieri et al. Supply chain performance measurement systems: A systematic review and research agenda. **International Journal of Production Economics**, v. 183, p. 299-315, 2017.

MARCHAND, Marie; RAYMOND, Louis. Researching performance measurement systems. **International Journal of Operations & Production Management**, 2008.

Mathworks. Site de suporte do software MATLAB. Disponível em: <<http://www.mathworks.com/help/nnet/ref/traingd.html>>. Acesso em 20 de agosto de 2018.

MENTZER, John T.; SCHUSTER, Allan D. Computer modeling in logistics: Existing models and future outlook. **Journal of Business Logistics**, v. 3, n. 1, 1978.

MOHARAMKHANI, Arezoo; BOZORGI-AMIRI, Ali; MINA, Hassan. Supply chain performance measurement using SCOR model based on interval-valued fuzzy TOPSIS. **International Journal of Logistics Systems and Management**, v. 27, n. 1, p. 115-132, 2017.

MONTGOMERY, D. C.; RUNGER, G. C. Estatística aplicada e probabilidade para engenheiros. São Paulo: LTC, 2008. 476p. NOMURA, ES et al. Crescimento e produção de antúrio cultivado sob diferentes malhas de sombreamento. **Ciência Rural Santa Maria**, v. 39, n. 5, p. 1394-1400, 2009.

MUKHERJEE, Indrajit; ROUTHROY, Srikanta. Comparing the performance of neural networks developed by using Levenberg–Marquardt and Quasi-Newton with the gradient descent algorithm for modelling a multiple response grinding process. **Expert Systems with Applications**, v. 39, n. 3, p. 2397-2407, 2012.

NAINI, Seyed Gholamreza Jalali; ALIAHMADI, Ali Reza; JAFARI-ESKANDARI, Meisam. Designing a mixed performance measurement system for environmental supply chain management using evolutionary game theory and balanced scorecard: A case study of an auto industry supply chain. **Resources, conservation and recycling**, v. 55, n. 6, p. 593-603, 2011.

NHU, Hien Nguyen; NITSUWAT, Supot; SODANIL, Maleerat. Prediction of stock price using an adaptive Neuro-Fuzzy Inference System trained by Firefly Algorithm. In: **2013 International Computer Science and Engineering Conference (ICSEC)**. IEEE, 2013. p. 302-307.

NUDURUPATI*, Sai S.; BITITCI, Umit S. Implementation and impact of IT-supported performance measurement systems. **Production Planning & Control**, v. 16, n. 2, p. 152-162, 2005.

PATUWO, Eddy; HU, Michael Y.; HUNG, Ming S. Two-group classification using neural networks. **Decision Sciences**, v. 24, n. 4, p. 825-845, 1993.

PHIELIX, Esther; MENSINK, Marco. Type 2 diabetes mellitus and skeletal muscle metabolic function. **Physiology & behavior**, v. 94, n. 2, p. 252-258, 2008.

REZAEI, Mustafa Jahangoshai; JOZMALEKI, Mehrdad; VALIPOUR, Mahsa. Integrating dynamic fuzzy C-means, data envelopment analysis and artificial neural network to online prediction performance of companies in stock exchange. **Physica A: Statistical Mechanics and its Applications**, v. 489, p. 78-93, 2018.

RIEDMILLER, Martin; BRAUN, Heinrich. A direct adaptive method for faster backpropagation learning: The RPROP algorithm. In: **IEEE international conference on neural networks**. IEEE, 1993. p. 586-591.

RUNGER, George C. Estatística aplicada e probabilidade para engenheiros. **Editora LTC: Rio de Janeiro, Brazil**, 2009.

RUTKOWSKI, Leszek. FLEXIBLE NEURO-FUZZY SYSTEMS. Structures, Learning and Performance Evaluation. Czestochowa-Polonia. 2004.

SABRI, Naseer et al. Fuzzy inference system: Short review and design. **Int. Rev. Autom. Control**, v. 6, n. 4, p. 441-449, 2013.

SANTRA, Apurba Kumar; CHAKRABORTY, Niladri; SEN, Swarnendu. Prediction of heat transfer due to presence of copper–water nanofluid using resilient-propagation neural network. **International Journal of Thermal Sciences**, v. 48, n. 7, p. 1311-1318, 2009.

SELLITTO, Miguel Afonso et al. A SCOR-based model for supply chain performance measurement: application in the footwear industry. **International Journal of Production Research**, v. 53, n. 16, p. 4917-4926, 2015.

SHAFIEE, Morteza; LOTFI, Farhad Hosseinzadeh; SALEH, Hilda. Supply chain performance evaluation with data envelopment analysis and balanced scorecard approach. **Applied Mathematical Modelling**, v. 38, n. 21-22, p. 5092-5112, 2014.

TAKAGI, Tomohiro; SUGENO, Michio. Fuzzy identification of systems and its applications to modeling and control. **IEEE transactions on systems, man, and cybernetics**, n. 1, p. 116-132, 1985.

TAYLAN, Osman; KARAGÖZOĞLU, Bahattin. An adaptive neuro-fuzzy model for prediction of student's academic performance. **Computers & Industrial Engineering**, v. 57, n. 3, p. 732-741, 2009.

TKÁČ, Michal; VERNER, Robert. Artificial neural networks in business: Two decades of research. **Applied Soft Computing**, v. 38, p. 788-804, 2016.

TRIPATHY, P. P.; KUMAR, Subodh. Neural network approach for food temperature prediction during solar drying. **International journal of thermal sciences**, v. 48, n. 7, p. 1452-1459, 2009.

YANG, Jing; JIANG, Hua. Fuzzy Evaluation on Supply Chains' Overall Performance Based on AHM and M (1, 2, 3). **JSW**, v. 7, n. 12, p. 2779-2786, 2012.