

INTELIGÊNCIA ARTIFICIAL APLICADA A SISTEMAS ERP: UMA REVISÃO SISTEMÁTICA DA LITERATURA

[\[ver artigo online\]](#)

Leonardo Patrick Pereira Pinto¹

RESUMO

Essa pesquisa tem como objetivo identificar na literatura as principais aplicações de redes neurais artificiais (RNA) para gerenciamento de estoque. A abordagem dessa pesquisa considera principalmente modelos para aplicação em sistemas Enterprise Resource Planning (ERP). Foram considerados artigos que podem contribuir na pesquisa de desenvolvimento de modelos para sustentação da tomada de decisão das empresas. Para tanto, o método utilizado compreendeu usando três bases de dados: Scopus, CAPES e Scielo. No total, 8 artigos foram selecionados com base em critérios de inclusão de uma amostragem inicial de 213. A análise dos artigos selecionados permitiu identificar a principal arquitetura de rede neural utilizada para criação de modelos preditivos em sistemas ERP.

Palavras-chave: Arquitetura de redes neurais, redes neurais artificiais, planejamento de recursos empresariais.

ARTIFICIAL INTELLIGENCE APPLIED TO ERP SYSTEMS: A SYSTEMATIC LITERATURE

ABSTRACT

This research aims to identify in the literature the main applications of artificial neural networks (ANN) for inventory management. The approach of this research mainly considers models for application in Enterprise Resource Planning (ERP) systems. Articles that can contribute to research on the development of models to support the decision-making of companies were considered. Therefore, the method used comprised using three databases: Scopus, CAPES and Scielo. In total, 8 articles were selected based on inclusion criteria of an initial sample of 213. The analysis of selected articles allowed identifying the main neural network architecture used to create predictive models in ERP systems.

Keywords: Neural Network Architecture, Artificial Neural Networks, Enterprise Resource Planning.

¹ Mestrando em informática, UFES, Espírito Santo, Leonardo.p.pinto@edu.ufes.br.



1. INTRODUÇÃO

A inteligência Artificial pode otimizar a gestão do estoque, com a utilização de modelos computacionais para calcular diversas variáveis no contexto empresarial, aumentando a eficiência processual, através da aplicação de redes neurais artificiais com o objetivo de melhorar o tempo de resposta operacional e diminuindo o custo significativamente como resultado da melhor gestão do giro dos produtos. No que tange aprendizagem profunda, diversas soluções vêm sendo pesquisadas, novas abordagens estão sendo propostas, através da sua aplicação. Os modelos gerados a partir de algoritmos de aprendizagem de máquina são ótimos para analisar uma grande quantidade de dados, otimizando o processamento de informações. O Enterprise Resource Planning (ERP) é um sistema de gestão que permite acesso fácil e integrado, utilizado para ter uma visão completa dos recursos de uma empresa em termos de bens, inventário, gestão de estoque, gestão financeira, gestão de compra e venda. Por outro lado, as redes neurais artificiais estão se tornando uma necessidade em aplicações que requerem inteligência artificial por permitir novas perspectivas em várias áreas, inclusive para o gerenciamento da cadeia de suprimentos, permitindo o aprimoramento contínuo.

2. METODOLOGIA

Esta revisão sistemática da literatura (SLR) segue as diretrizes propostas por [Kitchenham and Charters 2007], apropriadas para área de engenharia de software, permitindo uma avaliação justa, rigorosa e auditável.

A revisão sistemática apresentada nesse artigo utiliza cinco etapas que permitiram a seleção de artigos sem viés, seguindo critérios definidos na primeira etapa de protocolo. A etapa denominada resultados brutos, consistiu em listar os artigos após a pesquisa nas bases de dados utilizando o conjunto de palavras chaves denominado “String” de busca, encontrada na Tabela 1.

Após a listagem dos artigos resultados da pesquisa das bases é aplicado o filtro 1 onde é analisado os critérios de inclusão (CI) exposto na Tabela 4 e critérios de exclusão (CE), presente Tabela 5, para tal análise foi considerado somente o título e resumo. Na próxima etapa do SLR, a etapa filtro 2 uma leitura profunda dos artigos foi realizada aplicando também os critérios de seleção CI e CE, nessa etapa as perguntas da pesquisa da Tabela 3 foram analisadas a cada um dos artigos com objetivo de selecionar os artigos relevantes para o escopo global da

pesquisa, chegando ao resultado final. Cada uma das etapas do fluxo de revisão é mostrada na Figura 1.



Figura 1. Etapas para seleção dos artigos

Figura 1. Etapas para seleção dos artigos

String de busca	("Inventory Control"OR "Inventory Controlled") AND "ERP"AND ("Sucess prediction"OR "Prediction") AND ("Neural NetWorks"OR "neural networks"OR "ANN"OR "NNT").
------------------------	---

Tabela 2: Listagem dos Artigos de controle.

CA1	Predicting TEC in China based on the neural networks optimized by genetic algorithm
CA2	ERP success prediction: An artificial neural network approach
CA3	ERP Neural Network Inventory Control
CA4	An ERP software selection process with using artificial neural network based on analytic network process approach
CA5	Inventory management and cost reduction of supply chain processes using AI based time-series forecasting and ANN modeling
CA6	Decision rules-based method for dynamic adjustment of Min Max

Tabela 3: Perguntas da pesquisa.

RQ1	What is the best AI model for product classification in inventory management?
RQ2	How to redeem, based on analysis of historical data,the possible peaks and valleys of stock of product?
RQ3	How to apply artificial neural networks to management decisions?
RQ4	It is possible to classify the demand for items in stock with the Multilayer Perceptron network
RQ5	Which models applied for stock prediction in ERP systems

Tabela 4: Critério de inclusão.

IC1	It is application in ERP systems or Uses neural networks applied to inventory control
IC2	Uses neural networks applied to user Demand forecasts

Tabela 5: Critério de exclusão.

EC1	It does not provide an abstract.
EC2	It is just an abstract.
EC3	It is not written in English.
EC4	It is a copy or an older version of another publication that has already been considered.
EC5	It is not a primary study (e.g., editorials, summaries of keynotes, tutorials, etc.).
EC6	It is not possible to have access to the full version of the publication.
EC1	It does not provide an abstract.

2.1 PESQUISA

Os mecanismos de busca possuem uma interface simplificada, onde é possível utilizar uma consulta personalizada digitando palavras chaves, ou utilizar qualquer um dos vários recursos de filtro. A busca simples, utilizando texto com filtros, retornou resultados amplos, por vezes sem ligação com a área de pesquisa, fazendo com que o processo de busca de artigos de referência se torne um processo cansativo. Ajustando a estratégia de busca para utilizar o conjunto de palavras chaves de busca que pode ser consultado na Tabela 1, obtivemos uma melhora expressiva dos resultados, aumentando a precisão, assertividade, conectados fortemente relacionados a linha de pesquisa proposta. Melhoramos ainda mais nossos resultados quando refinamos as buscas utilizando os artigos de controle (CA).

A limitação referente a quantidade nós possíveis nos buscadores, fez com que fosse necessário reduzir significativamente o tamanho do conjunto de palavras chaves. Os buscadores possuem regras distintas quanto ao tamanho máximo do nó e também quanto ao limite de caracteres dos textos digitados, impossibilitando que a “String” de busca não pudesse mais ser ajustada. A tabela 6 contém os artigos da etapa de resultado brutos, nela é possível consultar o critério base para exclusão ou inclusão do artigo em questão.

Ano da publicação	Título	
2013	Intermittent demand forecasts with neural networks	IC1
2013	Solving a novel inventory location model with stochastic constraints and (R, s, S) inventory control policy	EC1
2013	Intelligent sales prediction for pharmaceutical distribution companies: a data mining based approach	EC1
2020	Adaptive Inventory Control Based on Fuzzy Neural Network under Uncertain Environment	EC1
1996	Neural controller for business yield management	EC1
1997	Neural network identification of critical factors in a dynamic just-in-time kanban environment	EC1
2007	A model of inventory management using neural networks	IC1
2019	Exact and approximate solution for optimal inventory control of two-stock with reworking and forecasting of demand	EC1
2021	A deep q-learning-based optimization of the inventory control in a linear process chain	IC1
1998	Brief Application Description. Neural Networks Based Forecasting Techniques for Inventory Control Applications	IC1
2014	Early Adverse Life Events and Resting State Neural Networks in Patients With Chronic Abdominal Pain : Evidence for Sex Differences	EC1
2017	Single-hidden layer neural networks for forecasting intermittent demand	IC2
2007	Remaining life estimation of used components in consumer products: Life cycle data analysis by Weibull and artificial neural networks	IC2
2017	Intelligent sleeping car berth inventory control system in the case of variable capacity of railcars	EC1

1997	Implementation of fuzzy logic systems and neural networks in industry	IC3
2009	Using an artificial neural network prediction model to optimize work-in-process inventory level for wafer fabrication	IC2
2010	A new methodology for multi-echelon inventory management in stochastic and neuro-fuzzy environments	EC6
2014	Review of building energy modeling for control and operation	EC6
2017	Estimating surplus food supply for food rescue and delivery operations	IC2
2008	A multi-echelon inventory management framework for stochastic and fuzzy supply chains	EC2
2018	Predicting TEC in China based on the neural networks optimized by genetic algorithm	EC2
2013	ERP success prediction: An artificial neural network approach	IC2
2013	Direct method for training feed-forward neural networks using batch extended kalman filter for multi-step-ahead predictions	EC5

Com base no objetivo proposto, uma revisão sistemática de literatura foi realizada, e nessa seção foi descrito as facilidades e dificuldades de uso dos desses mecanismos, utilizando as questões de pesquisa juntamente com a estratégia para a sua construção. A relação do conjunto de palavras chaves de busca apresentada na Tabela 1, com as questões formuladas. Por fim, apresentamos o resultado que é exibido no gráfico da Figura 2, onde fica expomos a parcela de artigos com suas respectivas fontes na etapa resultado.

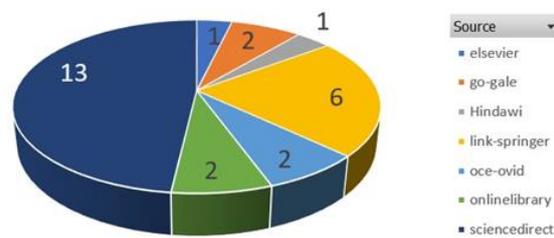


Figura 2. Apresenta o resultado bruto da pesquisa dividida por fontes.

Na etapa de resultados brutos listamos 27 artigos foram selecionados, após aplicar os critérios de inclusão e exclusão somente oito artigos foram selecionados, na etapa filtro 2. Na etapa de filtro 2, após realizar a leitura na íntegra de todos os oito artigos, foi verificado que todos tentavam responder as perguntas de pesquisa e estavam classificados por critério de inclusão. Ao final, restaram oito artigos classificados com grande impacto na pesquisa realizada.

2.2 Pesquisa inicial e construção da “String” de busca

Inicialmente a combinação de palavras chaves foi construída baseando-se apenas nas perguntas de controle de pesquisa presentes na Tabela 1. Após os primeiros ciclos de validação a o conjunto de palavras-chave foi sendo ajustado sempre levando em consideração os artigos de controles descritos na Tabela 2, utilizados para garantir um resultado consistente utilizando como artigo de controles artigos relevantes encontrados em uma pesquisa prévia manual.

Ao final de todas as interações o conjunto de palavras chaves obtida apresentada na Tabela 3. As palavras estão conectadas utilizando operadores booleanos para formar uma “String” que foi utilizada posteriormente nos buscadores das plataformas citadas.

2.3. Relação da “String” de busca com as questões formuladas

A “String” de busca descrita pode ser dividida em quatro partes. A primeira (“Inventory Control”OR “Inventory Controlled”) pretende buscar artigos para responder a pergunta RQ1. A segunda parte AND “ERP”, abrange as respostas referentes as perguntas RQ2 e RQ5. A quarta

parte, AND ("Sucess predction "OR "Prediction") compreende os artigos que correspondem as questões RQ3. Por fim, AND ("Neural NetWorks "OR "neural networks "OR "ANN"OR "NNT"), apresenta resultados a indagação RQ4.

3. RESULTADOS E DISCURSÃO

Esta seção apresenta os resultados encontrados na literatura sobre modelos de aprendizado de máquina propostos até os dias atuais e aplicados a sistemas Enterprise Resource Planning (ERP).

Várias pesquisas foram realizadas sobre o uso de redes neurais para estratégia de negócios. Apresentaremos aqui os artigos mais relevantes encontrados em nossa pesquisa metodológica. Eles possuem uma forte ligação com o tema da pesquisa e abrem o horizonte de possibilidade que podemos explorar sobre o tema.

O controle de estoque adequado é um desafio para o gerenciamento da cadeia de suprimentos, especialmente sob demanda flutuante e imprevisível. Redes de distribuição complexas tornam o problema ainda mais difícil. Apesar de muitos métodos de controle de estoque terem sido desenvolvidos, a política Mín-Máx ainda é um dos métodos mais frequentemente implementados em sistemas de planejamento de recursos empresariais. A abordagem padrão é, no entanto, bastante estática e ineficaz para controlar estoques com alta variabilidade na demanda. A implementação do método Min-Max aprimorado em uma empresa do setor automotivo resultou em um aumento significativo do volume de vendas da empresa, conforme exposto por Puka et al. (2021). Graças ao uso de regras de decisão, a abordagem proposta é flexível o suficiente para complementar outros métodos existentes de gestão de estoque, tornando possível automatizar processos de controle de estoque, mesmo em um ambiente complexo e dinâmico.

Técnicas de descoberta de conhecimento para resolver os problemas de estoque em uma grande empresa de distribuição médica foi apresentada por Bansal (1998) que propôs o uso de mineração de dados baseada em rede neural. A pesquisa utilizou dados de uma grande organização descentralizada para testar o desempenho da rede. O protótipo foi bem-sucedido na redução do nível total de estoque em 50 por cento na organização, mantendo o mesmo nível de probabilidade de que a demanda de um determinado cliente seja atendida.

Gerenciar a demanda intermitente é uma tarefa vital em vários contextos industriais, e uma boa capacidade de previsão é um pré-requisito fundamental para um sistema de controle de estoque eficiente em ambientes estocásticos.

Redes Neurais treinadas utilizando a técnica de back-propagation foram treinadas por [Lolli et al. 2017], sendo essas comparadas com máquinas de aprendizado extremo e redes neurais de referência, bem como métodos de previsão padrão para demanda intermitente em series em tempo real, combinando diferentes padrões de entrada e arquiteturas. Uma análise estatística foi então conduzida para validar o melhor desempenho por meio de diferentes níveis de agregação.

Nos últimos anos, pesquisas foram conduzidas em redes neurais feedforward de camada única oculta, com resultados promissores. Em particular, a retro propagação foi adotada como um algoritmo baseado em gradiente descendente para redes de treinamento. Porém, ao gerenciar um grande número de itens, não é viável otimizar as redes em nível de item, devido ao esforço necessário para ajustar os parâmetros durante a fase de treinamento. Um algoritmo de aprendizado mais simples e rápido, denominado máquina de aprendizado extremo, foi proposto na literatura para tratar desse problema, mas nunca foi tentado para prever a demanda intermitente. Por um lado, uma comparação extensiva de redes de camada oculta única treinadas por retro propagação é necessária para melhorar nosso entendimento delas como preditores de demanda intermitente. Por outro lado, também vale a pena testar máquinas de aprendizado extremo neste contexto, devido à sua menor complexidade computacional e boa capacidade de generalização (Lolli et al. 2017).

Um Q-learning profundo foi desenvolvido por Dittrich and Fohlmeister (2021) que utilizou como base um método para um controle de estoque auto otimizado. Neste método, o processo de decisão é baseado em uma rede neural artificial. Sua entrada é modelada como um vetor de estado que descreve os estoques e pedidos atuais na cadeia de processo. A saída representa um vetor de controle que controla os pedidos de cada estação individual. Além disso, uma função de recompensa, que é baseada no armazenamento resultante e nos custos de pedidos atrasados, é implementada para otimização de decisão baseada em simulações.

Os avanços na tecnologia de sensor e comunicação permitem que as empresas realizem uma troca global de dados para obter um controle de estoque holístico. Devido ao crescimento dos mercados globalizados e à globalização resultante das redes de produção em diferentes

empresas, a otimização de estoque e pedido está se tornando cada vez mais importante no contexto das cadeias de processo. Assim, um controle de estoque adaptável e continuamente auto otimizado em nível global é necessário para superar os desafios resultantes (Dittrich and Fohlmeister 2021).

Uma rede para calcular a prioridade do software ERP foi projetada e treinada por Yazgan et al. (2009). O modelo de rede neural artificial (RNA) é treinado pelos resultados obtidos na ANP. Parece que não há nenhuma grande dificuldade para prever as prioridades do software com o modelo de RNA treinado. Por meio desses resultados, o modelo de RNA tornou-se adequado para uso na seleção de ERP para outra nova decisão.

Para utilizar o modelo ANP para a seleção de ERP para uma nova organização, é necessário um novo grupo de pareceres de especialistas segundo Yazgan et al. (2009), que também expõe que opiniões de muitos especialistas são obtidas durante a construção do modelo ANP para o ERP de seleção e, em seguida, as opiniões são reduzidas a um único valor por métodos como meios geométricos para obter os resultados desejados. Neste caso, o mesmo problema estará em contra-ataque. No modelo proposto por ele, quando os modelos ANP e ANN são configurados, uma seleção de software ERP pode ser feita facilmente por meio da opinião de um único especialista.

Um modelo capaz de prever com sucesso a implantação de um sistema ERP foi proposto por Rouhani and Ravasan (2013), considerando diversos fatores relacionados a uma organização ou ambiente de projeto. Propuseram a ideia de prever o sucesso pós implementação do ERP com base em perfis organizacionais foi discutida. Assim como na necessidade de criar as expectativas das organizações de ERP, um sistema especialista foi desenvolvido explorando o método de Rede Neural Artificial (RNA) para articular as relações entre alguns fatores organizacionais e o sucesso do ERP. A função do sistema especialista está em preparação para obter dados das novas empresas que desejam implementar ERP e para prever o nível de sucesso provável do sistema (Rouhani and Ravasan 2013).

Um artigo recentemente foi elaborado por Dittrich and Fohlmeister (2021), exhibe a rede neural artificial e como ela é utilizada com o aproximar de função dentro da estrutura do algoritmo de aprendizado profunda. Os neurônios de entrada da rede neural artificial representam o vetor de estado, que descreve o estado atual da cadeia de processo como base para a tomada de decisão. Um vetor de estado contendo várias informações referente ao estado

da utilização dos recursos da empresa são processadas pelo modelo. Como saída temos um vetor de controle que é utilizado para apoiar a tomada de decisão da empresa.

4. CONCLUSÃO

Essa pesquisa atingiu o objetivo inicial, à medida que explorou e identificou na literatura um conjunto de oito artigos de alta qualidade para a pesquisa em questão, incluindo um modelo eficiente para prever o giro de estoque que pode ser integrado a sistemas ERP para aprendizado, treinamento e validação dos dados. Diante disso, podemos concluir que é possível construir um sistema atualizado continuamente, realizando uma integração excelente, podendo o modelo de ser construído se tornar um componente do ERP, garantindo a entrega contínua de dados atualizados, em um sistema retroalimentado, o que torna possível exibir painéis de dados e, simultaneamente, criar expectativas computadas dinamicamente. Essa pesquisa demonstrou a aplicação de uma Rede Neural Artificial para prever o giro de produtos, estoque min-max, e podemos até mesmo realizar previsão de vendas. Como trabalhos a serem desenvolvidos a partir deste, podem-se sugerir os seguintes:

1. Criar sistema para exibição em tempo real das previsões de estoque, com objetivo de medir o resultado e realizar aprimoramentos no modelo para garantir a velocidade necessária para o negócio empresarial.
2. Comparar desempenho da rede com outros modelos e arquiteturas.
3. Explorar a arquitetura de processamento e aprendizado considerando dados reais, retroalimentando o modelo de forma contínua.

REFERÊNCIAS

Bansal, K. (1998). Brief application description neural networks based forecasting techniques for inventory control applications.

Dittrich, M. A. and Fohlmeister, S. (2021). A deep q-learning-based optimization of the inventory control in a linear process chain. *Production Engineering*, 15(1): pages 35–43.

Farhat, J. and Owayjan, M. (2017). ERP Neural Network Inventory Control. *Procedia Computer Science*, 114:288–295.

Kourentzes, N. (2013). Intermittent demand forecasts with neural networks. *International Journal of Production Economics*, 143(1):198–206.

Lolli, F., Gamberini, R., Regattieri, A., Balugani, E., Gatos, T., and Gucci, S. (2017). Single-hidden layer neural networks for forecasting intermittent demand. *International Journal of Production Economics*, 183(May 2015):116–128.

Puka, R., Skalna, I., Stawowy, A., Duda, J., and Karkula, M. (2021). Decision rules-based method for dynamic adjustment of Min–Max ordering levels. *Applied Soft Computing*, 107:107370.

Rouhani, S. and Ravasan, A. Z. (2013). ERP success prediction: An artificial neural network approach. *Scientia Iranica*, 20(3):992–1001.

Yazgan, H. R., Boran, S., and Goztepe, K. (2009). An ERP software selection process with using artificial neural network based on analytic network process approach. *Expert Systems with Applications*, 36(5):9214–9222

Kitchenham and Charters (2007). Guidelines for performing Systematic Literature Reviews in Software Engineering. *School of Computer Science and Mathematics*