

Study on Daily Demand Forecasting Orders Using Artificial Neural Network

R. P. Ferreira, A. Martiniano, A. Ferreira, A. Ferreira and R. J. Sassi, *Member, IEEE*

Abstract— In recent decades, Brazil has undergone several transformations, from a closed economy to a market economy. Transport, treatment and distribution of orders remained follow these trends. As a result, the delivery parcel service has become highly complex and competitive. In this context, the forecast demand of orders comes as differential, leading structured productivity and high level of customer service. The paper aims to provide for the daily demand of orders in an Orders Treatment Centre for fifteen days using Artificial Neural Network (ANN). The methodological synthesis of the article is the development of a Artificial Neural Network Multilayer Perceptron (MLP), trained by error back-propagation algorithm. The data for the experiments were collected for 60 days, 45 days to training and 15 days for testing. Experiments were performed with ten different topologies of ANN by changing the following parameters: number of hidden layers, number of neurons in the hidden layers, learning rate, momentum rate and stopping criteria. The results obtained with use of ANN in daily demand forecast orders showed good adhesion to the experimental data in the training and testing phases.

Keywords— Demand Forecasting, Orders, Artificial Neural Network.

I. INTRODUÇÃO

OS NOVOS hábitos de consumo dos brasileiros trouxeram ao mercado produtos com ciclo de vida mais curto e, conseqüentemente volumes crescentes de itens coletados ou distribuídos todos os dias [1].

O ambiente logístico de transporte, tratamento e distribuição de encomendas sofreu modificações constantes em decorrência de mudanças nos mercados, nas condutas de concorrentes, nos fornecedores e na tecnologia utilizada. Em razão disso, o serviço de entrega de encomendas tornou-se altamente complexo e competitivo.

Para articular ou aprimorar uma estratégia empresarial que responda a este ambiente em transformação, é necessária prever a demanda diária de encomendas considerando fatores relevantes e avaliação de alternativas eficientes [2].

Existem várias técnicas de previsão de demandas disponíveis, entre elas as Redes Neurais Artificiais considerados modelos matemáticos de previsão inspirados no

funcionamento dos neurônios biológicos [3, 4, 5]. Nesse contexto, a previsão da demanda de encomendas surge como diferencial, levando produtividade estruturada e alto nível de serviço ao cliente. Objetivo do artigo foi prever a demanda diária de encomendas em um Centro de Tratamento de Encomendas (CTE), durante quinze dias, utilizando uma Rede Neural Artificial (RNA).

O artigo está organizado após essa seção introdutória da seguinte forma: na seção II são apresentados os conceitos básicos da previsão da demanda de encomendas. Na seção III são apresentadas as redes neurais artificiais, a *Multilayer Perceptron* (MLP), o algoritmo de treinamento da MLP e os critérios de parada de treinamento. Na seção IV é apresentada a metodologia do artigo. Descrevem-se na seção V os resultados experimentais. O trabalho é encerrado na seção VI com as considerações finais.

II. PREVISÃO DA DEMANDA DE ENCOMENDAS

O planejamento e o controle das atividades da cadeia de suprimentos/logística dependem de estimativas acuradas dos volumes de produtos e serviços a serem processados pela cadeia de suprimentos. Tais estimativas ocorrem tipicamente na forma de planejamentos e previsões [3].

De acordo com [6], a necessidade de reduzir custos, ao mesmo tempo elevar níveis de serviços, continuará a crescer. Muitas empresas começaram a examinar suas cadeias de abastecimento e sua rede de distribuição como uma das poucas áreas remanescentes onde podem reduzir custos.

O Centro de Tratamento de Encomendas evolui para atender às pressões contínuas de redução de custo, aliada as mudanças das necessidades do cliente será um elemento crítico na capacitação das empresas para competir com sucesso.

Destaca-se ainda que, quando a incerteza da variável é tão alta que as técnicas mais comuns de previsão e suas utilizações no planejamento da cadeia de suprimentos levam a resultados insatisfatórios, surge a necessidade de outras modalidades de previsão [3].

A previsão de demanda é essencial para a empresa como um todo, à medida que proporciona a entrada básica para o planejamento e controle de todas as áreas funcionais, entre as quais Logística, *Marketing*, Produção e Finanças.

Os níveis de demanda e os momentos em que ocorrem afetam fundamentalmente os índices de capacidade, as necessidades financeiras e a estrutura geral de qualquer negócio. Cada uma das áreas funcionais tem problemas específicos de previsão. A previsão de demanda abrange tanto a natureza espacial quanto a natureza temporal da demanda, a extensão de sua viabilidade e seu grau de aleatoriedade [3].

R. P. Ferreira, Universidade Nove de Julho (UNINOVE), São Paulo, Brasil, kasparov@uninove.br

A. Martiniano, Universidade Nove de Julho (UNINOVE), São Paulo, Brasil, andrea.martiniano@gmail.com

A. Ferreira, Universidade de São Paulo (USP), São Paulo, Brasil, arthur2.ferreira@usp.br

A. Ferreira, Faculdade Santa Rita de Cássia (FSR), São Paulo, Brasil, aleisterferreira@hotmail.com

R. J. Sassi, Universidade Nove de Julho (UNINOVE), São Paulo, Brasil, renato.sassi@ieee.org

Prover a capacidade produtiva para satisfazer à demanda atual e futura é uma responsabilidade fundamental da administração de produção [7].

Isso implica em obter o equilíbrio adequado entre capacidade e demanda e satisfazer os clientes de forma eficaz em custo. Obtendo o equilíbrio errado, deixará de atender à demanda e terá custos excessivos.

Embora a previsão de demanda seja geralmente responsabilidade dos departamentos de vendas e/ou marketing, é um insumo muito importante para a decisão do planejamento e controle de capacidade, normalmente uma responsabilidade da gerência de produção. Afinal, sem uma previsão de demanda não é possível planejar efetivamente para futuros eventos, somente reagir a eles. Por isso é importante que os tomadores de decisão entendam a base e os fundamentos logísticos para essas previsões de demanda.

As Redes Neurais Artificiais são modelos constituídos por unidades de processamento simples, chamados de neurônios artificiais, que calculam funções matemáticas. Estes modelos são inspirados na estrutura do cérebro e têm como objetivo simular o comportamento humano, tais como: aprendizagem, associação, generalização e abstração quando submetidas a treinamento [4].

São particularmente eficientes para o mapeamento entrada/saída de sistemas não lineares e para realizar processamento paralelo, além de simular sistemas complexos. Generalizam os resultados obtidos para dados previamente desconhecidos, ou seja, produzem respostas coerentes e apropriadas para padrões ou exemplos que não foram utilizados no seu treinamento [4].

Por fim, podem ser aplicadas em diversas áreas e na solução de vários problemas como: reconhecimento de padrões [8], descoberta de conhecimento e mineração em bases de dados [9], medicina [10], negócios [11], indústria automotiva [12], previsão do comportamento do tráfego veicular urbano [13], qualidade nos serviços [14], entre outros.

III. MULTILAYER PERCEPTRON

A MLP consiste de um conjunto de unidades (nós ou neurônios), que constituem a camada de entrada, uma ou mais camadas ocultas e uma camada de saída, onde o sinal de entrada se propaga pela RNA camada por camada. Na Fig. 1 é apresentada a estrutura básica de uma MLP.




Figura 1. Estrutura básica da RNA do tipo MLP. Fonte: Adaptado de [13].

Observa-se na Figura 1 os dados (vetores de dados) de entrada da rede (X_1, \dots, X_n), os neurônios da camada de entrada da rede (Ne_1, \dots, Ne_n) com seus respectivos pesos, os neurônios que formam a camada intermediária da rede (No_1, \dots, No_n) e a camada de saída (Ns_1), formada por um neurônio.

As RNAs possuem a capacidade de aprender por exemplos e fazer interpolações e extrapolações do que aprenderam. Um conjunto de procedimentos bem definidos, para adaptar os pesos de uma RNA para que ela possa aprender uma determinada função, é chamado algoritmo de treinamento ou de aprendizado [4].

O aprendizado de uma RNA usa um conjunto de dados correspondentes a uma amostra de sinais para entrada e saída do sistema. Para esse treinamento, a rede utiliza algoritmos de aprendizado.

Inicialmente a rede permanece inerte e o algoritmo de aprendizado modifica individualmente os pesos das interconexões de tal forma que o comportamento da rede reflita a ação desejada. Em outras palavras, a rede pode alterar sua estrutura interna de maneira incremental até que se alcance o desempenho esperado de estimação dos dados [15].

Como resultado do treinamento, produzirá valores de saída similares ao conjunto de dados para valores que sejam iguais às amostras de treinamento. Para valores intermediários, a rede produzirá uma interpolação. Ou seja, podem aprender através de exemplos [15].

O algoritmo de retro propagação do erro (*error back-propagation*), utilizado na MLP, consiste, basicamente, em determinar as variações nos pesos sinápticos da RNA, tendo como objetivo minimizar o erro obtido na saída através do aprendizado do vetor de treinamento (entrada-saída) [16].

Para isso, o algoritmo baseia-se no método do gradiente descendente, o qual, dada uma medida do erro, procura modificar o conjunto de pesos w_{ij} da rede, reduzindo o erro na direção mais íngreme da superfície definida no espaço w [4].

Em resumo, o algoritmo do gradiente descendente estabelece mudanças nos pesos w_{ij} por uma quantidade Δw_{ij} proporcional ao gradiente do erro.

O algoritmo de retro propagação do erro (*error back-propagation*) funciona da seguinte forma: apresenta-se um padrão à camada de entrada da rede, esse padrão é processado camada por camada até que a camada de saída forneça a resposta processada, f_{MLP} , como mostra a Equação (1):

$$f_{MLP}(x) = \varphi \left(\sum_1^{Non} v_i \cdot \varphi \left(\sum w_{ij} x_j + b_{i0} \right) + b_0 \right) \quad (1)$$

Na qual v_i e w_{ij} são pesos sinápticos; b_{i0} e b_0 são os *biases*; e φ a função de ativação, comumente especificada como sendo a função sigmóide.

A Fig. 2 mostra a função sigmóide.




Figura 2. Função sigmóide. Fonte: Adaptado de [17].

O princípio deste algoritmo, para cálculo dos erros nas camadas intermediárias, é o seu cálculo por retroalimentação, possibilitando, desta forma, o ajuste dos pesos proporcionalmente aos valores das conexões entre camadas.

De acordo com [4], a MLP possui as seguintes características: função de ativação não-linear (sigmoidal), uma ou mais camadas de neurônios ocultos e um alto grau de conectividade. Uma MLP treinada com o algoritmo de retro propagação realiza um mapeamento não linear de entrada-saída.

Em um processo iterativo como o algoritmo *error back-propagation*, uma questão importante é sobre o critério de parada do treinamento [15].

Em termos absolutos, a solução final ocorrerá para o índice de desempenho (erro global) igual a zero ou dentro de um valor muito pequeno [4].

Contudo, se durante a fase de treinamento o erro não for pequeno e não tiver tendência a diminuir, dois enfoques podem ser adotados [4]:

- Limitar o número de iterações, ou seja, o treinamento cessa após ter ocorrido um valor limite, prefixado, de épocas de treinamento.
- Amostrar e tirar a média de certo número de épocas, por exemplo, 500 épocas. Se o erro médio do último conjunto de 500 épocas não for melhor que o das 500 anteriores o treinamento deve ser cessado, indicando que um mínimo local foi alcançado. Depois disso, a rede deve estar ainda pronta para ser reutilizada para testes [4].

IV. METODOLOGIA

Os dados foram coletados numa empresa de grande porte durante 60 dias úteis, 45 dias para treinamento e 15 dias para teste.

A metodologia experimental consistiu no desenvolvimento de uma MLP treinada com o algoritmo de *error back-propagation*.

Foram realizados dez experimentos variando a topologia da MLP segundo a quantidade de camadas ocultas, o número de neurônios nas camadas ocultas, a taxa de aprendizagem, a taxa de *momentum*.

a) Topologia e Parâmetros

A abordagem selecionada para a escolha das topologias da MLP foi a abordagem empírica, que consiste em testar várias topologias até encontrar uma que apresente um resultado satisfatório [18].

A inclusão do termo *momentum* tem por objetivo aumentar a velocidade de treinamento da rede neural e reduzir o perigo de instabilidade. Recomenda-se que o valor da taxa de *momentum* fique compreendido entre 0 e 1 [19].

A utilização de um grande número de camadas escondidas não é recomendada. Cada vez que o erro médio durante o treinamento é utilizado para atualizar os pesos das sinapses da camada imediatamente anterior, ele se torna menos útil ou preciso. Testes empíricos com a MLP *back-propagation* para problemas de estimação de função podem ser resolvidos utilizando-se apenas uma camada, mas, pode ser necessário a utilização de duas camadas escondidas [16, 20].

Com relação ao número de neurônios nas camadas escondidas, este é geralmente definido empiricamente. Deve-se ter cuidado para não utilizar nem unidades demais, o que pode levar a rede a memorizar os dados de treinamento (*overfitting*), ao invés de extrair as características gerais que permitirão a generalização, nem um número muito pequeno, que pode forçar a rede a gastar tempo em excesso tentando encontrar uma representação ótima [16, 20, 21].

O parâmetro taxa de aprendizado tem grande influência durante o processo de treinamento da MLP. Uma taxa de aprendizado muito baixa torna o aprendizado da rede muito lento, ao passo que uma taxa de aprendizado muito alta provoca oscilações no treinamento e impede a convergência do processo de aprendizado. Geralmente seu valor varia de 0,1 a 1,0 [16, 20, 21].

Os critérios de parada mais utilizados são:

- Número de épocas (ciclos): define o número de vezes em que o conjunto de treinamento é apresentado à rede;
- erro: consiste em encerrar o treinamento após o erro médio quadrático ficar abaixo de um valor a pré-definido. Este valor depende muito do problema. Uma sugestão é estabelecer um valor de 0,01 no primeiro treinamento e depois ajustá-lo em função do resultado [20, 21].

A Tabela I apresenta as topologias e os parâmetros utilizados nos dez experimentos realizados.

TABELA I. TOPOLOGIAS E PARÂMETROS UTILIZADOS NA MLP.

Experimento	Camadas ocultas	Neurônios nas camadas ocultas	Taxa de aprendizado	Taxa de <i>momentum</i>	Critério de parada da RNA
Exp. 1	2	5	0,3	0,5	Erro menor que 0,01 ou 200 épocas
Exp. 2	2	7	0,5	0,7	Erro menor que 0,01 ou 200 épocas
Exp. 3	2	9	0,7	0,9	Erro menor que 0,01 ou 200 épocas
Exp. 4	2	11	0,9	0,95	Erro menor que 0,01 ou 200 épocas
Exp. 5	2	15	0,95	0,99	Erro menor que 0,01 ou 200 épocas
Exp. 6	3	5	0,3	0,5	Erro menor que 0,01 ou 200 épocas
Exp. 7	3	7	0,5	0,7	Erro menor que 0,01 ou 200 épocas
Exp. 8	3	9	0,7	0,9	Erro menor que 0,01 ou 200 épocas
Exp. 9	3	11	0,9	0,95	Erro menor que 0,01 ou 200 épocas
Exp. 10	3	15	0,95	0,99	Erro menor que 0,01 ou 200 épocas

As doze entradas da MLP foram:

- Semana do mês (primeira semana, segunda, terceira ou quarta semana);
- Dia da semana (segunda a sexta-feira);
- Encomendas urgentes;
- Encomendas não urgentes;
- Encomendas do tipo A;
- Encomendas do tipo B;
- Encomendas do tipo C;
- Encomendas do setor fiscal;
- Encomendas do setor controlador de trânsito;
- Encomendas do setor bancário (1);
- Encomendas do setor bancário (2);
- Encomendas do setor bancário (3).

A saída da MLP é a previsão da demanda de encomendas diária. A Fig. 3 mostra a topologia da MLP utilizada no experimento 5.




Figura 3. Topologia da RNA do tipo MLP.

V. RESULTADOS EXPERIMENTAIS

As Fig. 4 a 13 mostram os resultados dos experimentos, a curva com marcador (quadrado) representa os dados reais (saída desejada) e a curva com marcador (triangular) representa a saída da RNA.

O eixo x com marcador (losango) corresponde aos dias de teste (15 dias). O eixo y corresponde à quantidade de encomendas, a variação do eixo y está entre 177.901 encomendas (mínimo) e 413.307 encomendas (máximo).

A Fig. 4 mostra a fase de teste do experimento 1.




Figura 4. Fase de Teste da MLP (Experimento 1).

A Fig. 5 mostra a fase de teste do experimento 2.




Figura 5. Fase de Teste da MLP (Experimento 2).

A Fig. 6 mostra a fase de teste do experimento 3.




Figura 6. Fase de teste da MLP (Experimento 3).

A Fig. 7 mostra a fase de teste do experimento 4.




Figura 7. Fase de Teste da MLP (Experimento 4).

A Fig. 8 mostra a fase de teste do experimento 5.




Figura 8. Fase de Teste da MLP (Experimento 5).

A Fig. 11 mostra a fase de teste do experimento 8.




Figura 11. Fase de Teste da MLP (Experimento 8).

A Fig. 9 mostra a fase de teste do experimento 6.




Figura 9. Fase de Teste da MLP (Experimento 6).

A Fig. 12 mostra a fase de teste do experimento 9.




Figura 12. Fase de Teste da MLP (Experimento 9).

A Fig. 10 mostra a fase de teste do experimento 7.

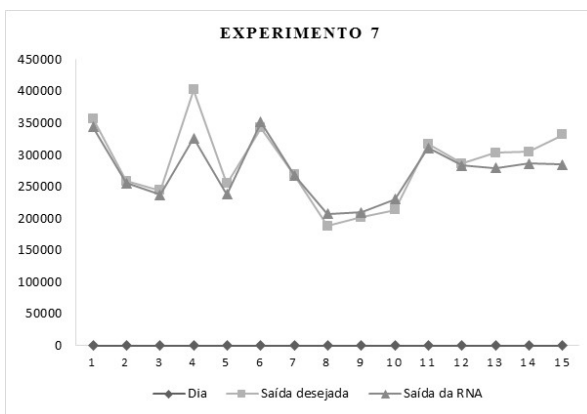


Figura 10. Fase de Teste da MLP (Experimento 7).

A Fig. 13 mostra a fase de teste do experimento 10.




Figura 13. Fase de Teste da MLP (Experimento 10).

A Tabela II apresenta as taxas de erros dos experimentos - (1 a 10).

TABELA II. TAXAS DE ERROS DOS EXPERIMENTOS.

Dia	Exp.01	Exp.02	Exp.03	Exp.04	Exp.05	Exp.06	Exp.07	Exp.08	Exp.09	Exp.10
	Erro (%)	Erro (%)	Erro (%)	Erro (%)	Erro (%)	Erro (%)	Erro (%)	Erro (%)	Erro (%)	Erro (%)
1	-1,0%	-0,7%	-0,1%	0,9%	-2,4%	5,4%	3,8%	3,4%	4,0%	0,04%
2	-6,9%	-1,6%	-2,6%	-3,2%	-3,3%	6,0%	1,4%	-5,7%	-1,1%	-5,4%
3	-7,8%	-0,2%	-1,2%	-0,8%	-1,2%	3,6%	2,9%	-4,5%	-0,5%	0,0%
4	15,3%	14,3%	14,5%	4,5%	8,6%	6,8%	19,0%	23,5%	10,3%	13,8%
5	8,7%	4,8%	5,3%	6,4%	4,8%	6,6%	6,5%	6,1%	7,1%	5,3%
6	-3,8%	2,7%	-2,3%	-0,1%	0,0%	4,6%	-2,6%	-2,8%	-1,2%	-2,0%
7	11,1%	2,3%	-5,2%	-3,6%	-1,6%	4,8%	0,1%	-7,7%	-3,8%	-1,2%
8	-	-	-	-	-	-	-	-	-	-
9	-5,4%	-4,3%	-4,6%	-0,5%	0,01%	-5,8%	-3,9%	-6,2%	-5,0%	2,1%
10	-5,5%	-7,0%	-3,9%	-1,8%	0,8%	-7,8%	-7,9%	-7,2%	-6,9%	0,8%
11	-8,1%	5,4%	-2,5%	0,9%	-2,5%	14,5%	1,9%	-4,8%	3,6%	-1,0%
12	-9,0%	3,2%	-2,2%	-3,5%	-1,0%	10,0%	1,0%	-7,3%	-0,8%	1,1%
13	-0,2%	2,5%	2,4%	1,4%	6,7%	7,9%	7,9%	0,8%	2,7%	3,4%
14	12,7%	5,5%	3,3%	3,0%	5,0%	7,7%	6,1%	6,6%	2,8%	5,6%
15	18,4%	5,9%	3,4%	6,3%	8,2%	8,5%	14,2%	10,7%	9,4%	7,2%

Observa-se na Tabela II os dois maiores erros percentuais de cada experimento (destacados em negrito).

O experimento 5 com a MLP de 2 camadas ocultas, taxa de aprendizado igual a 0,95, taxa *momentum* 0,99 e o número máximo de épocas igual a 200 apresentou o melhor resultado.

Pode-se considerar que a topologia adotada no experimento 5 adaptou-se melhor ao conjunto de dados apresentado, o que resultou na melhor previsão.

Adicionalmente foram realizados mais cinco experimentos (5.1 a 5.5) a partir do experimento 5, trocando-se o número de camadas ocultas e a taxa de aprendizado. Esses experimentos foram realizados no intuito de avaliar a mudança dos valores de saída.

A Tabela III apresenta as topologias e os parâmetros utilizados nos cinco experimentos adicionais.

TABELA III. TOPOLOGIAS E PARÂMETROS UTILIZADOS NOS CINCO EXPERIMENTOS ADICIONAIS.

Experimento 5	Camadas ocultas	Neurônios nas camadas ocultas	Taxa de aprendizado	Taxa de <i>momentum</i>	Critério de parada da RNA
Exp. 5.1	3	15	0,3	0,99	Erro menor que 0,01 ou 200 épocas
Exp. 5.2	3	15	0,5	0,99	Erro menor que 0,01 ou 200 épocas
Exp. 5.3	3	15	0,7	0,99	Erro menor que 0,01 ou 200 épocas
Exp. 5.4	3	15	0,9	0,99	Erro menor que 0,01 ou 200 épocas
Exp. 5.5	3	15	0,95	0,99	Erro menor que 0,01 ou 200 épocas

A Tabela IV apresenta as taxas de erros dos experimentos adicionais com a presença do experimento 5.

TABELA IV. TAXAS DE ERROS DOS EXPERIMENTOS ADICIONAIS COM A PRESENÇA DO EXPERIMENTO 5.

Dia	Exp. 5	Exp. 5.1	Exp. 5.2	Exp. 5.3	Exp. 5.4	Exp. 5.5
	Erro (%)	Erro (%)	Erro (%)	Erro (%)	Erro (%)	Erro (%)
1	-2,40%	4,99%	0,71%	3,99%	3,46%	0,43%
2	-3,30%	-0,50%	-3,67%	-0,58%	-0,61%	-0,60%
3	-1,20%	2,33%	-0,72%	2,43%	0,38%	-1,61%
4	8,60%	12,41%	18,95%	-2,74%	14,17%	20,23%
5	4,80%	5,46%	7,92%	6,16%	6,25%	3,65%
6	0,00%	-0,06%	0,33%	-1,28%	0,09%	-2,04%
7	-1,60%	-1,87%	-2,01%	-4,55%	-2,47%	-2,40%
8	-5,70%	-10,42%	-12,77%	-11,74%	-12,61%	-13,56%
9	-0,01%	-2,97%	-3,55%	-4,71%	-3,85%	-6,03%
10	0,80%	-9,08%	-6,05%	-8,21%	-8,00%	-7,90%
11	-2,50%	2,87%	2,03%	-0,86%	1,75%	-1,57%
12	-1,00%	2,51%	1,57%	-4,21%	-1,94%	-2,92%
13	6,70%	5,25%	5,45%	2,40%	4,64%	-0,19%
14	5,00%	5,71%	9,36%	1,04%	5,22%	-3,88%
15	8,2%	9,21%	9,15%	7,08%	9,58%	-4,69%

Observa-se na Tabela IV os dois maiores erros percentuais de cada experimento adicional (destacados em negrito). Os experimentos adicionais confirmam que a topologia e os parâmetros utilizados no experimento 5 apresentam a melhor previsão entre todos.

VI. CONSIDERAÇÕES FINAIS

A topologia da MLP do experimento 5 aplicada à previsão da demanda de encomendas apresentou boa aderência aos dados experimentais nas fases de treinamento e teste, identificando padrões de comportamento em um ambiente logístico complexo que envolve, transporte, tratamento e distribuição de encomendas.

A contribuição do trabalho reside na aplicação da MLP para previsão da demanda em empresas de transporte, tratamento e distribuição de encomendas, permitindo adequar recursos produtivos, conforme a demanda diária, evitando rupturas durante o processo e perda do prazo de entrega, além de reduzir o custo com recursos disponibilizados desnecessariamente em operações mal dimensionadas por falta de previsão da demanda adequados.

Pretende-se dar continuidade aos estudos com a realização de novos experimentos aplicando a MLP em outros problemas de previsão de demanda com o intuito de validar o modelo apresentado, pretende-se ainda realizar outros experimentos para prever separadamente a demanda de encomendas urgentes e não urgentes.

AGRADECIMENTOS

À Universidade Nove de Julho (Uninove) pelo apoio à pesquisa. À Universidade de São Paulo (USP) pela bolsa de Iniciação Científica.

REFERÊNCIAS

- [1] TODAY *Logistics & Supply Chain*. São Paulo: Cecília Borges, Ano III, n. 38, 2009.
- [2] D. J. BOWERSOX, D. J. CLOSS, *Logística Empresarial: o processo de integração da cadeia de suprimento*. Tradução de Equipe CEL e Adalberto Ferreira Neves. São Paulo: Atlas, 2010.
- [3] R. H. BALLOU, *Gerenciamento da Cadeia de Suprimentos/Logística Empresarial*. Tradução de Raul Rubenich. 5. ed. Porto Alegre: Bookman, 2006.
- [4] S. HAYKIN, *Redes Neurais – Princípios e Práticas*. Bookman. 2a edição. Porto Alegre, 2001.
- [5] I. N. SILVA, D. H. SPATTI, R. A. FLAUZINO, *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas*. SP: Artliber, 2010.
- [6] E. BANZATO, E. C. JUNIOR, J. M. BANZATO, R. A. MOURA, S. F. T. RAGO, *Atualidades na armazenagem*. São Paulo: IMAM, 2008.
- [7] N. SLACK, S. CHAMBER, C. HARDLAND, A. HARRISON, R. JOHNSTON, *Administração da Produção*. São Paulo: Atlas, 2009.
- [8] T. S. *Comparison of Different Learning Algorithms for Pattern Recognition with Hopfield's Neural Network*. *Procedia Computer Science*, vol. 71, 2015, Pages 68-75. doi:10.1016/j.procs.2015.12.205.
- [9] N. JOTHI, N. A. RASHID, W. HUSAIN. *Data Mining in Healthcare – A Review*. *Procedia Computer Science*, vol. 72, 2015, Pages 306-313. doi:10.1016/j.procs.2015.12.145.
- [10] S. AGRAWAL, J. AGRAWAL. *Neural Network Techniques for Cancer Prediction: A Survey*. *Procedia Computer Science*, Volume 60, 2015, Pages 769-774. doi:10.1016/j.procs.2015.08.234.
- [11] M. TKÁČ, R. VERNER. *Artificial neural networks in business: Two decades of research*. *Applied Soft Computing*, vol. 38, January 2016, Pages 788-804. doi:10.1016/j.asoc.2015.09.040.
- [12] C. AFFONSO, R. J. SASSI. *Application of neurofuzzy networks for the processing of automotive parts by polymer injection molding*. *Production*, 25(1), 157-169. 2015. doi.org/10.1590/S0103-65132014005000005.
- [13] R. P. FERREIRA, Combinação de Técnicas da Inteligência Artificial para Previsão do Comportamento do Tráfego Veicular Urbano na Cidade de São Paulo. 107 p. Dissertação (Mestrado em Engenharia de Produção) – Universidade Nove de Julho, São Paulo, 2011.
- [14] G. R. OÑA, J. OÑA. *Neural networks for analyzing service quality in public transportation*. *Expert Systems with Applications*, vol. 41, Issue 15, 1 November 2014, Pages 6830-6838. doi:10.1016/j.eswa.2014.04.045.
- [15] M. G. SIMÕES, I. S. SHAW, *Controle e Modelagem fuzzy*. São Paulo: Blucher: FAPESP, 2007.
- [16] A. P. BRAGA, A. C. P. L. F. CARVALHO, T. B. LUDERMIR, *Redes Neurais Artificiais: Teoria e Aplicações*. Rio de Janeiro. Ed. LTC, 2ª ed. Rio de Janeiro, 2011.
- [17] R. J. SASSI, L. A. SILVA, D. M. E. HERNANDEZ. *A Methodology using Neural Networks to Cluster Validity Discovered from a Marketing Database*. In: 10th Brazilian Symposium on Neural Networks (SBRN), Salvador. *IEEE Proceedings of SBRN*. v. 1. p. 03-08, 2008.
- [18] R. G. PAREKH, J. YANG, V. G. HONAVAR. *MUstart - A Constructive Neural Network Learning Algorithm for Multi-Category Pattern Classification*. In: Proceedings of the IEEE/INNS International Conference on Neural Networks, ICNN'97, 1997.
- [19] T. M. MITCHELL. *Machine Learning*. McGraw-Hill, 1997.
- [20] C. M. BISHOP. *Neural Networks for Pattern Recognition*. Oxford University Press, 1995.
- [21] J. M. ZURADA. *Introduction to Artificial Neural Systems*; PWS Publishing, 1992.



Ricardo Pinto Ferreira Doutorando em Informática e Gestão do Conhecimento pela Universidade Nove de Julho, Mestre em Engenharia de Produção na área de Gestão e Otimização da Produção pela Universidade Nove de Julho (2011). Realizando pesquisa nos seguintes temas: Inteligência computacional, Absenteísmo, Presenteísmo, Roteirização de Veículos, Lógica Fuzzy, Redes Neurais Artificiais e *Data Mining*. Docente nos cursos de Engenharias na Universidade Nove de Julho. Membro do *EURO Working Group on Vehicle Routing and Logistics Optimization (VeRoLog)* filiado à Association of the European Operational Research Societies. Membro da *Brazilian Fuzzy Community*.



Andréa Martiniano da Silva Mestre em Engenharia de Produção pela Universidade Nove de Julho (2012). Realiza pesquisa nos seguintes temas: Gestão do Absenteísmo e Presenteísmo, Inteligência computacional, Redes Neurais Artificiais, Mapas Auto-Organizáveis de Kohonen e *Data Mining*.



Arthur Ferreira Graduando em Sistemas de Informação pela Universidade de São Paulo (USP). Realiza pesquisas em Criptografia, Lógica Fuzzy, Redes Neurais Artificiais e Reconhecimento de Padrões. Bolsista de Iniciação Científica pela Universidade de São Paulo (USP).



Aleister Ferreira Graduando em Administração. Foi aluno de Iniciação Científica na Universidade Nove de Julho com bolsa de iniciação tecnológica no CNPq. Realiza pesquisa nos seguintes temas: Algoritmos genéticos, Algoritmo de otimização por colônia de formigas, Redes Neurais Artificiais, Lógica Fuzzy. Membro do *EURO Working Group on Vehicle Routing and Logistics Optimization (VeRoLog)* filiado à Association of the European Operational Research Societies.



Renato José Sassi Doutor em Engenharia Elétrica pela Escola Politécnica da Universidade de São Paulo. Pesquisador e docente no Programa de Mestrado em Engenharia de Produção e no Programa de Mestrado e Doutorado em Informática e Gestão do Conhecimento ambos da Universidade Nove de Julho. Pesquisador Associado do Grupo de Inteligência Computacional, Modelagem e Neurocomputação (ICONE) do Laboratório de Sistemas Integráveis (LSI) da Escola Politécnica da Universidade de São Paulo (USP), Membro do IEEE. Realiza pesquisa nos seguintes temas: Inteligência Analítica, Inteligência Computacional, Descoberta de Conhecimento em Bases de Dados, Mineração de Dados e Métodos de Apoio à Tomada de Decisão.