

Dashboard* Inteligente para apoio à tomada de decisão em empresa de *courier

Intelligent *dashboard* to support for decision making in business *courier* company

Dashboard* inteligente para apoyo a la toma de decisiones en empresas de *courier

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. Pós-graduado em Tecnologia da Informação e Internet na área de Ciência da Computação. MBA em Administração na área de Logística Empresarial e *Supply Chain*, nível de Especialização. Bacharel em Administração de Empresas, São Paulo, Brasil
kasparov@uninove.br

Andréa Martiniano

Bacharel em Administração de Empresas com Habilitação em Gestão e Negócios pela Faculdade Sumaré . Pós-graduada Latu Sensu em Tecnologia da Informação e Internet na área de Ciência da Computação, pela Universidade Nove de Julho Mestre em Engenharia de Produção pela Universidade Nove de Julho, São Paulo, Brasil .
andrea.martiniano@gmail.com

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 , São Paulo, Brasil
rjsassi@gmail.com

Editor Científico: José Edson Lara
Organização Comitê Científico
Double Blind Review pelo SEER/OJS
Recebido em 30.03.2016
Aprovado em 07.06.2016



Este trabalho foi licenciado com uma Licença Creative Commons - Atribuição – Não Comercial 3.0 Brasil

Agradecimentos

À Universidade Nove de Julho pelo apoio à pesquisa.

À Universidade Corporativa dos Correios pela bolsa de estudo.

Ao Professor Gary Johns, professor *Emeritus of Management, Honorary Concordia University Research Chair in Management, John Molson School of Business, Concordia University Montreal, Quebec, Canada*, pelo apoio à pesquisa.

RESUMO

O objetivo do artigo foi pesquisar, avaliar e apresentar um estudo sobre um *dashboard* inteligente para apoio à tomada de decisão em empresa de *courier* baseado em técnicas de Inteligência Artificial. O Brasil passou por diversas transformações e os serviços, de forma geral, foram amoldando-se às novas exigências de clientes e mercado. Em razão disso, o serviço de *courier* tornou-se complexo e competitivo; assim, ao transporte, ao tratamento e à distribuição, restou acompanhar essas tendências. Nesse contexto, a aplicação de técnicas inteligentes surge como alternativa, buscando produtividade e alto nível de serviço. A síntese metodológica do artigo consiste no desenvolvimento de um *dashboard* apoiado por técnicas de Inteligência Artificial. Uma Rede Neural Artificial do tipo *Multilayer Perceptron*, treinada pelo algoritmo de *error back-propagation* foi desenvolvida e aplicada para realizar previsões de demanda e previsão do absentismo. Essas previsões foram apresentadas ao *dashboard* inteligente para apoiar a tomada de decisão. Adicionalmente foi aplicado outro tipo de rede neural artificial, o Mapa Auto-Organizável de Kohonen para gerar agrupamentos buscando melhor visualização a ser utilizada no *dashboard*. Os dados para a realização dos experimentos foram coletados em uma empresa de *courier*. Concluiu-se que a aplicação das técnicas auxiliou na criação de um *dashboard* inteligente para apoiar a tomada de decisão.

Palavras-chave: *Dashboard* Inteligente; Tomada de Decisão; Redes Neurais Artificiais; Empresa de *Courier*.

ABSTRACT

The aim of this paper was to research, evaluate and present a study on an intelligent *dashboard* to support decision making in *Courier* Company based on Artificial Intelligence techniques. Brazil has gone through several transformations of general services have been adapting to the new demands of customers and market. As a result, the *courier* service has become highly complex and competitive. The transport, treatment and distribution remained follow these trends. In this context, the application of intelligent techniques to support decision-making is an alternative, seeking productivity and high level of service. The methodological synthesis of the article is to develop a *dashboard* supported by Artificial Intelligence techniques. An Artificial Neural Network (ANN) Type Multilayer Perceptron (MLP), trained by error back-propagation algorithm was developed and applied to make demand forecast and forecast absenteeism, these forecasts were presented in intelligent *dashboard* to support decision. In addition we applied the Self-Organizing Map of Kohonen to generate clusters seeking better visualization to be used on the *dashboard*. The data for the experiments were collected in a *courier* company. It was concluded that the

application of techniques helped in the creation of an intelligent *dashboard* to support decision making.

Keywords: Intelligent *Dashboard*, Decision Making, Artificial Neural Networks, *Courier Company*.

RESUMEN

El objetivo del artículo fue investigar, evaluar y presentar un estudio sobre un dashboard inteligente para apoyo a la toma de decisiones en empresas de courier, con base en las técnicas de Inteligencia Artificial. Brasil pasó por muchas transformaciones, y los servicios, de modo general, se adecuaron a las nuevas exigencias de los clientes y del mercado. En virtud de ello, el servicio de courier se volvió complejo y competitivo, y al transporte, tratamiento y distribución les resultó acompañar esas tendencias. En este contexto, la aplicación de técnicas inteligentes surge como una alternativa para la productividad y el alto nivel de servicio. La síntesis metodológica del artículo consiste en el desarrollo de un dashboard apoyado en técnicas de la Inteligencia Artificial. Una Red Neuronal Artificial de tipo Perceptrón Multicapa entrenada por el algoritmo de error back-propagation fue desarrollada y aplicada para realizar las previsiones de demanda y absentismo. Esas previsiones fueron presentadas al dashboard inteligente para apoyar a la toma de decisiones. Además, se aplicó otro tipo de red neuronal artificial, el Mapa Auto-organizado de Kohonen, para generar agrupamientos con el fin de mejorar la visualización en el dashboard. Los datos para la realización de los experimentos fueron recopilados en una empresa de courier. Se concluyó que la aplicación de las técnicas auxilió en la creación de un dashboard inteligente para apoyar a la toma de decisiones.

Palabras clave: Dashboard Inteligente, La toma de Decisiones, Redes Neuronales Artificiales, Empresa de Courier.

1 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 (Today, 2009).

Ao transporte, tratamento e distribuição de encomendas restaram acompanhar essas tendências. Em razão disso, o serviço de entrega de encomendas tornou-se altamente complexo e competitivo.

Assim, o ambiente logístico de transporte, tratamento e distribuição de encomendas sofre modificações constantes em decorrência de mudanças nos mercados nas condutas de concorrentes nos fornecedores e na tecnologia utilizada.

Para articular ou aprimorar uma estratégia empresarial que responda a esse ambiente em transformação, é necessária uma metodologia de planejamento e de projeto que considere fatores relevantes e avalie alternativas de forma eficiente (Bowersox & Closs, 2010). Nesse contexto, a previsão da demanda e previsão do absenteísmo surge como diferencial, levando produtividade estruturada e alto nível de serviço ao cliente; a previsão busca reduzir o risco de ruptura no processo logístico.

De acordo com Ballou (2006), existem várias técnicas de previsão disponíveis, entre elas as Redes Neurais Artificiais, que consistem em modelos matemáticos que podem realizar a tarefa de previsão, inspirados no funcionamento dos neurônios biológicos. As Redes Neurais Artificiais surgem como alternativa para a previsão da demanda de encomendas e previsão do absenteísmo.

Assim, um *dashboard* pode apresentar informações relevantes que permitem monitorar dados operacionais, ligeiramente resumidos e atualizados com frequência.

O objetivo do presente artigo foi pesquisar, avaliar e apresentar um estudo sobre um *dashboard* inteligente para apoio à tomada de decisão em empresa de *courier* baseado em técnicas de Inteligência Artificial.

O artigo está organizado, após essa seção introdutória, da seguinte forma: na seção 2, apresenta-se o Referencial Teórico, com conceitos básicos de *dashboards*, previsão da demanda de encomendas, previsão do absenteísmo e redes neurais artificiais. Na seção 3, os Métodos de Trabalho são apresentados. Os Resultados dos experimentos computacionais são descritos na seção 4, e na seção 5, apresenta-se a descrição de *dashboard* inteligente. O artigo é encerrado com as Considerações finais, na seção 6.

2 REFERENCIAL TEÓRICO

2.1 *Dashboards*

Os *dashboards* proporcionam exibições visuais de informações importantes, que são consolidadas e organizadas em uma tela única para serem absorvidas de maneira fácil e rápida. A partir do *dashboard*, é fácil ver, por exemplo, se todos os

Key Performance Indicators (KPIs) estão dentro dos padrões de desempenho esperados. Os *dashboards* são exibições visuais usadas para monitorar o desempenho operacional (Turban, Sharda, Aronson, & King, 2009).

A Tabela 1 apresenta as características do *dashboard*.

Tabela 1
Características do *dashboard*

Característica	Dashboard
Propósito	Mede o desempenho
Usuários	Supervisores, especialistas
Atualizações	Transmissões na hora certa
Dados	Eventos
Exibição	Gráficos visuais, dados brutos

Fonte: Adaptado de Turban, E., Sharda, R., Aronson, J. E. & King, D. (2009). *Business Intelligence: Um enfoque gerencial para a inteligência do negócio*. Porto Alegre: Bookman.

Segundo Turban, Sharda, Aronson e King (2009), são três os tipos de *dashboards*:

a) *Dashboards* operacionais. Usados por funcionários da linha de frente e por supervisores para monitorar os principais dados operacionais que são ligeiramente resumidos e atualizados com frequência durante o dia.

b) *Dashboards* táticos. Usados por gerentes e analistas para acompanhar diária ou semanalmente dados detalhados e resumidos, gerados a partir de processos e projetos departamentais.

c) *Dashboards* estratégicos. Usados por executivos, gerentes e equipe para monitorar mensal ou trimestralmente dados detalhados e resumidos, pertencentes à execução de objetivos estratégicos.

O projeto de um *dashboard* engloba diversas informações em uma única tela. O desafio fundamental do projeto é exibir todas as informações de forma objetiva e de uma maneira que possa ser interpretada rapidamente (Turban, Sharda, Aronson, & King, 2009).

Em geral, os *dashboards* exibem números (medidas quantitativas). Para acelerar a interpretação dos números, esses precisam ser colocados em um contexto. Isso pode ser feito comparando-se os números relevantes a outros

números de referência ou de alvo, indicando se os números estão bons, regulares ou ruins, mostrando se uma tendência é positiva ou negativa, e usando mecanismos ou componentes especializados de visualização para definir o contexto comparativo e evolutivo (Turban, Sharda, Aronson, & King, 2009).

2.2 Previsão da demanda de encomendas

O planejamento e o controle das atividades da cadeia de suprimentos e 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 (Ballou, 2006).

De acordo com Banzato, Carillo Junior, Banzato, Moura e Rago (2008), a necessidade de reduzir custos e 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. Essa questão, aliada às mudanças das necessidades dos clientes, será um elemento crítico na capacitação das empresas para competir com sucesso.

Destaca ainda Ballou (2006) 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.

A previsão de demanda é essencial para a empresa como um todo. Ela proporciona a entrada básica para o planejamento e controle de todas as áreas funcionais como: 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 (Ballou, 2006).

Para Slack, Chamber, Hardland, Harrison & Johnston (2009), prover a capacidade produtiva para satisfazer à demanda atual e futura é uma responsabilidade fundamental da administração de produção. O equilíbrio adequado entre capacidade e demanda satisfará 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 (Slack, Chamber, Hardland, Harrison & Johnston, 2009).

2.3 Previsão do absenteísmo

O absenteísmo em geral é definido como o não comparecimento ao trabalho, conforme o programado. Há historicamente uma longa pesquisa, já que esse fenômeno, em parte, gera um alto custo para as empresas, além de seu status de indicador desfavorável (Johns, 2010; Miraglia & Johns, 2015).

O absenteísmo é considerado a falta ou a ausência de um funcionário em seu ambiente de trabalho e pode ser definido também como a incapacidade temporária ou permanente dessa ausência (Martiniano, Ferreira, & Sassi, 2010).

O absenteísmo pode ser atribuído a causas conhecidas e a causas ignoradas. Entre as conhecidas, estão todas as amparadas por lei, justificadas ao empregador, solicitando-lhe a permissão de ausência. É o caso de férias, casamentos, nascimentos, óbitos e mudanças de domicílio. As ignoradas são justificadas geralmente por problemas de saúde do trabalhador e/ou de seus dependentes ou de fatores aleatórios os mais diversos (Penatti, Zago, & Quelhas, 2006).

Esses problemas podem ser evitados ao se reconhecer que o funcionário pode não estar disponível para realizar seu trabalho conforme o programado. Isso geralmente significa que o trabalho será feito de forma menos eficiente por outro funcionário ou não é será feito (Cascio & Boudreau, 2008).

De acordo com Martiniano, Ferreira, Affonso e Sassi (2012), com a previsão do absenteísmo, é possível estimar qual será a parcela da produtividade a ser afetada. Por exemplo, em determinado mês, estima-se uma taxa de absenteísmo de 6,5%,

que pode representar para a empresa 10%, 15% ou 20% a menos de capacidade produtiva. Essa informação antecipada ajuda na tomada de decisões em muitos aspectos, com o objetivo de reduzir os impactos do absenteísmo no trabalho:

- Planejamento de férias;
- Convocação de horas extras;
- Trabalho no fim de semana ou feriado;
- Contratação de mão de obra temporária;
- Remanejamento de efetivo interno ou externo, entre outras.

Neste contexto, a previsão do absenteísmo pode ser de grande ajuda na tomada de decisão, evitando a perda de produtividade e a ruptura no processo logístico (Martiniano, Ferreira, Affonso & Sassi, 2012).

2.4 Redes Neurais Artificiais (RNAs)

As Redes Neurais Artificiais (RNAs) são modelos constituídos por unidades de processamento simples, chamados de neurônios artificiais, que calculam funções matemáticas. Esses modelos são inspirados na estrutura do cérebro e têm como objetivo simular o comportamento humano, tais como: a aprendizagem, a associação, a generalização e a abstração, quando submetidas a treinamento (Haykin, 2001).

De acordo com Haykin (2001), as RNAs são particularmente eficientes para o mapeamento de entrada/saída de sistemas não lineares e para realizar processamento paralelo, além de simular sistemas complexos. As RNAs 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.

As RNAs podem ser aplicadas em diversas áreas e na solução de vários problemas, como: reconhecimento de padrões Haykin (2001), descoberta de conhecimento em bases de dados Sassi (2006), medicina (Blazadonakis & Michalis, 2008), previsão de risco de crédito (Selau & Ribeiro, 2009), indústria automotiva (Affonso, 2010), previsão do comportamento do tráfego veicular urbano (Ferreira, 2011), previsão do Absenteísmo (Martiniano, Ferreira, Affonso, & Sassi, 2012) e para identificar empregados absenteístas e presenteístas (Martiniano, Ferreira, &

Sassi, 2012), previsão de demanda (Ferreira et al., 2016) entre outros, conforme Tkác e Verner (2016).

Tkác e Verver (2016) realizaram uma vasta pesquisa entre os anos de 1994 e 2015 sobre a aplicação das redes neurais artificiais na área de negócios. Concluíram que as RNAs foram aplicadas em diversas áreas, como: gestão de recursos humanos, previsão de demanda, previsão do comportamento de ações, detecção de fraudes e em tarefas de classificação e agrupamento. Esses autores ressaltaram ainda que existe uma grande gama de assuntos para pesquisas adicionais.

2.4.1 A Multilayer Perceptron (MLP)

Uma RNA do tipo *Multilayer Perceptron* (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, em que o sinal de entrada se propaga pela RNA camada por camada. Na Figura 1 é apresentada a estrutura básica de uma RNA do tipo MLP.

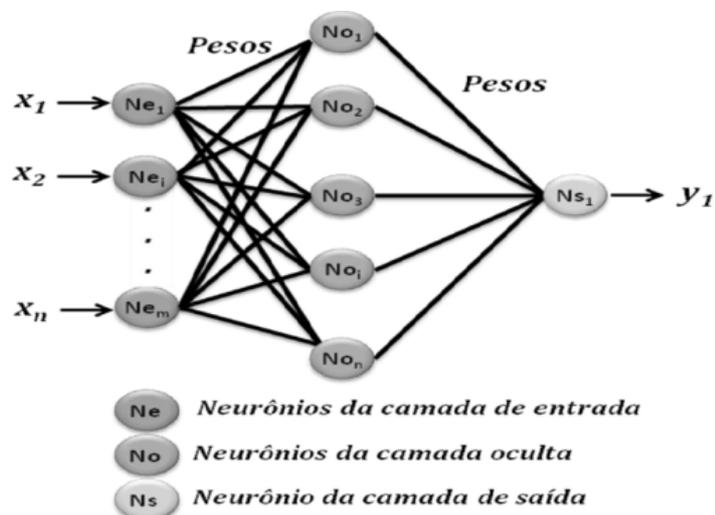


Figura 1
Estrutura básica da RNA do tipo MLP

Fonte: Adaptado de Sassi, R.J. (2006). Uma arquitetura híbrida para a descoberta de conhecimento em base de dados: teoria dos *rough sets* e redes neurais artificiais mapas auto organizáveis. (Tese de Doutorado em Engenharia Elétrica. Escola politécnica da Universidade de São Paulo, SP, Brasil). Recuperado de www.teses.usp.br/teses/disponiveis/3/3142/tde-16032007.../teseversaorevisada.pdf

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_m) 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) são formadas por um neurônio.

A rede MLP normalmente é aplicada em problemas de classificação Carvalho (2005), de aproximação (ou análise de regressão), que inclui previsão e modelagem de séries temporais em áreas como: controle (Mitchell, 1997), diagnóstico (Silva, 2009) e *data mining* (Bigus, 1996).

2.4.2 Algoritmo de treinamento

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 (Bigus, 1996).

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 (Simões & Shaw, 2007).

Como resultado do treinamento, a RNA 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, as RNAs podem aprender através de exemplos (Simões & Shaw, 2007).

O algoritmo de retroprogramação do erro ou *error back-propagation*, consiste, basicamente, em determinar as variações nos pesos sinápticos da MLP, tendo como objetivo minimizar o erro obtido na saída através do aprendizado do vetor de treinamento (entrada-saída), segundo Rumelhart, Hinton e Williams (1986).

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 (Haykin, 2001).

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 retropropagação 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)

$$f_{MLP}(x) = \varphi \left(\sum_1^{Non} v_l \cdot \varphi \left(\sum w_{lj} x_l + b_{l0} \right) + b_0 \right) \quad (1)$$

onde v_l e w_{lj} são pesos sinápticos; b_{l0} e b_0 são os *biases*; e φ a função de ativação, comumente especificada como sendo a função sigmóide. A Figura 2 mostra a função sigmóide.

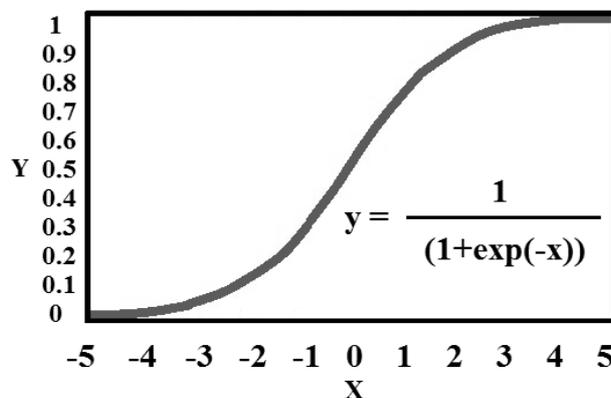


Figura 2

Função Sigmóide

Fonte: Adaptado de Sassi, J.R., Silva, L.A., & Hernandez, E. Del M. (2008). [A Methodology Using Neural Network to Cluster Validity Discovered from a Marketing Database](#). *10th Brazilian Symposium on Neural Networks*, Salvador, BA, Brasil.

O princípio deste algoritmo, para cálculo dos erros nas camadas intermediárias, é o seu cálculo por retroalimentação, possibilitando, dessa forma, o ajuste dos pesos proporcionalmente aos valores das conexões entre camadas. De acordo com Kaykin (2011), a MLP possui as seguintes características: função de

ativação não linear (sigmoïdal), uma ou mais camadas de neurônios ocultos e um alto grau de conectividade. Uma RNA MLP treinada com o algoritmo de retropropagação realiza um mapeamento não linear de entrada-saída.

De acordo com Simões e Shaw (2007), em um processo iterativo como o algoritmo de retropropagação do erro, uma questão importante é sobre o critério de parada do treinamento.

Em termos absolutos, a solução final ocorrerá para o índice de desempenho (erro global) igual a zero ou dentro de um valor muito pequeno. Contudo, se durante a fase de treinamento o erro não for pequeno e não tiver tendência a diminuir, dois enfoques podem ser adotados (Haykin, 2001):

a) Limitar o número de interações, ou seja, o treinamento cessa após ter ocorrido um valor limite, prefixado, de épocas de treinamento.

b) 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.

2.4.3 Mapa auto-organizável de Kohonen

O Mapa auto-organizável de Kohonen ou *Self Organizing Map* (SOM) foi desenvolvido pelo pesquisador finlandês Teuvo Kohonen no início da década de 80 (Kohonen, 1982).

A rede SOM é utilizada em uma gama de aplicações, incluindo agrupamento e visualização de dados multidimensionais (Kohonen, 2001). Essas características, utilizadas na geração de agrupamentos, também são chamadas de *clusters* (Vesanto, 2002; Vesanto & Alhoniemi, 2000). Os nós da rede SOM estão localmente interconectados por uma relação de vizinhança, determinando a topologia do mapa. Num mapa bidimensional, a vizinhança pode ser hexagonal ou retangular.

Segundo Kohonen (2001), em um mapa auto-organizável, os neurônios estão colocados em nós de uma grade, que é normalmente uni ou bidimensional. Os neurônios se tornam seletivamente sintonizados a vários padrões de entrada (estímulos) ou classes de padrões de entrada no decorrer de um processo de

aprendizagem.

O algoritmo de aprendizado da rede SOM é composto por três fases: competição, cooperação e adaptação (Kohonen, 2001):

a) Competição. Para cada padrão de entrada, os neurônios da grade calculam seus respectivos valores de uma função discriminante. Esta função discriminante fornece a base para a competição entre os neurônios. O neurônio com o maior valor da função discriminante é declarado vencedor da competição.

O princípio para o processo de aprendizado competitivo é a concorrência entre os neurônios, com o objetivo de determinar o vencedor da competição, pois o processo é não supervisionado, ou seja, não tem a saída desejada.

O prêmio para o neurônio vencedor da competição é o ajuste dos seus pesos, proporcionalmente aos valores do padrão de entrada apresentados, visando melhorar o seu estado para a próxima competição. Se todas as conexões laterais desse neurônio vencedor forem nulas, implica que somente os seus pesos serão ajustados e assume-se a estratégia de que o vencedor leva tudo. Por causa disso, este tipo de rede é também chamado de rede do tipo “o vencedor leva tudo” (*winner-takes-all*).

b) Cooperação. O neurônio vencedor determina a localização espacial de uma vizinhança topológica de neurônios excitados, fornecendo assim a base para a cooperação entre os neurônios vizinhos.

c) Adaptação Sináptica. Este último mecanismo permite que os neurônios excitados aumentem seus valores individuais da função discriminante em relação ao padrão de entrada através de ajustes adequados aplicados a seus pesos sinápticos. Os ajustes feitos são tais que a resposta do neurônio vencedor à aplicação subsequente de um padrão de entrada similar é melhorada.

Para cada dado apresentado à rede, haverá uma competição entre todos os neurônios pelo direito de representá-lo. Vence a competição o neurônio que tiver o vetor de pesos mais próximo do vetor de dados. A Figura 3 mostra um modelo da rede SOM.

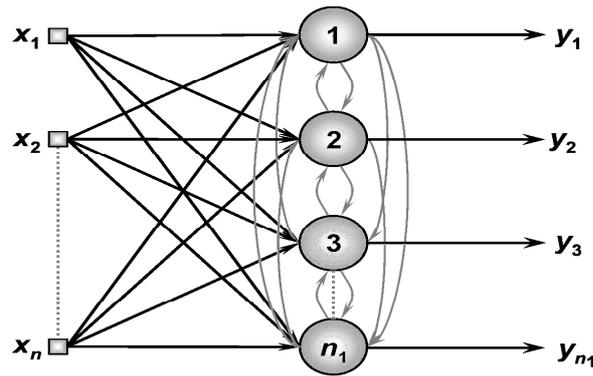


Figura 3

Modelo da rede SOM.

Fonte: Silva, I. N., Spatti, D. H., & Flauzino, R. A. (2010). *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas*. SP: Artliber.

As conexões laterais entre os neurônios da Figura 3 assumem o papel de que um neurônio pode influenciar na resposta de saída produzida por outro neurônio.

3 MÉTODOS DE TRABALHO

3.1 Método - Previsão da demanda de encomendas

A metodologia para a previsão da demanda de encomendas consiste no desenvolvimento de RNAs do tipo *multilayer perceptron*, treinadas através do algoritmo de *error back-propagation*. Os dados foram coletados numa empresa de grande porte durante 60 dias úteis, dos quais 45 dias foram destinados para treinamento e 15 dias para testes. Os parâmetros utilizados para o desenvolvimento da RNA no experimento 1 foram: número de neurônios de entrada igual a 12, número de camadas ocultas igual a 2, número de neurônios nas camadas ocultas igual a 5, taxa de aprendizado constante igual a 0,3, fator de momento constante igual 0,5, critério de parada erro igual 0,01 e número máximo de iterações ou épocas igual a 200. As doze entradas da RNA foram: semana do mês (primeira semana, segunda, terceira ou quarta semana); dia da semana (segunda a sexta-feira); encomendas urgentes; não urgentes; tipo de carga (três tipos: A, B, C); encomendas do setor fiscal; encomendas do setor controlador de trânsito e três entradas com clientes do setor financeiro. A saída da RNA é a Previsão da demanda de encomendas por dia. A Figura 4 mostra a arquitetura da RNA do tipo MLP utilizada no experimento 1.

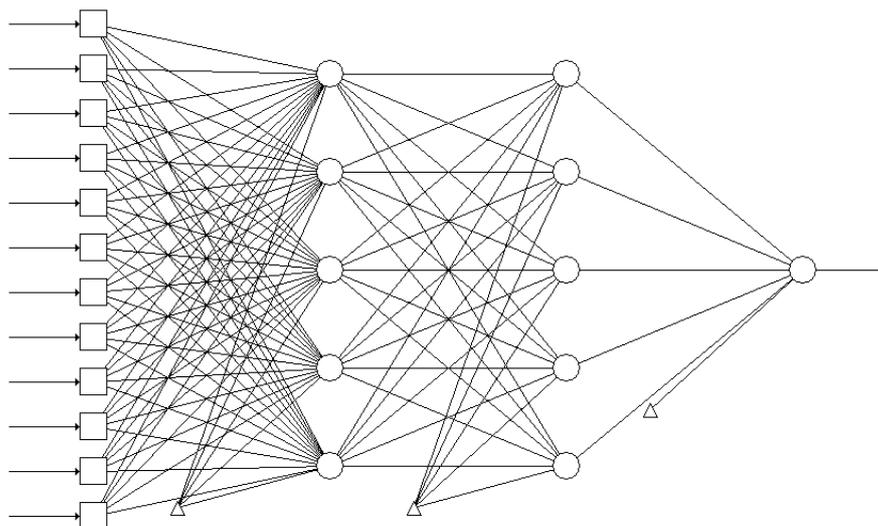


Figura 4
Arquitetura da RNA do tipo MLP (Previsão da demanda de encomendas).
Fonte: dados da pesquisa.

A Tabela 2 apresenta os parâmetros utilizados nos quatro experimentos realizados.

Tabela 2
Parâmetros utilizados na RNA do tipo MLP

Experimento	Número de neurônios de entrada	Camadas ocultas	Número de neurônios nas camadas ocultas	Taxa de aprendizado	Taxa de <i>momentum</i>	Critério de parada da RNA
Experimento 01	12	2	5	0,3	0,5	200 épocas
Experimento 02	12	2	7	0,5	0,7	200 épocas
Experimento 03	12	2	10	0,7	0,7	150 épocas
Experimento 04	12	3	5	0,5	0,9	100 épocas

Fonte: dados da pesquisa.

3.2 Método - Previsão do absentismo

A metodologia para a previsão do absentismo consiste no desenvolvimento de RNAs do tipo *multilayer perceptron*, treinadas através do algoritmo de *error back-propagation*. Os dados foram coletados numa empresa de grande porte durante 27 meses, sendo 24 meses para treinamento e 3 meses para teste. O parâmetro utilizado para o desenvolvimento da RNA no experimento foi: número de neurônios de entrada igual a 21, número de camadas ocultas igual a 2, número de neurônios nas camadas ocultas igual a 10, taxa de aprendizagem constante igual a 0,5, fator de momento constante igual 0,9, critério de parada erro igual 0,01 e número máximo de iterações ou épocas igual a 500. As 21 entradas da RNA foram o tempo de afastamento classificado através do Código Internacional de Doenças (CID).

A Tabela 3 apresenta o Código Internacional de Doenças por categorias. A saída da RNA é a Previsão do absentismo ao trabalho em horas.

Tabela 3
Código Internacional de Doenças

Capítulo	Descrição
I	Algumas doenças infecciosas e parasitárias (A00-B99)
II	Neoplasias [tumores] (C00-D48)
III	Doenças do sangue e dos órgãos <u>hematopoéticos</u> e alguns transtornos imunitários (D50-D89)
IV	Doenças endócrinas, nutricionais e metabólicas (E00-E90)
V	Transtornos mentais e comportamentais (F00-F99)
VI	Doenças do sistema nervoso (G00-G99)
VII	Doenças do olho e anexos (H00-H59)
VIII	Doenças do ouvido e da apófise <u>mastóide</u> (H60-H95)
IX	Doenças do aparelho circulatório (I00-I99)
X	Doenças do aparelho respiratório (J00-J99)
XI	Doenças do aparelho digestivo (K00-K93)
XII	Doenças da pele e do tecido subcutâneo (L00-L99)
XIII	Doenças do sistema osteomuscular e do tecido conjuntivo (M00-M99)
XIV	Doenças do aparelho geniturinário (N00-N99)
XV	Gravidez, parto e puerpério (O00-O99)
XVI	Algumas afecções originadas no período perinatal (P00-P96)
XVII	Malformações congênitas, deformidades e anomalias cromossômicas (Q00-Q99)
XVIII	Sintomas, sinais e achados anormais de exames clínicos e de laboratório, não classificados em outra parte (R00-R99)
XIX	Lesões, envenenamento e algumas outras consequências de causas externas (S00-T98)
XX	Causas externas de morbidade e de mortalidade (V01-Y98)
XXI	Fatores que influenciam o estado de saúde e o contato com os serviços de saúde (Z00-Z99)

Fonte: Disponível em <http://blog.doctorfound.com/tabela-cid-completa/>

A Figura 5 mostra a arquitetura da RNA do tipo MLP utilizada no experimento.

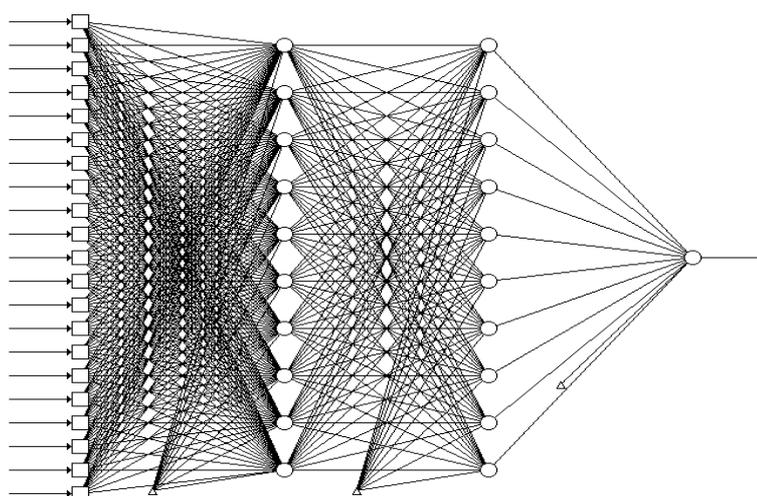


Figura 5
Arquitetura da RNA do tipo MLP (Previsão do absentismo)
Fonte: dados da pesquisa

3.3 Método - rede SOM

As entradas da rede SOM foram: Dia da semana, encomendas urgentes e encomendas não urgentes.

Os Parâmetros utilizados na rede SOM foram:

a) Vizinhança topológica: hexagonal.

Segundo Haykin (2001), a vizinhança topológica hexagonal oferece tradicionalmente resultados melhores que a vizinhança retangular. Para Kohonen (2001), a vizinhança topológica hexagonal proporciona melhor qualidade na análise visual dos agrupamentos; por esse motivo, essa última foi a escolhida.

b) Função de vizinhança topológica: gaussiana.

A função de vizinhança topológica gaussiana faz com que o algoritmo da rede SOM convirja com maior rapidez (Haykin, 2001). Para Kohonen (2001), a função de vizinhança baseada em uma gaussiana tende a destacar melhor os agrupamentos.

Os Parâmetros de treinamento utilizados na rede SOM são os seguintes:

a) Número de épocas igual a 2500.

b) Taxa de aprendizagem igual a $\eta = 0,5$ na fase inicial de treinamento e, na fase de convergência, a taxa foi de $\eta = 0,05$ (Kaski & Kohonen, 1997).

4 RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS

Uma vez apresentados nas seções anteriores os Métodos de Trabalho e o Referencial Teórico, nesta seção são apresentados os resultados dos experimentos.

4.1 Método experimental 1: Previsão de demanda de encomendas

A Figura 6 mostra a fase de treinamento da MLP (dados reais e a saída da rede - experimento 1). O eixo x corresponde aos dias de treinamento, o eixo y corresponde à quantidade de encomendas.

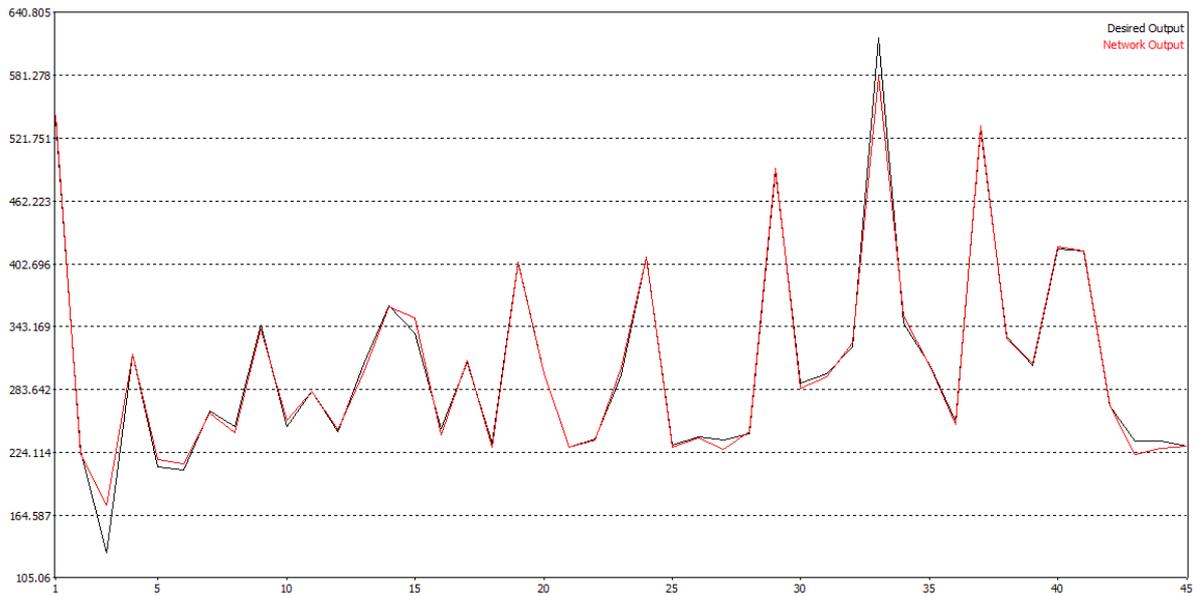


Figura 6
Fase de Treinamento da RNA. Experimento 1
Fonte: dados da pesquisa.

A Figura 7 mostra a fase de teste da MLP (dados reais e dados de saída da rede - experimento 1), referente ao período de previsão.

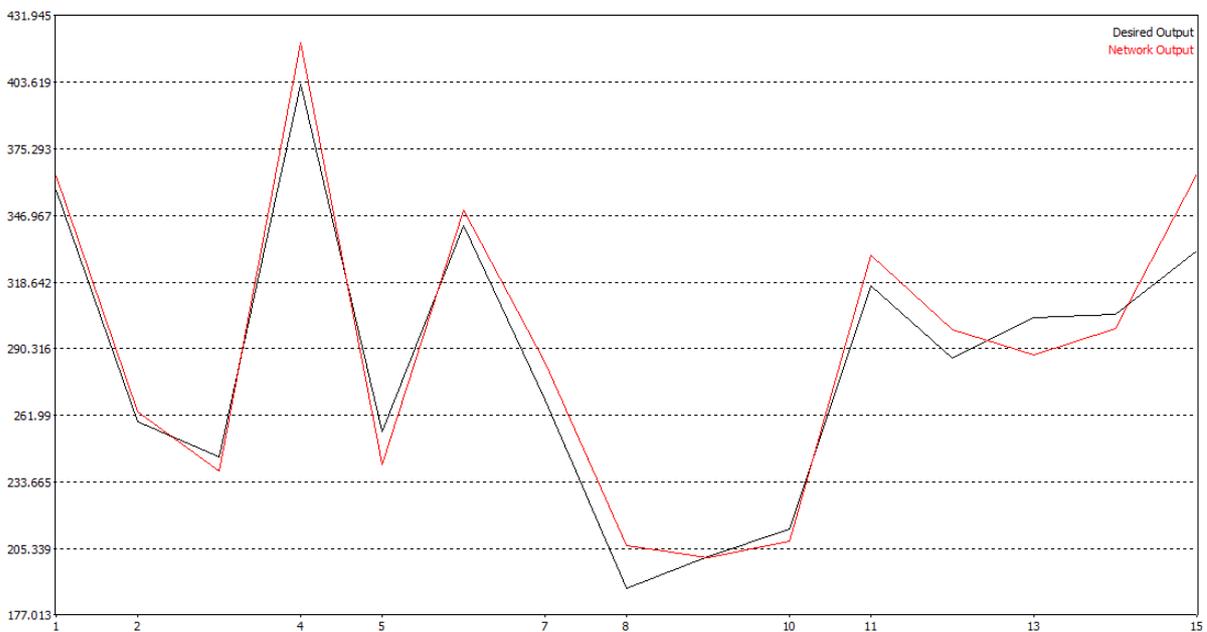


Figura 7
Fase de Teste da RNA. Experimento 1
Fonte: dados da pesquisa.

A Figura 8 mostra a fase de treinamento da MLP (dados reais e dados de saída da rede - experimento 2).

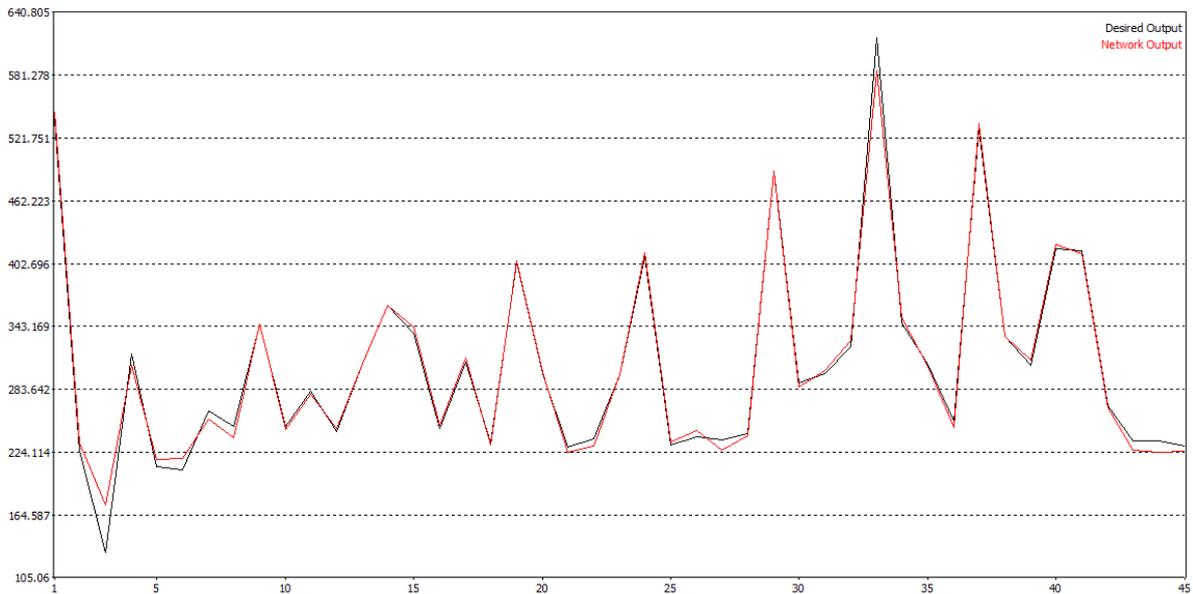


Figura 8
Fase de Treinamento da RNA. Experimento 2.
Fonte: dados da pesquisa.

A Figura 9 mostra a fase de teste da MLP (dados reais e dados de saída da rede - experimento 2), referente ao período de previsão.

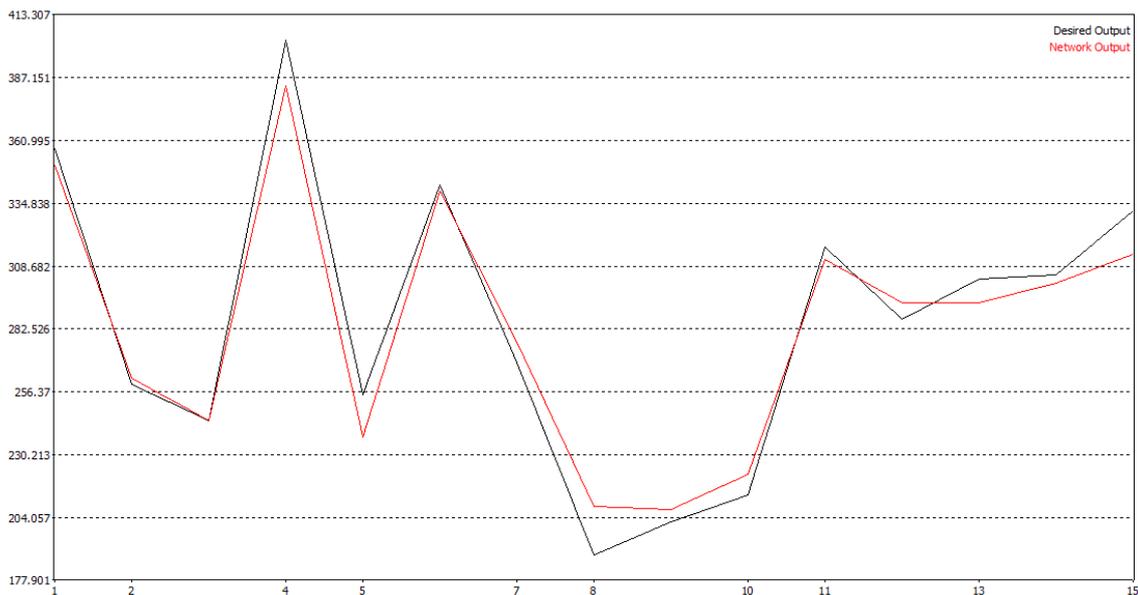


Figura 9
Fase de teste da RNA. Experimento 2.
Fonte: dados da pesquisa.

A Figura 10 mostra a fase de treinamento da MLP (dados reais e dados de saída da rede - experimento 3).

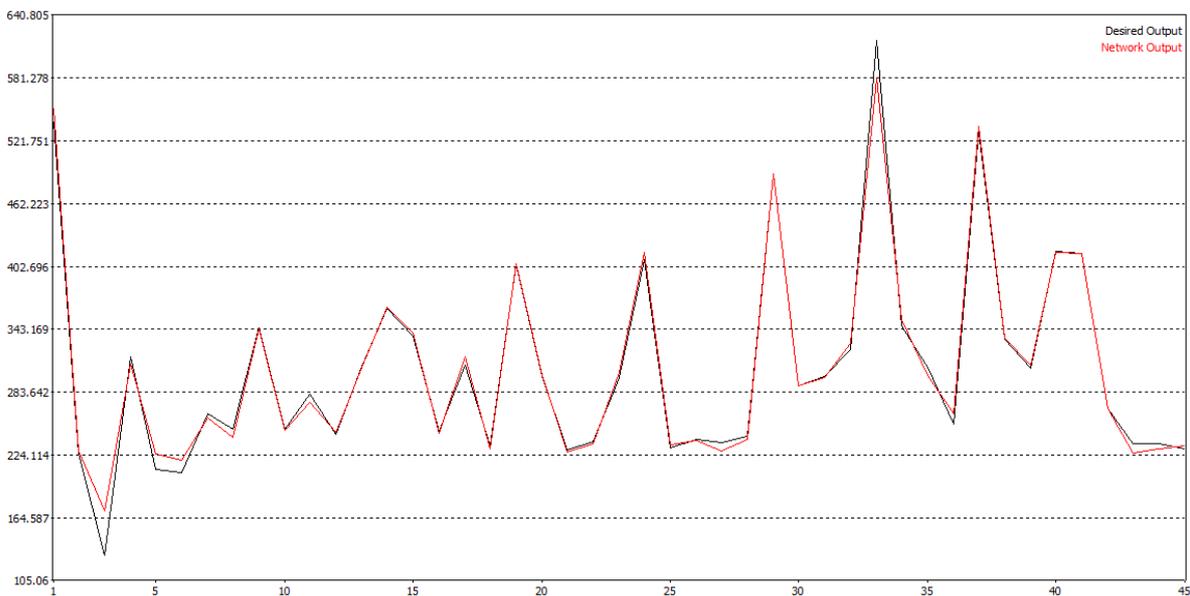


Figura 10
Fase de treinamento da RNA. Experimento 3.
Fonte: dados da pesquisa.

A Figura 11 mostra a fase de teste da MLP (dados reais e dados de saída da rede - experimento 3), referente ao período de previsão.

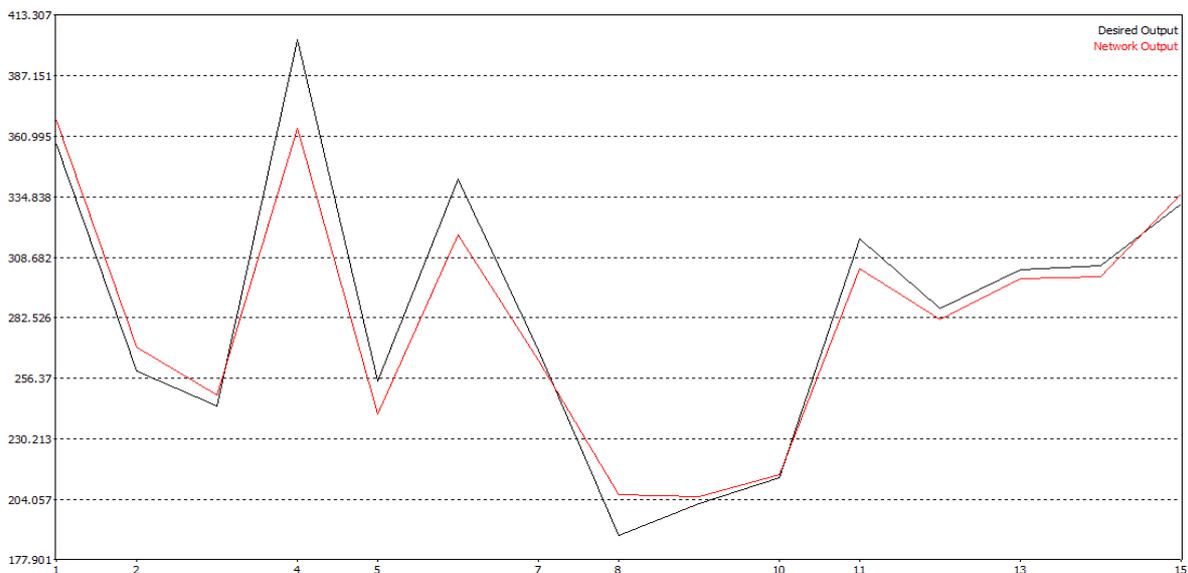


Figura 11
Fase de teste da RNA. Experimento 3.
Fonte: dados da pesquisa.

A Figura 12 mostra a fase de treinamento da MLP (dados reais e dados de saída da rede - experimento 4).

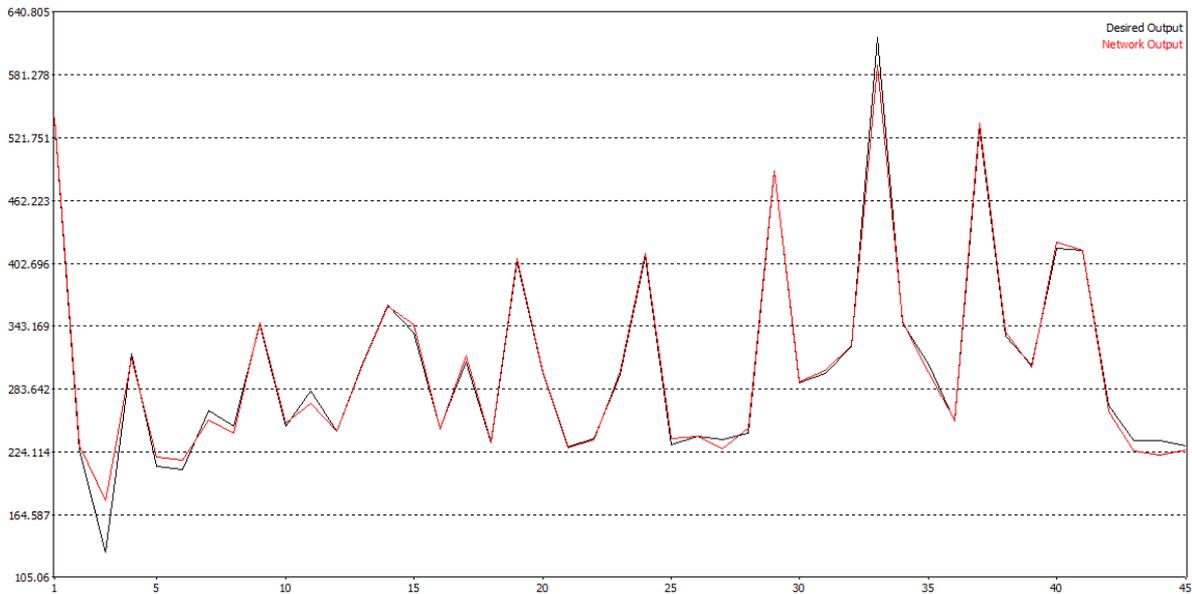


Figura 12
Fase de treinamento da RNA. Experimento 4.
Fonte: dados da pesquisa.

A Figura 13 mostra a fase de teste da MLP (dados reais e dados de saída da rede - experimento 4), referente ao período de previsão.

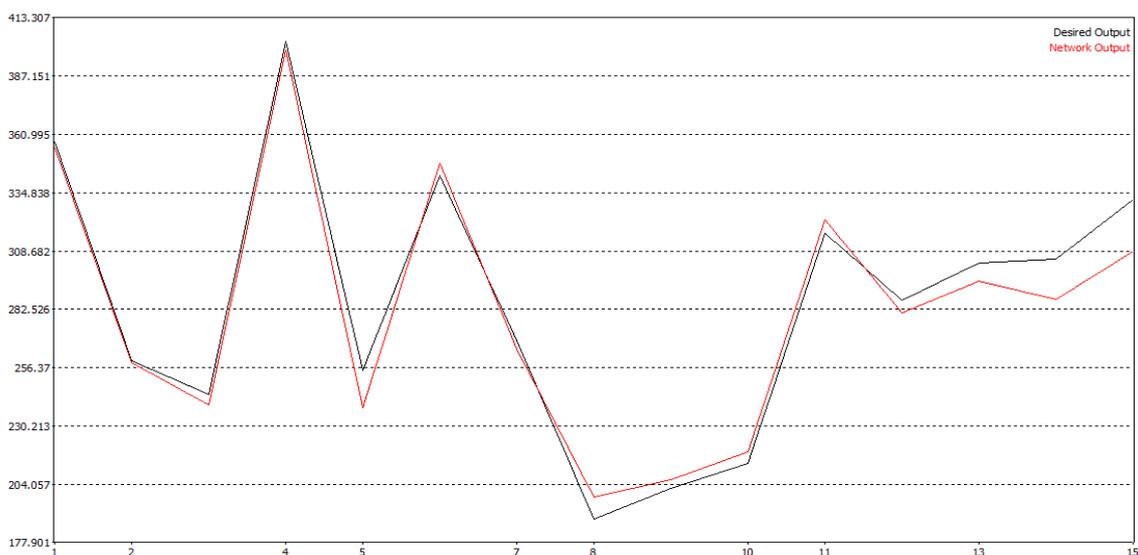


Figura 13
Fase de teste da RNA. Experimento 4.
Fonte: dados da pesquisa.

A Tabela 4 apresenta os resultados dos experimentos 1 (um) e 2 (dois).

Tabela 4
Experimentos 1 e 2

Experimento 1				Experimento 2			
Saída desejada	Saída da RNA	Erro	Erro (%)	Saída desejada	Saída da RNA	Erro	Erro (%)
357394	363820	-6.426	1,80%	357394	350884	6.510	-1,82%
259246	263467	-4.221	1,63%	259246	262099	-2.853	1,10%
244235	238234	6.001	-2,46%	244235	244316	-81	0,03%
402607	420356	-17.749	4,41%	402607	383946	18.661	-4,64%
255061	241088	13.973	-5,48%	255061	237569	17.492	-6,86%
342606	349398	-6.792	1,98%	342606	339828	2.778	-0,81%
268640	284392	-15.752	5,86%	268640	277184	-8.544	3,18%
188601	206413	-17.812	9,44%	188601	208709	-20.108	10,66%
202022	201645	377	-0,19%	202022	207233	-5.211	2,58%
213509	208241	5.268	-2,47%	213509	221871	-8.362	3,92%
316849	330183	-13.334	4,21%	316849	311335	5.514	-1,74%
286412	298236	-11.824	4,13%	286412	293366	-6.954	2,43%
303447	287562	15.885	-5,23%	303447	293479	9.968	-3,28%
304950	298795	6.155	-2,02%	304950	301712	3.238	-1,06%
331900	364577	-32.677	9,85%	331900	313555	18.345	-5,53%

Fonte: dados da pesquisa.

Observa-se no experimento 1 que os maiores erros são de 9,44% e 9,85%. No experimento 2, o maior erro é de 10,66%. Os demais resultados apresentam erros menores.

A Tabela 5 apresenta os resultados dos experimentos 3 e 4.

Tabela 5
Experimentos

3

e

4

Experimento 3				Experimento 4			
Saída desejada	Saída da RNA	Erro	Erro (%)	Saída desejada	Saída da RNA	Erro	Erro (%)
357394	368063	-10669	2,99%	357394	354985	2409	-0,67%
259246	269817	-10571	4,08%	259246	258795	451	-0,17%
244235	249214	-4979	2,04%	244235	239476	4759	-1,95%
402607	364619	37988	-9,44%	402607	398959	3648	-0,91%
255061	240887	14174	-5,56%	255061	238451	16610	-6,51%
342606	318292	24314	-7,10%	342606	348095	-5489	1,60%
268640	264040	4600	-1,71%	268640	264455	4185	-1,56%
188601	206145	-17544	9,30%	188601	198491	-9890	5,24%
202022	205087	-3065	1,52%	202022	206296	-4274	2,12%
213509	214609	-1100	0,52%	213509	218679	-5170	2,42%
316849	303630	13219	-4,17%	316849	322827	-5978	1,89%
286412	281644	4768	-1,66%	286412	281091	5321	-1,86%
303447	299470	3977	-1,31%	303447	295232	8215	-2,71%

Fonte: dados da pesquisa.

Observa-se no experimento 3 que os maiores erros são de 9,30% e 9,44%. No experimento 4, o maior erro é de 7,04%. Os demais resultados apresentam erros menores. Concluiu-se que o experimento 4 apresentou o melhor resultado.

Observou-se nos resultados apresentados, tanto na fase de treinamento, como na fase de testes, que os quatro experimentos mostraram resultados satisfatórios, encorajando a realização de novos experimentos utilizando outras arquiteturas de RNAs e outras entradas, buscando melhorar o modelo proposto.

4.2 Método experimental 2: Previsão do absentéismo

A Figura 14 mostra a fase de treinamento da MLP (dados reais e dados de saída da rede). O eixo x corresponde aos meses de treinamento (24 meses), o eixo y corresponde ao absentéismo total do mês em horas.

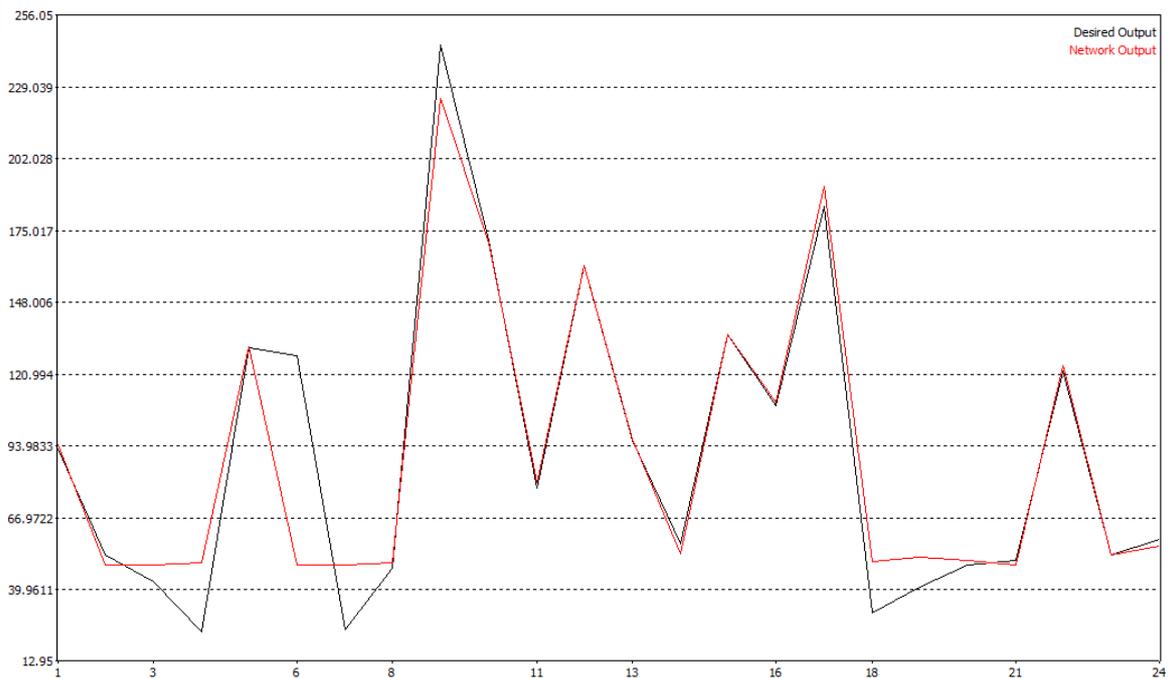


Figura 14
Fase de treinamento da MLP.
Fonte: dados da pesquisa.

Observa-se, na fase de treinamento, que a MLP foi capaz de aprender o padrão de comportamento.

A Figura 15 mostra a fase de teste da MLP (dados reais e dados de saída da rede), referente ao período de previsão do absentismo (3 meses).

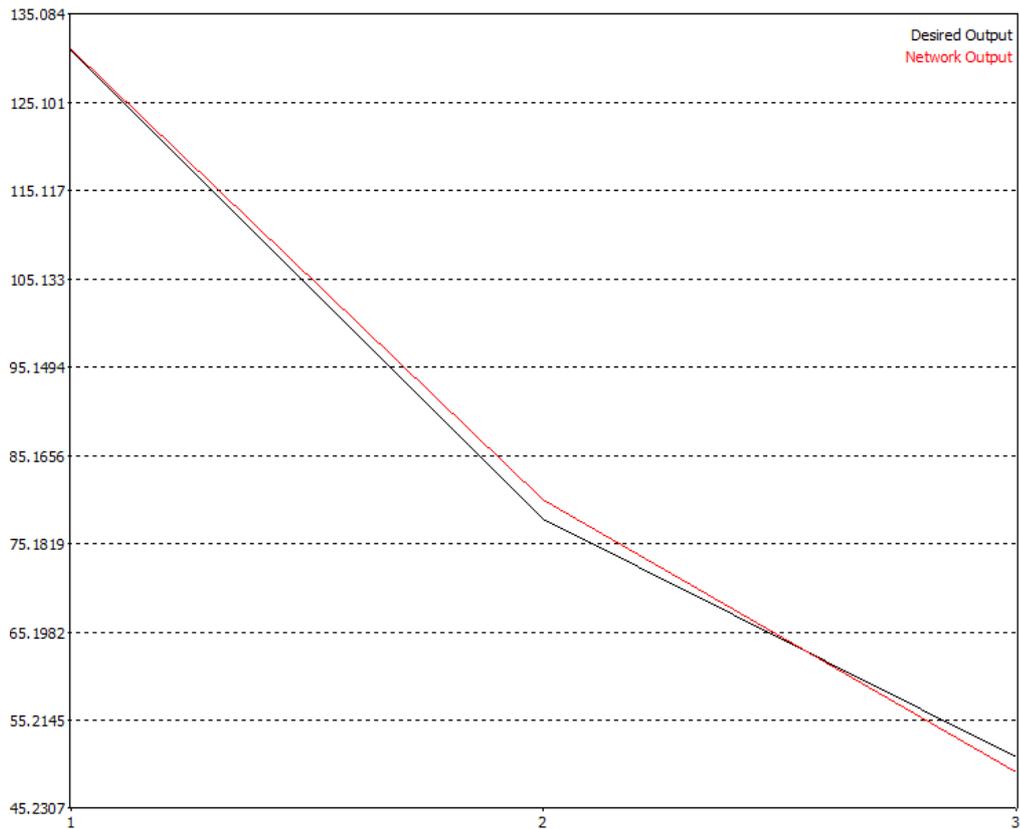


Figura 15
Fase de teste da RNA
Fonte: dados da pesquisa.

A Tabela 6 apresenta os resultados do experimento (Previsão do absenteísmo).

Tabela 6
Experimento (Previsão do absenteísmo)

Saída desejada	Saída da RNA	Erro	Erro (%)
131	131,152359	-0,152359	-0,10%
78	80,166964	-2,166964	-2,70%
51	49,314984	1,685016	3,40%

Fonte: dados da pesquisa.

Observa-se que a MLP conseguiu resultados bastante próximos aos dados reais, permitindo auxiliar na tomada de decisão quanto à ação que deve ser tomada para reduzir o risco de ruptura do processo logístico.

4.3 Experimentos computacionais – Mapa Auto-Organizável de Kohonen

O Mapa Auto-Organizável é uma arquitetura de rede neural artificial, em que as principais aplicações estão no campo de agrupamento, classificação e visualização de dados. Por esse motivo também foi escolhida para compor os experimentos computacionais nesse artigo.

A Figura 16 mostra os *clusters* gerados pela rede SOM.

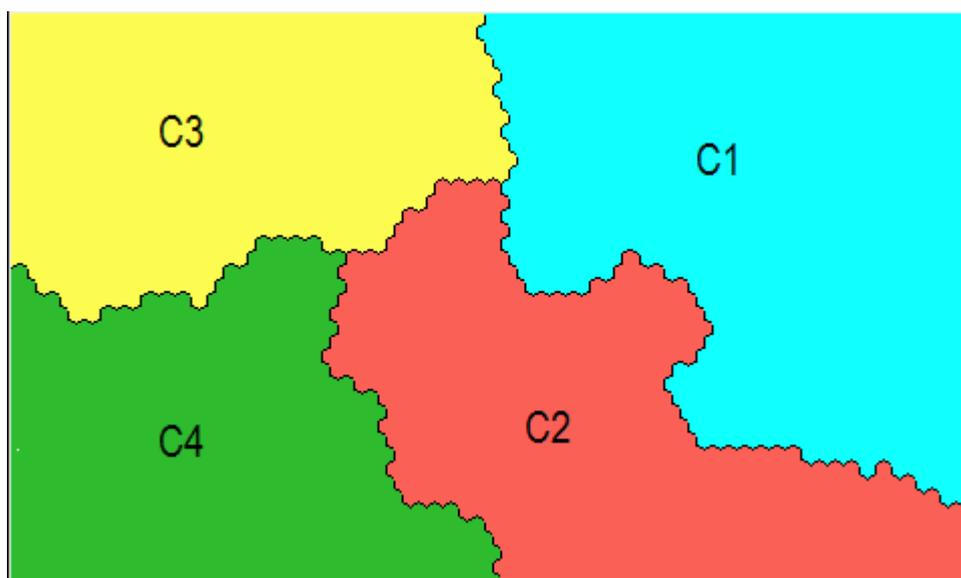


Figura 16

Rede SOM rotulada

Fonte: dados da pesquisa.

A rede SOM agrupou os registros com base na similaridade dos atributos, permitindo a análise dos *clusters* gerados. Observa-se que apenas quatro *clusters* foram gerados, o que indica que dois dias da semana tem características bastante semelhantes entre si.

A Figura 17 mostra os *clusters* gerados pela rede SOM (Atributo Dia da Semana).

Observa-se que existem semelhanças nas demandas de encomendas entre as terças e quartas-feiras e entre as quintas e sextas-feiras. As segundas-feiras não apresentam semelhanças com as demandas de encomendas nos demais dias da semana.

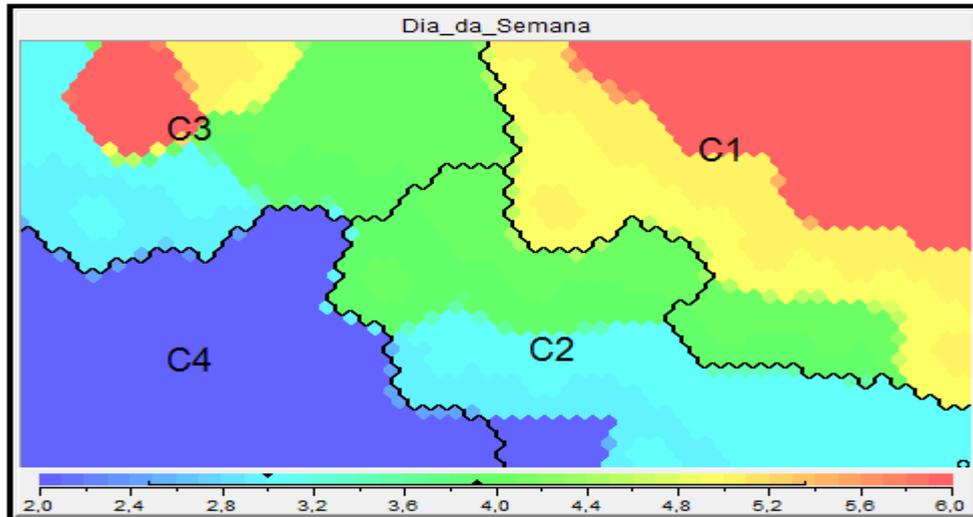


Figura 17
Atributo Dia da Semana
Fonte: dados da pesquisa.

A Figura 18 mostra os *clusters* gerados pela rede SOM (Atributo Encomendas Urgentes). Observa-se que nas segundas-feiras a demanda de encomendas urgentes é bastante elevada, demandando mais tempo e recursos para o processo logístico, sendo o dia, isoladamente, com maior demanda de encomendas urgentes.

As terças, quartas e sextas-feiras apresentam algumas demandas com ponto mais elevado entre 150.000 e 160.000 encomendas. As quintas-feiras apresentam as menores demandas e variações de demanda de encomendas urgentes.

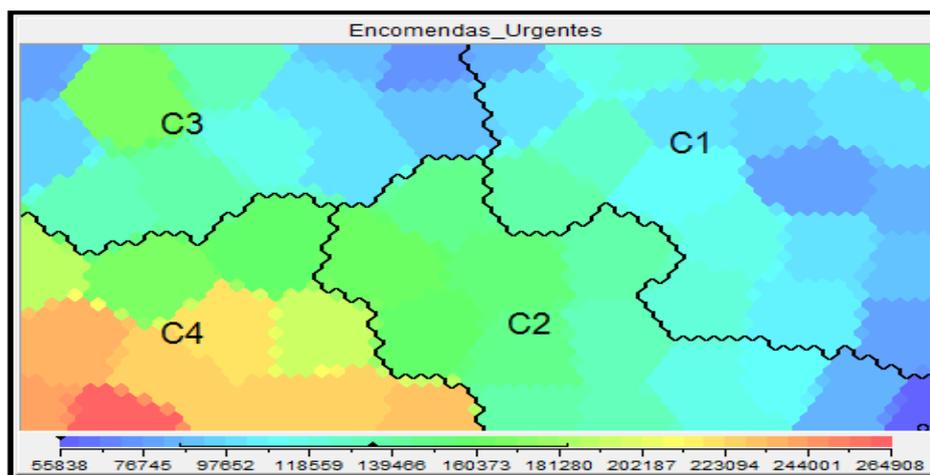


Figura 18
Atributo Encomendas Urgentes
Fonte: dados da pesquisa.

A Figura 19 mostra os *clusters* gerados pela rede SOM (Atributo Encomendas Não Urgentes). Observa-se que as segundas e terças-feiras apresentam algumas demandas de encomendas não urgentes com ponto mais elevado entre 320.000 e 336.000 encomendas. Apresentam ainda algumas demandas entre 155.000 e 207.000 encomendas. As quintas e sextas-feiras apresentam as menores demandas e variações de demanda de encomendas não urgentes.

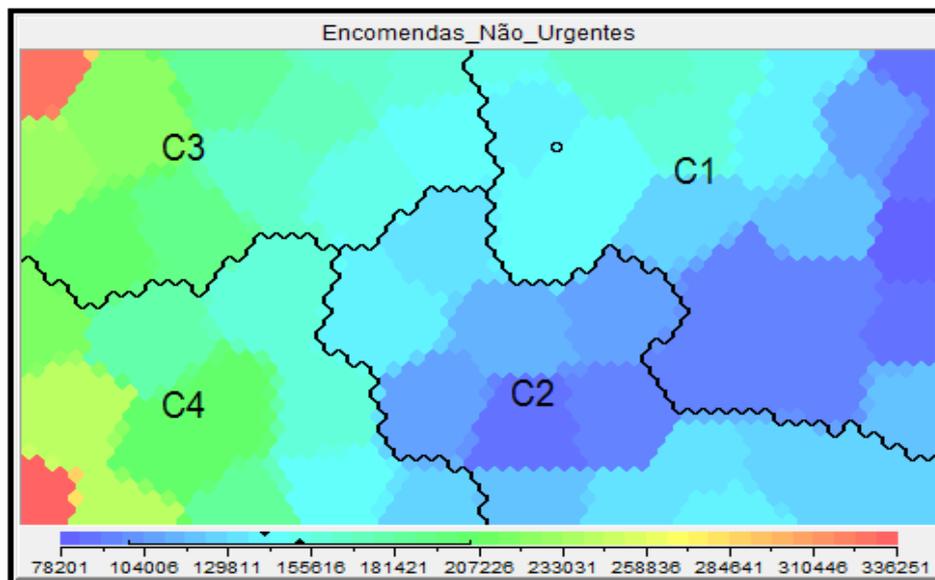


Figura 19
Atributo Encomendas Não Urgentes.
Fonte: dados da pesquisa

5 DASHBOARD INTELIGENTE

O *dashboard* inteligente apresentado nessa seção tem características operacionais e é feito para utilização na linha de frente por supervisores para monitorar os principais dados operacionais que são resumidos e atualizados com frequência durante o dia.

A Figura 20 mostra o *dashboard* inteligente proposto após as compilações e processamentos realizados nos experimentos computacionais com o uso de técnicas de Inteligência Artificial, conforme o apresentado na seção anterior.

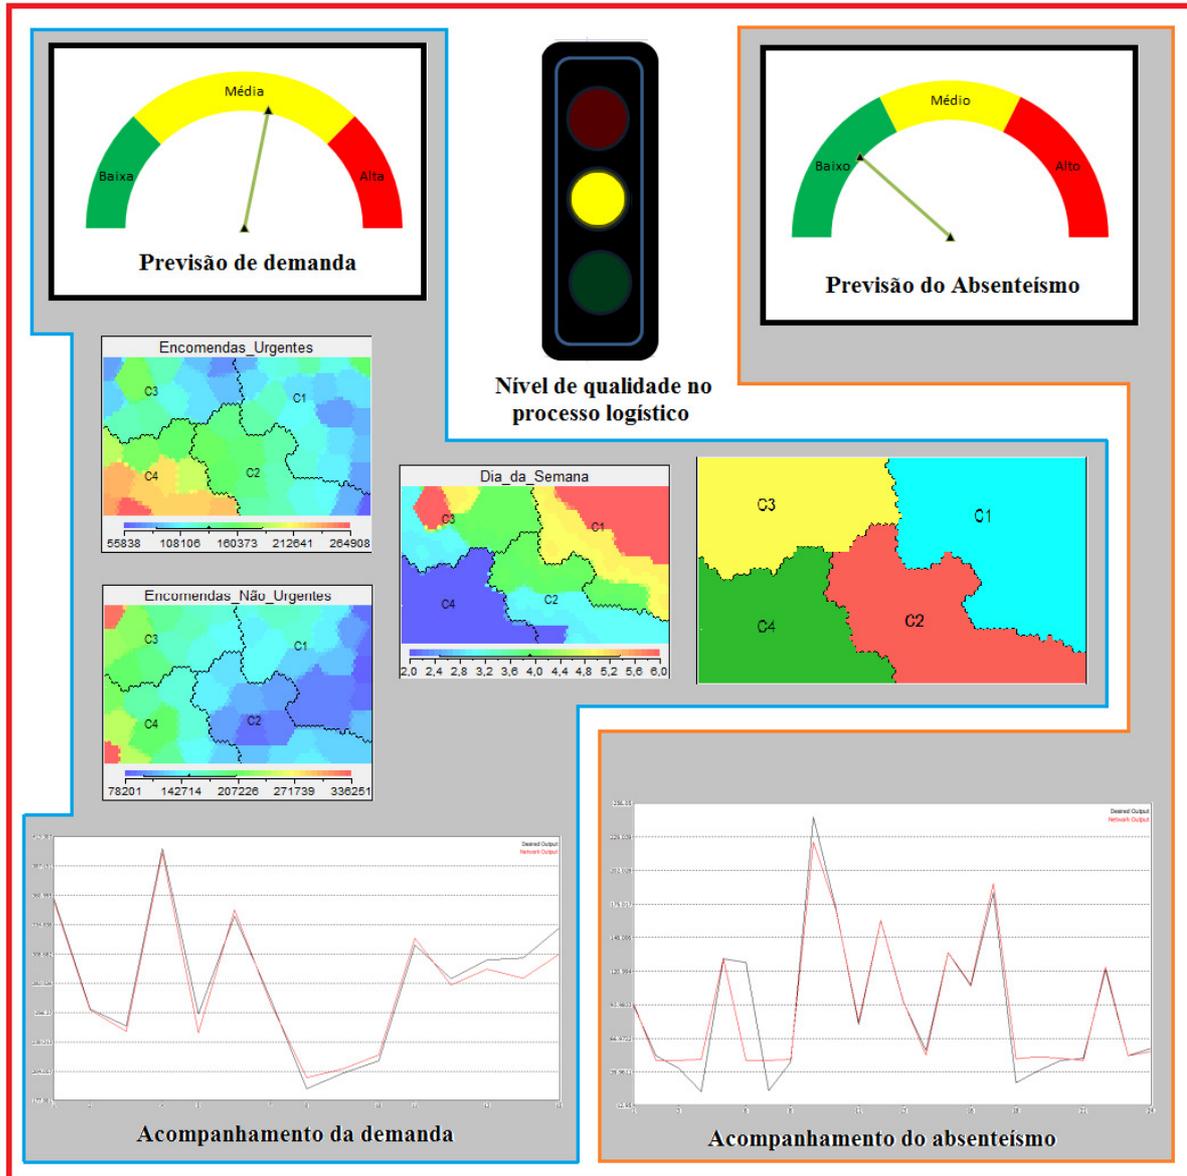


Figura 20
Dashboard Inteligente.
Fonte: elaborado pelos autores.

O semáforo do *dashboard* inteligente tem a função de informar de imediato a situação da operação logística de maneira objetiva; a saber, neste caso, a previsão de demanda de encomendas e a previsão do absenteísmo.

- O semáforo na cor verde indica que a operação logística ocorrerá dentro do padrão de qualidade desejado, sem risco de ruptura durante o processo logístico.

- O semáforo na cor amarela indica que a operação logística precisa de pequenos ou médios ajustes para que ocorra dentro do padrão de qualidade desejado, eliminando risco de ruptura durante o processo logístico.

- O semáforo na cor vermelha indica que a operação logística precisa de grandes e imediatos ajustes para que ocorra dentro do padrão de qualidade desejado, evitando risco de ruptura durante o processo logístico.

6 CONSIDERAÇÕES FINAIS

O *dashboard* inteligente proposto tem a função de fornecer de forma rápida o *status* diário do processo de operação logística e os indicadores da previsão da demanda de encomendas e previsão do absenteísmo.

A apresentação das informações no *dashboard* permite adequar recursos produtivos conforme a demanda diária, evitando ou eliminando rupturas durante o processo logístico de tratamento e consequente perda de prazo de entrega, além de reduzir o custo com recursos disponibilizados desnecessariamente em operações mal dimensionadas.

Pretende-se, com estudos futuros, ampliar a pesquisa com a realização de novos experimentos, acrescentando outros indicadores importantes no processo logístico de transporte, tratamento e distribuição de encomendas. Pretende-se também utilizar outras técnicas de Inteligência Artificial para ampliar a pesquisa apresentada no artigo.

REFERÊNCIAS

- Affonso, C., Sassi, R. J., & Barreiros, R. M. (2015). Biological image classification using rough-fuzzy artificial neural network. *Expert Systems with Applications*, 42, 9482-9488.
- Ballou, R. H. (2006). *Gerenciamento da Cadeia de Suprimentos/Logística Empresarial* (5a ed.). Porto Alegre: Bookman.
- Banzato, E., Carillo Junior, E., Banzato, J. M., Moura, R. A., & Rago, S. F. T. (2008). *Atualidades na armazenagem*. São Paulo: IMAM.
- Bigus, J. P. (1996). *Data Mining with Neural Network: Solving Business Problems from Applications Development to Decision Support*. McGraw-Hill.
- Blazadonakis, E., & Michalis, Z. (2008). Support Vector Machines and Neural Networks as Marker Selectors in Cancer Gene Analysis. *Intelligent Techniques and Tools for Novel System Architectures*. Berlin, Heidelberg: Springer-Verlag, pp. 237-258.

- Bowersox, D. J., & Closs, D. J. (2010). *Logística Empresarial: o processo de integração da cadeia de suprimento*. São Paulo: Atlas.
- Braga, A. P., Carvalho, A. C. P. L. F., & Ludermir, T. B. (2011). *Redes Neurais Artificiais: Teoria e Aplicações (2a ed.)*. Rio de Janeiro: Ed. LTC.
- Carvalho, L. A. V. (2005). *Data Mining: a Mineração de dados no Marketing, Medicina, Economia, Engenharia e Administração*. Rio de Janeiro: Editora Ciência Moderna Ltda.
- Cascio, W., & Boudreau, J. (2008). *Investing in People: Financial Impact of Human Resource Initiatives*, Pearson Education, Inc. New Jersey: FT Press.
- Ferreira, R. P. (2011). *Combinação de Técnicas da Inteligência Artificial para Previsão do Comportamento do Tráfego Veicular Urbano na Cidade de São Paulo*. (Dissertação de Mestrado em Engenharia de Produção, Universidade Nove de Julho, São Paulo, SP, Brasil).
- Ferreira, R. P., Sassi, R. J., & Martiniano, A. (2015). Applying Ant Colony Optimization and Kohonen Self-Organizing Map in Vehicle Routing and Scheduling Problems. *Pesquisa Naval (SDM)*, 27, 69-80.
- Ferreira, R. P., Martiniano, A., Ferreira, A. & Sassi, R. J. (2016). Study on daily demand forecasting orders using artificial neural network. *IEEE Latin America Transactions*, 14 (3), 1519-1525.
- Haykin, S. (2001). *Redes Neurais – Princípios e Práticas (2a ed.)*. Porto Alegre: Bookman.
- Johns, G. (2010). Presenteeism in the workplace: A review and research agenda. *Journal of Organizational Behavior*, 31, 519 – 542.
- Johns, G. (2003). How methodological diversity has improved our understanding of absenteeism from work. *Human Resource Management Review*, 13 (2), 157-184.
- Kaski, S., & Kohonen, T. (1997). Winner-Takes-All Networks. *Triennial Report (1994 – 1996)*, Neural Networks Research Centre & Laboratory of Computer and Information Science, Helsinki University of Technology, Finland.
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43, 59-69.
- Kohonen, T. (2001). *Self-Organizing Maps (3a. ed.)*. New York, Springer.
- Martiniano, A. S., Ferreira, R. P., Affonso, C. & Sassi, R. J. (2012). Aplicação de uma Rede Neuro Fuzzy na Previsão do Absenteísmo no Trabalho. *CISTI'2012 - 7ª Conferencia Ibérica de Sistemas y Tecnologías de Información*, II, 41-44.
- Martiniano, A., Ferreira, R. P., & R. J. Sassi. (2010). *Control and monitoring of the indexes of absenteeism and presenteeism with aid of the technology of the information*. 7º CONTECSI, 7ª Conferência Internacional sobre Sistemas de

Informação e Gestão de Tecnologia. ISBN: 978-85-99693-06-30, p. 489-506.

- Martiniano, A., Ferreira, R. P., & Sassi, R. J. (2012). Aplicação da Mineração de Dados na Identificação de Empregados Absenteístas e Presenteístas de uma Empresa de *Courier* da Cidade de São Paulo. *VIII– EMEPRO, Encontro Mineiro de Engenharia de Produção*. Itajubá, MG, Brasil.
- Miraglia, M., Johns, G. (2015). Going to Work III: A Meta-Analysis of the Correlates of Presenteeism and a Dual-Path Model. *Journal of Occupational Health Psychology*, pp.1-23.
- Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
- Penatti, I., Zago, J. S., & Quelhas, O. (2006). Absenteísmo: as consequências na gestão de pessoas. *III SEGeT – Simpósio de Excelência em Gestão e Tecnologia*. Recuperado de periodicos.sbu.unicamp.br/ojs/index.php/labore/article/download/8634453/8156
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning Internal Representations by Error Propagation. In *Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Vol. 1: Foundations*, D. E. (Rumelhart and J. L. McClelland, Eds.). *Mit Press Computational Models Of Cognition And 12 Perception Series*. MIT Press, Cambridge, MA. (pp. 318-362).
- Sassi, R.J. (2006). Uma arquitetura híbrida para a descoberta de conhecimento em base de dados: teoria dos *rough sets* e redes neurais artificiais mapas auto-organizáveis. (Tese de Doutorado em Engenharia Elétrica. Escola politécnica da Universidade de São Paulo, SP, Brasil). Recuperado de www.teses.usp.br/teses/disponiveis/3/3142/tde-6032007.../teseversaorevisada.pdf
- Sassi, R. J. (2012). An Hybrid Architecture for Clusters Analysis: Rough Sets Theory and Self-Organizing Map Artificial Neural Network. *Pesquisa Operacional* (Impresso), 32, 139-163.
- Sassi, J.R., Silva, L.A., & Hernandez, E. Del M. (2008). [A Methodology Using Neural Network to Cluster Validity Discovered from a Marketing Database](#). *10th Brazilian Symposium on Neural Networks*, Salvador, BA, Brasil.
- Selau, L. P. R., & Ribeiro, J. L. D. (2009). Uma sistemática para construção e escolha de modelos de previsão de risco de crédito. *Gestão Produção*, 16 (3), 398-413.
- Silva, L. A. (2009). *Categorização de Imagens Médicas para Sistemas de Recuperação de Imagens por Conteúdo Baseada em Transformada Wavelet e Mapas Auto-Organizáveis*. (Tese de Doutorado em Engenharia Elétrica. Escola Politécnica da Universidade de São Paulo, São Paulo, SP, Brasil).
- Silva, I. N., Spatti, D. H., & Flauzino, R. A. (2010). *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas*. SP: Artliber.

- Simões, M. G., & Shaw, I. S. (2007). *Controle e Modelagem fuzzy*. São Paulo: Blucher - FAPESP.
- Slack, N., Chamber, S., Hardland, C., Harrison, A., & Johnston, R. (2009). *Administração da Produção*. São Paulo: Atlas.
- Tkác, M., & Verner, R. (2016). Artificial neural networks in business: Two decades of research. *Applied Soft Computing*, 38, 788–804.
- Today Logistics & Supply Chain* (2009). São Paulo: Cecilia Borges, Ano III, (38).
- Turban, E., Sharda, R., Aronson, J. E., & King, D. (2009). *Business Intelligence: Um enfoque gerencial para a inteligência do negócio*. Porto Alegre: Bookman.
- Vesanto, J. (2002). *Data Exploration Process Based on the Self-Organizing Map*. PhD thesis, Helsinki University of Technology.
- Vesanto, J. & Alhoniemi, E. (2000). Clustering of the Self-Organizing Map. *IEEE Transactions on Neural Networks*, 11 (2), 586-600.