

PREVISÃO DE FATURAMENTO PARA LOJAS DO SETOR DE VAREJO COM REDES NEURAIAS

Laura Araújo Alves

Universidade Federal Fluminense

laura_alves_aa@yahoo.com.br

Rachel Cardoso Chicralla

Universidade Federal Fluminense

chelchicralla@gmail.com

Vivian Peçanha Leite

Universidade Federal Fluminense

vivianpleite@hotmail.com

João Carlos Correia Baptista Soares de Mello

Universidade Federal Fluminense

joacsmello@gmail.com

Luiz Biondi Neto

Universidade do Estado do Rio de Janeiro

luizbiondi@terra.com.br

Resumo

Este estudo tem por objetivo desenvolver uma metodologia de previsão de demanda para lojas do setor de varejo utilizando o método de Inteligência Artificial denominado Redes Neurais Artificiais. Para tanto, foram analisadas de forma aprofundada as diferentes tipologias de redes neurais artificiais a fim de selecionar a mais adequada para o estudo em questão. Tendo em vista a diversidade das variáveis utilizadas para a modelagem, a rede de Kohonen mostrou-se a mais indicada para agrupar os dados com o objetivo de homogeneizá-los, aumentando assim a confiabilidade da previsão realizada. Para o desenvolvimento do método, foram utilizadas as redes Multi-Layer Perceptron, já que estas se apresentam mais adequadas para a realização do trabalho proposto. Desta forma, foi desenvolvido um modelo que a partir da entrada de um conjunto de dados que caracteriza um novo ponto de venda, o usuário tenha como resultado um intervalo de confiança para a venda (faturamento) que será obtida por esta nova loja.

Palavras-chaves: Redes Neurais Artificiais, Previsão de demanda, Setor de Varejo

Abstract

This study aims to develop a methodology of demand forecasting for the Retail sector stores, using a method of artificial intelligence called neural networks. Thus, different types of artificial neural networks were analyzed in detail in order to select the most suitable one for this study. Given the diversity of variables used for modeling the networks, the Kohonen network presented the most indicated to cluster the data in order to homogenize them, increasing the reliability of the prediction performed. To develop the method, it was used the Multi-Layer Perceptron networks, since they were considered more suitable to perform the proposed work. Therefore, this study presents a model that given a data set that features a new point of sale, the user has a result that consists in a confidence interval for the sale (income) that will be obtained by this new store.

Keywords: Artificial Neural Networks, Demand Forecast, Retail Sector

1. Introdução

O comércio varejista representa expressiva atuação no cenário econômico brasileiro atual, apresentando tendência de crescimento cada vez maior. O estudo divulgado pela Deloitte, no relatório Análise Setorial Varejo – Um setor em transformação, relaciona o aumento da classe média, a desconcentração de renda e a situação de pleno emprego no Brasil hoje como alguns dos principais responsáveis pelo aumento do consumo e, por conseguinte, aumento das vendas no setor varejista.

Os dados do Instituto Brasileiro de Geografia e Estatística (IBGE) confirmam esta tendência. De acordo com a Pesquisa Mensal do Comércio de Fevereiro/2012, o comércio varejista apresentou crescimento de 6,7% em termos de volume de vendas nos últimos 12 meses. Esta mesma pesquisa também aponta um crescimento de 11,4% da receita de vendas neste setor em todo o Brasil, tendo o Estado do Rio de Janeiro crescido 10% no mesmo período de 12 meses.

Estes números indicam o crescimento expressivo do setor em questão, justificando o fato de grandes empresas varejistas estarem implantando agressivos planos de expansão, buscando satisfazer a demanda crescente do mercado. Entretanto, para viabilizar que esta expansão ocorra de forma sustentável, é necessário o estudo dos potenciais locais de alocação dos novos estabelecimentos.

Nos estudos realizados por Rozental & Pizzolato (2009) sobre a localização de shoppings centers na Barra da Tijuca, os autores ressaltam as principais preocupações intrínsecas à escolha da localização de uma instalação. Segundo eles, a localização do ponto de venda das instalações privadas costuma ser orientada pela priorização de um dos fatores: minimização dos custos ou maximização dos lucros da empresa.

Portanto, torna-se primordial que a empresa conheça *a priori* qual o faturamento esperado para cada um dos potenciais pontos de venda estudados, garantindo assim a escolha dos locais que resultem em maior retorno para a mesma.

A importância da previsão de demanda para as decisões gerenciais é ressaltada por Souza *et al* (2010) na sua pesquisa sobre a previsão de consumo de cimento no Estado do Rio Grande do Sul, na qual os autores buscam bases científicas e criteriosas para pautar decisões no gerenciamento das futuras produções de cimento do governo.

Vislumbrando a necessidade de um estudo mais profundo sobre a avaliação dos potenciais pontos de venda das lojas varejistas, o presente estudo busca no campo de pesquisa da previsão de demanda, técnicas adequadas para este fim. Sendo assim, o presente artigo se propõe a realizar um estudo de uma empresa do setor varejista, com o objetivo de definir um modelo matemático que viabilize a previsão de faturamento de novas lojas, considerando as características específicas do mercado em questão.

Tendo em vista a complexidade deste tipo de previsão, uma vez que não há disponibilidade do histórico de vendas da nova loja e não é trivial a comparação entre pontos de venda de diferentes localidades, o método escolhido para o desenvolvimento deste modelo foi a técnica de Inteligência Artificial denominada Rede Neural Artificial (RNA).

As Redes Neurais consistem em ferramentas computacionais baseadas nos neurônios biológicos e têm como principal objetivo resolver problemas complexos que envolvam variáveis independentes, através da identificação dos padrões existentes entre estas variáveis e da aproximação das funções apresentadas à rede (TERRA; PASSADOR, 2010).

Como a empresa pesquisada atua a nível nacional, as variáveis apresentadas à rede neural teriam características bastante particulares e pouco homogêneas, o que poderia reduzir a confiabilidade da previsão realizada.

Desta forma, a primeira etapa do método foi a criação de clusters, cuja finalidade seria aglomerar as diferentes localizações segundo suas características homogêneas. Desta forma, na etapa de previsão de faturamento, foi criada uma rede neural para cada um dos clusters definidos, pretendendo assim obter resultados mais confiáveis.

Para a etapa de definição dos clusters foi utilizada a rede de Kohonen, que segundo Tiwari & Misra (2011), as redes de Kohonen, também conhecidas como Self-Organizing Maps (SOM), constituem um dos mais conhecidos métodos para análise de cluster.

Meksen *et al.* (2009) realizaram um estudo sobre agrupamento de defeitos utilizando as redes de Kohonen e segmentaram o funcionamento destas redes neurais em três etapas: a primeira é responsável pelo aprendizado dos neurônios da rede sobre o comportamento das variáveis apresentadas à mesma. Desta forma, quando uma variável de entrada é apresentada à rede, esta calcula os pesos do seu neurônio, que são atualizados a cada nova variável de entrada apresentada. Na segunda etapa, a rede encontra o neurônio vencedor, que é aquele que mais combina com as variáveis de entrada apresentadas. Já na terceira etapa, a rede atualiza os pesos do neurônio vencedor e da sua vizinhança, que formarão os clusters do mapa de Kohonen.

Com os clusters definidos, a segunda fase do método desenvolvido neste estudo foi a criação das redes neurais *Multi-Layer Perceptron*, que foram as que se apresentaram mais adequadas à finalidade de previsão de demanda pretendida nesta pesquisa.

Desta forma, este trabalho se propõe a desenvolver um modelo que a partir da entrada de um conjunto de dados que caracteriza um novo ponto de venda, o usuário tenha como resultado um intervalo de confiança para a venda (faturamento) que será obtida por esta nova loja.

Assim, o presente estudo encontra-se organizado da seguinte forma: a seção 2 apresenta a metodologia utilizada na pesquisa e como foi realizada a aplicação dos dois tipos de redes neurais utilizadas no trabalho; a seção 3 apresenta os resultados encontrados, bem como os gráficos e dados que pautam as conclusões do estudo e, por fim, a seção 4 sintetiza as conclusões da pesquisa e apresenta as sugestões de estudos com base nas restrições encontradas ao longo deste trabalho.

2. Aplicação das Redes Neurais Artificiais

Para o desenvolvimento de uma rede capaz de estimar o faturamento de novas lojas e atingir os objetivos propostos, foi aplicada uma metodologia híbrida contemplando dois diferentes tipos de rede. Conforme explicitado na seção 1 deste estudo, os tipos de rede utilizados foram as redes de Kohonen e as redes *Multi-Layer Perceptron*.

Posteriormente, foram definidas as variáveis a serem utilizadas em cada uma das redes escolhidas e, desta forma, foi possível a coleta e o tratamento dos dados a serem utilizados como entrada para as redes.

O próximo passo foi a escolha do *software* mais adequado para a realização da modelagem do problema e a criação das redes neurais.

Com o *software* escolhido, foi criada a rede de Kohonen, com o objetivo de segmentar as amostras e gerar *clusters* homogêneos com os dados coletados. Em seguida, para cada um destes *clusters*, foi desenvolvida uma rede *Multi-Layer Perceptron*, a fim de realizar a previsão do faturamento das novas lojas inseridas neste *cluster*.

2.1. Definição das Variáveis

Para a criação da rede, foram definidas as variáveis que pudessem determinar a classificação das diferentes lojas espalhadas por todo o Brasil. De acordo com a opinião de especialistas da área de varejo, foi notada a necessidade de medir as mesmas variáveis para a cidade em que a loja analisada se encontra e para uma área com raio de 500m ao redor do ponto de venda, onde a loja em questão exerce e recebe influência.

Desta forma, as variáveis de entrada utilizadas para definir os *clusters* foram:

- Comércio local, representado pelo número de estabelecimentos comerciais, tais como: farmácias, bancos, supermercados, restaurantes e lojas de varejo concorrentes;
- Número de lojas de varejo da mesma marca;

- População por km²;
- Renda média da população;
- Local da loja, que pode assumir dois valores: ou a loja está localizada dentro do *Shopping Center* ou a loja está localizada na rua;
- Área do salão de venda;
- Produto Interno Bruto da cidade onde a loja se localiza.

Para a segunda etapa do estudo, foram consideradas as mesmas variáveis utilizadas na etapa de *clusterização*, visto que além de possibilitar a segmentação das lojas, elas influenciam diretamente no faturamento das mesmas. Além destas variáveis, foi necessária a consideração da variável de saída, faturamento, para que a rede pudesse ser treinada adequadamente.

2.2. Coleta e Tratamento dos Dados

Para a realização deste estudo, foram selecionadas 298 lojas da empresa de estudo consideradas com características semelhantes àquelas buscadas para a expansão da empresa. Os dados referentes a estas lojas foram coletados de três fontes distintas: através da ferramenta interna da empresa para levantamento de dados sobre possíveis pontos de venda, do site do Instituto Brasileiro de Geografia e Estatística (IBGE) e do fornecimento de informações pela própria empresa.

Tendo em vista que tais dados apresentavam unidades de medidas distintas, eles foram normalizados apresentando assim o mesmo padrão e facilitando seu manuseio de forma mais homogênea.

Esta normalização se deu da seguinte forma:

- As variáveis qualitativas, como o local da loja, apresentaram valor 1 (para lojas localizadas na rua) ou valor 0 (para lojas localização no *shopping center*);
- Cada uma das variáveis quantitativas teve o seu somatório calculado e o valor da variável em questão para cada uma das lojas foi calculado dividindo o valor inicial pelo somatório calculado.

Desta forma, todas as variáveis consideradas assumiram um valor entre 0 (zero) e 1 (um), tornando assim possível a utilização de valores mais homogêneos.

Após esta normalização, analisou-se a correlação das variáveis a serem utilizadas com o intuito de minimizar a redundância dos dados inseridos na rede. Como resultado desta análise, foi encontrada uma alta correlação entre seis variáveis referentes ao comércio da cidade. Desta forma, estas variáveis foram substituídas por apenas uma delas, considerada a mais relevante pelo especialista da empresa.

2.3. Definição dos Clusters

Dentre os diversos *softwares* utilizados para a modelagem das redes neurais, o MATLAB[®] versão 7.10.0 foi o escolhido para a aplicação prática deste trabalho, sendo utilizado para o desenvolvimento das duas redes utilizadas.

A escolha da rede de Kohonen para a *clusterização* dos dados foi embasada por pesquisas realizadas utilizando com sucesso este tipo de rede para propósitos similares ao deste estudo. Neste sentido, os autores Mangiameli *et al.* (1996) desenvolveram estudos que comprovaram a eficiência dos *Self-Organizing Maps* no processo de criação de agrupamentos.

Primeiramente, foi definido que a topologia da grade seria a Hexagonal, por ser a mais usual dentre os estudos de especialistas e apresentar bons resultados. Em seguida, foram feitos testes com diferentes dimensões de grade para determinar a melhor disposição de *clusters* para este trabalho. As dimensões testadas foram: 2x2, 3x2, 3x3, 4x4.

Ao analisar as configurações dos *clusters* gerados por cada dimensão de grade, foi determinado que a dimensão 3x3 apresentava a melhor distribuição considerando os objetivos e passos seguintes deste estudo. A escolha da dimensão de grade 3x3 se deu principalmente em função da busca de um equilíbrio na distribuição das amostras.

A grade 2x2, devido às suas características, gerou apenas quatro *clusters*. Destes, dois apresentaram uma grande quantidade de amostras, caracterizando *clusters* pouco homogêneos. Em contrapartida, a grade 4x4 (com 15 *clusters*) apresentou alguns agrupamentos com um número muito pequeno de amostras ou até mesmo com apenas uma amostra, o que torna inviável o posterior treinamento de uma rede *MLP*.

As grades 3x2 e 3x3 apresentaram resultados parecidos de distribuição de amostras, sendo satisfatória a escolha tanto da configuração de 6 *clusters* quanto a de 7 *clusters*. Entretanto, um *cluster* a mais representa uma homogeneidade ainda maior dos dados em cada *cluster*, fator esse, determinante para a escolha da grade de dimensão 3x3, cuja distribuição é representada na Tabela 1.

Tabela 1. Configuração dos *Clusters* com grade 3X3

Cluster	Grade 3x3						
	1	2	3	4	5	6	7
Nº de Amostras	75	38	44	32	37	35	37

2.4. Desenvolvimento das Redes *Multi-Layer Perceptron*

Como dito anteriormente, para cada *cluster* definido, foi desenvolvida uma rede *Multi-Layer Perceptron* com a finalidade de realizar a previsão de faturamento do *cluster* em questão. Dessa forma, ao ser feita a previsão de um novo ponto de venda, primeiramente este será agrupado utilizando a rede de Kohonen. E, posteriormente, será utilizada a rede *MLP* mais adequada para o *cluster* no qual este ponto de venda ficou alocado.

Além disso, foi desenvolvida uma rede *MLP* utilizando os dados coletados de todas as lojas da empresa em questão, isto é, sem a aplicação da rede de Kohonen para o agrupamento destes dados. A finalidade desta rede *MLP* não *clusterizada* é atender os casos de novos pontos de venda que não se encaixem em nenhum dos *clusters* propostos.

O desenvolvimento das redes *MLP* foi composto por duas fases: treinamento e teste da rede.

2.4.1. Treinamento da Rede

O primeiro passo para o desenvolvimento das redes *MLP* foi a definição dos seus parâmetros e a posterior execução do treinamento da rede no MATLAB®.

Para o treinamento da rede de cada *cluster*, foi necessário ajustar os parâmetros iniciais da rede a fim de encontrar a melhor configuração para cada *MLP*, pois cada *cluster* apresenta um vetor de entrada (P) e um vetor alvo (T) diferentes. Os parâmetros que foram alterados são: número de camadas ocultas, número de neurônios em cada camada e função de ativação. Os demais parâmetros utilizados no treinamento da rede mantiveram-se fixos para todas as redes desenvolvidas em cada *cluster* e apresentaram os seguintes valores:

- Algoritmo utilizado para a minimização do erro: Levenberg-Marquadt (`trainlm`)
- No máximo de iterações para a apresentação do treinamento: 50
- Taxa de aprendizado: 9.95 (`net.trainParam.lr`)
- No de máximo de iterações: 300000 (`net.trainParam.epochs`)
- Erro aceitável para o treinamento: 1e-9 (`net.trainParam.goal`)

Nesta fase de treinamento da rede, o MATLAB® utiliza o método de validação cruzada com o objetivo de potencializar a capacidade de generalização da rede e minimizar o

denominado *overfitting*, que consiste na memorização dos padrões de entrada e, conseqüentemente, no não aprendizado da rede.

Desta forma, o MATLAB[®] divide aleatoriamente os dados de entrada em três subconjuntos: subconjunto de treinamento (60% da amostra), subconjunto de validação (20% da amostra) e subconjunto de teste (20% da amostra).

O subconjunto de treinamento é utilizado no ajuste dos pesos, enquanto o subconjunto de validação estima a capacidade de generalização da rede durante a fase de aprendizagem (BRAGA, 2000). Segundo Braga (2000), “o treinamento deve ser interrompido quando o erro do conjunto de validação começar a subir, ou seja, quando a rede começar a incorporar o ruído presente nos dados, o que causa degradação na sua capacidade de generalização”.

O terceiro subconjunto testa se o treinamento da rede ocorreu de forma satisfatória, pois um novo conjunto de dados que não fez parte do treinamento é apresentado à rede e, caso esta tenha aprendido os padrões de entrada, será capaz de gerar um vetor de saída próximo ou igual ao vetor alvo, apresentando assim um valor baixo para o erro de teste.

Através das curvas de erro geradas pelo MATLAB[®], foi possível definir a configuração ótima para a rede *MLP*, sendo aquela que apresentou o menor erro de teste. Segundo Biondi Neto *et al.* (2009), a curva de erro reflete o erro médio quadrático (eixo vertical) em função na quantidade de iterações (eixo horizontal) realizadas pela rede. As iterações representam quantas vezes um conjunto completo de padrões de entrada foi apresentado à rede neural.

A Figura 1 ilustra a curva de erro de uma das redes desenvolvidas neste estudo. O erro de teste é representado pela curva de cor vermelha.




Figura 1. Curvas de erro da *MLP* (Fonte: MATLAB versão 7.10.0)

De acordo com os estudos realizados por Dias (2008), “o erro quadrático médio é um critério de parada para o algoritmo de treinamento de uma rede neural artificial”. Segundo os autores, este erro representa a diferença entre o valor de saída esperado da rede neural e o valor real gerado pela mesma durante o seu treinamento.

2.4.2. Teste da Rede

A fase de teste consiste na apresentação de novos padrões de entrada à rede com a finalidade que esta gere um vetor de saída próximo ao vetor alvo, comprovando a sua capacidade de generalização dos padrões de entrada.

No código deste treinamento são inseridos os dados da nova loja, não sendo necessária a inserção do vetor alvo, uma vez que este será o resultado calculado pela rede.

A fim de testar a capacidade de generalização da rede, foi selecionada uma amostra aleatória de aproximadamente treze lojas para cada *cluster* e para os dados não *clusterizados*.

Para cada uma destas amostras, foi aplicado um ruído de 2% no valor de cada uma das variáveis de entrada, com exceção das variáveis que não apresentavam alteração, ou seja, mantinham o mesmo valor independente da loja daquele *cluster*.

Com isto, estes dados com ruído foram inseridos como vetor de entrada no código de treinamento de cada rede e o vetor de saída gerado foi comparado com o vetor alvo esperado, que constitui o faturamento real das lojas utilizadas no teste da rede.

Com esta comparação, foi possível calcular o percentual de erro apresentado pela rede *MLP* para a previsão do faturamento de lojas com características similares às lojas que fizeram parte do treinamento da rede. Este erro foi relevante para a análise da capacidade de generalização da rede desenvolvida neste estudo.

3. Resultados

A apresentação dos resultados deste trabalho está segmentada em três partes que correspondem às principais fases deste estudo – Agrupamento de Dados, Desenvolvimento das Redes *MLP* e Aplicação do Método Desenvolvido.

3.1. Agrupamento de Dados

A partir da dimensão de grade selecionada 3x3, foram gerados um total de 7 *clusters*, onde estão distribuídas as 298 amostras. Ao analisar esses *clusters*, pode-se perceber que as divisões apresentam coerência e homogeneidade em seus dados, com base em opiniões de especialistas.

De modo geral, constatou-se que em nenhum dos *clusters* as lojas localizadas em shopping e as localizadas em rua se misturaram. Cada *cluster* apresentou apenas lojas localizadas em *shoppings* ou em ruas. De fato, as lojas que se encontram em *shoppings* têm um perfil, na maioria das vezes, muito diferente de uma loja de rua, já que o comércio dentro de um *shopping* é muito favorecido e potencializado. Portanto, acredita-se que as variáveis que mapeiam o comércio em um raio de 500m do ponto da loja tenham influenciado muito nesta configuração dos *clusters*.

Outro fator de destaque desse agrupamento se deu no isolamento das lojas situadas nas cidades do Rio de Janeiro e de São Paulo. Todas as lojas dessas cidades se dividiram em dois *clusters*, o 6 e o 7, seguindo a lógica apresentada acima: um *cluster* continha as lojas das duas cidades que eram localizadas em *shoppings* e o outro *cluster* apresentava as lojas localizadas em ruas.

As cidades do Rio de Janeiro e de São Paulo são de fato muito diferentes das outras cidades brasileiras utilizadas no treinamento dessa rede. Para as variáveis que analisam a cidade como um todo ao invés do raio de 500m do ponto, Rio de Janeiro e São Paulo apresentaram quantidades expressivamente maiores que as outras cidades. Acredita-se que esse fato foi determinante para a separação delas em *clusters* isolados, já que suas características não são comparáveis às das outras cidades, principalmente por serem as cidades mais importantes do país em termos econômicos.

O *cluster* 1 se diferenciou por apresentar 75 amostras, um número muito superior comparado aos demais *clusters* que apresentaram uma média de 30 amostras conforme mostra a Tabela 1 apresentada na seção 2.3. Em função disto, o *cluster* 1 apresentou dados menos homogêneos que os outros, apesar de conter apenas lojas situadas em *shoppings*.

Os *clusters* 2 e 4 apresentaram apenas lojas localizadas em ruas, todavia ao analisar mais aprofundadamente as variáveis de cada uma delas verificou-se que os pontos das lojas do *cluster* 4 contavam com um comércio mais desenvolvido em suas redondezas. E isso foi observado também para outros *clusters*. Pôde-se concluir que, de maneira geral, o agrupamento dividiu os pontos de venda que eram localizados em locais com o comércio mais desenvolvido de pontos onde o comércio é mais escasso.

3.2. Método de Previsão Desenvolvido

A eficácia da rede neural pode ser medida pela diferença entre o resultado apresentado pela rede e o resultado esperado. Esta diferença constitui o erro do método desenvolvido e quanto menor este erro, maior a confiabilidade dos resultados fornecidos pela rede neural. Com a finalidade de garantir que o método desenvolvido neste trabalho apresentasse um bom desempenho, foi medido o percentual de erro apresentado em cada uma das fases que compõem o desenvolvimento da rede *MLP*.

O gráfico 2 apresenta as curvas de erro da amostra não *clusterizada*, ou seja, a rede em questão foi treinada com todos os dados coletados neste estudo, sem apresentar homogeneidade nos padrões de entrada. Enquanto os gráficos 3 e 4 apresentam as curvas de erro dos *clusters* 3 e 4, respectivamente.




Figura 2. Curvas de erro da MLP dos dados não *clusterizados*




Figura 3. Curvas de erro da MLP do *cluster* 3




Figura 4. Curvas de erro da *MLP* do *cluster 4*

Apesar da similaridade dos gráficos de erros dos *clusters*, existe uma variação relativa ao número de amostras e à função de ativação determinada. Desta forma, a Tabela 2 mostra o erro mínimo encontrado em cada *cluster*.

Tabela 2. Erro mínimo das *MLP* (Fonte: MATLAB versão 7.10.0)

MLP	Menor erro
Não clusterizado	10^{-3}
Cluster 1	10^{-4}
Cluster 2	10^{-15}
Cluster 3	10^{-14}
Cluster 4	10^{-4}
Cluster 5	10^{-5}
Cluster 6	10^{-15}
Cluster 7	10^{-6}

Os gráficos ilustram o baixo nível de erro apresentado pelas redes na fase de treinamento e de teste realizada pelo MATLAB®, alcançando um maior erro mínimo de grandeza 10^{-15} . Estes valores baixos alcançados pela curva de teste indicam o aprendizado e a capacidade de generalização das redes desenvolvidas para cada *cluster*.

Os gráficos também comprovam a eficácia da *clusterização* dos dados, uma vez que o gráfico 2 apresentou um erro de teste maior do que os demais gráficos, comprovando que a criação dos *clusters* tornou os dados mais homogêneos, aumentando a capacidade de previsão das redes criadas.

Dentre os erros gerados por cada *cluster*, nota-se que o *cluster 1* apresentou um erro maior do que os demais. Este fato pode ser justificado devido à menor homogeneidade dos seus dados, conforme citado anteriormente.

A segunda fase do desenvolvimento da *MLP* consistiu no teste da rede através da apresentação de padrões de entrada com um ruído de 2% em cada uma das variáveis.

Os *clusters 6* e *7*, compostos apenas por lojas das cidades do Rio de Janeiro e São Paulo, apresentaram um erro consideravelmente maior do que os demais. Observou-se que ao aplicar o ruído nas variáveis “número de lojas da rede” e “renda média” da cidade, a rede apresentou um erro de previsão muito elevado. Isso se deve muito provavelmente ao fato destas variáveis apresentarem apenas dois diferentes valores.

PESQUISA OPERACIONAL PARA O DESENVOLVIMENTO

Com isto, a rede não obteve um número razoável de padrões de entrada para estas variáveis, acarretando num baixo aprendizado da mesma em relação à alteração de valores destas duas variáveis. Entretanto, considerando o fato de que estes dois *clusters* são compostos apenas pelas duas cidades já citadas, estas variáveis apresentarão sempre os mesmos valores, não sendo necessário o aprendizado da rede para possíveis ruídos.

Com base no exposto acima, foram desconsiderados os ruídos aplicados nas duas variáveis citadas para os *clusters* 6 e 7. A Tabela 3 demonstra os valores para o erro médio dos *clusters* nesta segunda fase.

Tabela 3. Erro médio apresentado pelas redes *MLP* na fase de teste

	Erro médio do teste(σ)
Não clusterizado	4,09%
Cluster 1	1,04%
Cluster 2	0,92%
Cluster 3	1,17%
Cluster 4	0,85%
Cluster 5	1,93%
Cluster 6	1,48%
Cluster 7	0,83%

Os erros encontrados nos testes ratificam o melhor desempenho da previsão realizada pelos *clusters* em comparação à realizada pela rede treinada com os dados não *clusterizados*, que apresentaram um erro médio de 4,09% contra o maior erro médio encontrado nos *clusters* de 1,17%.

Com a finalidade de gerar um intervalo de confiança para a previsão de faturamento, foi considerada uma distribuição normal cuja média μ é o valor calculado pela rede neural desenvolvida. Enquanto o desvio padrão é o erro médio σ calculado na fase de teste e exposto na tabela 3. Desta forma, para uma confiança de 95,5%, será gerado para cada *cluster* um intervalo correspondente a $(\mu - 2\sigma, \mu + 2\sigma)$, no qual o faturamento anual do novo ponto de venda da empresa deve estar contido.

3.3. Aplicação do Método Desenvolvido

Como forma de corroborar os resultados apresentados no item anterior do método de previsão de demanda desenvolvido neste trabalho, foi feita uma aplicação deste para a previsão de faturamento de lojas recém-inauguradas para posterior comparação com os resultados previstos pela empresa de estudo.

Foram selecionadas sete novas lojas e seus dados coletados conforme o procedimento realizado para as amostras utilizadas no treinamento. Inicialmente, estas lojas foram *clusterizadas* para identificar qual código da rede *MLP* seria utilizado para realizar sua previsão de faturamento, uma vez que para cada *cluster* gerado foi desenvolvida uma rede *MLP* diferente. O método de agrupamento destas lojas foi o mesmo utilizado na formação dos *clusters* desta pesquisa e sua descrição encontra-se detalhada na seção 2.3.

Como era esperado da configuração destas novas lojas nos *clusters*, a situada na cidade do Rio de Janeiro foi agrupada no *cluster 7*, que consiste no *cluster* que contém apenas as cidades do Rio de Janeiro e de São Paulo. Isso valida mais uma vez a consistência dos resultados dos agrupamentos.

Feita a *clusterização*, gerou-se a previsão do faturamento de cada uma das lojas a partir das redes *MLP* específicas de cada um dos *clusters*. Foram determinados intervalos de confiança para esses resultados e em seguida foram comparados às previsões feitas por especialistas da empresa, conforme mostra a coluna “Previsão Empresa A” da Tabela 4.

A coluna “Previsão Empresa A” apresenta a previsão inicial realizada pelos gestores da empresa antes de inaugurar as lojas. Esta previsão é realizada de maneira qualitativa e pauta-se

PESQUISA OPERACIONAL PARA O DESENVOLVIMENTO

nas experiências vivenciadas pelos gestores responsáveis por estimar o faturamento dos novos pontos de venda.

Após a inauguração das novas lojas e a análise do desempenho de vendas das mesmas, os gestores da empresa revisaram as metas de faturamento, cujos valores encontram-se dispostos na coluna “Reavaliação Previsão Empresa A” da Tabela 4. Esta revisão das metas foi realizada apenas com base na experiência dos gestores e no desempenho inicial das lojas, portanto, a previsão feita pelo método proposto neste trabalho não influenciou a reavaliação da empresa A.

Tabela 4. Comparação entre a previsão do método proposto e a previsão da empresa

Loja	Método de Previsão			Previsão Empresa A	Reavaliação Previsão Empresa A
	Limite Inferior	Faturamento	Limite Superior		
305	R\$ 11.022.425,65	R\$ 11.256.562,14	R\$ 11.490.698,64	R\$ 20.000.000,00	R\$ 20.000.000,00
362	R\$ 15.338.988,77	R\$ 15.954.845,82	R\$ 16.570.702,87	R\$ 7.000.000,00	R\$ 8.000.000,00
577	R\$ 5.845.811,49	R\$ 5.944.490,03	R\$ 6.043.168,56	R\$ 3.500.000,00	R\$ 6.000.000,00
375	R\$ 42.888.439,97	R\$ 43.916.076,15	R\$ 44.943.712,33	R\$ 14.000.000,00	R\$ 22.000.000,00
583	R\$ 6.815.170,51	R\$ 6.933.032,06	R\$ 7.050.893,60	R\$ 5.000.000,00	R\$ 6.000.000,00
379	R\$ 6.008.175,13	R\$ 6.120.797,81	R\$ 6.233.420,49	R\$ 11.000.000,00	R\$ 18.000.000,00
413	R\$ 21.219.769,03	R\$ 21.670.515,76	R\$ 22.121.262,48	R\$ 8.000.000,00	R\$ 13.000.000,00

Apesar de não ser possível comparar a previsão realizada pelas Redes Neurais Artificiais e o faturamento anual realizado pelos novos pontos de venda, visto que estes ainda não possuem um ano de funcionamento, foi possível comparar e verificar que as novas previsões feitas pela empresa se tornam mais próximas da previsão realizada pela Rede Neural Artificial desenvolvida neste estudo.

Como é possível notar na Tabela 4, a reavaliação da empresa indica um cenário crescente de vendas para todas as lojas, com exceção da loja 305. Este cenário se deve ao fato da empresa não ter realizado uma estimativa inicial confiável. Ressalta-se que a reavaliação de previsão realizada aproxima-se dos valores estimados apresentados pela rede neural desenvolvida neste estudo. Portanto, é notável que o cenário real de vendas está configurando uma realidade mais próxima do quadro previsto nesta pesquisa.

Portanto, esta conclusão ratifica a relevância deste estudo na aplicação de redes neurais artificiais no contexto de previsão de demanda em novos pontos de venda. Estes casos específicos são demasiado complexos por não apresentarem histórico de vendas e por possuírem variáveis bastante diversificadas.

A decisão de abertura e a localização de um novo estabelecimento são cruciais para a expansão sustentável de todas as organizações e, por este motivo, devem ser pautadas em dados coerentes que justifiquem o retorno esperado desta expansão. Os autores Oro *et al.* ratificam a relevância do propósito deste estudo ao citar na sua pesquisa que “todo investimento tem implícita a condição de retorno. Neste sentido, a lucratividade do negócio torna-se fundamental, pois nenhuma empresa pode operar com prejuízos contínuos.”

4. Conclusão

O presente estudo se baseou na criação de uma metodologia a ser aplicada para a previsão de faturamento de novos pontos de venda do setor varejista através da aplicação do conceito de Redes Neurais Artificiais. Esta metodologia permitiu gerar diferentes tipos de modelagem de acordo com características consideradas relevantes para casos particulares de empresas do setor de comércio em geral.

PESQUISA OPERACIONAL PARA O DESENVOLVIMENTO

Com o objetivo final de prever o faturamento anual de novos pontos de vendas, foi realizado o levantamento de variáveis que pudessem estar relacionadas com o proposto objetivo, sendo elas relacionadas ao comércio e às características da população.

Após o levantamento de variáveis relevantes, realizou-se a análise e a comparação entre as 298 amostras utilizadas para o treinamento das redes, considerando suas particularidades. Esta comparação possibilitou o agrupamento de amostras com características consideradas semelhantes, através da Rede de Kohonen.

Através das redes *Multi-Layer Perceptron*, foi possível a determinação de intervalos estimados para o faturamento anual de lojas da empresa em estudo, considerando o erro encontrado nos testes de cada um dos *clusters* determinados.

Ao realizar a comparação entre o faturamento anual previsto obtido pela rede *MLP* considerando os dados *clusterizados* através da rede de Kohonen e considerando todos os dados coletados das lojas da empresa em questão, foi possível verificar que a rede *clusterizada* apresentou valores mais próximos dos reais, sendo este fato ratificado por especialistas do ramo de varejo.

É notável a relevância do trabalho realizado, que pode ser aprimorado através de novos estudos que levantem variáveis não mencionadas, tais como variáveis relacionadas ao mix de produtos das lojas e à situação do transporte local, considerando transporte público e estacionamento para automóveis próximo à loja, o que impacta no fluxo de pessoas próximo ao ponto de venda.

Referências Bibliográficas

BRAGA, Antônio de P.; CARVALHO, André P. de L. F. de; LUDERMIR, Teresa B. Redes Neurais Artificiais: Teoria e Aplicações. Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora S.A., 2000.

DELOITTE. Análise Setorial Varejo: Um setor em grande transformação. 2009. Disponível em: <<http://www.deloitte.com/assets/Dcom-Brazil/Local%20Assets/Documents/Analise%20Setorial%20Varejo.pdf>>. Acesso em: 21 abr. 2012.

DIAS, C. G. A implementação e o estudo de redes neurais artificiais em ferramentas de software comerciais. Revistas Científicas de América Latina, el Caribe, España y Portugal, Exacta, São Paulo, v.6, n.1, págs. 119-128, jan. - jun./2008.

IBGE. Pesquisa Mensal de Comércio - Fevereiro, 2012. Disponível em: <<http://www.ibge.com.br/home/estatistica/indicadores/comercio/pmc/defaulttab.shtm>>. Acesso em: 21 abr. 2012.

MANGIAMELI P.; CHEN, S. K.; WEST, D. A comparison of SOM neural networks and hierarchical clustering methods. European Journal of Operations Research, (93): 402-417, 1996.

MATLAB. Software de aplicação de Redes Neurais. Disponível em: <<http://www.mathworks.com/products/matlab/>>. Acesso em: 16 nov. 2010.

MEKSEN, T. M.; BOUDRAA, B.; BOUDRAA, M. Defects Clustering using Kohonen Networks during Ultrasonic Inspection. International Journal of Computer Science, v.36, n.3, 1 ago. 2009.

NETO, Luiz Biondi. Introdução às Redes Neurais Artificiais. Aula ministrada na disciplina de Redes Neurais na Universidade Estadual do Rio de Janeiro, 2010.

NETO, Luiz Biondi; FUKUDA, Fernando H.; RODRIGUES, Pierre T.; AMERICO, Marcio; JUNIOR, Moacir P. L. Sistema Inteligente para detecção e diagnóstico de falhas em geradores de energia elétrica de usinas termoeletricas. Engvista, V. 11, n. 2, 2009.

ORO, Ieda Margarete; BEUREN, Ilse Maria; HEIN, Nelson. A análise da eficiência de empresas familiares brasileiras. RAE Eletrônica, São Paulo, v.8, n.2, dez. 2009.

PESQUISA OPERACIONAL PARA O DESENVOLVIMENTO

ROZENTAL, Marcelo; PIZZOLATO, N. Domingues. Localização de *shoppings centers* de vizinhança. Estudo de caso: Barra da Tijuca, Rio de Janeiro – RJ. Pesquisa Operacional para o Desenvolvimento, Rio de Janeiro, v.1, n.3, pp. 199-207, 2009.

SNNS. Software de aplicação de Redes Neurais. Disponível em: <<http://www.ra.cs.uni-tuebingen.de/SNNS/>>. Acesso em: 16 nov. 2010.

SOUZA, F. M.; ALMEIDA, S. G. de; GUARNIERI, J. P.; SOUZA, A. M.; LOPES, L. F. D. Previsão do consumo de cimento no Estado do Rio Grande do Sul. Pesquisa Operacional para o Desenvolvimento, Rio de Janeiro, v.2, n.1, p. 1-86, jan. - abr./2010.

TERRA, L. A. A.; PASSADOR, J. L. Redes Neurais Artificiais na previsão da inflação: aplicação como ferramenta de apoio à análise de decisões financeiras em organizações de pequeno porte. Revista de Administração Mackenzie, São Paulo, v.13, n.1, p. 68-86, jan. – fev./2012.

TIWARI, M. MISRA, B. Application of Cluster Analysis in Agriculture: A review article. International Journal of Computer Application, India, v.36, n.4, Dez/2011.