

Avaliação de Modelos de Previsão de Vendas a Partir da Exploração de Técnicas de Análise de Séries Temporais, Métodos Causais e de Redes Neurais Artificiais

Filipe Drumond Reis

DM&P - Desenvolvimento de Mercados e Produtos
Rua Montevideu, 411 — Sion — Belo Horizonte — MG — 30315-560
drumondreis@gmail.com

Plínio Rafael Reis Monteiro

Centro de Pesquisas e Pós-Graduação em Administração (CEPEAD) - FACE - UFMG
Av. Antônio Carlos, 6627 — Pampulha — Belo Horizonte — MG — 31270-901
preisufmg@gmail.com

Fernando Silva Parreiras

Laboratório de Sistemas de Informação Avançados - LAIS, Universidade FUMEC
Av. Afonso Pena, 3880 — Cruzeiro — Belo Horizonte — MG — 30130-009
fernando.parreiras@fumec.br

RESUMO

A previsão de vendas é fundamental para organizações uma vez que permite melhorar o planejamento e a tomada de decisão sobre o futuro da empresa. Na tentativa de diminuir o grau de incerteza inerente da previsão, emerge o seguinte problema de pesquisa: Quais são as técnicas que apresentam maior acurácia quando aplicadas para previsão de vendas? Este trabalho descreve a avaliação de forma quantitativa de modelos de previsão aplicados em dados reais de uma indústria brasileira do segmento têxtil. Foram desenvolvidas e avaliadas técnicas estatísticas de suavização exponencial, modelos ARIMA, regressão e redes neurais artificiais otimizadas pela técnica de algoritmos genéticos. A pesquisa mostrou que a inclusão de variáveis externas auxilia na melhor acurácia dos modelos de previsão e que a adoção de métodos que captam variações não lineares nem sempre gera ganhos de previsão. Por fim, os resultados mostraram que a otimização por Algoritmos Genéticos pode gerar modelos com uma capacidade preditiva superior.

PALAVRAS CHAVE. Previsão de Vendas, Redes Neurais, ARIMA e Algoritmos Genéticos.

Área Principal: AD&GP - PO na Administração e Gestão da Produção

ABSTRACT

Sales forecasting is fundamental to organizations, once it allows to improve planning and decision making in a company's future. In the attempt to reduce uncertainty inherent of forecasting, the following research problem emerges: Which techniques present more accuracy when applied to sales forecast? To answer this question, this thesis evaluated in a quantitative manner the forecast methods applied in the data of a Brazilian Industry from the textile segment. Statistical techniques of exponential smoothing, ARIMA methods, regression and neural networks optimized by the genetic algorithms technique were developed and evaluated. This extensive research has shown that the inclusion of external variables can help in a better accuracy of forecasting models and also that the utilization of methods which can recognize nonlinear variations will not always generate forecasting gains. At last, the results have shown that optimization by genetic algorithms can generate models with a superior predictive capacity.

KEYWORDS. Sales Forecast. Neural Networks. ARIMA. Genetic Algorithms.

Main Area: OR in Administration & Production Management.

1. Introdução

Modelos de previsão são aplicados em áreas financeiras, econômicas, meteorológicas, de produção de energia, de sociologia, entre outras [Thomassey et al. 2005]. Entre as diversas técnicas de previsão existem as que são baseadas em modelos estatísticos e matemáticos. Estes modelos utilizam dados históricos que são estudados a fim de se identificar os seus comportamentos e padrões para que sejam traçadas projeções futuras com base nos mesmos.

Inicialmente os métodos de previsão de vendas se concentravam em métodos estatísticos lineares baseados em análises de séries temporais como modelos ARIMA - modelo autoregressivo integrado de média móvel e modelos de suavização exponencial. Contudo, estes métodos são baseados em funções lineares entre as séries temporais e esta característica impediria que modelos desta natureza capturassem variações não lineares nas séries, ciclos assimétricos ou variações ocasionais [Wong and Guo 2010, Thomassey et al. 2005]. Na busca de modelos que permitissem a captura de parâmetros não lineares, diversas pesquisas desenvolveram e testaram modelos baseados em técnicas de Inteligência Artificial, sobretudo por meio do desenvolvimento de sistemas baseados em Redes Neurais Artificiais [Wong and Guo 2010]. Além das diferentes características de cada método de previsão, outra dimensão que emerge nas pesquisas de modelagem de previsão diz respeito a otimização dos métodos, que vem sendo impulsionada pelo avanço da tecnologia da informação.

Diante dessas novas possibilidades que o processamento computacional permite e a necessidade de se utilizar previsões de vendas como suporte a gestão comercial no âmbito tático e operacional, emerge a seguinte questão de pesquisa: Quais modelos de previsão apresentam maior acurácia quando aplicadas para previsão de vendas em uma indústria têxtil brasileira?

Os resultados apresentados neste trabalho podem ser utilizados para auxiliar às organizações a tomarem decisões no ambiente comercial, além de outras questões alinhadas às decisões táticas e operacionais de vendas como estratégia de descontos comerciais a ser aplicada, aumento da força de vendas, ações de promoção em clientes e regiões.

Mesmo com o reconhecimento de sua importância, sistemas estruturados de previsão são muitas vezes difíceis e complexos de serem implementados e principalmente de serem utilizados no dia a dia das organizações. A importância e as possibilidades de utilização das previsões de vendas pelas empresas justificam a relevância do tema do ponto de vista das organizações.

Se por um lado existe uma relativa ausência de implementações de modelos mais complexos e robustos de previsão nas organizações, tem-se, por outro lado, uma difusão de pesquisas sobre o problema de previsão, como foi encontrado em uma revisão sistemática da literatura [Drummond Reis et al. 2014].

Este trabalho tem como objetivo avaliar modelos quantitativos de previsão baseados em análise de séries temporais, em métodos causais e em técnicas de inteligência artificial para a previsão de vendas a ser testada em dados reais de uma indústria têxtil.

Este trabalho está organizado da seguinte forma. No capítulo 2 apresenta-se a conceituação dos principais métodos de previsão de vendas, as técnicas de otimização utilizadas para melhoria de desempenho dos modelos e as técnicas de avaliação de desempenho de acurácia. Ainda no capítulo 2 analisa-se estudos empíricos que desenvolveram e testaram modelos de previsão de vendas identificando as principais técnicas de previsão e de avaliação utilizadas. No capítulo 3 descreve-se a metodologia da pesquisa adotada abordando o problema de previsão, as bases de dados utilizadas, os modelos desenvolvidos e avaliados e as hipóteses testadas. No capítulo 4 apresenta-se os modelos de previsão de vendas desenvolvidos e seus resultados comparando o desempenho de cada um deles. Por fim, conclui-se com as considerações finais.

2. Visão Geral das Técnicas de Previsão

Os métodos de previsão podem ser separados em técnicas de Julgamento (Abordagens Qualitativas ou Técnicas Subjetivas) e técnicas Estatísticas ou Quantitativas. As técnicas de julgamento envolvem a participação preponderante do conhecimento humano na previsão, seja de

indivíduos isoladamente seja de grupos e especialistas. Já as técnicas estatísticas pressupõem a utilização de modelos quantitativos a partir de dados históricos.

Os métodos quantitativos podem ser classificados em dois tipos, Análises de Séries Temporais e Métodos Causais [Passari 2003, Lemos 2006] ou de acordo com a proposição de Armstrong [Armstrong 2008] com apenas uma variável, quando se realiza a extrapolação a partir da própria série temporal e múltipla quando se analisa mais de uma variável na previsão. Seja qual for o tipo de método quantitativo utilizado pressupõe-se o uso de dados históricos quantitativos. Dessa forma, para o desenvolvimento de modelos estatísticos de previsão se faz necessário uma base de dados. A sua maior vantagem é sua imparcialidade diante da previsão, tanto previsões ruins como boas podem ser feitas, porém o seu desempenho depende, em grande parte, da qualidade dos dados de entrada [Armstrong 2008].

O método de Redes Neurais pode tanto ser caracterizado como Séries Temporais como por Métodos Causais dependendo do tipo de variável utilizada em sua construção. Este trabalho testou redes neurais tanto como método de serie temporal como método causal, com mais de uma variável de entrada. Para efeito de descrição do método, optou-se por apresentá-lo dentre os métodos causais.

Estudos têm desenvolvido modelos híbridos, caracterizados como HIS – Hybrid Intelligent Systems [Bahrammizae 2010]. Basicamente são sistemas robustos que integram e combinam técnicas buscando a solução de problemas. A combinação de técnicas, em geral, é apresentada como uma arquitetura híbrida em que se tem uma dimensão com os métodos de previsão tradicionais com métodos de inteligência artificial.

Uma Revisão Sistemática da Literatura [Drummond Reis et al. 2014] aponta que a pesquisa em previsão de vendas tem buscado formas de melhorar o desempenho de uma previsão combinando os métodos de previsão com técnicas de inteligência artificial que buscam a otimização na fase de definição das variáveis de entrada (inputs), no sistema de inferência ou no sistema de aprendizado. As principais técnicas de inteligência artificial encontradas na Revisão Sistemática da Literatura foram baseadas em lógica fuzzy, em algoritmos evolucionários com ênfase nos algoritmos genéticos e em técnicas de data mining destacando-se modelos de segmentação.

3. Descrição do Experimento

O objetivo geral deste trabalho é avaliar modelos quantitativos de previsão baseados em análise de séries temporais, em métodos causais e em técnicas de inteligência artificial. Para cumprilo foram desenvolvidas alternativas de modelos de previsão em cada método e aquela alternativa com a melhor acurácia foi eleita para ser testada e comparada com os demais métodos, conforme Figura 1.

Com o objetivo de comparar a acurácia de modelos lineares versus modelos não lineares de previsão e vendas, foi comparado a Média dos Erros Percentuais Absolutos (MAPE) dos métodos A, B e D que são métodos que captam efeitos lineares e C e E que são métodos que captam efeitos lineares e não lineares. Para avaliar se a inclusão de variáveis externas gera ganho na capacidade de previsão, foi comparada a MAPE dos métodos C (sem inclusão de variáveis externas) e E (com inclusão de variáveis externas) e comparado os métodos B (sem inclusão de variáveis externas) e D (com inclusão de variáveis externas). Com o objetivo de avaliar se otimização por Algoritmos Genéticos gera ganho na capacidade de previsão, foi comparada a MAPE dos métodos E e F (Modelo com otimização por Algoritmo Genético).

3.1. Uma Descrição do Setor Têxtil

A pesquisa desenvolvida neste trabalho analisa os dados de vendas de uma empresa têxtil brasileira que atua nas etapas de fiação, tecelagem e beneficiamento de 57 tecidos de algodão, comercializando seus produtos para confecções que posteriormente irão produzir peças de vestuário para serem comercializadas aos consumidores finais.

A indústria produz e comercializa dois tipos distintos de segmento de tecido. Ela comercializa produtos para confecções do segmento Denim e do segmento Brim. O setor de vestuário,

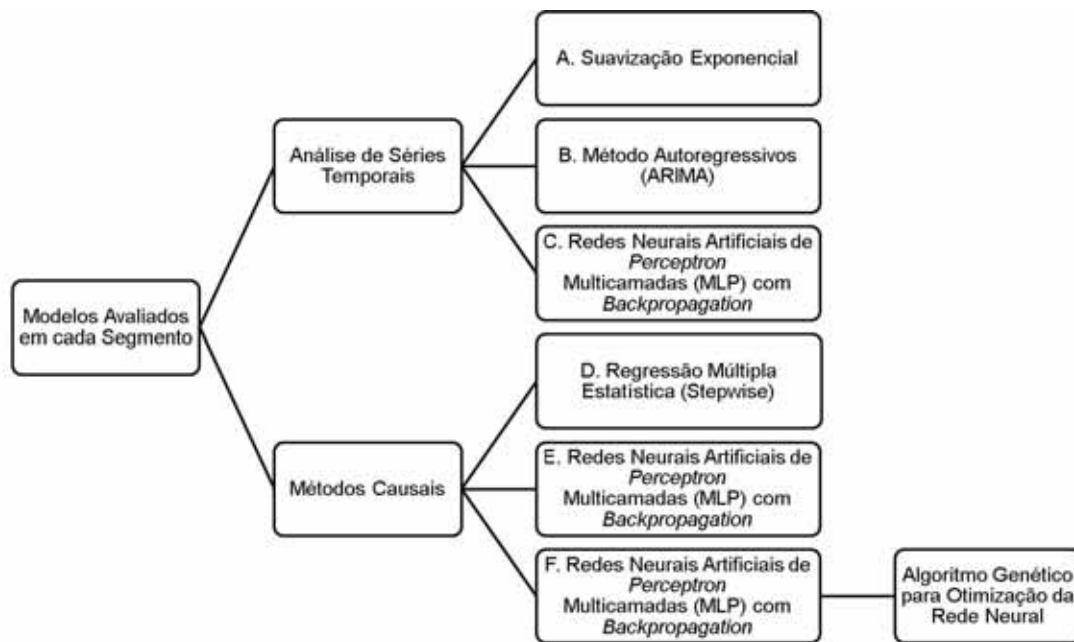


Figura 1: Modelos de Previsão Avaliados

que consome os tecidos dos dois segmentos, se caracteriza por ter vendas em maior quantidade no segundo semestre do ano devido, sobretudo ao Natal em que as famílias consomem mais produtos do gênero. Outra característica importante é que tendências de moda podem influenciar as vendas assim como produtos substitutos como malhas e tecidos sintéticos. Dessa forma, existe uma característica importante no setor que é sensação de imprevisibilidade das vendas, pois flutuações são comuns.

O problema de previsão de vendas no contexto em estudo passa a ser fundamental para o planejamento da produção, compra de insumos e gestão comercial e de marketing ao mesmo tempo em que se apresenta complexo por apresentar oscilações constantes.

3.2. Construção das Bases de Dados

Os dois Segmentos investigados possuem séries de vendas mensais, correspondem ao período de janeiro de 2006 a novembro de 2013 e representam a quantidade de metros faturados a cada mês. Para efeito de uma comparação da capacidade de predição de cada modelo as séries foram separadas em dois conjuntos. De janeiro de 2006 a março 2013 foi o período utilizado para desenvolvimento e treinamento dos modelos de previsão. As alternativas de cada modelo com o melhor desempenho na fase de treinamento foram selecionadas e testadas no período de abril de 2013 a novembro de 2013. A avaliação da acurácia de cada método utilizada na comparação foi relativa ao seu desempenho na fase de teste em termos de MAPE.

Como os modelos precisam dos dados passados para iniciar as previsões os dados do primeiro ano (2006) serão utilizados no treinamento, mas não será estimado o erro para esse período.

Para os modelos de Redes Neurais Artificiais baseados em Métodos Causais (Modelos E e F) e para as Regressões (Modelo D) foram acrescentadas cinco variáveis do ambiente como independentes e explicativas das vendas. Basicamente elas estão relacionadas ao nível de atividade econômica, ao custo de produção e volume de importação. Não é objetivo deste trabalho fazer uma análise mais profunda sobre as potenciais variáveis econômicas que poderiam afetar as vendas de uma indústria têxtil. Não obstante, optou-se por utilizar algumas variáveis ambientais mais comumente utilizadas em modelos de explicação de vendas.

Além da incorporação das variáveis ambientais de acordo com sua disponibilidade no momento da previsão também foram introduzidas variações temporais em todas as variáveis. A jus-

tificativa para isso é que uma variável pode ter impacto em outra depois de um determinado período de tempo, ou seja, uma variação em determinada variável independente pode afetar a variável dependente em um período posterior (lag). Não se espera efeitos com mais de 12 meses, dessa forma todas as variáveis foram defasadas em 12 variáveis sendo que cada uma apresentava uma defasagem de 1 a 12 meses.

A base de vendas do **Segmento A**, que representa os tecidos de Denim, possui uma distribuição com uma pequena tendência de crescimento e uma variação sazonal próximo a anual. A base de vendas do **Segmento B**, que representa os tecidos de Brim também apresenta uma característica de maior venda nos meses de agosto a outubro por serem os meses que abastecem as confecções para as vendas de vestuário no Natal.

3.3. Desenvolvimento dos Modelos de Previsão

Cada método avaliado possui alternativas de modelos dentro dele. Dessa forma em cada um deles foram avaliados mais de uma alternativa e escolhida a melhor para comparar com os demais métodos. No próximo capítulo são detalhados os resultados das alternativas testadas bem como os procedimentos principais para a construção de cada modelo.

Os resultados das previsões foram comparados em dois momentos. No primeiro momento foram analisadas as alternativas dentro de cada método comparando-se o desempenho das mesmas em função do MAPE (Média dos erros percentuais absolutos) obtido na fase de treinamento. As alternativas com melhor desempenho foram selecionadas e avaliadas durante a fase de teste, sendo novamente mensurado o desempenho das mesmas em função do MAPE.

Cada um dos seis métodos foi desenvolvido respeitando as mesmas condições de disponibilidade dos dados e delimitando-se o tempo para treinamento e para teste. É apresentado primeiro o desenvolvimento de cada um dos modelos por segmento investigado considerando apenas a fase de treinamento e na sequência são avaliados os resultados na fase de teste.

3.3.1. Modelo A - Suavização Exponencial

Como era esperado dadas as características sazonais da série do **Segmento A**, os modelos sazonais baseados no Método de Holt-Winters tiveram o melhor desempenho em termos de acurácia.

Os métodos sazonais de Efeitos Aditivos e os de Efeito Multiplicativos tiveram desempenho próximo. Basicamente a diferença entre eles é que aquele baseado em efeitos multiplicativos é mais indicado para séries em que a tendência e sazonalidade dependem do nível da série. Já o modelo de efeitos sazonais aditivos é mais indicado quando a tendência e a sazonalidade não dependem do nível.

Dado o desempenho na fase de treinamento e considerando que os métodos tiveram o mesmo comportamento em termos de significância dos parâmetros, selecionou-se aquele que obteve o melhor desempenho em termos de MAPE. Dessa forma, o Método de Holt-Winters para Efeitos Sazonais Aditivos foi o indicado dentre as alternativas de Suavização Exponencial.

Assim como no **Segmento A**, os métodos sazonais tiveram um desempenho superior na suavização exponencial para o **Segmento B**. O melhor modelo foi de Holt-Winters para Efeitos Sazonais Aditivos, que é mais indicado quando a tendência e a sazonalidade não dependem do nível. O desempenho dele será utilizado para comparação com as previsões dos demais métodos.

3.3.2. Modelo B - Método Autoregressivo (ARIMA)

A construção dos modelos Box-Jenkins é baseada em um ciclo iterativo, no qual a escolha do modelo é feita com base nos próprios dados. Para desenvolver os modelos ARIMA para os dois segmentos estudados serão realizadas as três etapas descritas na revisão da literatura, que são:

1. Identificação: consiste em descobrir qual modelo dentre as várias opções descreve o comportamento da série. A identificação do modelo a ser estimado é baseada no comportamento das funções de autocorrelações (ACF) e das funções de autocorrelações parciais (PACF).

2. Estimação: consiste em estimar os parâmetros.
3. Verificação: consiste em avaliar se o modelo estimado é adequado para descrever o comportamento dos dados.

Ao se analisar a série para o **Segmento A** nota-se sazonalidade em que os meses de novembro, dezembro são marcados por menores vendas. A série tem um comportamento não estacionário. Dessa forma a diferenciação é necessária para remover a presença de tendência e permitir a correta estimação dos parâmetros. Para tornar a série estacionária removeu-se a tendência anual diferenciando a série em 12 meses e aplicou-se a primeira diferença. Dessa forma, a série estacionária tem uma diferença na componente não sazonal e uma diferença na componente sazonal.

O **Segmento B** apresenta um comportamento similar quanto a sazonalidade ao **Segmento A**, no entanto as variações sazonais são mais perceptíveis no gráfico de evolução das vendas. A série também tem um comportamento não estacionário. Para torná-la estacionária removeu-se a tendência anual diferenciando a série em 12 meses e aplicou-se a primeira diferença. Dessa forma, a série estacionária tem uma diferença na componente não sazonal e uma diferença na componente sazonal.

3.3.3. Modelo C - Redes Neurais Artificiais de Perceptron Multicamadas (MLP) com Backpropagation

Foram testados modelos de Redes Neurais supervisionadas baseados em Multicamadas treinadas por meio do algoritmo de retropropagação (backpropagation). Os modelos foram treinados com bases nos dados de janeiro de 2006 a março de 2013. Foram avaliadas as seguintes combinações de Topologia e variações no algoritmo de treinamento.

Topologia: Foram testadas Redes Neurais com uma e duas camadas ocultas com funções de ativação dos neurônios de Curva Sigmoide. Foram testadas diferentes configurações de número de neurônios em cada camada. As opções foram: 3, 6, 9, 12, 15, 18, 21, 24, 27, 29, 32 neurônios em cada camada.

Treinamento: Para se estimar os pesos utilizou-se o algoritmo de backpropagation. Foram testadas redes com diferentes configurações de treinamento. Os parâmetros e as opções de configurações testadas foram: Taxa de Aprendizagem: 0.01, 0.1, 0.2, 0.3, 0.5, 0.7, 0.9, 1; Termo de Momento: 0.01, 0.1, 0.2, 0.3, 0.5, 0.7, 0.9, 1; % de períodos utilizados para Validação: 10%, 20%, 30%

Com relação a Redes Neurais Artificiais MLP com Backpropagation para o **Segmento A**, as 10 redes com melhor desempenho apresentaram apenas 1 camada e taxa de aprendizagem de 0,01. Os demais parâmetros variaram entre as 10 redes com melhor desempenho. Nota-se que não houve grandes variações nas medidas de erro entre as fases de treinamento e teste.

Com relação ao **Segmento B**, as 10 redes com melhor desempenho no **Segmento B** apresentaram arquiteturas e parâmetros variados. Os erros na fase de treinamento se mostraram maiores do que no **Segmento A**.

3.3.4. Modelo D - Regressão Múltipla Estatística (Stepwise)

A construção das regressões em cada segmento se deu pelo método stepwise para seleção de variáveis, refinamento do modelo e avaliação da qualidade de ajuste. O primeiro passo consiste em fornecer todas as variáveis de entrada para o modelo que irá excluir ou manter a variável avaliando a sua importância para explicar variações no modelo específico. Dessa forma, o procedimento constrói modelos com as variáveis com as maiores importâncias estatísticas. Contudo, nem sempre o modelo criado corresponde ao mais adequado seja porque algumas das variáveis podem possuir coeficientes não significativos ou por ainda existirem variáveis altamente correlacionadas. Dessa forma, opções de regressões foram construídas para alcançar modelos mais criteriosos do ponto de vista estatístico. Além disso, a regressão dentre dos métodos causais de previsão tem uma característica de tentar explicar os efeitos das variáveis relacionando-os com a teoria. Dessa forma

também foram evitados modelos que apresentavam em seus parâmetros efeitos contraditórios em uma primeira análise.

Para o **Segmento A** a regressão construída apresentou 9 variáveis das 70 disponíveis, todas elas significativas ao nível de significância 10%. Esse modelo apresentou um MAPE na fase de treinamento de 8,78% e mostrou-se um modelo bem comportado do ponto de vista estatístico. Dessa forma, foi selecionado como o modelo de regressão com melhor desempenho para o **Segmento A**.

Para o **Segmento B** a regressão construída apresentou 11 variáveis independentes das 70 disponíveis, todas elas significativas à 10%. Partiu-se do modelo gerado pelo procedimento Stepwise tomando-se o passo (step) com melhor ajuste. Esse modelo apresentou um MAPE na fase de treinamento de 9,34% e mostrou-se um modelo bem comportado do ponto de vista estatístico. Dessa forma, foi selecionado como o modelo de regressão com melhor desempenho para o **Segmento B**.

3.3.5. Modelo E - MLP com Backpropagation e inputs de Variáveis Ambientais

Foram testados modelos de Redes Neurais supervisionadas baseados em Multicamadas treinadas por meio do algoritmo de retropropagação (backpropagation). Os modelos seguiram as mesmas condições de arquitetura e treinamento dos desenvolvidos na seção anterior. A única diferença foi a incorporação de outras variáveis como inputs do modelo.

As redes construídas seguiram as seguintes variações. Topologia: Foram testadas Redes Neurais com uma e duas camadas ocultas com funções de ativação dos neurônios de Curva Sigmoides. Foram testadas diferentes configurações de número de neurônios em cada camada. As opções foram: 3, 6, 9, 12, 15, 18, 21, 24, 27, 29, 32 neurônios em cada camada.

Treinamento: Para se estimar os pesos utilizou-se o algoritmo de backpropagation. Foram testadas redes com diferentes configurações de treinamento. Os parâmetros e as opções de configurações testadas foram: Taxa de Aprendizado: 0.01, 0.1, 0.2, 0.3, 0.5, 0.7, 0.9, 1. Termo de Momento: 0.01, 0.1, 0.2, 0.3, 0.5, 0.7, 0.9, 1. Percentual de períodos utilizados para Validação: 10%, 20% e 30%

Variáveis de Entradas: Foram testadas redes com todas as variáveis ambientais disponíveis no momento da previsão e um cenário com todas as variáveis que possuem correlação significativa a 5% com a variável dependente.

Com relação ao MLP com Backpropagation e inputs de Variáveis Ambientais para o **Segmento A**, não houve grandes diferenças de desempenho entre as Redes desenvolvidas com todas as variáveis ambientais e aquelas apenas com as variáveis selecionadas. Apesar disso, as redes com melhor desempenho são as que utilizaram todas as variáveis como input do modelo. No **Segmento B** não houve diminuição relevante no MAPE devido a seleção de variáveis correlacionadas para input do modelo.

3.3.6. Modelo F - MLP com Backpropagation combinada com Algoritmo Genético

Os Algoritmos Genéticos foram utilizados na construção do Modelo F como técnica de busca e otimização, capaz de procurar soluções ótimas ou quase ótimas em um intervalo de domínio. Com esse objetivo definiu-se os parâmetros do Algoritmo Genético de forma que ele evoluísse a população de indivíduos (no caso configuração das redes neurais) encontrando soluções melhores em termos de um menor erro de previsão.

Foram testadas algumas configurações de evolução. As evoluções de maior sucesso são aquelas que se consegue atingir os melhores parâmetros de fitness (função objetivo do modelo) do melhor indivíduo. Uma forma de mostrar o desempenho da evolução é plotando a evolução da fitness do melhor indivíduo, do pior indivíduo e da média da população a cada geração. Para o **Segmento A** as duas melhores configurações de evolução foram a com uma taxa de combinação de 90% e uma mutação de 10% e a com uma taxa de combinação de 80% e de mutação de 30%.

Para o **Segmento B** as duas melhores configurações de evolução foram a com uma taxa de combinação de 80% e uma mutação de 40% e a com uma taxa de combinação de 70% e de

mudança de 30%. Considerando o melhor indivíduo da última geração da segunda configuração tem-se uma rede com uma camada oculta, oito neurônios nessa camada, uma taxa de aprendizagem de 0,359, um termo de momento de 0,375 e 0% de períodos destinados a validação durante a fase de treinamento.

4. Resultados das Previsões de Vendas

4.1. Comparação dos Modelos

É importante destacar que apesar da seleção das alternativas dentro de cada modelo ter seguido um critério objetivo, as variações no erro entre as alternativas não necessariamente eram significativas do ponto de vista estatístico. O critério utilizado neste trabalho é avaliar as diferenças absolutas no erro de previsão, indo de encontro a outras pesquisas que buscam a avaliar a percepção sobre a avaliação do gestor que toma a decisão com base nas previsões.

Assim como na análise das alternativas por modelo, essa seção também fará comparações apenas considerando as diferenças absolutas entre os métodos. Não obstante, ao final das comparações faz-se uma reflexão sobre a relevância dessas diferenças para as organizações.

4.2. Comparação dos Modelos para o Segmento A

Os modelos podem ser classificados em duas dimensões: quanto à modelagem de efeitos lineares e não lineares e quanto ao tipo de método - causal ou de análise de séries temporais. Os modelos lineares desenvolvidos e avaliados foram o Modelo A de suavizações exponencial, o Modelo B baseado no método ARIMA e o Modelo D baseado em regressões lineares. Por sua vez, os modelos não lineares desenvolvidos e testados foram os modelos baseados em Redes Neurais Artificiais ilustrados pelos modelos C e E.

Os modelos baseados em análise de uma única série temporal, ou seja, sem a inclusão de variáveis externas são os modelos A de suavização exponencial, B que utiliza ARIMA e C que utiliza RNA somente com a própria série de vendas como neurônios de entrada. Já os modelos D de regressão linear e E de RNA possuem outras cinco variáveis que auxiliam na previsão dos valores futuros das vendas.

O modelo F baseado em redes neurais capta efeitos não lineares e utiliza variáveis externas para a previsão das vendas. Contudo, ele possui um importante diferencial em relação aos demais que é a combinação com outra técnica de inteligência artificial para sua otimização. Dessa forma, a comparação com os ganhos da otimização será realizada de forma separada.

No Segmento A, conforme observado na Figura 2, os erros na fase de teste ficaram próximos. De qualquer maneira, nota-se que os modelos D e E tiveram uma média dos erros percentuais absolutos menor, sendo que o modelo de regressão foi aquele que teve o melhor desempenho.

O terceiro objetivo era avaliar ou testar a hipótese de que os métodos com capacidade de modelar efeitos não lineares nas séries temporais possuem um menor erro de previsão. No segmento A, nota-se que o modelo de melhor desempenho foi um método que capta efeito linear nos seus parâmetros demonstrando que nesse caso a utilização dos modelos não lineares não foi responsável por gerar ganhos relevantes de previsão.

O quarto objetivo específico era avaliar se a inclusão de variáveis externas gera previsões com um menor erro. De acordo com os resultados obtidos no teste dos modelos no segmento A, nota-se que os modelos D e E que são métodos causais tiveram um melhor desempenho o que aponta que os modelos com inclusão de variáveis externas possibilitaram um ganho de acurácia de previsão, ainda que não tenha sido em grande magnitude.

4.3. Comparação dos Modelos para o Segmento B

No Segmento B, conforme observado na Figure 3, os erros na fase de teste tiveram uma variação maior que no segmento A. Nota-se que os modelos C e E tiveram uma média dos erros percentuais absolutos na fase de teste menor, sendo que a Rede Neural com a inclusão de variáveis externas teve o menor erro de previsão.




Figura 2: Comparação dos Modelos para o Segmento A




Figura 3: Comparação dos Modelos para o Segmento B

Considerando a fase de teste, os resultados mostram que para o segmento B os modelos que captam efeitos não lineares conseguiram um desempenho superior aos modelos lineares. Os resultados mostram também que apesar da regressão não ter apresentado um melhor desempenho na fase de teste ainda assim o melhor modelo foi utilizando variáveis causais, porém agora em um método de redes neurais.

4.4. Modelo MLP com Otimização por Algoritmo Genético versus demais modelos

O quinto objetivo era avaliar se a combinação de um método de previsão com técnicas de inteligência artificial para otimização gera um modelo com menor erro de previsão. O Modelo F foi construído com base em redes neurais de multicamadas treinadas pela retropropagação do erro, assim como o modelo E, a diferença é que no modelo F combinou-se a escolha da melhor configuração de rede a partir da utilização do algoritmo genético de evolução. As Figuras 4 e 4 mostram os resultados dos 6 modelos e demonstram que o modelo F conseguiu um erro inferior nos dois segmentos.

Era natural que o algoritmo genético conseguisse um modelo com um erro inferior na fase de treinamento, pois o objetivo da evolução era chegar a indivíduos com esse perfil. Os resultados




Figura 4: Comparação Modelo MLP com Otimização por Algoritmo Genético versus demais modelos para o Segmento A

nos dois segmentos mostram que a solução encontrada pelo algoritmo genético conseguiu um desempenho superior aos demais modelos alcançando ganhos de 2,6 pontos percentuais no segmento A e 2,0 pontos percentuais no segmento B em relação ao melhor modelo sem otimização.




Figura 5: Comparação Modelo MLP com Otimização por Algoritmo Genético versus demais modelos para o Segmento B

4.5. Comparação dos Modelos com Melhor Desempenho

A avaliação final das melhores alternativas de cada modelo testado aponta que os métodos híbridos obtiveram um melhor desempenho em termos de erro de previsão. A utilização do algoritmo genético como técnica de busca e otimização possibilitou a identificação de uma solução com melhor capacidade preditiva, conforme pode ser visto na Figura 6.

Os modelos de Redes Neurais que utilizam dados do ambiente mostraram um desempenho bom nos dois segmentos, por outro lado o uso das redes sem as variáveis externas não tiveram o mesmo desempenho.

O modelo de regressão possui um importante diferencial em relação aos demais que é a capacidade de compreender os efeitos das variáveis preditoras na variável prevista, trazendo uma visão teórica para o estudo de previsão. O modelo conseguiu bons resultados tanto na fase de treinamento como na fase de teste. Além disso, foi o modelo com melhor desempenho no segmento A com exceção do modelo F.

O segmento B apresentava uma sazonalidade e uma variação maior ao longo de sua série temporal de vendas e os modelos não lineares podem ter conseguido captar efeitos que influenciam nessas variações. Por outro lado, no segmento A a captação dos efeitos pelos modelos lineares foi suficiente para se conseguir previsões com um erro menor.

Importante ressaltar que todos os modelos tiveram erros relativamente baixos, em que o modelo de pior resultado no segmento A (Modelo B) teve uma média dos erros percentuais absolutos de 6,78% na fase de teste. No segmento B, o modelo de pior desempenho (Modelo A) teve uma média dos erros percentuais absolutos maior, 11,41%.

Modelo	Segmento A	Segmento B
	MAPE Teste	MAPE Teste
A - Suavização Exponencial	6,35%	11,41%
B. Método Autoregressivos (ARIMA)	6,78%	10,16%
C. MPL com <i>Backpropagation</i> sem variáveis externas	6,27%	8,13%
D. Regressão Múltipla Estatística (Stepwise)	5,58%	11,26%
E. MLP com <i>Backpropagation</i> com variáveis externas	5,74%	5,84%
F. MPL com <i>Backpropagation</i> combinada com otimização por meio de Algoritmo Genético	2,92%	3,85%

Figura 6: Comparação dos Modelos Testados

5. Análise dos Resultados

Diferente do que se esperava, os resultados de teste apresentaram erros menores do que os da fase de treinamento. Uma das hipóteses é que a série poderiam possuir dados heterogêneos o que estaria dificultando a fase de treinamento. Testou-se dados de entrada mais recentes (2 e 3 anos) para a fase de treinamento e de fato observou-se menores erros na fase de treinamento, porém maiores erros na fase de teste.

Os modelos implementados no contexto da indústria estudada demonstraram que as previsões por eles geradas podem auxiliar as decisões no ambiente organizacional uma vez que apresentaram erros relativamente baixos. Contudo, a complexidade para o seu desenvolvimento talvez ainda seja um impeditivo para serem mais difundidos nas indústrias brasileiras.

Por outro lado, a diferença entre os modelos mais complexos e de maior esforço computacional apresentaram um melhor resultado, mas dependendo do contexto de utilização das previsões a relação de esforço e ganho de acurácia talvez não se faça necessária. Nesse sentido, os modelos de Suavização Exponencial podem ser utilizados como ferramentas de previsão interessantes.

A diferença entre os resultados entre o segmento A e B mostra que as variáveis de entrada e a série a ser prevista são fatores preponderantes para o resultado do modelo. Dessa forma, os melhores modelos podem variar de acordo com o contexto e características do problema de previsão a ser estudado. Não obstante, os modelos híbridos mostram-se como um importante desenvolvimento científico, pois os resultados de ganho de previsão têm se mostrado consistentes.

6. Conclusão

Este trabalho tem como objetivo geral avaliar modelos quantitativos de previsão baseados em análise de séries temporais, em métodos causais e em técnicas de inteligência artificial para a previsão de vendas a ser testada em dados reais de uma indústria têxtil.

Para as séries de vendas analisadas de uma indústria têxtil brasileira, a inclusão de variáveis externas ou causais auxiliaram na melhor acurácia dos modelos de previsão. Nem sempre os modelos que captam efeitos não lineares possuem um desempenho superior aos modelos lineares. Além disso, os resultados mostraram que o modelo baseado em Redes Neurais Artificiais Multicamadas com Backpropagation quando otimizado por algoritmo genético permitiu a parametrização da rede que alcançasse um erro de previsão menor.

Entre as limitações do trabalho, identifica-se que os modelos de previsão baseados em Redes Neurais se mostraram instáveis. Uma rede com a mesma arquitetura possuía um coeficiente de variação significativo o que indica que ela não está estável e é altamente dependente da semente aleatória que dá início ao seu treinamento. O esforço para encontrar uma boa configuração de rede que não gere um overfitting exigiu muitas horas de análise e programação. Essa situação dificulta o uso mais intensivo das técnicas de inteligência artificial no ambiente organizacional. Além disso, as Redes Neurais mostraram-se sensíveis aos dados de treinamento. A utilização de outras técnicas de avaliação do erro diante de dados de treinamento diferentes podem auxiliar na construção de conclusões gerais.

Referências

- Armstrong, J. (2008). Sales forecasting. Technical report, University of Pennsylvania - Marketing Department. Disponível em dx.doi.org/10.2139/ssrn.1164602.
- Bahrammizadeh, A. (2010). A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems. *Neural Comput. Applic.*, 19:1165–1195.
- Drummond Reis, F., Abreu Gomes, O., and Silva Parreiras, F. (2014). Métodos Quantitativos de Previsão de Vendas: uma Revisão Sistemática da Literatura. In *XXXIV Encontro Nacional de Engenharia de Produção (ENEGEP 2014)*, Curitiba, Brasil, 7 a 10 de outubro, 2014. Anais.
- Lemos, F. (2006). Metodologia para seleção de métodos de previsão de demanda. Dissertação de mestrado, Programa de Pós-Graduação em Engenharia de Produção, Escola de Engenharia da Universidade Federal do Rio Grande do Sul, Porto Alegre.
- Passari, A. (2003). Exploração de dados atomizados para previsão de vendas no varejo utilizando redes neurais. Dissertação de mestrado, Departamento de Administração da Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, São Paulo.
- Thomassey, S., Happiette, M., and Castelain, J.-M. (2005). A global forecasting support system adapted to textile distribution. *International Journal of Production Economics*, 96(1):81–95.
- Wong, W. and Guo, Z. (2010). A hybrid intelligent model for medium-term sales forecasting in fashion retail supply chains using extreme learning machine and harmony search algorithm. *International Journal of Production Economics*, 128(2):614–624.