

# ESTUDO DOS MÉTODOS DE PREVISÃO DE DEMANDA APLICADO EM UMA EMPRESA DE AUDITORIAS MÉDICAS

## STUDY OF METHODS OF FORECASTING DEMAND APPLIED IN A MEDICAL COMPANY AUDITS

Aline Castello Branco Mancuso<sup>1,\*</sup>, Liane Werner<sup>1</sup>

### RESUMEN

A previsão de demanda é um dos principais fatores para a eficiência do gerenciamento das organizações, afetando diretamente a lucratividade do negócio. Quanto maior a acurácia da previsão de demanda melhor será o desempenho empresarial. Neste ideal, métodos de combinação de previsões e suas previsões individuais vêm sendo constantemente comparados. O objetivo principal deste trabalho é averiguar como as redes neurais artificiais (RNA) e o modelo de combinação por regressão se comportam frente a uma série de dados reais (divergentes), métodos encontrados como melhores no estudo de simulação (séries estacionárias) em Mancuso (2013). Aplicado aos dados de demanda dos serviços na área de auditoria médica, três técnicas de previsão foram avaliadas: RNA, Box-Jenkins (ARIMA), alisamento exponencial; e três combinações foram consideradas: média simples (aritmética), variância mínima e regressão. Os resultados demonstram a superioridade dos métodos de combinação, em termos precisão, comparados às previsões individuais. A combinação por regressão obteve as previsões mais acuradas, mas as previsões obtidas com RNA não apresentaram o mesmo destaque.

**Palavra Chave:** Previsão de demanda, combinação de previsões, auditoria médica.

### ABSTRACT

Demand forecasting is a major factor for the efficiency of the management of organizations, directly affecting business profitability. Higher accuracy of the prediction, better the business performance. In this ideal, methods of combining individual forecasts and their forecasts are being constantly compared. The main objective of this work is to investigate how artificial neural networks (ANN) and regression model combination behave in the face of a series of real data (divergent), better methods found in the simulation study (stationary series) in Mancuso (2013). Applied to demand data services in the area of medical audit, three forecasting techniques were evaluated: ANN, Box-Jenkins (ARIMA), exponential smoothing, and three combinations were considered: simple average (arithmetic mean), minimum variance and regression. The results demonstrate the superiority of combination methods, in terms precision, compared to individual forecasts. The combining regression obtained the most accurate predictions, but the predictions obtained with RNA did not show the same prominence.

**Keywords:** Demand forecasting, combined forecast, medical audit.

<sup>1</sup>Universidade Federal do Rio Grande do Sul (UFRGS), Programa de Pós Graduação em Engenharia de Produção (PPGEP). CEP 90.035-190 Brasil, Porto Alegre /RS. liane@producao.ufrgs.br

\*Autor para correspondência: aline.mancuso@gmail.com

Recebido: 25.11.2013 Aceitado: 15.04.2014

## INTRODUÇÃO

A competição empresarial se desenvolveu significativamente nas últimas décadas. Muitas empresas, se não todas, precisam lidar com novos e crescentes critérios para concorrer e garantir a própria sobrevivência. Neste contexto, a previsão de demanda se tornou um dos principais fatores na gestão das empresas, revelando-se como uma alternativa estratégica para enfrentar as oscilações da demanda e, assim, evitar prejuízos.

A previsão de demanda é, portanto, fundamental para o planejamento da demanda e, por extensão, para a cadeia produtiva (Wang & Chang, 2010). No entanto, esta alternativa estratégica não é exclusiva das indústrias, empresas prestadoras de serviços também exigem organização e planejamento. Em setores que possuem grande rotatividade e flexibilidade de serviços, com “*lead times*” variados, exige-se uma habilidade dinâmica de resposta. O negócio que possui estas características necessita de um elevado nível de precisão na previsão de demanda, para evitar o desbalanceamento dos recursos (tanto humanos como de equipamentos) e, conseqüentemente, os gastos desnecessários. Além de buscar um atendimento eficaz aos clientes.

Este é o caso da área de auditoria médica, onde a previsão de demanda é um desafio. Os dados históricos disponíveis para a previsão nesta área da saúde apresentam tendência, sazonalidade e fatores não controláveis (fatores naturais). Busca-se, então, como alternativa para o gerenciamento eficiente, a utilização de modelos estocásticos de previsão de séries temporais.

Neste sentido, o presente trabalho busca verificar se o método combinação de previsão por regressão e a utilização de redes neurais artificiais (RNA), encontrados como mais acurados na simulação de Mancuso (2013), também são os mais precisos quando aplicados a uma série real. A diferença segue no comportamento dos dados, a simulação avalia séries estacionárias, enquanto uma série real apresenta dados divergentes. Aplicado aos dados de demanda dos serviços na área de auditoria médica, são comparadas, em termos de acurácia, as seguintes técnicas de previsão: redes neurais artificiais (RNA), alisamento exponencial (AE), Box-Jenkins (ARIMA) e combinações. Calculando-se as previsões combinadas obtidas por meio da média simples, da variância mínima e por regressão. Assim como em Mancuso (2013), as medidas empregadas para a escolha do método mais preciso são MAE, MAPE, RMSE e o coeficiente U de Theil.

Este artigo está estruturado em cinco seções, sendo esta introdução a primeira. A seção dois contextualiza alguns métodos de previsão de demanda. A seção três descreve os dados utilizados e os procedimentos metodológicos desenvolvidos. Os resultados e discussões estão apresentados na seção quatro. E por último, na seção cinco, encontram-se as principais conclusões deste estudo.

### Previsão de Demanda

Realizar previsões é necessário, pois as organizações operam em uma atmosfera de incerteza. As decisões afetam o futuro da organização, porém devem ser tomadas com base nas informações do presente. Uma suposição ponderada sobre o futuro se torna mais valiosa do que uma suposição não ponderada. Além do mais, a previsão de demanda desempenha um importante papel em diversas áreas da organização como, por exemplo, na área de recursos humanos, planejando o nível da força de trabalho, e no setor financeiro, planejando o uso de recursos (Fogliatto *et al.*, 2005).

Contudo, a questão segue em que tipo de previsão (modelo) utilizar. Dado um conjunto de dados

históricos disponíveis, percebem-se na literatura diversos critérios a considerar na seleção dos métodos, entre eles o padrão dos dados existentes e o grau de acurácia desejado. Visto que, busca-se uma avaliação dos melhores métodos para previsão, aplicados em uma série real, o presente referencial teórico será subdividido em duas partes: (i) métodos de previsão e medidas de acurácia e (ii) previsão de demanda em auditorias médicas.

### **Métodos de previsão e Medidas de acurácia**

A previsão pode ser definida como um processo quantitativo ou qualitativo para a determinação de dados futuros. Dentre os métodos quantitativos, dois tipos básicos de modelos são usados: modelos de séries temporais (foco deste estudo) e modelos causais. Conforme Kerkkänen *et al.* (2009), existem pelo menos 70 diferentes técnicas para previsão de séries temporais. Entende-se por série temporal uma sequência de observações históricas sobre uma variável de interesse.

Em séries temporais, a metodologia Box-Jenkins é uma das mais conhecidas e utilizadas para previsões (Chen & Wang, 2007; Xuet *et al.*, 2010). Segundo Chen & Wang (2007) a vantagem desta técnica é sua flexibilidade, outros autores apontam o fato de serem simples e de baixo custo (Makridakis *et al.*, 1998; Martínez & Zamprogno, 2003; Morettin & Tolo, 2006). Já para Armstrong & Brodie (1999) o alisamento exponencial é o método mais popular e com o melhor custo/benefício entre as técnicas de séries temporais. Taylor (2003) também valoriza o alisamento exponencial por sua robustez e praticidade nas aplicações em que um grande número de séries é considerado. No entanto, estes métodos sofrem a limitação de serem técnicas lineares, isto é, inadequadas para muitos problemas do mundo real. Neste ponto, Zhang (2003) sugere que as RNA podem ser uma alternativa promissora aos tradicionais métodos lineares por sua capacidade de modelação não-linear.

Todavia, desde Bates & Granger (1969) as técnicas de previsões deixaram de ser estudadas apenas de forma individual. Diversos métodos de combinação de previsões foram ganhando destaque por seu desempenho. No entanto, ainda não há um consenso de que algum método seja superior aos demais.

A média simples é um dos métodos mais conhecidos para combinação de previsões (Clemen, 1989; Menezes *et al.*, 2000). Para diversos autores este método é muitas vezes preferível à combinação ponderada (Figlewski & Urich, 1983; Jeong & Kim, 2009; Hsiao & Wan, 2011). Stock & Watson (2004) já definem o desempenho da média simples como um enigma da combinação de previsões. Jeong & Kim (2009) comparam teórica e empiricamente a média simples e a média ponderada e Menezes *et al.* (2000) discutem o desempenho da média aritmética em algumas situações específicas.

Superando o desempenho da média aritmética, Martins & Werner (2012) apontam a combinação de previsões pelo método da variância mínima como mais acurado. Mas, além dos métodos considerados usuais, a literatura apresenta uma grande variedade de estudos com outros enfoques. Poncela *et al.* (2011), por exemplo, propõem a utilização de técnicas de redução da dimensão, apontando a previsão de mínimos quadrados parciais (PLS), de regressão por componentes principais e de análise fatorial como superiores aos modelos usuais. Wang & Chang (2010) destacam a combinação por redes neurais (*fuzzy neural networks*). Já Hsiao & Wan (2011) apresentam um enfoque Bayesiano como superior ao clássico. Contudo, ainda no enfoque clássico, além da combinação via variância mínima, ajustes por regressão também têm ganhado destaque pelo potencial apresentado em termos de acurácia (Weatherford & Kimes, 2003; Chen, 2011; Mancuso, 2013).

Diversos estudos que comparam o desempenho de diferentes combinações concluem que nem sempre os métodos mais sofisticados são superiores aos mais simples (Stock & Watson,

2004; Koning *et al.*, 2005). Contudo, uma conclusão é unânime: a precisão das previsões pode ser substancialmente melhorada através da combinação de previsões individuais (Clemen, 1989). Segundo Hibon & Evgeniou (2005), a vantagem da combinação está na seleção de diferentes técnicas ao invés de escolher uma única previsão, além do melhor desempenho.

Em suma, a intenção é uma maior eficiência do sistema de previsão de demanda, reduzindo a incerteza e os erros. Assim, quanto maior for o grau de precisão associado às previsões melhor será o desempenho da organização. Para tanto, são utilizadas medidas de acurácia como indicadores dessa imprecisão e, também, como critério para seleção de métodos. A maioria das técnicas de previsão é fundamentada em minimizar a soma de quadrados ou de valores absolutos dos erros de previsão, e esta é uma maneira de medir a acurácia dos modelos. Entretanto, existem várias formas de medir a acurácia, dentre elas: o valor médio dos erros absolutos (MAE - *Mean Absolute Error*), o valor médio dos erros absolutos percentuais (MAPE - *Mean Absolute Perceptual Error*), a raiz do erro médio quadrático (RMSE - *Root Mean Squared Error*) e o coeficiente U de Theil.

As medidas relativas, baseadas em percentuais, independem de escala (ordem de grandeza dos dados), enquanto as medidas absolutas se caracterizam por serem dependentes da escala. Neste primeiro grupo, o MAPE é a medida mais utilizada nos estudos com comparação de métodos (Armstrong & Collopy, 1992). No segundo grupo, o RMSE tem sido considerado um dos mais populares para comparação de métodos, porém criticado por ser mais sensível à *outliers* do que o MAE (Armstrong & Collopy, 1992; Hyndman & Koehler, 2006). Hyndman e Koehler (2006) indicam a medida MAE quando todas as séries estão na mesma escala, pois sua compreensão é mais simples. Para Theil & Scholes (1967), a avaliação das previsões está frequentemente condicionada à heterogeneidade dos dados subjacentes, sendo algumas observações mais fáceis de prever que outras. Para tanto, Henri Theil propôs o coeficiente de desigualdade U.

### **Previsão de demanda em auditorias médicas**

A auditoria em serviços de saúde é um tema dos mais relevantes às instituições de saúde, porquanto essencial à manutenção da própria “saúde financeira” de tais organizações (Paes & Maia, 2005). Para tanto, no momento em que a saúde no Brasil apresentou um quadro onde os serviços públicos não tinham como atender às demandas da população e o acesso ao setor privado se tornou cada vez mais restrito, empresas foram criadas e desenvolvidas com foco na gestão destas organizações.

De acordo com a Agência Nacional de Saúde (ANS), a auditoria médica abrange um conjunto de atividades que consiste na revisão, perícia, intervenção ou exame de contas de serviços ou procedimentos realizados por organizações prestadoras de serviços de saúde. Para garantir a eficiência da prestação dos serviços de saúde, a auditoria médica é realizada com o objetivo de sinalizar as situações de não conformidade, tornando possível a intervenção no processo, além de se certificar sobre o cumprimento dos procedimentos padrões das rotinas (Nascimento, 2010).

Contudo, empresas deste nicho de mercado necessitam de uma ação gerencial voltada a garantir a segurança das operadoras de saúde associadas. Sendo a previsão de demanda recurso fundamental ao seu gerenciamento.

## **MATERIAIS E MÉTODOS**

De forma aplicada a dados quantitativos reais de uma empresa de auditoria na área da saúde, esta pesquisa se caracteriza como exploratória e descritiva: explora o uso dos métodos de

previsão em uma série temporal divergente (não estacionária), procurando descrever o conjunto de dados com máxima precisão possível, descobrindo suas relações e conexões, sua natureza e características, sem manipulá-los. Definindo-se um estudo de caso, por ser um procedimento de pesquisa em um contexto local.

A análise dos dados e dos métodos foi realizada com os softwares R-Project versão 2.15.0. Esta seção descreve o estudo de caso considerado e a metodologia empregada, detalhando os passos básicos para a realização da análise comparativa dos métodos de previsão (técnicas e combinações).

## **Estudo de Caso: Auditoria Médica**

Este estudo de caso foi fundamentado nos dados disponibilizados por uma empresa de auditorias e consultorias na área da saúde, sendo estes transformados matematicamente devido a questões de sigilo. Trata-se de uma empresa de pequeno porte que atualmente conta com aproximadamente 30 operadoras de saúde associadas. Assim, a demanda da empresa é estabelecida pelo total mensal de solicitações efetuadas no sistema.

## **Etapas de Pesquisa**

A fase inicial deste estudo contemplou seleção dos dados históricos das solicitações médicas registradas pela empresa, ou seja, a quantidade de auditorias e consultorias prestadas (demanda real); assim como sua análise descritiva. Tais dados serão obtidos diretamente da fonte oficial, compreendendo o período de setembro de 2006 a maio de 2012, resultando em 69 observações mensais. Após a análise preliminar dos dados, foram realizadas as três etapas descritas a seguir.

### **Etapa 1: Realização das modelagens individuais e obtenção das previsões**

Optou-se pelas técnicas tradicionais e de inteligência artificial dentre as diversas técnicas quantitativas de previsão baseadas em séries temporais. Por tradicional se definiu as técnicas de alisamento exponencial e de Box-Jenkins, pois ambas são amplamente difundidas (Armstrong & Brodie, 1999; Morettin & Tolo, 2006; Chen & Wang, 2007; Xu *et al.*, 2010). Segundo Abdel-Aal & Al-Garni (1997), os modelos Box-Jenkins são largamente utilizados tanto na medicina como na engenharia (Werner & Ribeiro, 2003). Dentro da inteligência artificial, optou-se pela previsão baseada em redes neurais artificiais, pois esta técnica tem apresentado um crescimento em suas aplicações e mostrado vantagens sobre as técnicas tradicionais (Calôba *et al.*, 2002; Paliwal & Kumar, 2009; Martins, 2011; Mancuso, 2013).

A rede neural utilizada neste trabalho será do tipo *feedforward* (direta) com *Perceptrons* de múltiplas camadas (*Multilayer Perceptrons* – MLP) e seu ajuste foi realizado com o pacote *neuralnet*. Para a definição dos parâmetros dos modelos, foi utilizada a opção de escolha automática, disponibilizada pelo programa computacional, a qual visa minimizar os erros.

### **Etapa 2: Cálculo das combinações de previsões**

Com as previsões individuais das três técnicas selecionadas na etapa anterior, foram calculadas as previsões combinadas. Para tanto, considerou-se o grupo de modelos de combinação listados na tabela 1.

**Tabela 1.** Modelos de Combinação de Previsões

Modelo	Fórmula
Média Simples	$C_i = \sum_{p=1}^3 \hat{y}_{pi} / 3$
Variância Mínima	$C_i = \sum_{p=1}^3 k_p \hat{y}_{pi} \text{ onde } k_p = \left( \sum_{i=1}^{69} e_{pi}^2 \right)^{-1} / \sum_{p=1}^3 \left( \sum_{i=1}^{69} e_{pi}^2 \right)^{-1}$
Regressão	$C_i = \alpha + \sum_{p=1}^3 \beta_p \hat{y}_{pi} + \varepsilon_i$

onde  $C_i$  é a previsão combinada para o período  $i$ , com  $i = 1, 2, 3, \dots, 69$  (total de observações);  $\hat{y}_{pi}$  é o valor da previsão  $p$  para o período  $i$ , tal que  $p =$  RNA (1), ARIMA (2) e Alisamento Exponencial (3); e, no modelo de regressão,  $\alpha$  e  $\beta_p$  são os coeficientes angular e linear, respectivamente, com  $\varepsilon_i$  o erro aleatório (ruído) para o período  $i$ . Supondo erros não correlacionados e  $\varepsilon_i$  com distribuição normal, média zero e variância constante. Sendo que  $k_p$  (peso da previsão  $p$ ) é deduzido pela equação desenvolvida a partir da proposta de Bates & Granger (1969) para o cálculo dos pesos, onde  $e_{pi} = (y_i - \hat{y}_{pi})$  é o erro da previsão  $p$  para o período  $i$ .

**Etapa 3:** Comparação das medidas de acurácia.

Os métodos de previsão (individuais e combinações) foram avaliados conforme o desempenho das medidas de acurácia: MAE, MAPE, RMSE e U de Theil, assim como em Mancuso (2013).

## RESULTADOS E DISCUSSÃO

Como resultado desta pesquisa, descreve-se primeiramente o comportamento dos dados a serem modelados. Seguindo-se, então, com a análise comparativa dos seis modelos validados.

### Análise Preliminar dos Dados

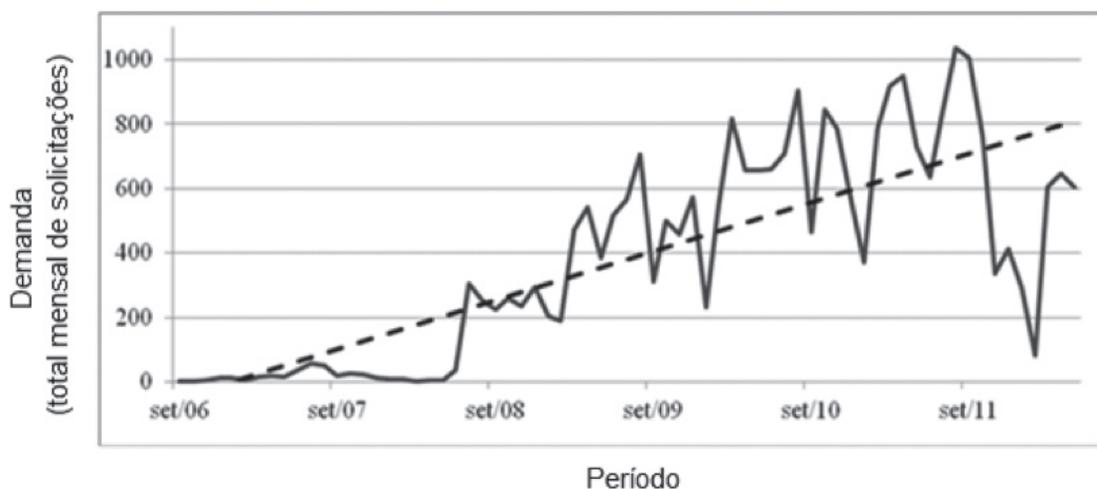
Para uma análise preliminar dos dados, primeiramente buscou-se identificar qual tipo de comportamento de série de dados esta demanda mensal se identificava. Assim, a análise exploratória dos dados permite investigar relações e estruturas comportamentais do conjunto de observações coletadas. A tabela 2 apresenta as estatísticas descritivas anuais para a demanda mensal.

**Tabela 2.** Análise descritiva anual da demanda de auditorias e consultorias prestadas pela empresa.

	2006	2007	2008	2009	2010	2011	2012	Total
Mínimo	01	04	03	188	233	337	83	01
Máximo	11	56	303	704	903	1035	647	1035
Média	05	24	136	451	654	731	446	380
Mediana	04	19	130	486	657	772	603	337
Desvio padrão	04	16	132	154	185	245	248	321
Curtose	2,65	0,15	-2,25	0,25	1,20	-1,01	-1,16	-1,20
Assimetria	1,50	1,05	0,08	-0,48	-0,92	-0,55	-0,96	0,29
Total	30	293	2008	5802	8222	7990	1855	26200

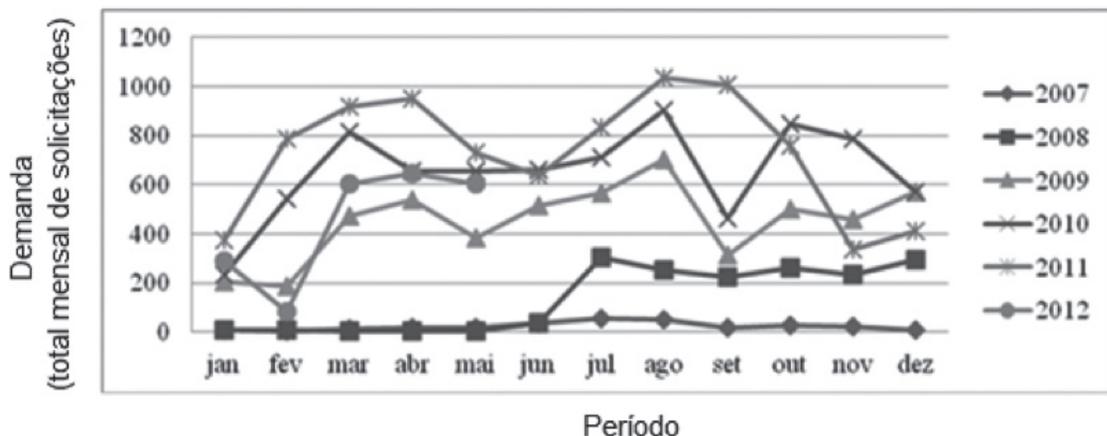
Ao analisar a tabela 2 é necessário atentar para o fato de que o conjunto de dados tem o seu início no mês de setembro de 2006 e seu término no mês de maio de 2012. Percebe-se, entretanto, um crescimento na demanda histórica entre 2008 e 2010, assim como o aumento da variabilidade nos anos subsequentes, 2011 e 2012. Esta estrutura comportamental da série é melhor reconhecida pelo gráfico da figura 1.

Ainda na tabela 2, os valores para curtose e assimetria encontrados para esta série variam entre negativos e positivos. A curtose, por ser uma medida que caracteriza o “achatamento” da curva da função de distribuição, quando negativa indica um pico mais tênue, um corpo mais grosso e uma cauda mais fina que a distribuição normal; e um valor positivo costuma indicar um pico mais agudo, um corpo mais fino e uma cauda mais grossa. Já a assimetria negativa representa a cauda esquerda da função maior que a do lado direito; e um valor positivo indica a cauda direita maior que a do lado esquerdo. Logo, apenas no ano de 2008 os dados apresentam ser simétricos (assimetria  $< 0,15$ ), sendo que nos anos de 2006 e 2007, os dados apresentaram uma forte assimetria ( $> 1,0$ ). Referente à curtose, considerando que a curva normal (Gaussiana) tem curtose igual a zero, os dados de 2008, 2011 e 2012 representam uma curva platicúrtica (mais achatada na sua parte superior), 2006 e 2010 (leptocúrtica) e 2007 e 2009 (mesocúrtica).



**Figura 1.** Histórico da demanda mensal de auditorias e consultorias prestadas pela empresa.

A figura 1 apresenta o gráfico dos dados históricos coletados da demanda. Este gráfico demonstra a relação dos valores demandados em função do período de observação, possibilitando o estudo do comportamento e das principais características da série. Assim, é possível observar que a série apresenta tendência positiva, indicada pela linha tracejada e confirmada ao se observar a média anual da demanda na tabela 2, que cresce ao longo dos anos. Porém, destaca-se uma queda na demanda em 2012. Sugere-se também o comportamento sazonal dos dados, que atinge altas quantidades nos meses de março/abril e julho/agosto caindo imediatamente em setembro/outubro, atingindo os níveis mais baixos em janeiro. Esta regularidade dos dados pode ser analisada pelo gráfico da figura 2.



**Figura 2.** Análise anual da demanda de auditorias e consultorias prestadas pela empresa.

Analisando a figura 2, pode-se desconfiar da sazonalidade dos dados, destacada pelo padrão de demanda relacionado aos meses. O teste de Fisher para verificar a existência de periodicidade na série confirma esta suspeita, com p-valor < 0,001 a série apresenta sazonalidade. Datas comemorativas (ex. ano novo) e férias são exemplos de fatores que podem interferir na demanda do setor médico. Assim, descreve-se a série em estudo como não estacionária e sazonal.

### Análise dos Métodos de Previsão

Com a realização da análise exploratória dos dados, verificou-se a estrutura comportamental da série em estudo. Fundamentando-se, assim, a modelagem da série. Como verificado anteriormente, a série apresenta tendência, sazonalidade e alta variabilidade. Logo, pela metodologia de Box-Jenkins, conclui-se que o processo SARIMA  $(0, 1, 1) \times (1, 1, 1)_{12}$  foi o mais adequado. Para a técnica de alisamento exponencial o modelo multiplicativo de Holt-Winters foi o que melhor se ajustou.

Após a comparação de distintas arquiteturas para as redes neurais, o modelo definido foi a *redfeedforward* (direta) de três camadas, com 30 variáveis explicativas na camada de entrada (referentes as 30 operadoras de saúde associadas a empresa), dois neurônios na camada intermediária e uma variável na camada de saída (total de demanda). Os demais parâmetros foram selecionados automaticamente pelo simulador. Para esta técnica em particular, enfrentou-se dificuldades, visto a divergência dos dados. Dos diversos modelos testados, obteve-se a convergência apenas com a alteração do parâmetro *stepmax*, sendo este expressivamente aumentado.

A figura 3 representa as três técnicas de previsões individuais modeladas e selecionadas a partir de um conjunto de validação. Na sequência, a figura 4 ilustra as três técnicas combinadas, tendo como base os modelos descritos anteriormente. Em ambas as figuras os valores reais observados estão representados por pontos.

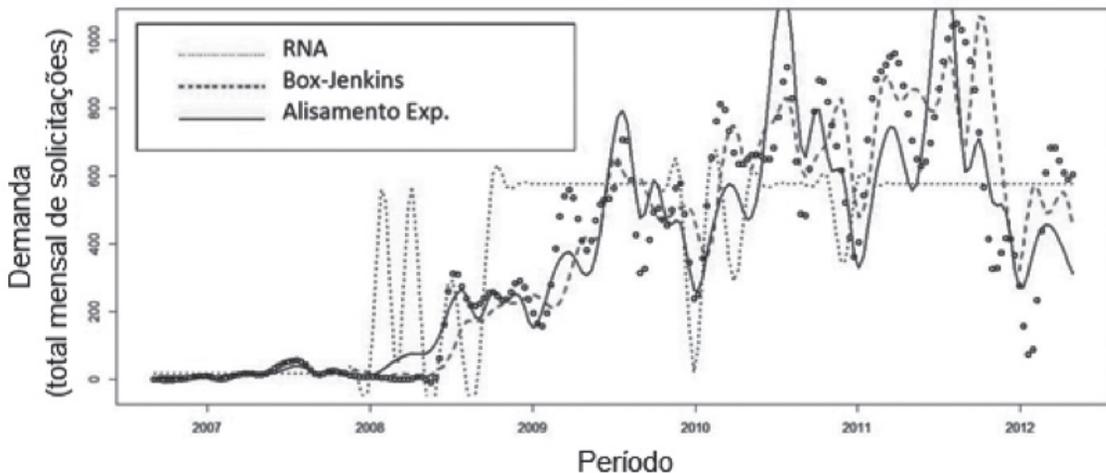


Figura 3. Modelos de Previsões Individuais

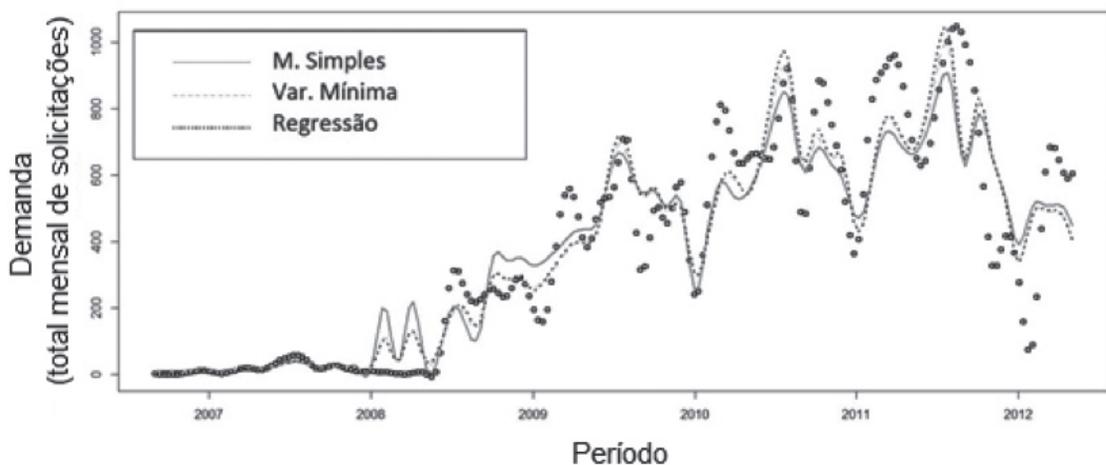


Figura 4. Modelos de Previsões Combinadas

Conforme a figura 3, apesar das redes neurais possuírem capacidade de aproximar relações complexas entre variáveis, as estimativas em regiões com menores concentrações de observações são visualmente imprecisas e seguem um padrão com representação limitada. Já os demais modelos de previsão individual, ao contrário da rede neural, subestimam a variabilidade dos valores extremos.

Observando a figura 4, percebe-se a suavização dos modelos, sendo as combinações por regressão e variância mínima muito similares em seu comportamento. Já no modelo de combinação por média simples é possível notar a contribuição das previsões por redes neurais. Contudo, apenas a tabela 3 permite uma real noção da acurácia dos modelos.

**Tabela 3.** Medidas de acurácia para a previsão de demanda dos seis modelos.

	<b>MAE</b>	<b>MAPE</b>	<b>RMSE</b>	<b>U de Theil</b>
<b>RNA</b>	156,51	418,52	219,78	0,2299
<b>ARIMA</b>	92,99	43,46	145,36	0,1464
<b>Alis. Exp.</b>	94,25	124,99	136,13	0,1403
<b>Média Simples</b>	91,74	190,06	129,22	0,1346
<b>Var. Mínima</b>	85,35	138,41	122,17	0,1264
<b>Regressão</b>	84,97	133,27	121,43	0,1244

Conforme constatado na tabela 2, a variabilidade no regime da série prejudica a acurácia dos modelos em geral. A menor média absoluta dos erros (MAE) foi de 84,97, obtida pela combinação via Regressão, seguida pela combinação por Variância Mínima. Assim como a raiz quadrada do erro quadrático médio (RMSE) e o coeficiente de desigualdade U de Theil, que também obtiveram melhores resultados para a combinação via Regressão, seguida pela combinação via Variância Mínima. Já a média percentual dos erros (MAPE) destaca o modelo de Box-Jenkins como melhor representação; visto que, este modelo apresentou maiores erros quando as previsões foram inferiores a demanda real (erros negativos), comparado às previsões com erros positivos. Observa-se que, o índice MAPE penaliza mais as previsões que excedem a demanda real do que as que são inferiores a esta. Fato que pode ser verificado pelo erro médio dos modelos, que foi de 3,71 para o ARIMA enquanto para alisamento exponencial, média simples e variância mínima o erro médio foi de 15,82; 4,03 e 5,55 respectivamente. Lembrando que, para os modelos RNA e Regressão, uma das suposições é média zero para os resíduos.

Contudo, verifica-se a superioridade dos métodos de combinação, em termos precisão, comparados às previsões individuais. As três combinações modeladas apresentaram maiores acurácias que as previsões individuais. Assim como em Mancuso (2013), a combinação por regressão foi o método mais preciso. Destacando-se, assim, a superioridade da combinação por regressão frente à dados divergentes. No entanto, a modelagem RNA apresentou as maiores medidas de acurácia. Nesta modelagem, em particular, obteve-se grande resistência à convergência, sendo necessários maiores recursos computacionais para tal.

## CONCLUSÕES

Baseando-se em quatro medidas de acurácia: MAE, MAPE, RMSE e U de Theil; o processo de regressão para combinação de previsões foi o mais cotado, precedido pela combinação via variância mínima, assim como em Mancuso (2013). Constatando-se, então, a equivalência do melhor método de previsão para séries estacionárias. No entanto, o modelo RNA não demonstrou superioridade em relação às demais técnicas de previsão individuais.

A respeito do modelo RNA, apesar de ser uma técnica para séries não lineares, obtiveram-se dificuldades para a convergência da série, sendo necessários maiores recursos computacionais, comparando-se aos demais métodos. Ainda no conjunto de validação, observou-se uma resistência ao acompanhamento das flutuações da série, selecionando-se o mais acurado. No entanto, estas dificuldades são devidas ao número de períodos observados; visto que, a técnica subdivide-se em treinamento, validação e teste.

Contudo, novamente a metodologia de combinação das previsões individuais destaca-se perante as demais técnicas. O indicativo dos resultados deste estudo é, claramente, que a

combinação de previsões pelo método de regressão não deve ser ignorado pelos previsores. Em suma, ainda que os ganhos da combinação sejam limitados, os riscos associados ao se incorporar previsões de diferentes fontes a um modelo parecem ser baixos frente aos ganhos em absorver informações complementares, desde que tratadas de forma adequada.

## REFERÊNCIAS

- ABDEL-AAL, Radwan., and AL-GARNI, Ahmed. Forecasting monthly electric energy consumption in eastern Saudi Arabia using univariate time-series analysis. *Energy*, 1997, vol. 22, no. 11, p. 1059-1069.
- ARMSTRONG, Jeff S., and COLLOPY, Fred. Error Measures for Generalizing About Forecasting Methods: Empirical Comparisons. *International Journal of Forecasting*, 1992, vol. 8, no. 1, p. 69-80.
- ARMSTRONG, Jeff S., and BRODIE, Roderick J. Forecasting for Marketing. [A. do livro] Graham J. Hooley e Michael K. Hussey. *Quantitative Methods in Marketing*. London: International Thompson Business Press, 1999, p. 92-119.
- BATES, John M., and GRANGER, Clive WJ. The Combining of Forecasts. *Operational Research Quarterly*, 1969, vol. 20, no. 4, p. 451-468.
- CALÔBA, Guilherme Marques., CALÔBA, Luiz Pereira., and SALIBY, Eduardo. Cooperação entre Redes Neurais Artificiais e técnicas 'clássicas' para previsão de demanda de uma série de vendas de cerveja na Austrália. *Pesquisa Operacional*, 2002, vol. 22, no. 3, p. 345-358.
- CHEN, Kuan-Yu. Combining linear and nonlinear model in forecasting tourism demand. *Expert Systems with Applications*, 2011, vol.38, p. 10368-10376.
- CHEN, Kuan-Yu., and WANG, Cheng-Hua. A hybrid SARIMA and suport vector machines in forecasting the production values of the machinery industry in Taiwan. *Expert Systems with Applications*, 2007, vol. 32, p. 254-264.
- CLEMEN, Robert T. Combining forecasts: A review and annotated bibliography. *International Journal of Forecasting*, 1989, vol. 5, p. 559-583.
- FIGLEWSKI, Stephen., and URICH, Thomas. Optimal Aggregation of Money Suply Forecasts: Accuracy, Profitability and Market Efficiency. *The Journal of Finance*, 1983, vol. 38, no 3, p. 695-710.
- FOGLIATTO, Flávio S., et al. Previsão de demanda por energia elétrica: método e aplicação. In *XXV Encontro Nacional de Eng. de Produção (ENEGEP)*, p. 3100-3107. ( 2005: Porto Alegre), [2005].
- HIBON, Michèle., and EVGENIOU, Theodoros. Combine or not to combine: selecting among forecasts and their combinations. *International Journal of Forecasting*, 2005, vol. 21, p. 15-24.
- HSIAO, Cheng., and WAND, Shui Ki. Comparison of forecasting methods with an aplication to predicting excess equity premium. *Mathematics and Computers in Simulation*, 2011, vol. 81, p. 1235-1246.
- HYNDMAN, Rob J., and KOEHLER, Anne B. Another look at measures os forecast accuracy. *International Journal of Forecasting*, 2006, vol. 22, p. 284-299.

JEONG, Dae., and KIM, Young-Oh. Combining single-value streamflow forecasts: A review and guidelines for selecting techniques. *Journal of Hydrology*, 2009, vol. 377, p. 284-299.

KERKKÄNEN, Annastiina., KORPELA, Jukka., and HUISKONEN, Janne. Demand forecasting errors in industrial context: Measurement and impacts. *Int. J. Production Economics*, 2009, vol. 118, p. 43-48.

KONING, Alex J., *et al.* The M3 competition: Statistical tests of the results. *International Journal of Forecasting*, 2005, vol. 21, p. 397-409.

MAKRIDAKIS, Spyros., WHEELWRIGHT, S., and HYNDMAN, Rob J. 1998. *Forecasting: Methods and Applications*. 3ª ed. New York : John Wiley & Sons, 1998.

MANCUSO, Aline Castello Branco. Uma investigação do desempenho de métodos de Combinação de Previsões: simulado e aplicado. *Dissertação de Mestrado*, UFRGS/ PGEP, Porto Alegre, 2013.

MARTINEZ, Raydonal Ospina., and ZAMPROGNO, Bartolomeu. Comparação de algumas técnicas de previsão em análise de séries temporais. *Revista Colombiana de Estadística*, 2003, vol. 26, no. 2, p. 129-157.

MARTINS, Vera Lúcia. Comparações de combinação de previsões correlacionadas e não correlacionadas com as suas previsões individuais: um estudo com séries industriais. *Dissertação de Mestrado*, UFRGS/ PGEP, Porto Alegre, 2011.

MARTINS, Vera Lúcia., and WERNER, Liane. Forecast combination in industrial series: A comparison between individual forecasts and its combinations with and without correlated errors. *Expert Systems with Applications*, 2012, vol. 39, p. 11479-11486.

MENEZES, Lilian M., BUNN, Derek W., and TAYLOR, James W. Review of guidelines for the use of combined forecasts. *European Journal of Operational Research*, 2000, vol. 120, p. 190-204.

MORETTIN, Pedro Alberto., and TOLOI, Clelia Maria de Castro. *Análise de Séries Temporais*. 2ª ed. São Paulo: Edgard Blucher, 2006. ISBN 852-12-0389-6.

NASCIMENTO, Francirene Maria Sousa. A auditoria médica como referência para melhoria da qualidade da prestação dos serviços de saúde. . *Dissertação de Mestrado*. Universidade Anhanguera/Uniderp, Belém, 2010.

HOSPITAL GERAL DE JUÍZ DE FORA. Manual de Auditoria de Contas Médicas. PAES, Pedro Paulo Lima., and MAIA, Juliana Ribeiro. Juiz de Fora (MG), 2005 [consultado em abril, 2014]. Disponível em: [http://dsau.dgp.eb.mil.br/arquivos/PDF/qualidade\\_gestao/manual\\_Auditoria.pdf](http://dsau.dgp.eb.mil.br/arquivos/PDF/qualidade_gestao/manual_Auditoria.pdf).

PALIWAL, Mukta., and KUMAR, Usha A. A Neural networks and statistical techniques: A review of applications. *Expert Systems with Applications*, 2009, vol. 36, p. 2-17.

PONCELA, Pilar., *et al.* Forecast combination through dimension reduction techniques. *International Journal of Forecasting*, 2011, vol. 27, p. 224-237.

STOCK, James H., and WATSON, Mark W. Combination Forecasts of Output Growth in a Seven-Country Data Set. *Journal of Forecasting*, 2004, vol. 23, p. 405-430.

TAYLOR, James W. Exponential smoothing with a damped multiplicative trend. *International Journal of Forecasting*, 2003, vol. 19, p. 715-725.

THEIL, Henri., and SCHOLES, Myron. Forecasting Evaluation Based on a Multiplicative Decomposition of Mean Square Errors. *Econometrica*, 1967, vol. 35, no. 1, p. 70-88.

WANG, Fu-Kwun., and CHANG, Ku-Kuang. Adaptive neuro-fuzzy inference system for combined forecasts in a panel manufacturer. *Expert Systems with Applications*, 2010, vol. 37, p. 8119-8126.

WEATHERFORD, Larry R., and KIMES, Sheryl. A comparison of forecasting methods for hotel revenue management. *International Journal of Forecasting*, 2003, vol. 19, p. 401-415.

WERNER, Liane., and RIBEIRO, José Luís Duarte. Previsão de Demanda: Uma aplicação dos Modelos Box-Jenkins na área de Assistência Técnica de Computadores Pessoais. *Gestão & Produção*, 2003, vol. 10, no. 1, p. 47-67.

XU, Xiaoyan., QI, Yuqing., and HUA, Zhongsheng. Forecasting demand of commodities after natural disasters. *Expert Systems with Applications*, 2010, vol. 37, p. 4313-4317.

ZHANG, Guoqiang Peter. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 2003, vol. 50, p. 159-175.