

# **Integração de métodos quantitativos e qualitativos para previsão de demanda no setor de autopeças**

Artigo a ser submetido ao periódico Gestão e Produção

**Fabício Fernandes (UFRGS)**

*fabricio-f@ig.com.br*

**Michel José Anzanello (UFRGS)**

*anzanello@producao.ufrgs.br*

## **RESUMO**

*O artigo tem como objetivo propor um método de previsão de demanda integrado que contemple tanto séries temporais quanto fatores contextuais. Para tal, são utilizados os modelos de suavização exponencial, ARIMA e média móvel. As previsões geradas pelo método quantitativo serão refinadas pelo método da análise hierárquica, AHP, incorporando a opinião de especialistas no processo. Tais especialistas são selecionados utilizando um indicador de consistência proposto por Ledauphin et al. (2006). O método gerou resultados robustos quando aplicado em dados de uma concessionária de veículos.*

**PALAVRAS-CHAVE:** *previsão de demanda; método da análise hierárquica; peças automotivas.*

## **ABSTRACT**

This paper proposes a forecasting framework integrating quantitative forecasting models and contextual factors. For that matter, we first estimate quantitative forecasting by testing the exponential smoothing, ARIMA and moving average forecasting models. Results are refined by the analytic hierarchy process, AHP, which incorporates experts' opinions into the analysis. Experts are selected based on the consistency index developed by Ledauphin *et al.* (2006). The proposed method performed remarkably when applied to data from an automotive company.

**KEYWORDS:** forecasting, AHP, automotive parts.

## **1. Introdução**

A competitividade e o aumento da instabilidade do mercado mundial exigem que o tempo de tomada de decisão das empresas seja reduzido constantemente. Prever a demanda é uma atividade importante, pois pode revelar as tendências de mercado e contribuir no planejamento estratégico da empresa (WERNER & RIBEIRO, 2003). A previsão de demanda é uma ferramenta essencial para tornar o processo decisório mais veloz e seguro. Segundo Gaither e Fraizer (2005), é necessário que as empresas sejam capazes de prever e que essa capacidade faça parte do planejamento dos negócios.

Um dos setores em que ferramentas de previsão de demanda assumem fundamental importância é o segmento automotivo. Segundo dados da ANFAVEA, o setor automotivo é responsável por quase um quarto do PIB industrial do país. O Brasil é o sexto maior produtor e quinto maior mercado mundial, tendo produzido mais de três milhões de unidades por ano desde 2004. Ainda segundo dados da ANFAVEA, o Brasil é um dos maiores conglomerados de marcas automotivas do mundo.

As técnicas de previsão de demanda usadas na cadeia de suprimentos do setor automotivo, no entanto, são caracterizadas pela simplicidade (média móvel e opinião de especialistas) (MESQUITA; CASTRO, 2008), podendo gerar resultados conflitantes. A aplicação de métodos integrados de previsão de demanda encontra largo respaldo na literatura. Werner e Ribeiro (2006) colocam que é necessário fazer uso de toda e qualquer informação de que se dispõe para geração de previsões confiáveis, visto que uma única técnica pode não ser suficiente. Lemos (2006) acrescenta que análises subjetivas devem ser integradas ao processo preditivo quando os métodos quantitativos não conseguem agregar aos modelos matemáticos mudanças internas e externas ao ambiente organizacional.

Em uma concessionária do setor automotivo, os ganhos oriundos da previsão integrada de demanda serão potencializados pela eficiente gerência dos estoques. Uma vez que as peças para venda e reposição têm um valor agregado significativo, Bornia (2009) destaca que o montante de capital investido em estoques pode se tornar uma ameaça à saúde financeira da empresa. Segundo Slack *et al.* (2007), estoques têm características ambivalentes, pois possuem tanto aspectos negativos quanto positivos. Para um melhor dimensionamento dos estoques através de previsão de demanda, Lemos (2006) destaca métodos qualitativos e quantitativos: os métodos qualitativos incluem a pesquisa de intenções e o método Delphi; já os quantitativos englobam a média móvel, suavização exponencial e o método de Box-Jenkins, entre outros.

Este artigo propõe um método de previsão de demanda integrado que busca inserir fatores contextuais em uma previsão obtida através de análise quantitativa. Para isso, o histórico de vendas da empresa é coletado e analisado através de métodos quantitativos de previsão de demanda. O melhor modelo é selecionado com base em critérios de aderência aos dados. Para minimizar a chance de discrepâncias das informações oriundas dos especialistas, utiliza-se o coeficiente  $\alpha$ , proposto por Ledauphin *et al.* (2006), que mede o grau de concordância de um especialista em relação a um grupo. Uma vez definidos os especialistas mais consistentes, a análise qualitativa é viabilizada pela ferramenta AHP (*Analytic Hierarchy Process*).

O artigo está dividido em cinco seções, incluindo a presente introdução. Na seção 2, é apresentado um breve referencial teórico, definindo os conceitos abordados no decorrer do artigo. A metodologia é desenvolvida na seção 3, enquanto que o estudo de caso é apresentado na seção 4. A última seção traz as conclusões.

## 2. Referencial Teórico

### 2.1. Previsão de demanda

A previsão dos níveis de demanda é vital para qualquer empresa, visto que proporciona subsídios para o planejamento e controle de todas as áreas (BALLOU, 2006). Gerentes necessitam de previsões de longo e curto prazo tanto para tomar decisões estratégicas quanto para responder às questões mais imediatas da empresa (GAITHER & FRAIZER, 2005).

Martins *et al.* (2005) definem previsão de demanda como um processo metodológico para a determinação de dados futuros baseado em modelos estatísticos, matemáticos ou econométricos ou ainda em modelos subjetivos apoiados em uma metodologia de trabalho clara e previamente estabelecida.

Os métodos de previsão dividem-se basicamente em métodos quantitativos e qualitativos. Métodos quantitativos (ou objetivos) são métodos estruturados que podem ser reaplicados por outros analistas, sendo que as previsões obtidas pela réplica são idênticas às originais (ARMSTRONG *apud* LEMOS, 2006). Tais modelos usualmente apóiam-se em modelagens matemáticas. Os métodos qualitativos de previsão, também chamados de intuitivos ou subjetivos, dependem da experiência acumulada pelos especialistas (LEMOS, 2006). Tais grupos de métodos são descritos na sequência.

### 2.2. Métodos quantitativos de previsão de demanda

Métodos quantitativos utilizam dados históricos para prever a demanda em períodos futuros. A previsão da demanda futura requer a construção de modelos matemáticos a partir dos dados que descrevem a variação da demanda ao longo do tempo. Este grupo de dados é denominado série temporal (PELLEGRINI, 2000).

O emprego de cada modelo depende basicamente do comportamento da série temporal que se deseja analisar. Segundo Makridakis *et al.* (1998), as séries temporais podem ser representadas por quatro padrões: média, sazonalidade, ciclo e tendência. O padrão de média existe quando os valores da série flutuam em torno de uma média constante. A série possui padrão sazonal quando padrões cíclicos de variação se repetem em intervalos relativamente constantes de tempo. O padrão cíclico existe quando a série exibe variações ascendentes e descendentes, porém em intervalos não regulares de tempo. Finalmente, o padrão de tendência ocorre quando a série apresenta comportamento ascendente ou descendente por um longo período de tempo (PELLEGRINI & FOGLIATTO, 2001). Os métodos quantitativos mais abordados são a média móvel, a suavização exponencial e o método de Box-Jenkins.

#### 2.2.1. Média móvel

O método da média móvel é amplamente utilizado pela sua facilidade de implementação e pela necessidade de poucos dados históricos para sua aplicação (LEMOS, 2006). O método calcula a média dos dados de alguns períodos recentes, a qual se torna a previsão para o período seguinte. Makridakis *et al.* (1998) afirmam que este método é apropriado apenas para previsões de curto prazo, onde a série temporal não apresenta tendência nem sazonalidade.

Uma alternativa para esse tipo de carência do método é a média ponderada, onde se aplica pesos desiguais aos dados históricos. Essa simples modificação permite que a importância relativa de cada período passado seja considerada na construção da previsão (GAITHER & FRAIZER, 2005).

#### 2.2.2. Suavização exponencial

Miranda (2009) afirma que os modelos de suavização exponencial se caracterizam por decompor uma série temporal em componentes, suavizar seus valores passados (dar pesos diferenciados que decaem exponencialmente com o tempo) e depois recompor as componentes para fazer as previsões. As três componentes na suavização exponencial são: nível, tendência e sazonalidade. O nível é o valor médio da observação no período (valor

observado retirando a sazonalidade e o erro aleatório), a tendência é a diferença sequencial de dois níveis consecutivos e a sazonalidade é um evento que se repete com uma periodicidade constante.

A suavização exponencial apóia-se apenas nos dados da própria série para fazer previsões, não necessitando de nenhuma variável independente, tais como a inflação ou a área disponível para armazenar produtos. Isto traz a vantagem da rapidez, uma vez que não é necessário buscar ou medir outras variáveis (COELHO, 2008).

Os métodos de previsão de demanda que aplicam suavização exponencial se dividem em: (i) suavização exponencial simples; (ii) suavização exponencial linear de Holt; e (iii) suavização exponencial de Holt-Winters (MAKRIDAKIS *et al.*, 1998). O modelo de suavização exponencial simples, por exemplo, só apresenta a componente de nível; o modelo de Holt contempla tanto nível como tendência; por fim, o modelo de Holt-Winters utiliza o nível, tendência e sazonalidade na modelagem (MIRANDA, 2009). Tais métodos são melhor descritos na sequência.

A Suavização exponencial simples considera a previsão correspondente ao período anterior e faz um ajuste para obter a previsão para o período seguinte (GAITHER & FRAIZER, 2005). O ajuste é realizado através da multiplicação do erro de previsão do período anterior e uma constante de amortecimento alfa ( $\alpha$ ) delimitada entre zero e um. Ainda segundo Gaither & Fraizer (2005), quanto maior o valor de  $\alpha$  maior será sua resposta ao impulso. A representação matemática do modelo é expressa pela equação (1) (MAKRIDAKIS *et al.*, 1998).

$$F_{t+1} = \alpha Y_t + (1 - \alpha)F_t \quad (1)$$

Onde  $F_{t+1}$  é a previsão para o período  $t+1$ ,  $F_t$  é a previsão do período anterior,  $Y_t$  a demanda no período anterior e  $\alpha$  a constante de amortecimento.

A suavização exponencial de Holt, por sua vez, pode ser utilizada de maneira satisfatória em séries temporais com tendência linear (PELLEGRINI, 2000). A incorporação de um componente de tendência em previsões exponencialmente amortecidas é chamada de *exponencial móvel dupla*, pois tanto as estimativas de média como de tendência são amortecidas (GAITHER & FRAIZER, 2005). A representação matemática do modelo é expressa pelas equações (2), (3) e (4) (MAKRIDAKIS *et al.*, 1998).

$$F_{t+k} = L_t + kT_t \quad (2)$$

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (3)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (4)$$

Onde  $F_{t+k}$  é a previsão para o período  $t+k$ ,  $k$  é o horizonte da previsão,  $T_t$  é a estimativa da tendência no período  $t$ ,  $L_t$  a estimativa de nível no período  $t$ , e  $\alpha$  e  $\beta$  são constantes de amortecimento com valores entre 0 e 1.

Por fim, a suavização exponencial sazonal de Holt-Winters descreve apropriadamente dados de demanda onde se verifica a ocorrência de tendência linear, além de um componente de sazonalidade (PELLEGRINI, 2000). O método oferece duas abordagens distintas, as quais dependem da forma como é modelada a sazonalidade. A forma multiplicativa é indicada para séries temporais em que a amplitude da sazonalidade varia com o nível da demanda. A forma aditiva é apropriada para séries temporais cuja amplitude da sazonalidade é independente do nível da demanda (WINTERS *apud* LEMOS, 2006). As equações básicas do método multiplicativo são (5), (6), (7) e (8) (MAKRIDAKIS *et al.*, 1998):

$$F_{t+k} = (L_t + kT_t)S_{t-s+k} \quad (5)$$

$$L_t = \alpha \left( \frac{Y_t}{S_{t-s}} \right) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (6)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (7)$$

$$S_t = \gamma \left( \frac{Y_t}{L_t} \right) + (1 - \gamma)S_{t-s} \quad (8)$$

Onde  $s$  é o número de períodos por ciclo sazonal,  $S_t$  é a estimativa do componente sazonal no período  $t$  e  $\alpha$ ,  $\beta$  e  $\gamma$  são constantes de amortecimento com valores entre 0 e 1.

O método aditivo é menos comum que o multiplicativo. As equações básicas do método aditivo são (9), (10), (11) e (12) (MAKRIDAKIS *et al.*, 1998):

$$F_{t+k} = L_t + kT_t + S_{t-s+k} \quad (9)$$

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (10)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (11)$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (12)$$

Os valores das constantes de suavização  $\alpha$ ,  $\beta$  e  $\gamma$  são arbitrários. A determinação do melhor valor para a constante pode ser feita iterativamente, utilizando alguma forma de comparação (por exemplo, a média do quadrado dos erros, MQE) (PELLEGRINI, 2000).

### 2.2.3. Método de Box-Jenkins

O método de Box-Jenkins utiliza um algoritmo matemático complexo, com termos auto-regressivos e de média móvel, para identificar a forma do modelo matemático mais adequado para a série temporal (ARCHER *apud* LEMOS, 2006). Os modelos de Box-Jenkins, genericamente conhecidos por ARIMA (*Auto Regressive Integrated Moving Averages*), são modelos matemáticos que visam capturar o comportamento da correlação seriada ou autocorrelação entre os valores da série temporal, e com base nesse comportamento, realizar previsões futuras (WERNER & RIBEIRO, 2003).

Segundo Box *et al.* (1994), são três as fases de construção de um modelo Box-Jenkins: (i) identificação, consiste na seleção do modelo de Box-Jenkins que melhor descreve a série em questão; (ii) estimação, onde são estimados os parâmetros do modelo escolhido; e (iii) verificação, quando através dos resíduos (diferença do valor atual da série e o valor apresentado pelo modelo em análise) avalia-se se o modelo proposto é adequado.

### 2.3. Métodos Qualitativos

Toda forma de previsão de demanda possui um certo grau de subjetividade. Mesmo previsões oriundas de um sofisticado método estatístico dependem de julgamento humano para ajustes no método, forma e no conjunto das variáveis (GOODWIN, 2002). Entretanto, pesquisas apontam que o julgamento humano frequentemente é utilizado de forma direta para a realização da previsão de demanda e muitas vezes não possui um rigor tão grande quanto os métodos quantitativos (SANDERS & MANRODT, 1994).

A utilização de métodos estruturados no processo de previsão subjetiva melhora significativamente a acurácia das previsões (ARMSTRONG *apud* LEMOS, 2006). Neste artigo

os métodos qualitativos de previsão de demanda apresentados são: (i) pesquisa de intenções e (ii) o método Delphi.

### 2.3.1. Pesquisa de Intenções

O método de pesquisa de intenções avalia planos, metas e expectativas de indivíduos sobre o futuro de uma variável ou evento. Os entrevistados são perguntados sobre como eles se comportariam em diversas situações relacionadas à questão (ARMSTRONG *apud* LEMOS, 2006).

Os resultados deste método podem ser influenciados por três tipos de erros: (i) erro de amostragem; (ii) erro das respostas; e (iii) erro devido a falta de respostas. O erro de amostragem ocorre quando a amostra não é representativa. O erro das respostas ocorre quando o entrevistado não compreende as perguntas da pesquisa ou não expressa as reais intenções por outros motivos. E a falta de resposta acontece quando o entrevistado não é encontrado ou se nega a responder ao questionário (ARMSTRONG *apud* LEMOS, 2006).

### 2.3.2. Método Delphi

O método Delphi envolve a aplicação sucessiva de questionários a um grupo de especialistas ao longo de várias rodadas. A pesquisa visa, basicamente, a prospecção de tendências futuras sobre o objeto em estudo. No intervalo de cada rodada são feitas análises estatísticas das respostas e o resultado é compilado em novos questionários que, por sua vez, são novamente distribuídos ao grupo (KAYO & SECURATO, 1997). Os autores ainda acrescentam que o método Delphi possui outras características que o tornam atrativo: anonimato dos participantes, procedimentos estruturados e *feedback* aos participantes.

Algumas das desvantagens e restrições mais freqüentes referem-se à possibilidade de se forçar o consenso indevidamente, a dificuldade de redigir um questionário sem ambigüidades ou tendencioso, o tempo dispendido na realização do processo completo e os custos de elaboração elevados (WRIGHT, 1986).

## 2.4. *Analytic Hierarchy Process* – AHP

O *Analytic Hierarchy Process* (AHP) é um método que auxilia tomadores de decisões em situações complexas. Mais do que determinar qual a decisão correta, o AHP ajuda a justificar sua escolha. O AHP utiliza a decomposição e síntese das relações entre os critérios até que se

chegue a uma priorização dos seus indicadores, aproximando-se de uma melhor resposta (SAATY, 1991). Segundo Saaty (1994), o benefício do método é que, como os valores dos julgamentos das comparações pareadas são baseados em experiência, intuição e também em dados físicos, o AHP pode lidar com aspectos qualitativos e quantitativos de um problema de decisão.

De acordo com Saaty (1991), o AHP se sustenta em três passos principais: (i) a construção da hierarquia, (ii) a análise das prioridades e (iii) a verificação da consistência. Primeiramente, a hierarquia é construída de forma que o objetivo principal esteja no nível primário, critérios no nível intermediário e alternativas no nível inferior. Então são definidas as prioridades relativas dos elementos de cada nível de hierarquia, utilizando os pares de comparação. Isto pode ser efetuado usando o método de autovetor principal na matriz de comparação pareada.

A proposta do AHP é fornecer um vetor de pesos para expressar a importância relativa dos diversos elementos. O primeiro passo é medir o grau de importância do elemento de um determinado nível sobre aqueles de um nível inferior pelo processo de comparação pareada (SCHMIDT, 1995). A quantificação dos julgamentos é realizada utilizando-se a escala de valores mostrada na Tabela 1.

Tabela 1: Classificação numérica associada às comparações pareadas (Fonte: SAATY *et al.*, 2003)

<b>Pontuação</b>	<b>Intensidade</b>	<b>Forma de Avaliação</b>
1	Igual importância	As duas atividades contribuem igualmente para o objetivo.
3	Importância moderada	A experiência favorece uma atividade em relação à outra.
5	Importância forte	A experiência favorece fortemente uma atividade em relação à outra
7	Importância muito forte	Uma atividade é muito fortemente favorecida em relação à outra.
9	Importância extrema	A experiência favorece uma atividade em relação à outra, no mais alto grau.
2, 4, 6, 8	Valores Intermediários	Quando se procura uma condição de compromisso entre duas definições.

Saaty *et al.* (2003) apontam que os resultados obtidos com os julgamentos devem ser colocados numa matriz  $A$  quadrada  $n \times n$ . O número de julgamentos necessários para a construção da matriz é  $n(n-1)/2$ , onde  $n$  é o número de elementos da matriz  $A$ . Cada entrada da matriz de comparação,  $a_{ij}$ , deve ser considerada como uma estimativa da razão entre os elementos da linha de ordem  $i$  e os elementos da coluna de ordem  $j$ , isto é,  $a_{ij} = w_i/w_j$ . A

multiplicação da matriz  $A$  pelo vetor de pesos  $w$  [ver equação (13)] tem como resultado  $nw$ . Em teoria matricial, esta fórmula expressa o fato de que  $w$  é um autovetor de  $A$ , com autovalores de  $n$ .

$$Aw = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = \begin{bmatrix} w_1/w_1 & w_1/w_2 & \cdots & w_1/w_n \\ w_2/w_1 & w_2/w_2 & \cdots & w_2/w_n \\ \vdots & \vdots & \vdots & \vdots \\ w_n/w_1 & w_n/w_2 & \cdots & w_n/w_n \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = \begin{bmatrix} nw_1 \\ nw_2 \\ \vdots \\ nw_n \end{bmatrix} = n \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} \quad (13)$$

onde  $a_{ij} > 0$ ,  $a_{ij} = 1$ , para todo  $i = j$ ,  $a_{ji} = 1/a_{ij}$  e  $w$  é o vetor que representa os pesos numéricos que refletirão os julgamentos registrados.

Autovalores e autovetores podem ser definidos da seguinte forma:

Se  $A$  é uma matriz  $n \times n$ , então um vetor não nulo  $w$  em  $R^n$  é chamado autovetor de  $A$  se  $Aw$  é um múltiplo escalar de  $w$ , ou seja  $Aw = \lambda w$ , para algum escalar  $\lambda$ . O escalar  $\lambda$  é chamado autovalor de  $A$  e dizemos que  $w$  é um autovetor associado a  $\lambda$ . (ANTON, H.; RORRES, C. *Álgebra linear com aplicações*, Bookman, 2001, p.240).

Devido à sua complexidade, problemas de autovetor e autovalor são resolvidos, de forma geral, por recursos computacionais (SCHMIDT, 1995).

Uma vez encontrado o autovetor normalizado  $w$  e o autovalor máximo  $\lambda_{\max}$  associados à matriz  $A$ , a consistência dos julgamentos pode ser determinada pelo grau de inconsistência ou incomparabilidade (RC) (YAO *et al.*, 2003). De acordo com Saaty (1994), o resultado de (RC) deve ser menor que 0,1, caso contrário a qualidade dos julgamentos deve ser melhorada através de uma revisão das estimativas. RC é apresentado na equação (14).

$$RC = \frac{IC}{IR} \quad (14)$$

onde  $IC$  é chamado de índice de consistência e  $IR$ , índice de consistência randômico.

O índice de consistência é expresso pela equação (15), sendo  $n$  o tamanho da matriz.

$$IC = \frac{(\lambda_{\max} - n)}{(n - 1)} \quad (15)$$

O índice de consistência randômico vale-se da Tabela 1. Para cada ordem de matriz, constrói-se uma amostra de tamanho 100 e suas entradas são preenchidas randomicamente. A seguir,

as matrizes são calculadas e a média do índice de consistência (IC) para as 100 matrizes correspondentes a cada valor de  $n$  é obtida. A Tabela 2 mostra a ordem das matrizes e os respectivos índices de consistência randômico.

Tabela 2: Consistência média de matrizes randômicas (Fonte: YAO *et al.*, 2004)

Tamanho (n)	1	2	3	4	5	6	7	8	9
IR	0,00	0,00	0,58	0,90	1,12	1,24	1,32	1,41	1,45

Por fim, convém destacar as aplicações do AHP em cenários de previsão de demanda: Flores *et al.* (1990) utilizaram o método para previsão de ganhos, enquanto que Korpela & Tuominen (1996) aplicaram o AHP como ferramenta de decisão multicriterial para previsão de venda de produtos. Outras áreas de aplicações de sucesso podem ser encontradas em Vaidya & Kumar (2006).

## 2.5. Coeficiente alfa

Embora julgamentos diretos sejam muito utilizados em previsão de demanda, eles possuem inúmeras desvantagens quando comparados aos métodos estatísticos (GOODWIN, 2002). A mente humana tem uma capacidade de processamento de informações limitada, e a visão predominante é que as pessoas utilizam estratégias mentais simplificadas, chamadas heurísticas, para lidar com a complexidade envolvida no processo de previsão de demanda (BOLGER & HARVEY, 1996).

Desta forma, sempre que o julgamento humano é utilizado como ferramenta de decisão, é necessário garantir a confiabilidade das opiniões. Ledauphin *et al.* (2006) propõem um coeficiente ( $\alpha$ ) que quantifica quão bem as opiniões de um especialista se relacionam com as opiniões de um grupo. Este coeficiente varia entre -1 e 1, sendo que -1 significa que o especialista em questão está em total desacordo com o grupo, e 1 significa que o especialista está em plena concordância com o grupo. O coeficiente  $\alpha$  é obtido através de operações matriciais e a utilização do conceito de autovetor, sendo apresentado pela equação (16).

$$\alpha = \frac{\text{traço}(\mathbf{Y}_i^T \mathbf{C})}{\sqrt{\text{traço}(\mathbf{C}^T \mathbf{C})}} \quad (16)$$

onde  $Y_i$  é a matriz de opiniões centralizada associada ao especialista  $i$  e  $C$  é a matriz de configuração média ponderada. Para maiores detalhes, consulte Ledauphin *et al.* (2006).

### 3. Procedimentos Metodológicos

A metodologia proposta incorpora aspectos qualitativos a resultados gerados por modelos de previsão de demanda quantitativos. Esta pesquisa pode ser classificada de natureza aplicada, com uma abordagem quantitativa e procedimentos demonstrados através de um estudo de caso.

O método de previsão de demanda proposto neste trabalho consiste em 5 etapas, e integra tanto fatores contextuais quanto séries temporais. Nas etapas 1 a 3 são definidos os procedimentos relacionados ao levantamento de informações e à parte quantitativa do método. A etapa 4 trata do ajuste qualitativo onde, através do coeficiente  $\alpha$ , os especialistas mais aptos e consistentes são selecionados. Os pareceres dos especialistas são então parametrizados através de um índice para o ajuste da previsão, por meio da ferramenta AHP. Este índice pondera fatores relevantes relacionados ao cenário da empresa e à atividade de previsão de demanda. A etapa 5 traz a integração dos fatores quantitativos e qualitativos. A seguir são apresentadas as etapas para a operacionalização do método.

#### 3.1. Verificação da existência de dados, seleção dos especialistas e definição dos itens analisados

Esta etapa consiste em verificar a disponibilidade dos dados para modelagem. Para a análise quantitativa são necessários dados históricos da demanda. Para a obtenção das informações pertinentes à análise qualitativa, é necessário verificar a disponibilidade e nível de conhecimento de especialistas na área de previsão de demanda. Nesta etapa também é realizada a escolha dos produtos a serem modelados, com base na opinião de especialistas da área. Devem ser priorizados produtos considerados representativos ou com maiores dificuldades quanto à reposição.

#### 3.2. Modelagem quantitativa dos dados históricos

Aqui são coletados os dados históricos de venda mensais dos itens escolhidos na seção 3.2. Os dados históricos podem ser analisados graficamente, auxiliando na identificação de padrões, tendências, e sazonalidades na série temporal. Estes gráficos também podem auxiliar

os especialistas durante o preenchimento da matriz de comparação pareada da metodologia AHP (explicada na sequência). Um modelo de previsão é então ajustado aos dados históricos, e sua aderência avaliada por critérios como  $R^2$  e média dos erros quadrados. A modelagem é realizada através do *software NCSS 2007*.

### 3.3. Ajuste Qualitativo

O ajuste qualitativo agrega informação contextual na previsão, abordando informações que a série temporal não contempla (WEBBY; O'CONNOR *apud* LEMOS, 2006). A vantagem da integração de métodos quantitativos com qualitativos é a incorporação do conhecimento sobre a natureza e comportamento das variáveis de interesse no processo preditivo (LEMOS, 2006). As seções que seguem trazem a sistemática proposta para inclusão de aspectos qualitativos na modelagem da seção 3.2.

#### 3.3.1. Definição e classificação de fatores qualitativos que influenciam a demanda

Nesta etapa o conhecimento dos especialistas da empresa é empregado para fornecer fatores relevantes e não contemplados pelo processo preditivo do item em questão. Exemplos de fatores incluem aspectos de política da empresa, peculiaridades físicas dos itens a serem modelados e aspectos ambientais, entre outros. Uma vez definidos os fatores, os especialistas são incentivados a classificá-los em uma escala de 1 a 10, sendo que 1 significa reduzida representatividade do fator para a variação do comportamento da demanda. Em contrapartida, o valor 10 representa que o fator é de extrema importância para descrever a flutuação da demanda.

#### 3.3.2. Seleção dos avaliadores mais consistentes

Para aumentar a confiabilidade do conjunto de informações é empregado o coeficiente  $\alpha$  sugerido em Ledauphin *et al.* (2006). Tal coeficiente é aplicado para verificar a consistência da opinião dos especialistas em relação à opinião do grupo, utilizando a classificação dos fatores realizadas na etapa anterior. Cada especialista terá um  $\alpha$  associado às suas opiniões, sendo o coeficiente utilizado para selecionar os especialistas mais consistentes em termos de suas respostas. Os especialistas com  $\alpha$  acima de 0,7 preenchem a matriz de prioridades do AHP. Este valor foi escolhido pois apresenta um grau de consistência elevado sem grandes possibilidades de o método não selecionar nenhum especialista.

### 3.3.3. Definição da importância relativa dos fatores através do AHP

Nesta etapa os especialistas selecionados hierarquizam os fatores anteriormente definidos, valendo-se da Tabela 1 e de informações pertinentes aos fatores relacionados com a demanda. O objetivo é estabelecer uma ordem de importância entre os fatores avaliados. Uma vez definidos os pesos dos fatores selecionados, gera-se o vetor de priorização  $w_i$  que está relacionado com o preenchimento da matriz AHP realizado pelo especialista  $i$ . O vetor de priorização pode ser obtido através do *software Expert Choice* versão 11.5.

O vetor de prioridades  $\bar{w}$  a ser utilizado no cálculo do índice consolidado  $Y$  é dado pela média ponderada dos vetores  $w_i$  e dos coeficientes  $\alpha_i$  (equação 17).

$$\bar{w} = \frac{(\alpha_1 \cdot w_1) + (\alpha_2 \cdot w_2) + \dots + (\alpha_n \cdot w_n)}{\alpha_1 + \alpha_2 + \dots + \alpha_n} \quad (17)$$

### 3.3.4. Definição da intensidade de atuação do fator

Nesta etapa os entrevistados indicam sua opinião a respeito da intensidade com que o respectivo fator atuará na demanda no próximo período. Por exemplo, incentivo fiscal pode ser um fator que possua uma importância elevada, mas poderá receber um peso de atuação baixo caso não existam indicativos de que tal fator acontecerá no próximo período. Um vetor de intensidade  $I$  é então preenchido com a média aritmética das opiniões dos entrevistados.

### 3.4. Obtenção do índice de ajuste consolidado

Esta etapa consiste em calcular o índice consolidado  $Y$  com vistas ao ajuste da previsão de demanda obtida pelo método quantitativo, através da Eq. (18).

$$Y = (\bar{w}_1 \times \bar{I}_1) + (\bar{w}_2 \times \bar{I}_2) + \dots + (\bar{w}_n \times \bar{I}_n) \quad (18)$$

onde  $\bar{w}_1, \bar{w}_2, \dots, \bar{w}_n$  são as prioridades dos fatores obtidas através do vetor de priorização ponderado médio e  $\bar{I}_1, \bar{I}_2, \dots, \bar{I}_n$  são os valores da intensidade média de atuação dos respectivos fatores.

### 3.5. Ajuste qualitativo da previsão de demanda

Por fim, o índice consolidado é utilizado para ajustar a previsão obtida pelo método quantitativo. Na operacionalização, multiplicam-se os valores da previsão quantitativa pelo índice  $Y$ , conforme a Eq. (19):

$$P_{final} = P_{quantitativa} \times (1 + Y) \quad (19)$$

#### 4. Estudo de caso

O estudo de caso foi desenvolvido em uma concessionária de veículos do Estado do Rio Grande do Sul, que implementou um *software* de gerenciamento de estoques e previsão de demanda há seis meses. Este *software* utiliza apenas o método de média móvel e, de acordo com a opinião dos envolvidos no processo de compras, alguns itens apresentam dificuldades sistemáticas no momento da previsão (e, por consequência, na sugestão de compra apresentada). O resultado da previsão quantitativa gerado pelo *software* é avaliado por um analista. No caso da opinião do analista e a previsão do *software* divergirem, a opinião do analista prevalece. É consenso entre os envolvidos que as previsões de peças com vendas baixas ou esporádicas são as que apresentam maiores deficiências.

Devido ao número reduzido de profissionais na concessionária analisada e ao cenário em que a empresa atua, a correta utilização de informações contextuais é uma tarefa essencial para o processo de compras. Questões macroeconômicas e índices de acidentes nacionais são fatores tão importantes quanto a demanda da peça no momento da realização de pedidos de compra. Outra característica marcante da empresa é a comercialização de uma grande variedade de itens com características diversas. Tais aspectos devem ser considerados no momento de realizar a previsão de demanda.

##### 4.1. Verificação da existência de dados, seleção de especialistas e definição dos itens analisados

Para efetivar o estudo, foram entrevistados cinco funcionários da empresa que trabalham diretamente com atividades relacionadas à reposição e estocagem de peças automotivas. Destes cinco funcionários, três estão ligados ao setor de compras e dois atuam no gerenciamento do estoque físico. A escolha deste grupo de entrevistados foi determinada pelo grau de envolvimento e familiaridade com a atividade de previsão de demanda e os possíveis fatores que atuam na sua variabilidade. As opiniões coletadas são utilizadas na definição dos itens analisados e na análise qualitativa da previsão.

Os dados históricos de vendas de peças foram coletados do banco de dados do *software* de previsão de demanda da empresa. Para o estudo de caso foram selecionadas as últimas 32 observações, correspondendo ao período de janeiro de 2008 até agosto de 2010. Estes dados são utilizados para gerar a previsão quantitativa sugerida pelo método.

O item escolhido para a realização do estudo de caso é um para-choque da linha popular da montadora, pois é um item com rentabilidade e giro de estoque altos. O histórico de vendas do item (em unidades absolutas) pode ser verificado na Figura 1.

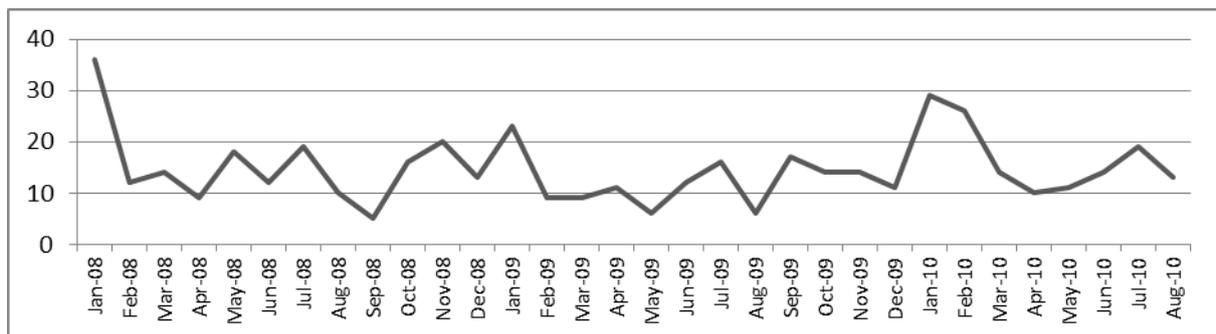


Figura 1 – Gráfico do histórico de venda do item selecionado

#### 4.2. Modelagem quantitativa dos dados históricos

A série temporal com as 32 observações foi ajustada a sete métodos distintos: as médias móveis de três (M-3), seis (M-6) e doze meses (M-12); as suavizações exponenciais simples (SES), de Holt e Holt-Winters (H-W); e o modelo ARIMA.

Uma vez ajustados os modelos utilizando o *NCSS 2007*, comparou-se o MAPE (média dos erros percentuais absolutos) de cada um dos sete modelos testados. O MAPE é uma das medidas de aderência utilizadas para avaliação dos métodos de previsão, e baseia-se na diferença entre o valor da série e a previsão para o mesmo período. Quanto menor o MAPE, melhor a qualidade da modelagem. Na Tabela 3, é apresentado o MAPE para cada um dos métodos aplicados.

Tabela 3: MAPE da modelagem da série temporal

	<b>M-3</b>	<b>M-6</b>	<b>M-12</b>	<b>SES</b>	<b>Holt</b>	<b>H-W</b>	<b>ARIMA</b>
<b>MAPE</b>	51,12%	36,54%	24,16%	34,42%	38,71%	23,44%	39,65%

Verifica-se que o método de Holt-Winters apresenta o menor valor dentre todas as técnicas de modelagem, sendo escolhido para modelar a série temporal. A série temporal e as previsões (em valores absolutos) fornecidas pelo método são apresentadas na Figura 2.

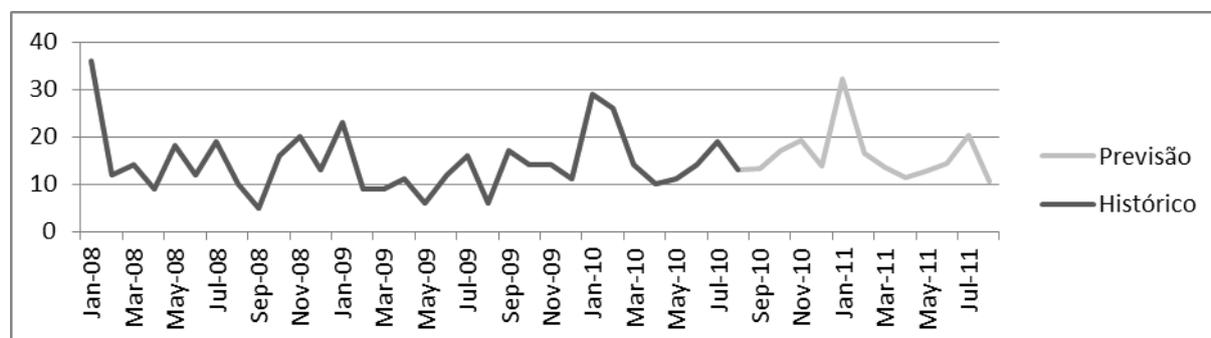


Figura 2 – Gráfico do histórico de venda e a previsão quantitativa do item selecionado

### 4.3. Ajuste Qualitativo

A partir desta etapa o conhecimento dos especialistas é utilizado para introduzir fatores qualitativos na previsão quantitativa previamente selecionada.

#### 4.3.1. Definição e classificação de fatores qualitativos que influenciam a demanda

Os cinco especialistas entrevistados apontaram 20 fatores qualitativos com potencial impacto na demanda. Carvalho (1995) e Johnson *et al.* (1993), entre outros, defendem a necessidade de se limitar o número de indicadores analisados, argumentando que o gerenciamento de elevado volume de informações é prejudicial ao processo de controle.

Seguindo este raciocínio foram selecionados oito fatores a serem analisados na etapa seguinte do método, valendo-se de *brainstorming*: (i) indicadores socioeconômicos; (ii) índice de acidentes de trânsito do trimestre; (iii) confiabilidade da marca; (iv) ações de marketing; (v) política de preços; (vi) demanda de veículos novos; (vii) incentivos fiscais; e (viii) lançamento de novo modelo de veículo. Estes fatores foram selecionados por contemplar informações diversas do ambiente da empresa. Outra característica importante é que os fatores trabalham tanto com variáveis que podem ser controladas pela empresa (ações de marketing e política de preços) quanto variáveis aleatórias (índices de acidentes e indicadores socioeconômicos), que escapam do controle da instituição. O levantamento das informações

dos quatro primeiros fatores é obtido através de análises repassadas pela montadora. O restante das informações são levantadas pela própria concessionária.

Em um segundo momento, através de entrevista individual, cada avaliador (AV) classificou os fatores de acordo com sua importância para a variação da demanda. Para isso, foi utilizada a escala apresentada na seção 3.4.1. O resultado da classificação realizada por cada um dos avaliadores pode ser conferido na Tabela 4.

Tabela 4: Classificação da importância do fator para a variação da demanda

	AV1	AV2	AV3	AV4	AV5
Indicadores socioeconômicos	5	5	6	8	8
Índices de acidentes de trânsito do trimestre	8	7	8	10	10
Política de preços (própria × concorrente)	10	8	9	10	9
Confiabilidade da marca	5	7	8	9	10
Ações de marketing	6	7	7	6	6
Demanda de veículos novos	8	7	5	7	7
Incentivos fiscais (redução de IPI)	2	8	2	9	8
Lançamento de novo modelo de veículo	5	7	5	8	9

Esta primeira classificação fornece subsídios para definir quais avaliadores estão melhor preparados para tomar parte do processo de ajuste da previsão de demanda. A finalidade deste passo é garantir consistência ao método proposto.

#### 4.3.2. Seleção dos avaliadores mais consistentes

Utilizando os dados apresentados na Tabela 4 como entradas para a realização do cálculo do coeficiente  $\alpha$  proposto por Ledauphin *et al.* (2006), obtêm-se os valores da Tabela 5.

Tabela 5: Coeficiente  $\alpha$  relacionado com avaliadores

	AV1	AV2	AV3	AV4	AV5
<b>Coeficiente <math>\alpha</math></b>	0,9159	0,3584	0,7260	0,2846	0,7539

Foram selecionados os avaliadores que possuem um  $\alpha$  superior à 0.7, fazendo com que os avaliadores 1, 3 e 5 tenham suas avaliações mantidas para as próximas etapas do método.

#### 4.3.3. Definição da importância relativa dos fatores através do AHP

Para que os fatores possam efetivamente ajustar a demanda, se faz necessário que sejam definidos seus pesos relativos de atuação. O método de análise hierárquica, AHP, é capaz de formalizar uma hierarquia dos fatores mais relevantes ao contexto da empresa.

Os especialistas selecionados na etapa anterior preenchem a matriz de comparação pareada definida pela metodologia AHP. Informações como o histórico de vendas e características especiais do item são fornecidas a todos os avaliadores. Com base nestes dados e utilizando a escala proposta por Saaty (2003), cada avaliador preencheu a sua respectiva matriz de comparação. Uma vez definidas as matrizes, a operacionalização do método da análise hierárquica e os cálculos necessários para a obtenção dos vetores de prioridades  $w$  são obtidos através *software Expert Choice* versão 11.5.

Os valores do grau de inconsistência (RC) de cada matriz retornados pelo *software* estão dentro da faixa recomendada por Saaty (1991). O RC da matriz AV1 foi 0,09, a matriz AV3 recebeu 0,08 e a matriz AV5 obteve RC igual a 0.07, conforme apresentado no Apêndice A. A saída destas matrizes são vetores de priorização ( $w$ ) contendo a importância relativa de cada fator para a flutuação da demanda.

A seguir, os vetores de prioridades individuais  $w_i$  são ponderados pelos respectivos coeficientes  $\alpha_i$ , conforme a equação (17). Este vetor ponderado  $w$  é o vetor utilizado para descrever a importância relativa de cada fator para a flutuação da demanda. A Tabela 6 traz os vetores de prioridades individuais e o vetor ponderado médio de prioridades ( $\bar{w}$ ).

Tabela 6: Vetores relativos à cada matriz e o vetor médio ponderado  $\bar{w}$

	<b>AV1</b>	<b>AV3</b>	<b>AV5</b>	<b><math>\bar{w}</math></b>
Indicadores socioeconômicos	0,032	0,064	0,058	0,050
Índices de acidentes de trânsito do trimestre	0,253	0,312	0,316	0,291
Política de preços (própria × concorrente)	0,407	0,224	0,139	0,267
Confiabilidade da marca	0,036	0,148	0,243	0,135
Ações de marketing	0,088	0,025	0,018	0,047
Demanda de veículos novos	0,118	0,036	0,030	0,065
Incentivos fiscais (redução de IPI)	0,020	0,105	0,071	0,062
Lançamento de novo modelo de veículo	0,045	0,087	0,125	0,083

A Figura 3 mostra os fatores do vetor médio ponderado classificados em ordem decrescente de importância.

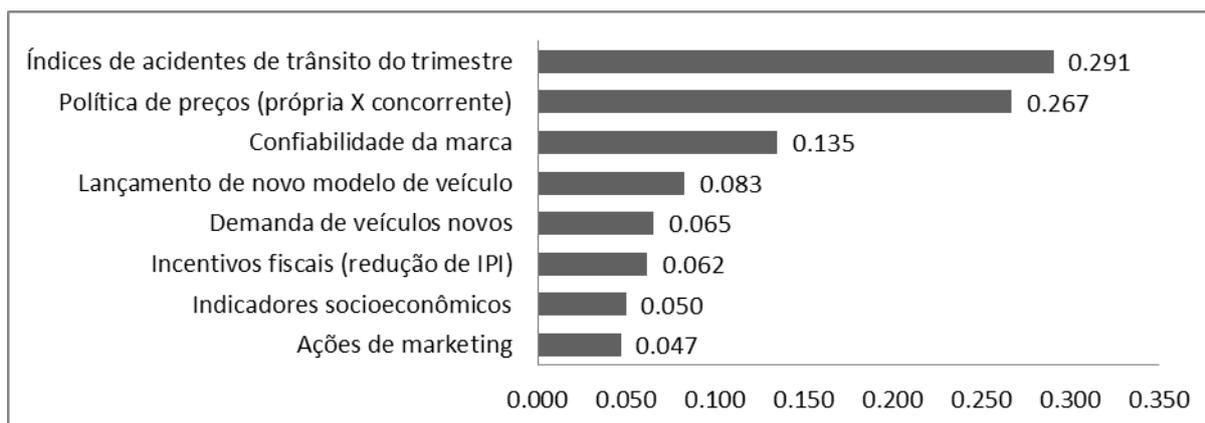


Figura 3: O vetor médio ponderado classificado em ordem decrescente de importância

Percebe-se que os fatores *índices de acidentes de trânsito* e *política de preços* da empresa se destacam segundo a opinião dos especialistas. Levando em consideração que o item analisado é um para-choque, a priorização parece descrever bem a realidade, pois se trata de um item que é diretamente afetado em acidentes e que possui um alto valor agregado.

#### 4.3.4. Definição da intensidade de atuação do fator

Valendo-se tanto das análises disponibilizadas pela montadora quanto dos levantamentos feitos pela própria empresa, os avaliadores agora quantificam a atuação de cada um dos fatores de variação da demanda para o próximo período. A Tabela 7 mostra a opinião de cada avaliador e a média aritmética simples destas opiniões.

Tabela 7: Intensidade de atuação individual e média

	I1	I3	I5	$\bar{I}$
Indicadores socioeconômicos	5%	10%	20%	11,67%
Índices de acidentes de trânsito do trimestre	30%	20%	15%	21,67%
Política de preços (própria × concorrente)	50%	10%	5%	21,67%
Confiabilidade da marca	0%	0%	0%	0%
Ações de marketing	2%	0%	10%	4%
Demanda de veículos novos	5%	-10%	-20%	-8,33%
Incentivos fiscais (redução de IPI)	-10%	-10%	-10%	-10%
Lançamento de novo modelo de veículo	0%	-5%	20%	5%

Esta quantificação tem como objetivo definir quanto e como os respectivos fatores estão contribuindo para a variabilidade da demanda. Por exemplo, o fator *índice de acidentes* irá atuar de forma a aumentar a demanda em 21,67% no próximo período. Já o fator de *incentivos fiscais*, segundo a opinião dos avaliadores, irá diminuir a demanda em 10%. Vale

ressaltar que, neste estudo, todos os avaliadores entendem que o fator *Confiabilidade da marca* não influencia na demanda para o próximo período.

#### 4.4. Obtenção do índice de ajuste consolidado

Nesta etapa define-se  $Y$ , que representa o ajuste qualitativo. Para isso são utilizados o vetor médio ponderado de priorização e o vetor de intensidade média obtidos anteriormente. A operacionalização é dada pela multiplicação dos componentes dos respectivos vetores. A Tabela 8 mostra os valores do índice de ajuste.

Tabela 8: Operacionalização do vetor de ajuste

	$\bar{w}$	$\bar{I}$	$(\bar{w} \times \bar{I})$
Indicadores socioeconômicos	0,050	11,67%	0,58%
Índices de acidentes de trânsito do trimestre	0,291	21,67%	6,30%
Política de preços (própria $\times$ concorrente)	0,267	21,67%	5,79%
Confiabilidade da marca	0,135	0%	0%
Ações de marketing	0,047	4%	0,19%
Demanda de veículos novos	0,065	-8,33%	-0,55%
Incentivos fiscais (redução de IPI)	0,062	-10%	-0,62%
Lançamento de novo modelo de veículo	0,083	5%	0,41%

O índice de ajuste consolidado é estimado através da equação (18):

$$Y = (0,050 \times 0,1167) + (0,291 \times 0,2167) + \dots + (0,083 \times 0,05) = 12,11\%$$

#### 4.5. Ajuste qualitativo da previsão de demanda

Utilizando o índice de ajuste consolidado  $Y$  para realizar o ajuste qualitativo da previsão de demanda conforme a equação (19), obtém-se a previsão de demanda final. A Figura 4 compara os níveis de demanda previstos pela modelagem puramente quantitativa e ajustada pelo método proposto.

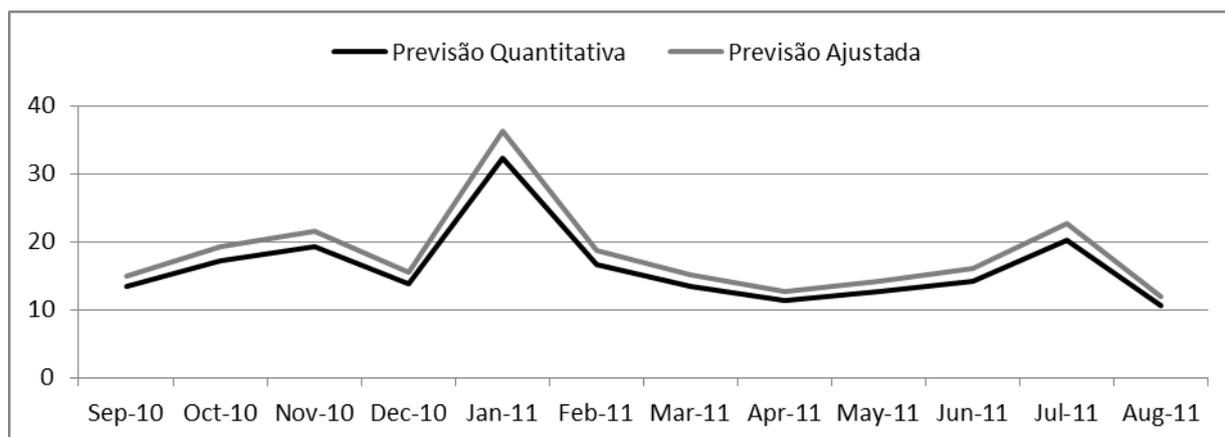


Figura 4: Comparação das previsões

Pode-se analisar também a diferença levando em consideração a sugestão pontual do modelo quantitativo para os próximos doze meses e a previsão ajustada pelo índice consolidado. A Tabela 9 apresenta os valores obtidos pela operacionalização do método de suavização de Holt-Winters através do *software NCSS 2007* e os valores ajustados pelo método proposto.

Tabela 9: Comparação das previsões pontuais quantitativas e ajustadas pelo método proposto

	Holt-Winters	Método proposto
Sep-10	13.383	15.004
Oct-10	17.167	19.246
Nov-10	19.285	21.620
Dec-10	13.794	15.465
Jan-11	32.285	36.195
Feb-11	16.638	18.653
Mar-11	13.537	15.176
Apr-11	11.384	12.762
May-11	12.743	14.287
Jun-11	14.288	16.019
Jul-11	20.305	22.764
Aug-11	10.609	11.894

## 5. Conclusão

A previsão de demanda se tornou uma etapa essencial para o planejamento das empresas, fornecendo informações importantes para a tomada de decisão. A partir da previsão de demanda a instituição pode estabelecer uma base sólida para nortear suas decisões e tratar eventuais problemas.

Neste artigo apresentou-se uma metodologia para obtenção de previsões de demanda através de fatores quantitativos e qualitativos. O método foi desenvolvido motivado pela necessidade de fazer bom uso de todas as informações disponíveis às empresas. Baseando-se em uma metodologia de cinco etapas, as séries temporais foram modeladas através de métodos quantitativos reconhecidos pela literatura. A definição do modelo quantitativo baseou-se na média dos erros percentuais absolutos (MAPE).

Na parte qualitativa do método proposto foram utilizados o coeficiente  $\alpha$  para selecionar os especialistas mais consistentes e garantir confiabilidade às informações utilizadas. Por fim, utilizou-se a metodologia AHP para relacionar os fatores qualitativos. Com a utilização do AHP, foi possível estabelecer prioridades que levaram à identificação da importância relativa dos fatores qualitativos e por consequência, o índice consolidado de ajuste. Uma das vantagens obtidas com a utilização do método é a possibilidade de personalizar o ajuste da previsão de demanda de um item, família ou classe de itens, através de fatores diferentes para cada caso ou pesos diferenciados para os fatores.

Com base nos resultados deste trabalho, percebe-se que o método proposto de previsão de demanda traz vantagens na compreensão da composição das previsões pontuais, pois são baseadas na previsão quantitativa e na classificação fatores qualitativos. Como proposta para estudos futuros, este artigo indica a verificação da atuação do chamado “efeito chicote” na seleção dos fatores qualitativos utilizados no método da análise hierárquica.

## REFERÊNCIAS

ANFAVEA – Associação Nacional dos Fabricantes de Veículos Automotores. Anuário Estatístico. Disponível em: <<http://www.anfavea.com.br>>. Acesso em: 26 mar. 10.

ANTON, H.; RORRES, C. *Álgebra linear com aplicações* – 8ª ed – Porto Alegre: Bookman, 2001.

BOLGER, F.; HARVEY, N. *Context-sensitive heuristics in statistical reasoning*. Quarterly Journal of Experimental Psychology, v. 46A, pp. 779-811, 1996.

BALLOU, R. H. *Gerenciamento da cadeia de suprimentos - Logística empresarial* - 5ª ed - São Paulo: Bookman, 2006.

BORNIA, A. C. *Análise Gerencial de Custos: Aplicação em Empresas Modernas* – 2ª ed – São Paulo: Atlas, 2009.

BOX, G. E. P.; JENKINS, G. M.; REINSELL, G. C. *Time series analysis: forecasting and control*. Prentice Hall. New Jersey, 1994.

CARVALHO, L. *Indicadores de desempenho gerencial*. Apostila (projeto Gestão Empresarial e Qualidade), Porto Alegre: SENAI / FIERGS, 1995.

COELHO, L. C. *Utilização de modelos de suavização exponencial para previsão de demanda com gráficos de controle combinados Shewhart-CUSUM*. Dissertação (mestrado) – Universidade Federal de Santa Catarina, Programa de Pós-Graduação em Engenharia de Produção, 2008.

FLORES B. E.; OLSON D. L.; WOLFE C. *Judgmental adjustment of forecasts: a comparison of methods*. International Journal of Forecasting, v. 7, n. 4, pp. 421-433, 1992.

GAITHER, N.; FRAIZER, G. *Administração da Produção e Operações* – 8ª ed – São Paulo: Pioneira Thomson Learning, 2005.

GOODWIN, P. *Integrating management judgment and statistical methods to improve short-term forecasts*. Omega, v. 30, issue 2, pp. 127-135, 2002.

LEDAUPHIN, S.; HANAFI, M.; QANNARI, E. M. *Assessment of the agreement among subjects in fixed vocabulary profiling*. Food Quality and Preference, v. 17, pp. 277-280, 2006.

LEMOS, F. O. *Metodologia para Seleção de Métodos de Previsão de Demanda*. Dissertação (Mestrado Profissionalizante em Engenharia) – Departamento de Engenharia de Produção e Transportes. Porto Alegre - Universidade Federal do Rio Grande do Sul, 2006.

JOHNSON, H. T.; KAPLAN, R. S. *Contabilidade gerencial: a restauração da relevância da contabilidade nas empresas*. Rio de Janeiro: Campus, 1993.

KAYO, E. K.; SECURATO, J. R. *Método Delphi: fundamentos, críticas e vieses*. Cadernos de Pesquisa em Administração, v. 1, n.4, pp. 51-61, 1997.

KORPELA J.; TUOMINEN M. *Inventory forecasting with a multiple criteria decision tool*. International Journal of Production Economics, n. 45, pp. 159–168, 1997.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C; HYNDMAN, R. J. *Forecasting Methods and Applications*. - 3ª ed - New York: John Wiley & Sons, 1998.

MARTINS, P. G.; LAUGENI, F. P. *Administração da produção*. – 2ª ed. - São Paulo: Saraiva, 2005.

MESQUITA, M. A.; CASTRO R. L. *Análise das práticas de planejamento e controle da produção em fornecedores da cadeia automotiva brasileira*. Gest. Prod., vol.15, n.1, pp. 33-42, 2008.

MIRANDA, R. G. *Espaço admissível para os parâmetros do modelo de suavização exponencial com dupla sazonalidade aditivo*. Tese (Doutorado) - Universidade Federal de Santa Catarina, Programa de Pós-Graduação em Engenharia de Produção, 2009.

PELLEGRINI, F. R. *Metodologia para implementação de sistemas de previsão de demanda*. Dissertação (Mestrado em Engenharia de Produção) - Departamento de Engenharia de Produção e Transportes. Porto Alegre - Universidade Federal do Rio Grande do Sul, 2000.

PELLEGRINI, F. R; FOGLIATTO, F. S. *Passos para implementação de sistemas de previsões de demanda: técnicas e estudo de caso*. Revista Produção, v. 11, n. 1, p. 43-64, 2001.

SAATY, T. L. *Método de análise hierárquica* – 1ª ed. - São Paulo: Makron, 1991.

SAATY, T. L. *How to make a decision: the analytic hierarchy process*, Interfaces, v. 24, n. 6, pp.19–43, 1994.

SAATY, T. L.; VARGAS L. G.; DELLMANN K. *The allocation of intangible resources: the analytic hierarchy process and linear programming*. Socio-Economic Planning Sciences, v. 37, n. 3, pp. 169-184, 2003.

SANDERS N.R., MANRODT K.B. *Forecasting practices in US Corporations: survey results*. Interfaces, n. 24, pp. 92–100, 1994.

SLACK, N.; CHAMBER, S.; HARLAND, C. HARRISON, A.; JOHNSTON, R. *Administração da Produção*. – 2ª ed. - São Paulo: Atlas, 2007.

SCHMIDT, A. M. A. *Processo de apoio à tomada de decisão abordagens: AHP e Macbeth*. Dissertação (mestrado) – Universidade Federal de Santa Catarina, Programa de Pós-Graduação em Engenharia de Produção, 1995.

VAIDYA, O. S.; KUMAR S. *Analytic hierarchy process: an overview of applications*. European Journal of Operational Research, v. 169, n. 1, pp. 1-29, 2006.

WERNER, L.; RIBEIRO, J. L. D. *Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais*. Revista Gestão & Produção, v. 10, n. 1, p. 47-67, 2003.

WERNER, L.; RIBEIRO, J. L. D. *Modelo composto para prever demanda através da integração de previsões*. Produção, v. 16, n. 3, 2006.

WRIGHT, J. T. C. *A técnica Delphi: Uma ferramenta útil para o planejamento do Brasil?* Anais, São Paulo: SPE – Sociedade Brasileira de Planejamento Empresarial, pp. 199-207, 1986.

YAO, Y.; LIAN, Z.; LIU S.; HOU, Z. *Hourly cooling load prediction by a combined forecasting model based on analytic hierarchy process*. International Journal of Thermal Science, n. 43, pp. 1107-1118, 2004.

## APÊNDICE A

Apêndice 1: Tabela de comparação pareada preenchida pelo Avaliador 1

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
Indicadores socioeconômicos (1)	1	1/7	1/9	1	1/3	1/5	2	1
Índices de acidentes de trânsito do trimestre (2)		1	1/5	7	5	5	9	5
Política de preços (própria × concorrente) (3)			1	7	5	5	7	5
Confiabilidade da marca (4)				1	1/3	1/5	3	1
Ações de marketing (5)					1	1	5	3
Demanda de veículos novos (6)						1	7	5
Incentivos fiscais (redução de IPI) (7)							1	5
Lançamento de novo modelo de veículo (8)								1

Apêndice 2: Tabela de comparação pareada preenchida pelo Avaliador 2

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
Indicadores socioeconômicos (1)	1	1/5	1/4	1/6	5	3	1/3	1
Índices de acidentes de trânsito do trimestre (2)		1	1	4	7	7	4	5
Política de preços (própria × concorrente) (3)			1	3	6	5	3	1
Confiabilidade da marca (4)				1	4	4	1	3
Ações de marketing (5)					1	1/2	1/5	1/4
Demanda de veículos novos (6)						1	1/3	1/2
Incentivos fiscais (redução de IPI) (7)							1	1
Lançamento de novo modelo de veículo (8)								1

Apêndice 3: Tabela de comparação pareada preenchida pelo Avaliador 3

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
Indicadores socioeconômicos (1)	1	1/5	1/3	1/5	5	3	1	1/3
Índices de acidentes de trânsito do trimestre (2)		1	5	1	9	7	3	5
Política de preços (própria × concorrente) (3)			1	1/3	7	5	5	1
Confiabilidade da marca (4)				1	9	7	5	1
Ações de marketing (5)					1	1/3	1/5	1/7
Demanda de veículos novos (6)						1	1/3	1/5
Incentivos fiscais (redução de IPI) (7)							1	1
Lançamento de novo modelo de veículo (8)								1